

DETECCIÓN AUTOMÁTICA DE LÍNEAS DE CULTIVO DE PAPA UTILIZANDO IMÁGENES DIGITALES

AUTOMATIC DETECTION OF POTATO CROP ROWS BY USING DIGITAL IMAGES

(Entregado 08/11/2016 - Revisado 03/05/2016)

Iván García

Ingeniero en Sistemas Computacionales por la Universidad Técnica del Norte (Ecuador) y Magíster en Gerencia Informática por la Pontificia Universidad Católica del Ecuador. Actualmente es candidato a Doctor en Ingeniería Informática por la Universidad Complutense de Madrid (España) y Profesor auxiliar titular a tiempo completo en la Universidad Politécnica Estatal del Carchi (Ecuador). Sus intereses de investigación incluyen: procesamiento de imágenes, visión por computador, aprendizaje automático e Inteligencia artificial.

David Herrera

Magíster en Agricultura Sostenible por la Universidad de las Fuerzas Armadas. Magíster en Diseño Curricular y Evaluación Educativa por la Universidad Técnica de Ambato. Ingeniero Agropecuario por la Universidad de las Fuerzas Armadas. Docente Titular de la Facultad de Industrias Agropecuarias y Ciencias Ambientales de la Universidad Politécnica Estatal del Carchi.

Jorge Mina

Magíster en Procesamiento de Alimentos por la Universidad Agraria del Ecuador. Magíster en Educación y Desarrollo Social por la Universidad Tecnológica Equinoccial. Diplomado Superior en Currículo por Competencias por la Universidad Técnica de Ambato. Ingeniero Agroindustrial por la Universidad Técnica del Norte. Decano y Docente Titular de la Facultad de Industrias Agropecuarias y Ciencias Ambientales de la Universidad Politécnica Estatal del Carchi.

Universidad Técnica del Norte - Ecuador
Universidad Politécnica Estatal del Carchi- Ecuador

E-mail: ivan.garcia@upec.edu.ec
carlos.herrera@upec.edu.ec
jorge.mina@upec.edu.ec

Resumen

El estudio propone un método para detección automática de líneas de cultivo en imágenes capturadas en campos de papa en las etapas iniciales de crecimiento. Las imágenes fueron obtenidas utilizando una cámara instalada en el frente del tractor en proyección en perspectiva. La identificación de las líneas de cultivo es importante para el guiado de vehículos autónomos y el tratamiento específico de la maleza, incluyendo la remoción de malas hierbas que quedan localizadas por fuera de las líneas de cultivo. Algunos problemas suelen ser comunes en el entorno agrícola que afectan la calidad y el procesamiento de las imágenes, tales como: iluminación no controlada, diferentes alturas y volúmenes de las plantas, presencia de maleza y discontinuidades en los surcos debido a defectos en la siembra o germinación. El método fue diseñado para hacer frente a estas situaciones indeseadas y consiste de tres fases: (i) segmentación de la imagen, (ii) identificación de puntos de inicio y (iii) detección de líneas de cultivo. La principal contribución del método es la habilidad de detectar líneas de cultivo tanto curvas como rectas. El rendimiento del método fue comparado contra 3 métodos existentes, demostrando ser bueno en términos de precisión y tiempos de procesamiento.

Palabras claves: *detección de líneas de cultivo, visión por computador, segmentación de imágenes, guiado autónomo.*

Abstract

The study proposes a method for detecting crop rows in images captured in potato fields during the initial growth stages. The images were obtained by using a camera installed onboard a tractor under perspective projection. The identification of the crop rows is important for precise autonomous guidance and site-specific treatments, including weed removal based on the identification of plants outside the crop rows. Several problems are common at Outdoor agricultural environments affecting the quality and image processing, such as: uncontrolled lightning conditions, different heights and volumes of plants, weed pressure and gaps along the crop rows due to defects during planting or germination. The proposed method was designed to cope with the above undesired situations and it consists of three phases: (i) image segmentation, (ii) identification of starting points and (iii) crop rows detection. The main contribution of the method is the ability for detecting both kinds curved and straight crop rows. The performance of the method was compared against 3 existing methods, showing to be good in terms of accuracy and time processing.

Keywords: *crop rows detection; machine vision; image segmentation; automatic guidance.*

1. Introducción

1.1 Planteamiento del problema

Los sistemas de visión artificial instalados en los tractores autónomos son herramientas útiles para la detección de filas anchas de cultivo (Emmi et al., 2014; RHEA, 2014) y es importante para los tratamientos específicos de maleza (Gée et al., 2008; Montalvo et al., 2012; Romeo et al., 2012; Guerrero et al., 2013), incluyendo la remoción de malas hierbas que quedan localizadas por fuera de las líneas de cultivo. En tales vehículos, la navegación es basada en Sistemas de Posicionamiento Global (GPS), y aunque esta tecnología proporciona una buena aproximación (Emmi et al. 2014) para el guiado, cuando pequeñas desviaciones ocurren, la detección de líneas de cultivo es también crucial para la corrección (Kise y Zhang, 2008; Rovira-Más et al., 2003).

Los entornos agrícolas son afectados por la iluminación no controlada (sombras, brillos) afectando la calidad y el procesamiento de la imagen. Vacíos (discontinuidades) pueden estar presentes en los surcos debido a defectos en la siembra o la germinación (por plagas o enfermedades). Alta densidad de maleza, con colores de verde similares a los cultivos, pueden aparecer en los espacios entre surcos y también cerca de ellos produciendo un ancho falso de las filas de cultivo proyectadas en la imagen y que pueden ocasionar falsas detecciones. Diferentes alturas y volúmenes de plantas, debido a varias etapas de crecimiento, también pueden crear varios problemas. Líneas curvas de cultivo junto con terrenos con pendientes y movimientos del tractor también añaden otros grados de dificultad. Las líneas curvas de cultivo pueden ser comunes en algunos campos debido a la topografía del terreno. Éstas no solo aparecen en terrenos accidentados, sino también en parcelas planas de tierra con una geometría irregular.

Diferentes enfoques basados en imágenes han sido conducidos para la detección de líneas de cultivo, algunos de ellos combinan varias técnicas y todas aplican algún conocimiento a priori plasmado en diferentes restricciones como: número de filas de cultivo a detectar, geometría del sistema visual, espacio entre filas, posición y orientación esperada de los surcos, parámetros intrínsecos y extrínsecos de la cámara, punto de fuga o proyección en perspectiva.

1.2 Revisión de métodos

A continuación se presenta una lista de categorías y métodos existentes para la detección de líneas de cultivo:

- a) Transformada de Hough (HT): Fue inicialmente propuesto por Hough (1962) para la detección de figuras en imágenes digitales. HT fue aplicada para la detección de líneas rectas de cultivo en varios cultivos de fila ancha: coliflor, remolacha dulce trigo (Marchant, 1996; Astrand y Baerveldt, 2005; Bakker et al., 2008, 2011; Rovira-Más et al., 2005; Han et al., 2012; Tellaache et al., 2008a, b). Modificaciones de la HT fueron también aplicadas por Ji y Qi (2011) con la HT aleatoria basada en gradiente y Gee et al. (2008) con una doble HT. Leemans y Destain (2006) aplicaron conocimiento a priori respecto a la posición y dirección de las filas de cultivo con la finalidad de restringir la búsqueda en el espacio de Hough. Olsen (1995) y Romeo et al. (2012) se inspiraron en la idea de la HT,

acumulación de píxeles verdes a lo largo de las líneas de exploración donde las filas de cultivo son esperadas.

- b) Regresión lineal: Estimaciones de la pendiente (m) y el intercepto (b) son obtenidas para las líneas rectas de cultivo ($y = mx + b$). La técnica de mínimos cuadrados es el método más común para el ajuste de la recta. Algodón, cereal y maíz son cultivos donde esta técnica fue aplicada (Billingsley y Schoenfish, 1997; Sogaard y Olsen, 2003; Tillett y Hague, 1999, Hague et al. 2006; Montalvo et al., 2012; Guerrero et al., 2013, Xue y Ju, 2010; Vidović y Scitovski, 2014).
- c) Franjas horizontales: La imagen es dividida en franjas horizontales (multi-Regiones de Interés, ROI) para encontrar agrupaciones de píxeles, donde los centros de gravedad determinan los filas de cultivo considerando sus alineaciones y ajustando líneas rectas por aplicar mínimos cuadrados o HT en cultivos de fila ancha de trigo, maíz y haba (Sogaard y Olsen, 2003; Fontaine y Crowe, 2006; Sainz-Costa et al., 2011; Burgos-Artizzu et al., 2011; Jiang et al., 2015).
- d) Punto de fuga: Filas de cultivo que son rectas y paralelas en la escena 3D son proyectadas en perspectiva intersectando en un punto y solamente estas líneas son consideradas en la imagen como potenciales líneas de cultivo (Pla et al., 1997). Romeo et al. (2012) y Jiang et al. (2016) combinaron el punto de fuga con la HT.
- e) Filtrado: Filas de cultivo paralelas en la escena 3D muestran patrones y características específicas después del filtrado. Hague y Tillett (2001) aplicaron filtros de paso de banda en el dominio de la frecuencia. Bossu et al. (2009) y Vioix et al. (2002) aplicaron wavelets y el filtro de Gabor en el dominio espacial.
- f) Estereovisión: Localización de las filas de cultivo y mapas de elevación fueron obtenidos desde dos cámaras estereó (Kise y Zhang, 2008), a veces combinado con una unidad de medición inercial (Rovira-Mas et al., 2008). Kise et al. (2005) detectaron un punto por imagen para guiar la navegación en rutas rectas y curvas.

Considerando la literatura citada, una nueva estrategia global fue diseñada para detectar líneas de cultivo rectas y curvas utilizando imágenes capturadas en campos de papa (hileras anchas). La estrategia propuesta explota el rendimiento de algunos métodos existentes para lograr un procedimiento válido para el máximo número de situaciones indeseadas que suelen ser comunes en los entornos agrícolas.

1.3 Organización del documento

La estructura del documento está organizado como sigue: En la sección 2 se explica el diseño (arquitectura) del método propuesto con las 3 fases enlazadas. En la sección 3 el rendimiento de la estrategia propuesta es evaluada en términos cualitativo y cuantitativo y finalmente, en la sección 4 las conclusiones más relevantes y trabajos a futuro son indicados.

2. Materiales y métodos

2.1 Conjunto de imágenes

Las imágenes usadas en el estudio fueron adquiridas durante Febrero y Marzo 2016 en un

campo de papa superchola (*Solanum tuberosum*) ubicado en la Hacienda Experimental San Francisco de la Universidad Politécnica Estatal del Carchi, Tulcán-Ecuador, cubriendo una hectárea (ha). El terreno es irregular con pendientes de hasta 12°. Todas las adquisiciones fueron espaciadas 7 días y obtenidas bajo diferentes condiciones de iluminación y diferentes etapas de crecimiento (hasta 45 días) como se indica en la Figura 1. En (a) plantas de diferentes tamaños en un día soleado, (b) baja presencia de maleza en un día oscuro, y (c) discontinuidades en los surcos en un día claro. Las filas de cultivo son espaciadas en promedio 0.85 m y los surcos curvados son orientados hacia la izquierda. Un total de 320 imágenes fueron aleatoriamente seleccionadas para la experimentación.

Las imágenes fueron obtenidas con una cámara a color goPro Hero 3+ black edition, modelo CHDHX-302, con una longitud focal de 3 mm. La cámara fue instalada en la parte frontal de un tractor New Holland TD90 moviéndose a una velocidad promedio de 3 km/h (~ 0.83 m/s). La cámara fue fijada a una altura de 2 m del suelo y con una inclinación de 45° como se indica en la Figura 2(a).

Las imágenes fueron adquiridas bajo proyección en perspectiva y almacenadas en el formato JPG de 24-bits con una resolución de 3000×2250 píxeles (7 Mpx). Sin embargo, solamente una área reducida del suelo es de interés para el guiado o para aplicar los tratamientos específicos. Esta área es llamada la Región de Interés (ROI). El tamaño y localización de la ROI debe ser especificada considerando: (i) el número de filas de cultivo a detectar y (ii) que la ROI proyectada contenga suficiente resolución (en píxeles) para identificar unívocamente las plantas verdes (cultivo y maleza) del suelo. En el método propuesto, 4 filas de cultivo son seleccionadas, el cual es el número usado en el proyecto RHEA (2014) debido a que los implementos tenían 4 pares de quemadores, cada par actuando sobre un surco.

Considerando las 4 filas de cultivo y el espacio entre filas de 0.85 m, el ancho total de la ROI es de 3.4 m. Esta área inicia a 3 m del tractor con la finalidad de evitar que elementos en el frente del tractor sean proyectados en la imagen. El largo fue fijado en 5 m porque todavía proporciona suficiente resolución. Esta área 3D en el campo resulta en una resolución de 2000 × 650 píxeles (ancho × largo), que representa aproximadamente el 20% de la imagen original. Figura 2(b) muestra la ROI encerrada en un rectángulo.

Las imágenes fueron procesadas usando un procesador Intel Core i7 2.0 GHz, 8 GB RAM y Windows 8.1 Pro (64-bits) y el programa Matlab de MathWorks (2015), versión 8.5 (R2015a).

2.2 Diseño del método (arquitectura)

El método propuesto fue basado en García-Santillán et al. (en prensa), el cual consiste de 3 fases enlazadas: (i) segmentación de la imagen, (ii) identificación de puntos de inicio y (iii) detección de filas de cultivo.

2.2.1 Segmentación de la imagen

La identificación de plantas verdes que pertenecen al cultivo con la finalidad de diferenciarlas de la maleza que también despliegan colores similares es crucial para la detección de líneas curvas de cultivo. Esto debido a que, a diferencia de otros métodos diseñados para la detección de hileras rectas de cultivo, no hay información a priori o restricciones geométricas aplicables para estimar

la posición y orientación de las filas de cultivo. Además, la discontinuidad (vacíos) de las líneas de cultivo, junto con la distribución irregular de la maleza refuerza la necesidad de lograr el máximo nivel de discriminación. Al respecto, el método propuesto por Otsu (1979) y usado en Montalvo et al. (2013) para aplicar una doble umbralización, ha ganado en rendimiento frente a otras estrategias de aprendizaje supervisado como: agrupamiento difuso (Romeo et al., 2013) o máquinas de vectores soporte (Guerrero et al., 2012). Estos métodos requieren un entrenamiento exhaustivo, a diferencia de la doble umbralización que tiene la habilidad de adaptarse a los cambios ambientales comunes en los entornos agrícolas. Bajo estas consideraciones, la fase de segmentación fue diseñada con 4 procesos: (a) determinación de la ROI; (b) identificación de verdes; (c) doble umbralización; y (d) operaciones morfológicas.

- a) Determinación de la ROI. – Como se explicó anteriormente (Figura 2b).
- b) Identificación de verdes.- Es llevado a cabo por aplicar índices de vegetación que son ampliamente usados en imágenes agrícolas para la identificación de plantas verdes (Burgos-Artizzu et al., 2011; Guijarro et al., 2011). En este estudio, dada una ROI en el espacio de color RGB, se aplicó el siguiente esquema de normalización (Gée et al., 2008):

$$r = \frac{R_n}{R_n + G_n + B_n}, \quad g = \frac{G_n}{R_n + G_n + B_n}, \quad b = \frac{B_n}{R_n + G_n + B_n} \quad (1)$$

donde R_n , G_n y B_n son las coordenadas RGB normalizadas que oscilan [0, 1] y fueron obtenidas

$$R_n = \frac{R}{R_{\max}}, \quad G_n = \frac{G}{G_{\max}}, \quad B_n = \frac{B}{B_{\max}} \quad (2)$$

como sigue:

donde R_{\max} , G_{\max} , B_{\max} son los valores máximos de los correspondientes canales espectrales, que en las imágenes de 24-bit es 255.

El clásico índice de vegetación ExG (Excess Green) dado en (3) (Sogaard y Olsen, 2003; Woebbecke et al., 1995) fue finalmente usado debido a su rendimiento en las imágenes probadas. Figura 3(a) muestra la ROI donde ExG fue aplicado.

$$ExG = 2g - r - b \quad (3)$$

- c) Doble umbralización.- Dado una imagen en escala de grises después de aplicar ExG, una primera umbralización fue aplicada para separar las plantas verdes (cultivo y maleza) del suelo. Luego, una segunda umbralización fue aplicada sobre los píxeles que representan las plantas verdes, lo cual permite, en su gran mayoría, la separación entre el cultivo y la maleza. Ambos procesos de umbralización son basados en el método de Otsu (1979). Figura 2(c) muestra los resultados obtenidos en la ROI (en RGB) donde el suelo es etiquetado en color oscuro, las plantas de papa en verde y la maleza en rojo. Figura 3(b) muestra la ROI como una imagen binaria conteniendo las plantas de papa en color blanco y el suelo en color negro. También pueden aparecer algunas áreas blancas pertenecientes a ciertos residuos de maleza, debido a la alta similitud con el cultivo en el color verde.

- d) Operaciones morfológicas.- La operación de Apertura (Onyango y Marchant, 2003) y filtro de mayoría fueron aplicados sobre la imagen binaria para remover pequeños parches y píxeles aislados. El resultado es una imagen binaria más limpia como se indica en la Figura 3(c).

2.2.2 Identificación de puntos de inicio

En este paso se aplica la HT para determinar puntos significantes en la base de la ROI, llamados puntos de inicio. La HT fue usada debido a que es una técnica fuerte en presencia de ruido o cuando están partes ocultas o incompletas en la imagen (Cuevas et al., 2010; Gonzalez y Woods, 2010; Pajares y De la Cruz, 2008). Dada la imagen binaria obtenida en la fase anterior, que contiene píxeles blancos que pertenecen al cultivo y ciertos restos de maleza, un conjunto de puntos de inicio son identificados para buscar las líneas de cultivo. El método fue restringido a 4 líneas de cultivo, el cual resulta ser suficiente para el guiado automático y la identificación de maleza localizada por fuera de las líneas de cultivo, siguiendo las ideas propuestas en RHEA (2014). Así, los 4 puntos de inicio son detectados como sigue:

- a) La ROI es dividida en 2 franjas horizontales de igual tamaño: superior e inferior. La Figura 4(a) muestra las dos sub-ROIs obtenidas. La idea fundamental es que con esta división, las líneas de cultivo curvas pueden ser aproximadas por segmentos lineales, especialmente en la sub-ROI inferior.
- b) La HT es aplicada en la franja inferior para identificar alineaciones de píxeles que representan los segmentos lineales esperados. Aquí se asume algunas restricciones por conocimiento a prior para lograr una máxima precisión, es decir, el número de segmentos lineales a ser detectados (cuatro), ángulo de inclinación oscilando entre $[-45^\circ, 45^\circ]$, distancia entre los segmentos lineales (0.85 m en el campo que representan en promedio 450 píxeles en la base de la ROI). La HT fue diseñada con una resolución de 1 píxel y 1° respectivamente en el espacio acumulador.
- c) La HT usa la representación polar de una recta definida como sigue (Gonzalez y Woods, 2010):

$$\rho = x \cdot \cos \theta + y \cdot \sin \theta \quad (4)$$

donde ρ es la distancia de la recta en el origen y θ es el ángulo que forma la normal con el eje-x. Para convertir los parámetros de Hough (ρ, θ) al espacio de parámetros de la imagen (pendiente, intercepto), las siguientes ecuaciones fueron usadas:

$$x_c = \frac{1}{A} \sum_i x_i; \quad y_c = \frac{1}{A} \sum_i y_i \quad (5)$$

donde m es la pendiente de la recta y b es el intercepto.

- d) Cuatro picos fueron identificados en el espacio polar de Hough, que determinan 4 parámetros m y b asociados a 4 segmentos lineales, verificando que cruzan la sub-ROI inferior. Las 4 líneas deben contener ciertas diferencias en superior a 300 píxeles, fijados por experimentación por los 0.85m de la separación entre filas de cultivo. Los puntos de intersección entre las líneas detectadas y el borde inferior de sub-ROI determinan los 4 puntos de inicio localizados en los puntos (x, y) . La Figura 4(a) muestra 4 puntos de inicio (círculos rojos) y las respectivas pendientes de las rectas (color cian). La pendiente de cada

línea indica la dirección desde la cual explorar las plantas dentro de la franja inferior de la ROI.

Sin embargo, la alta densidad de maleza puede causar errores en la detección de los puntos de inicio. Si 4 puntos de inicio no son identificados, entonces la imagen se rechaza y una nueva se captura y procesa. Esta y otras anomalías son asumidas por el algoritmo y se explican más adelante.

2.2.3 Detección de líneas de cultivo

En esta fase, tres procesos secuenciales son llevados a cabo para la detección de líneas de cultivo curvas y rectas: (a) extracción de puntos candidatos; (b) análisis de regresión y (c) selección y verificación de líneas de cultivo.

a) Extracción de puntos candidatos

La ROI es dividida en 12 subfranjas horizontales de igual altura como se muestra en la Figura 4(b). Este número fue establecido por experimentación para las imágenes de cultivo que fueron probadas. La franja inferior y superior de la ROI contiene 4 y 8 subfranjas respectivamente. Este número fue establecido debido a que las líneas de cultivo curvas aparecen más pronunciadas en la parte superior de la ROI y esto permite capturar esta variabilidad.

Las líneas de cultivo son extraídas de izquierda a derecha (etiquetadas como 1-4). Cada una es detectada por explorar verticalmente las subfranjas inferior y superior, basado en micro-ROIs, iniciando desde el punto de inicio asociado y con la pendiente usando como guía. Una micro-ROI es una región pequeña rectangular (ventana). La altura de cada micro-ROI es la misma que la correspondiente subfranja. El ancho varía en cada subfranja siendo inicialmente asignada en 150 píxeles en la base de la ROI y decrece gradualmente en un 5% según asciende por las subfranjas. El valor inicial fue establecido asumiendo que 150 píxeles corresponden a 0.28m en el campo sobre los 0.85m que es la distancia entre surcos. El tamaño y reducción progresiva del ancho garantiza que las hileras de cultivo son cubiertas. El objetivo de cada micro-ROI es encerrar el máximo número de plantas de cultivo dejando mayoritariamente fuera de la micro-ROI a los residuos de maleza que están localizados en los espacios entre surcos. Así, cada micro-ROI fue definida por 4 parámetros [x, y, ancho, alto], donde el punto (x, y) representa la esquina superior izquierda. Los parámetros y, ancho, alto son conocidos a priori como se explicó, mientras que x será obtenida automáticamente para cada subfranja. Los puntos candidatos son extraídos como sigue:

- 1) Poner la primera micro-ROI con su base centrada en el primer punto de inicio (Figura 5a y b, cruz roja). Calcular el centro geométrico (\bar{x} y \bar{y}) de la micro-ROI como sigue (Pajares y Cruz, 2008):

$$x_c = \frac{1}{A} \sum_i x_i; \quad y_c = \frac{1}{A} \sum_i y_i \quad (6)$$

donde X_i y Z_i representan los píxeles blancos pertenecientes a las plantas dentro de la micro-ROI; A es el número de píxeles blancos. Esta expresión minimiza los efectos de píxeles aislados, Figura 6(a). El centroide es el punto $P_n(x_c, y_c)$ (cruz verde).

- 2) Si la micro-ROI no contiene píxeles blancos, es considerada como un vacío (discontinuidad)

y el punto $P_n (x_c, y_c)$ es exactamente el centroide de la micro-ROI como se muestra en Figura 6(b). Tres vacíos consecutivos en el mismo surco son permitidos como máximo, es decir, aproximadamente 1.20 m de discontinuidad. Vacíos de longitudes mayores son candidatos a fallar considerando las configuraciones del sistema de visión y tamaño de la ROI (3.4m x 5m).

- 3) Siguiendo el segmento lineal estimado con la HT, tres micro-ROIs son puestas con sus bases centradas en los puntos de intersección entre el segmento lineal y las líneas inferiores de las subfranjas, Figura 7(a) y (b).
- 4) El proceso bosquejado en los pasos 1-3 es repetido para el resto de puntos de inicio, obteniendo 4 alineaciones de micro-ROIs en la franja inferior de la ROI con sus correspondientes centroides (P_n). Cada alineación es asociada a cada línea de cultivo a ser detectada.

Como se indicó antes, la franja superior de la ROI que contiene 8 subfranjas es explorada por poner 8 micro-ROIs para cada línea de cultivo esperada. Cada micro-ROI es centrada en el punto de intersección entre el borde inferior de la correspondiente subfranja y la línea recta estimada con los 4 centroides previos, es decir, con los puntos basados en el historial que define la tendencia de la línea de cultivo. La línea recta es ajustada por aplicar la técnica de mínimos cuadrados.

- 5) Así, la quinta micro-ROI es puesta, Figura 8(a), considerando los 4 últimos centroides (P_1, P_2, P_3, P_4) y entonces la pendiente correspondiente es obtenida. El punto de intersección (cruz roja en Figura 8b) en la siguiente subfranja es obtenida usando el último punto, centroide P_4 y la pendiente $m_{1,2,3,4}$.
- 6) El centroide P_5 (cruz verde) es calculado dentro de esta micro-ROI por usar la ecuación (6).
- 7) Este procedimiento (pasos 5 y 6) es aplicado para el resto de micro-ROIs dentro de la franja superior de la ROI para las 8 subfranjas, Figura 9(a). Por ejemplo, el centroide P_{12} , la línea es ajustada con los 4 últimos puntos, centroides (P_8, P_9, P_{10}, P_{11}) con la pendiente . Así, el punto de intersección (cruz roja en Figura 9b) en la siguiente subfranja es obtenida usando el último centroide P_{11} con la pendiente $m_{8,9,10,11}$. El centroide P_{12} (cruz verde) es finalmente obtenido como antes.
- 8) Una vez que las 12 subfranjas son procesadas, un conjunto de 12 puntos a lo largo de la línea de cultivo es obtenido.

El procedimiento completo (pasos 1-8) es repetido para el resto de puntos de inicio disponibles, como se muestra en la Figura 10.

b) Análisis de regresión

Una vez que el conjunto de puntos para cada línea de cultivo fue obtenido en el proceso anterior, polinomios de grado uno (línea recta) y dos (curva cuadrática) son ajustados por la técnica de mínimos cuadrados. Este método es usado para buscar la mejor curva que se ajuste a los puntos disponibles por minimizar la suma de los cuadrados de las desviaciones de los puntos a las curvas. Para líneas rectas los coeficientes a ser estimados son la pendiente (m) y el intercepto (b); y para el polinomio cuadrático los coeficientes a, b y c , ecuaciones (7).

$$y = mx + b; \quad y = ax^2 + bx + c \quad (7)$$

Figura 11(a) y (b) muestran las gráficas de los dos polinomios ajustados (recta cuadrática) para cada línea de cultivo en la ROI. En (a) son dibujados sobre la imagen binaria y en (b) sobre la imagen a color. Las líneas rectas aparecen en azul y las cuadráticas en rojo.

Mínimos cuadrados es una técnica de optimización para obtener una solución de un sistema de ecuaciones sobredeterminado, es decir, cuando un sistema tiene más ecuaciones que variables. El método encuentra aquella solución tal que al sustituir las incógnitas halladas en cada una de las ecuaciones, la suma de todos los errores al cuadrado es minimizada. Se calcula como sigue (De la Fuente y Trespaderne, 2012):

$$\min_p \sum_{i=1}^n \varepsilon_i^2(p, z) \quad (8)$$

Donde p es el vector de parámetros a ser estimados, como se definieron en (7), z es un vector formado a partir de los datos medidos, es decir, los centroides y un conjunto de n ecuaciones que modelan los errores cometidos al utilizar el vector de parámetros p como solución.

La técnica de mínimos cuadrados también entrega la norma de los residuos que es una medida de la calidad del ajuste. Cuanto menor sea la norma, mejor será el ajuste realizado. Definimos los residuos como la diferencia entre los valores experimentales y los valores predichos por el modelo. La norma de los residuos se obtiene como sigue:

$$R = \sqrt{\sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (9)$$

Donde n es el número de puntos, x los valores experimentales y \hat{x} los valores predichos del modelo.

Como resultado de este proceso, los coeficientes de los polinomios, ecuación (7), y la norma de residuos, ecuación (9) son obtenidos.

c) Selección y verificación de líneas de cultivo

Dos pasos fueron realizados en este proceso: (i) la selección de las líneas de cultivo y (ii) la verificación de las líneas seleccionadas. En el primer paso, el polinomio (recta o cuadrática) que mejor se ajusta a cada línea de cultivo es seleccionado en base a la norma de residuos (R) obtenida en el proceso anterior, ecuación (9). La línea con menor valor R es la seleccionada.

En el Segundo paso, un proceso de validación de las líneas seleccionadas es realizado. Tres pasos son verificados: (i) número de líneas detectadas, (ii) separación entre líneas y (iii) orientación de las líneas. En el primer caso, 4 líneas de cultivo deben ser idealmente detectadas (1-4). Si el número es menor que 4, la imagen es rechazada y una nueva imagen es capturada y procesada.

En el Segundo caso, 2 líneas adyacentes deben contener una distancia conocida de separación en la franja inferior de la ROI. Una separación mayor expresa alguna anomalía debido a defectos en la siembra o germinación. Así, si la distancia es mayor que un umbral, la imagen se rechaza. Aquí el umbral se estableció por experimentación en 600 píxeles.

En el tercer caso, 2 líneas detectadas no se deben cruzar dentro de la ROI. Esto puede suceder debido a la presencia de grandes vacíos (> 1.20 m) y una alta densidad de maleza. El punto de cruce () es verificado a través de las líneas rectas, igualando ambas ecuaciones. La regla es como sigue: si coordenada es mayor que cero, la imagen es rechazada.

Como resultado final, el método automático detecta 4 líneas de cultivo (curvas y rectas) y modeladas matemáticamente.

3. Resultados y discusión

El rendimiento del método fue estudiado en términos de un análisis cualitativo y cuantitativo, basado en el criterio de un experto (agronomo), para propósitos de comparación. Basado en la inspección visual de las líneas de cultivo en las imágenes originales RGB, el experto fija, al menos, 5 puntos a lo largo de cada fila de cultivo, dependiendo de la curvatura de las mismas. A más curvatura, más puntos fijados y a menos curvatura menos puntos. Una aplicación desarrollada en Matlab utilizando "Fitting curve toolbox" ajusta automáticamente la mejor curva para los puntos establecidos. Este procedimiento se realizó para todas las 320 imágenes de prueba disponibles. A este conjunto de imágenes y curvas suavizadas modeladas matemáticamente se le conoce como el "ground truth" y sirve para evaluar la precisión del método propuesto.

3.1 Análisis Cualitativo

La Figura 12 muestra ejemplos ilustrativos de imágenes donde las líneas de cultivo fueron detectadas de acuerdo a los parámetros intrínsecos y extrínsecos del sistema visual. En (a) y (b) 4 líneas curvas de cultivo son mostradas en rojo. En (c) y (d) una mezcla de líneas curvas y rectas es mostrada en rojo y azul respectivamente. Una simple inspección de la imagen, basado en el criterio del experto, permite ver que las filas de cultivo detectadas por el método propuesto coinciden satisfactoriamente con las líneas de cultivo esperadas del ground truth.

Algunas filas de cultivo pueden contener vacíos producidos por defectos en la siembra o germinación. En este estudio, estos vacíos no exceden los 1.20 m de discontinuidad en el mismo surco. Una longitud mayor puede resultar en una falla en la detección de la línea de cultivo. Sin embargo, el método detecta estas anomalías y la imagen es rechazada como se indicó en la sección anterior y una nueva imagen es capturada y procesada.

Además, es bastante común encontrar malezas distribuidas irregularmente en los espacios entre filas de cultivo, Figura 1(b). En este estudio, el método fue probado con un bajo nivel de malezas, es decir, hasta el 5% de cobertura de maleza de acuerdo a la escala de clasificación propuesta por Soto y Agüero (1992). El porcentaje de cobertura de maleza fue obtenido aplicando el método del cuadrante como sigue:

$$\% \text{ cobertura de maleza} = \frac{A_{\text{maleza}}}{A_{\text{muestreada}}} \times 100 \quad (10)$$

donde A_{maleza} es el área que es cubierta por la maleza, $A_{\text{muestreada}}$ es el área muestreada, es decir, $0.5\text{m} \times 0.5\text{m} = 0.25 \text{ m}^2$.

Un nivel mayor de maleza puede causar la incorrecta detección de la fila de cultivo. Sin embargo, como antes, el método detecta esta anomalía y la imagen es rechazada. Ambos, grandes vacíos y alta densidad de maleza, afectan significativamente la tasa de detección de las filas de cultivo, principalmente en las hileras curvas.

El radio mínimo de curvatura de las filas curvas de cultivo probadas en el campo fue de 19 m. Esta medida fue obtenida realizando cálculos topográficos. Un radio menor hace difícil la navegación del tractor en el campo y el riesgo de dañar el cultivo es alto.

3.2 Análisis cuantitativo

El rendimiento del método propuesto, denotado por MP en el resto del documento, fue también comparado cuantitativamente contra 3 métodos existentes de acuerdo a la similitud de sus resultados contra el ground truth obtenido manualmente para cada imagen, como se explicó antes. Los métodos de comparación son: (i) Transformada de Hough (HT) propuesta por Hough (1962), el cual es usado ampliamente para la detección de líneas rectas. Varias restricciones fueron aplicadas para mejorar su rendimiento, como: número de líneas a detectar, ángulo de inclinación $[-45^\circ \text{ y } 45^\circ]$ y la resolución del espacio de Hough fijado a 1 píxel y 1° . (ii) Regresión lineal basado en el estimador Theil-Shen (LR) propuesto por Guerrero et al. (2013) para ajustar las líneas rectas de cultivo. (iii) Regresión lineal basado en la técnica de mínimos cuadrados (OLR) propuesto por Montalvo et al. (2012), el cual usa plantillas para restringir el área donde las filas rectas de cultivo son esperadas.

Diferentes niveles de vacíos (discontinuidades) y densidades de maleza fueron considerados en las imágenes de prueba. Los niveles de vacíos bajo, medio y alto significan un vacío (0.40m), dos (0.80m) y tres vacíos (1.20m) respectivamente. Más de tres vacíos en el mismo surco no fueron considerados porque la probabilidad de fallar en la detección supera el 50% en la configuración usada en el sistema visual (ROI de 3.4m x 5m). Densidad de maleza bajo, medio y alto significa menos del 5%, entre 5% y 12%, y entre 12% y 25% respectivamente. Un nivel superior al 25% lleva al método a fallar con alta probabilidad ($> 50\%$).

El cálculo de la tasa de detección fue obtenida por el siguiente procedimiento: para cada imagen de prueba, las 4 líneas de cultivo detectadas por el método propuesto fueron separadamente comparadas por similitud (línea por línea, $L=1, 2, 3, 4$) contra las curvas suavizadas pertenecientes al ground truth. Así, cuando ambas curvas coinciden satisfactoriamente según el criterio del experto, un valor de uno se añade a la puntuación y cero de otro modo, ecuación (11).

$$f(L) = \begin{cases} 1 & \leftrightarrow \text{coincide} \\ 0 & \leftrightarrow \text{de otro modo} \end{cases} \quad (11)$$

La tasa de detección fue obtenida para cada línea de cultivo (L_{1-4}). La suma de las coincidencias

es dividida por el número de imágenes analizadas. La fórmula aplicada es como sigue:

$$tasa\ de\ detección_{(L)} = \left(\frac{1}{N} \sum_{i=1}^N f(L_i) \right) \times 100 \quad (12)$$

donde N es el número de imágenes usadas para las pruebas y $f(L_i)$ es obtenido por (11) para cada línea de cultivo. Finalmente, el promedio de la tasa de detección es calculada como sigue:

$$tasa\ de\ detección_{(promedio)} = \frac{1}{K} \sum_{L=1}^K tasa\ de\ detección_{(L)} \quad (13)$$

donde K = 4 representa el número de líneas de cultivo.

La Tabla 1 muestra el promedio de la tasa de detección en porcentaje y el tiempo de procesamiento en milisegundos para las 320 imágenes analizadas. A partir de estos resultados, se puede ver que la tasa de detección de líneas rectas y curvas del método propuesto (MP) alcanza el mejor rendimiento (87.9%) con bajo densidad de maleza y bajo nivel de vacíos. El peor caso es alcanzado con un alto nivel de maleza y vacíos.

MP fue comparado con los métodos existentes de HT, LR, OLR utilizando las imágenes de prueba que contienen solamente líneas rectas de cultivo. HT y MP fueron implementados en Matlab, mientras que LR y OLR en C++. A partir de los resultados de la Tabla 2, se puede ver que PM supera a HT, con valores similares a LR y peor que OLR. Esto indica que el método propuesto está en línea con los métodos existentes.

El tiempo de procesamiento para el proceso completo, incluyendo las 3 fases de segmentación, identificación de puntos de inicio y detección de líneas de cultivo, fue de 573 ms para el mejor caso (bajo nivel de maleza y vacíos) según la Tabla 1. Considerando que en general, los vehículos agrícolas trabajan a velocidades oscilando entre 3 y 6 km/h durante las tareas agrícolas, esto significa que en el peor caso (6 km/h), el vehículo necesita 3s para atravesar los 5m de largo de la ROI, el cual es muy superior al tiempo requerido para el procesamiento de una imagen. Además, se debe considerar que el tiempo de ejecución fue medido en Matlab bajo un lenguaje de programación interpretado. Esto puede disminuir significativamente si se implementa en un lenguaje de programación compilado (por ejemplo C++) ejecutándose en una plataforma y sistema operativo de tiempo real, por ejemplo LabView y CRio como en el proyecto RHEA (2014). Bajo estas consideraciones, el tiempo de procesamiento podría reducirse cerca del 40% con respecto al ya obtenido, como se reportó en RHEA, mejorando considerablemente el rendimiento para aplicaciones de tiempo real, el cual es un tópico de investigación a futuro.

La Tabla 3 muestra el tiempo de procesamiento en porcentaje (%) y milisegundos (ms) del método propuesto dividido por módulos. La segmentación consume el 41.0% del tiempo total, la identificación de los puntos de inicio el 8.6% y la detección de líneas de cultivo el 50.4%.

La Tabla 4 muestra el rango de coeficientes de mayor grado para ambos tipos de líneas de cultivo. Esto significa que los surcos analizados son limitados a un grupo de líneas rectas y curvas, de acuerdo a las ecuaciones que definen sus modelos matemáticos, ecuaciones (7), es decir, líneas rectas

con pendiente (m) y cuadráticas con orientación (hacia la izquierda) y coeficiente de curvatura (a). Gracias a este estudio, las líneas de cultivo son validadas por estos rangos de valores para cada tipo de línea. Esto permite una mejora importante durante el proceso de verificación, cuando las líneas de cultivo deben ser aceptadas o rechazadas dependiendo si los valores calculados para los coeficientes (m, a) están dentro o fuera de los rangos. El tratamiento de imágenes con surcos con orientación hacia la derecha es también importante cuando el tractor llega al final del campo de cultivo y debe regresar navegando por los surcos adyacentes. Este tópico de investigación queda planteado como un trabajo a futuro.

Finalmente, respecto a las limitaciones del MP, tres restricciones deben ser consideradas para su aplicación: (i) número de filas de cultivo a ser detectadas, (ii) la concavidad de las filas de cultivo y (iii) los parámetros intrínsecos y extrínsecos del sistema visual.

4. Conclusiones

El estudio propone un método automático para detectar líneas de cultivo rectas y curvas (orientados hacia la izquierda) en campos de papa superchola (*Solanum tuberosum*) basado en el concepto de región de interés (ROI). El método consiste de 3 fases enlazadas: segmentación, identificación de puntos de inicio y detección de líneas de cultivo. La detección de líneas de cultivo puede ser útil para el guiado automático de vehículos agrícolas y también para el tratamiento específico de la maleza que queda localizada por fuera de las líneas de cultivo.

El método ha sido probado utilizando imágenes adquiridas utilizando una cámara instalada en la parte frontal de un tractor en proyección en perspectiva bajo diferentes condiciones de iluminación (días soleado, oscuro y claro), comunes en los campos agrícolas. Las imágenes pertenecen a las etapas iniciales de crecimiento (hasta 45 días) conteniendo plantas con diferentes alturas y volúmenes, así como surcos incompletos (< 1.20m) y con baja densidad de maleza (< 5%) distribuidos irregularmente en los espacios entre filas.

En breve, el método detecta, en presencia de niveles bajos de maleza y vacíos/discontinuidades, el 87.9% de las líneas de cultivo curvas y rectas, así como el 90.7% sobre líneas rectas de cultivo (Tabla 2) en un tiempo inferior a los 573 ms (Tabla 3).

Adicionalmente, la robustez del método propuesto es complementado por 2 procedimientos para hacer frente a las situaciones indeseadas de los entonos agrícolas: (i) selección y verificación de líneas de cultivo y (ii) controlando la orientación y rango de valores de los coeficientes de mayor grado para cada tipo de línea recta y cuadrática (Tabla 4).

Finalmente, algunas mejoras son todavía posibles, tales como: (i) la identificación de puntos de inicio para determinar la dirección por donde explorar inicialmente las plantas pertenecientes al cultivo de papa; (ii) la implementación del algoritmo en un lenguaje de programación compilado (como C++) y ejecutándose en un sistema operativo y plataforma de tiempo real como LabView y Crio; (iii) la cuantificación de la densidad de maleza localizada en el espacio entre surcos, a partir de la detección de las líneas de cultivo y (iv) el tratamiento de cultivos con curvatura orientada hacia la derecha.

Agradecimientos

La presente investigación ha sido financiada parcialmente por la Universidad Politécnica Estatal del Carchi (Ecuador) y ha sido inspirada en el proyecto RHEA, financiado por la Unión Europea [FP7/2007-2013] (Automation and robotics for sustainable crop and forestry management).

FIGURAS

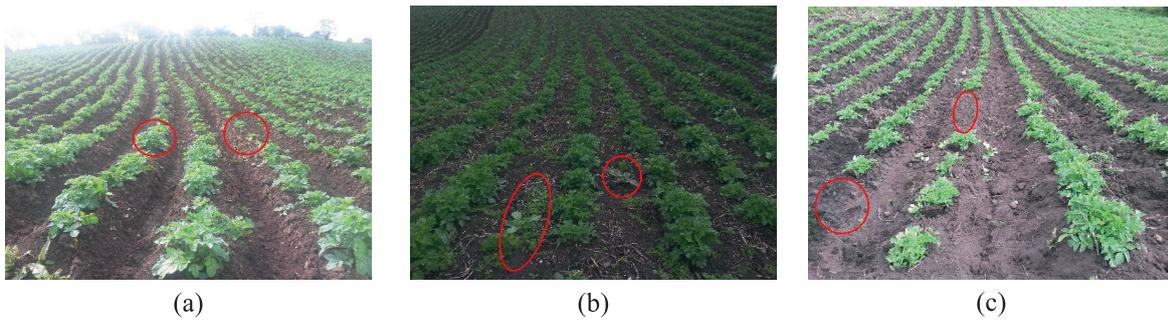


Figura 1 Ilustraciones de imágenes procesadas por el método propuesto; (a) con plantas de diferentes tamaños en un día soleado, (b) baja presencia de maleza en un día oscuro, y (c) discontinuidades en los surcos en un día claro

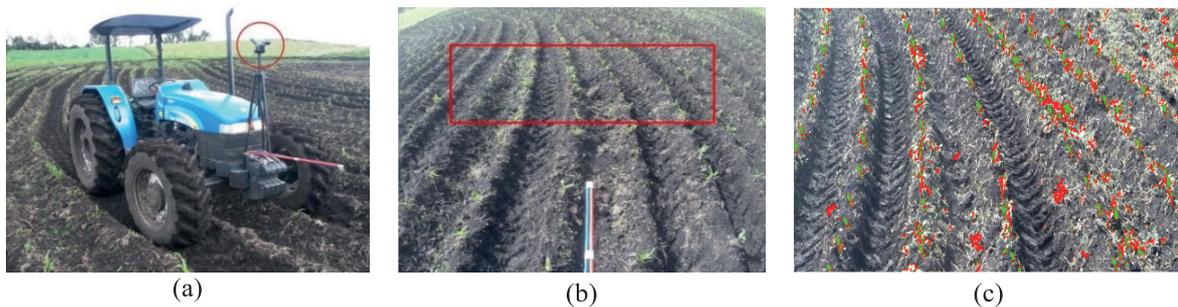


Figura 2 (a) Sistema visual instalado en la parte frontal de un tractor; (b) Localización de la ROI en la imagen original RGB (2000x650 píxeles); (c) identificación del suelo (oscuro), maleza (rojo) y cultivo de papa (verde).

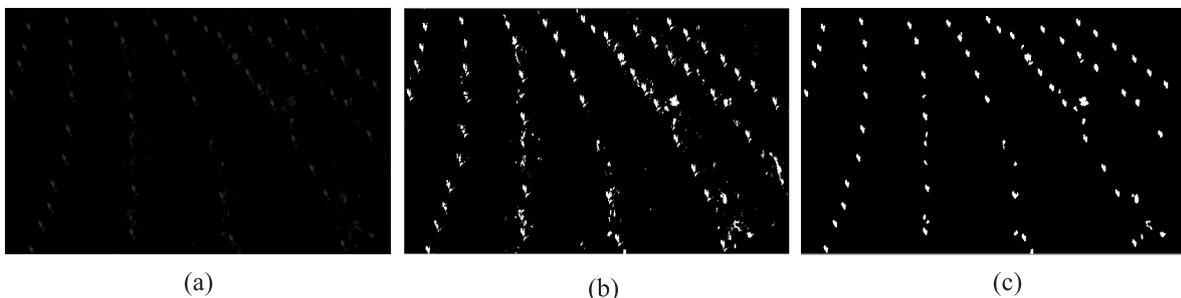


Figura 3 (a) Imagen en escala de grises después de aplicar ExG; (b) imagen binaria luego de aplicar la doble umbralización; (c) imagen binaria después de aplicar operaciones morfológicas.

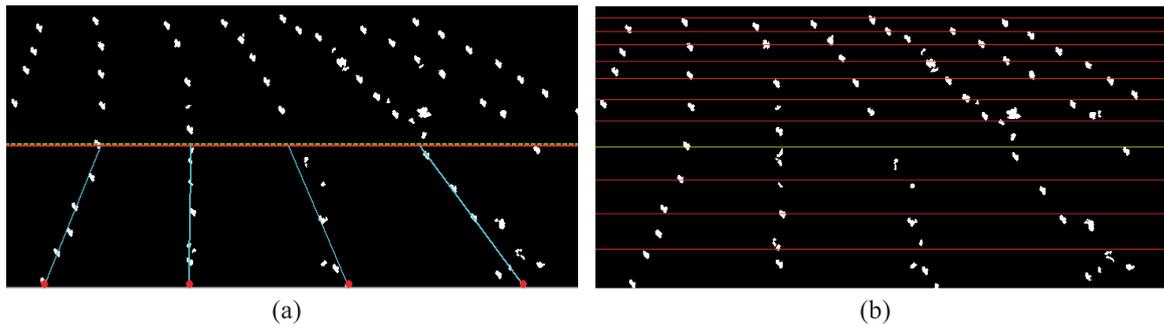


Figura 4 (a) Localización de los 4 puntos de inicio en la franja inferior de la ROI (punto y pendiente); (b) La franja inferior es dividida en 4 subfranjas y la franja superior en 8.

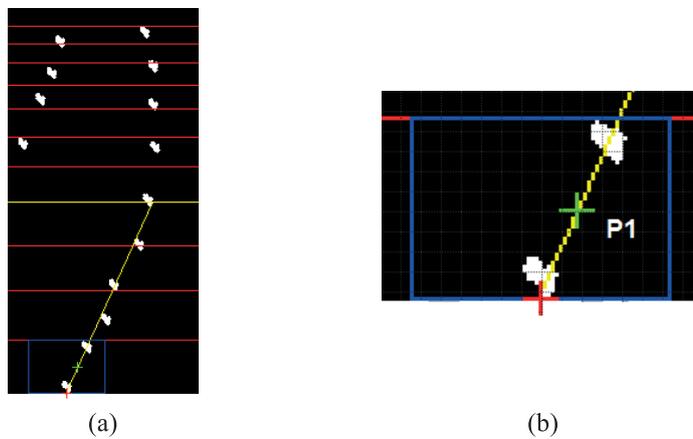


Figura 5 (a) Ubicación de la primera micro-ROI (rectángulo azul) en la primera subfranja de la línea de cultivo; (b) Imagen aumentada de la micro-ROI, donde la cruz roja representa el centro de la ventana en la parte inferior y la cruz verde P_1 es el centro geométrico.



Figura 6 Ejemplos de casos especiales. (a) Presencia de maleza dentro de la micro-ROI; (b) Vacíos (ausencia de objetos etiquetados) dentro de la micro-ROI.

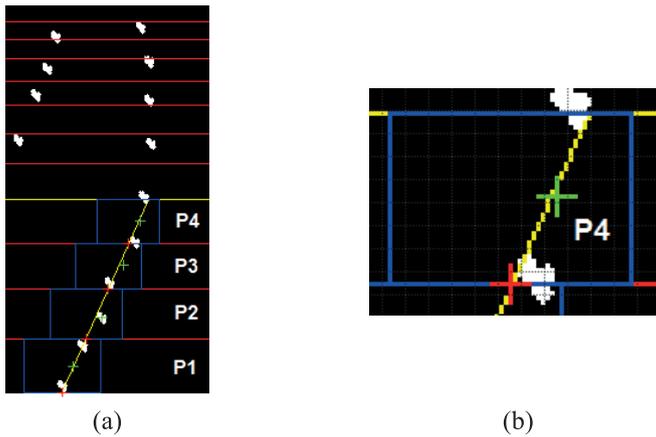


Figura 7 (a) Ubicación de la cuarta micro-ROI en la cuarta subfranja de la línea de cultivo; (b) Imagen aumentada de la micro-ROI, donde la cruz roja representa el centro de la ventana en la parte inferior y la cruz verde P_4 es el centro geométrico

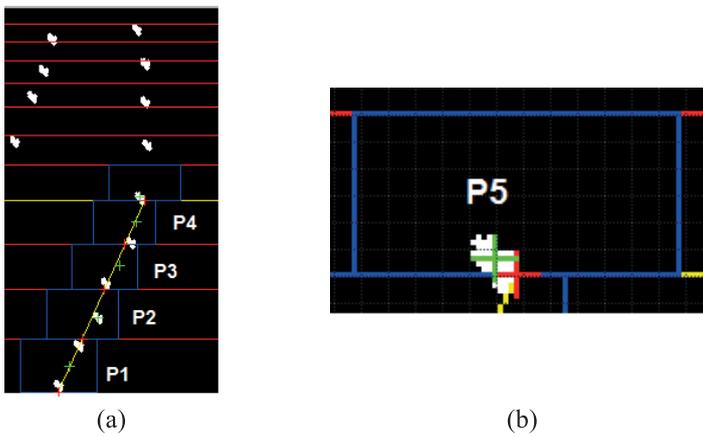


Figura 8 (a) Ubicación de la quinta micro-ROI en la quinta subfranja de la línea de cultivo; (b) Imagen aumentada de la micro-ROI, donde la cruz roja representa el centro de la ventana en la parte inferior y la cruz verde P_5 es el centro geométrico

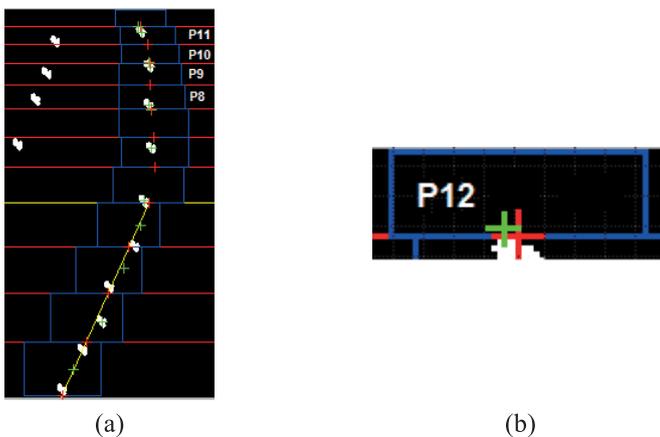


Figura 9 (a) Ubicación de la doceava micro-ROI en la subfranja #12 de la línea de cultivo; (b) Imagen aumentada de la micro-ROI, donde la cruz roja representa el centro de la ventana en la parte inferior y la cruz verde P_{12} es el centro geométrico

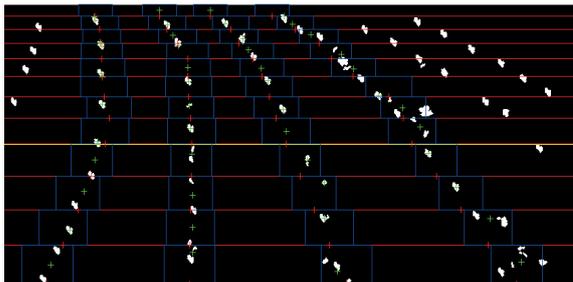


Figura 10 Ubicación de todas las micro-ROIs (rectángulos azules) a lo largo de las líneas de cultivo dentro de la ROI.

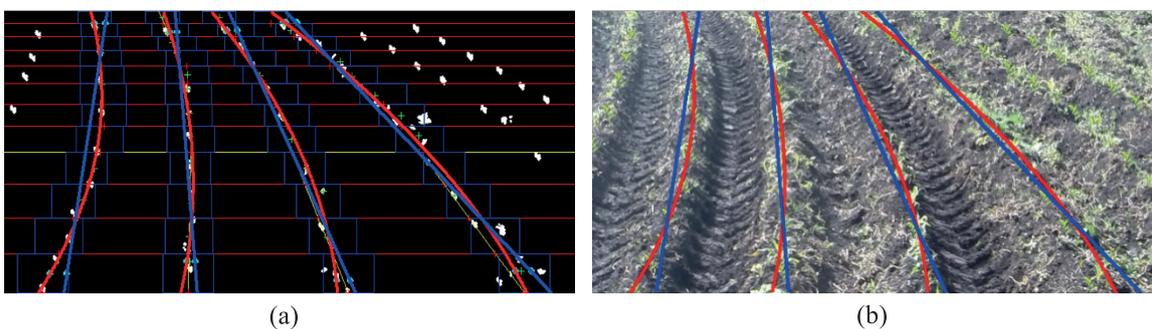


Figura 11 Gráficos de las líneas rectas (en azul) y cuadráticas (en rojo) ajustadas a cada línea de cultivo dentro de la ROI; (a) polinomios dibujados sobre la imagen binaria; (b) polinomios dibujados sobre la imagen RGB

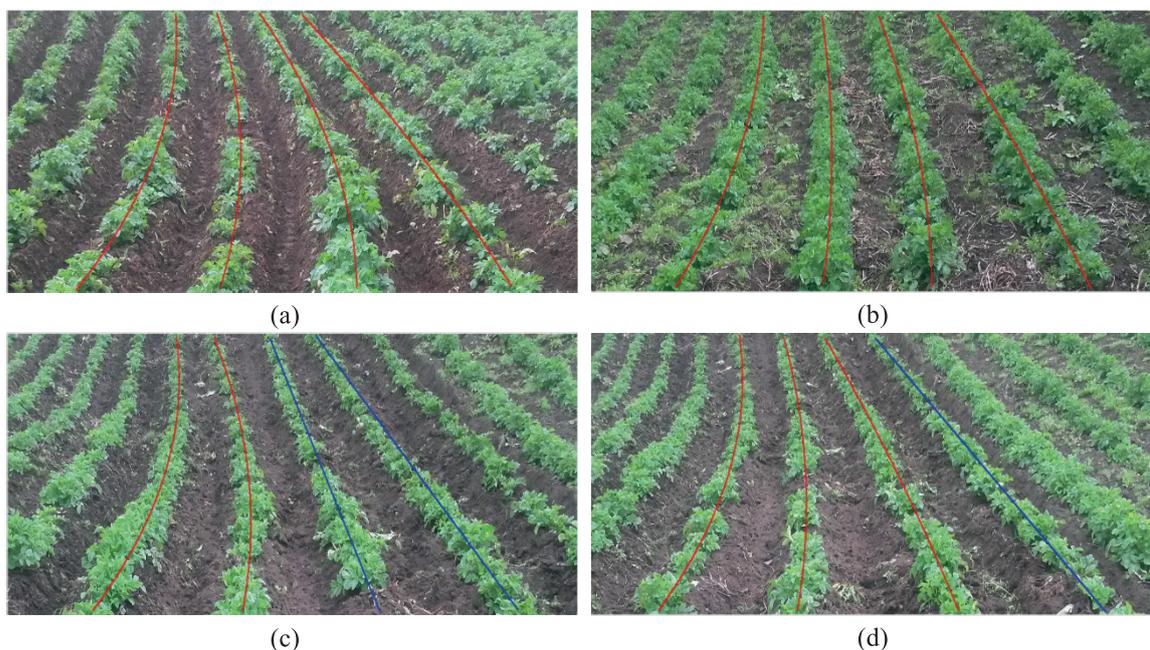


Figura 12 Ejemplo de imágenes probadas con las líneas de cultivo detectadas por el método automático; (a) y (b) 4 líneas curvas en rojo; (c) y (d) una mezcla de líneas curvas y rectas en rojo y azul respectivamente

Tabla 1

En promedio, tasa de detección de líneas rectas y curvas (%) y tiempo de procesamiento (ms) del método para diferentes niveles de vacíos y malezas.

Rendimiento	Niveles de vacíos y malezas		
	Bajo	Medio	Alto
Tasa de detección (%)	87.9	76.2	52.1
Tiempo de procesamiento (ms)	583	622	785

Tabla 2

Comparación del MP contra tres métodos existentes (HT, LR, OLR) en líneas rectas de cultivo.

Tasa de detección (%)	HT	LR	OLR	MP
Promedio	85.2	91.2	92.6	90.7
Posición	4	2	1	3

Tabla 3

En promedio, tiempo de procesamiento en porcentaje (%) y milisegundos (ms) del método dividido por módulos

Módulos	Porcentaje (%)	Niveles de vacíos y malezas		
		Bajo (ms)	Medio (ms)	Alto (ms)
1 Segmentación	41.0	239	255	322
2 Identificación de puntos de inicio	8.6	50	54	68
3 Detección de líneas de cultivo	50.4	294	313	395
TOTAL	100.0	583	622	785

Tabla 4

Rango de valores permitidos para los coeficientes de mayor grado en cada tipo de línea de cultivo

Tipo de línea	Modelo matemático	Coficiente de mayor grado	Rango de valores permitidos
Recta			[-1 y 1]
Cuadrática			[-0.0015 y 0]

Referencias Bibliográficas

- Astrand, B., Baerveldt, A. J. (2005). *A vision based row-following system for agricultural field machinery*. *Mechatronics*, 15(2), 251-269.
- Bakker, T., Wouters, H., van Asselt, K., Bontsema, J., Tang, L., Müller, J., van Straten, G. (2008). *A vision based row detection system for sugar beet*. *Comput. Electron. Agric.* 60, 87–95.
- Bakker, T., van Asselt, K., Bontsema, J., Muller, J., van Straten, G. (2011). *Autonomous navigation using a robot platform in a sugar beet field*. *Biosystems Engineering*, 109(4), 357-368.
- Billingsley, J., Schoenfisch, M. (1997). *The successful development of a vision guidance system for agriculture*. *Computers and Electronics in Agriculture*, 16(2), 147-163.
- Bossu, J., Gée, Ch., Jones, G., Truchetet, F. (2009). *Wavelet transform to discriminate between crop and weed in perspective agronomic images*. *Computers and Electronics in Agriculture*, 65, 133–143.
- Burgos-Artizzu, X. P., Ribeiro, A., Guijarro, M., Pajares, G. (2011). *Real-time image processing for crop/weed discrimination in maize fields*. *Computers and Electronics in Agriculture*, 75(2), 337-346.
- Cuevas, E., Zaldívar, D., Pérez, M. (2010). *Procesamiento digital de imágenes con Matlab y Simulink*. Ra-Ma Editorial, Madrid, Spain.
- De la Fuente, E., Trespaderne, F. (2012). *Visión artificial industrial: Procesamiento de imágenes para inspección automática y robótica*. Secretariado de publicaciones e intercambio editorial, Universidad de Valladolid. Valladolid, Spain.
- Emmi, L., Gonzalez-de-Soto, M., Pajares, G., Gonzalez-de-Santos, P. (2014). *New Trends in Robotics for Agriculture: Integration and Assessment of a Real Fleet of Robots*. *The Scientific World Journal*, vol. 2014, Article ID 404059, 21 pages.
- Fontaine, V., Crowe, T. (2006). *Development of line-detection algorithms for local positioning in densely seeded crops*. *Canadian biosystems engineering*, 48, 19-29.
- García-Santillán, I., Montalvo, M., Guerrero, J., Pajares, G. (en prensa). *Automatic detection of curved and straight crop rows from images in maize fields*. *Biosystems Engineering*.
- Gee, C., Bossu, J., Jones, G., Truchetet, F. (2008). *Crop/weed discrimination in perspective agronomic images*. *Computers and Electronics in Agriculture*, 60(1), 49-59.
- Gonzalez, R., Woods, R. (2010). *Digital Image Processing (3 ed.)*. Pearson/Prentice Hall, Upper Saddle River, N. J.
- Guerrero, J. M., Pajares, G., Montalvo, M., Romeo, J., Guijarro, M. (2012). *Support Vector Machines for crop/weeds identification in maize fields*. *Expert Systems with Applications*, 39, 11149-11155.
- Guerrero, J. M., Guijarro, M., Montalvo, M., Romeo, J., Emmi, L., Ribeiro, A., Pajares, G. (2013). *Automatic expert system based on images for accuracy crop row detection in maize fields*. *Expert Systems with Applications*, 40(2), 656-664.
- Guijarro, M., Pajares, G., Riomoros, I., Herrera, P. J., Burgos-Artizzu, X. P., Ribeiro, A. (2011). *Automatic segmentation of relevant textures in agricultural images*. *Computers and Electronics in Agriculture*, 75(1), 75-83.
- Hague, T., Tillett, N. D. (2001). *A bandpass filter-based approach to crop row location and tracking*. *Mechatronics*, 11, 1-12.
- Hague, T., Tillett, N. D., Wheeler, H. (2006). *Automated Crop and Weed Monitoring in Widely Spaced Cereals*. *Precision Agriculture*, 7(1), 21-32.
- Han, Y. H., Wang, Y. M., Kang, F. (2012). *Navigation line detection based on support vector machine for automatic agriculture vehicle*. *Proc. Int. Conf. Automatic Control and Artificial*

- Intelligence (ACAI 2012), 1381-1385.
- Hough, P. V. C. (1962). *Method and means for recognizing complex patterns*. US Patent Office No. 3069654.
- Ji, R., Qi, L. (2011). *Crop-row detection algorithm based on Random Hough Transformation*. *Mathematical and Computer Modelling*, 54(3-4), 1016-1020.
- Jiang, G., Wang, Z., Liu, H. (2015). *Automatic detection of crop rows based on multi-ROIs*. *Expert Systems with Applications*, 42(5), 2429-2441.
- Jiang, G., Wang, X., Wang, Z. (2016). *Wheat rows detection at the early growth stage based on Hough transform and vanishing point*. *Computers and Electronics in Agriculture*, 123, 211-223.
- Kise, M., Zhang, Q. (2008). *Development of a stereovision sensing system for 3D crop row structure mapping and tractor guidance*. *Biosystems Engineering*, 101(2), 191-198.
- Kise, M., Zhang, Q., Rovira-Más, F. (2005). *A stereovision-based crop row detection method for tractor-automated guidance*. *Biosystems Engineering*, 90(4), 357-367.
- Leemans, V., Destain, M.F., (2006). *Line cluster detection using a variant of the Hough transform for culture row localisation*. *Image Vision Comput.* 24(5), 541-550.
- Marchant, J. (1996). *Tracking of row structure in three crops using image analysis*. *Comput. Electron. Agric.* 15(2), 161-179.
- MathWorks, Inc. (2015). *Matlab Release 2015a*. Retrieved from http://www.mathworks.com/products/new_products/release2015a.html (last accessed August 03, 2015).
- Montalvo, M., Pajares, G., Guerrero, J. M., Romeo, J., Guijarro, M., Ribeiro, A., Cruz, J. M. (2012). *Automatic detection of crop rows in maize fields with high weeds pressure*. *Expert Systems with Applications*, 39(15), 11889-11897.
- Montalvo, M., Guerrero, J. M., Romeo, J., Emmi, L., Guijarro, M., Pajares, G. (2013). *Automatic expert system for weeds/crops identification in images from maize fields*. *Expert Systems with Applications*, 40(1), 75-82.
- Olsen, H. J. (1995). *Determination of row position in small-grain crops by analysis of video images*. *Computers and Electronics in Agriculture*, 12(2), 147-162.
- Onyango, C. M., Marchant, J. A. (2003). *Segmentation of row crop plants from weeds using colour and morphology*. *Computers and Electronics in Agriculture*, 39(3), 141-155.
- Otsu, N. (1979). *Threshold selection method from gray-level histograms*. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1), 62-66.
- Pajares, G., de la Cruz, J. M. (2008). *Visión por Computador. Imágenes digitales y aplicaciones* (2 ed.). RA-MA Editorial, Spain.
- Pla, F., Sanchiz, J. M., Marchant, J. A., Brivot, R. (1997). *Building perspective models to guide a row crop navigation vehicle*. *Image and Vision Computing*, 15, 465-473.
- RHEA. (2014). *Proceedings of the Second International Conference on Robotics and Associated High-Technologies And Equipment for Agriculture and Forestry*. New trends in mobile robotics, perception and actuation for agriculture and forestry (P. Gonzalez-de-Santos & A. Ribeiro Eds.). Madrid-Spain: PGM.
- Romeo, J., Pajares, G., Montalvo, M., Guerrero, J. M., Guijarro, M., de la Cruz, J. M. (2013). *A new Expert System for greenness identification in agricultural images*. *Expert Systems with Applications*, 40(6), 2275-2286.
- Romeo, J., Pajares, G., Montalvo, M., Guerrero, J. M., Guijarro, M., Ribeiro, A. (2012). *Crop Row Detection in Maize Fields Inspired on the Human Visual Perception*. *Scientific World Journal*. Article ID 484390, 10 pages.
- Rovira-Más, F., Zhang, Q., Reid, J.F., Will, J.D. (2003). *Machine vision based automated tractor*

- guidance. International Journal Smart Engineering System Design*, 5(4), 467-480.
- Rovira-Más, F., Zhang, Q., Reid, J. F., Will, J. D. (2005). *Hough-transform-based vision algorithm for crop row detection of an automated agricultural vehicle*. Proceedings of the Institution of Mechanical Engineers Part D-Journal of Automobile Engineering, 219(D8), 999-1010.
- Rovira-Más, F., Zhang, Q., Reid, J. F. (2008). *Stereo vision three-dimensional terrain maps for precision agriculture. Computers and Electronics in Agriculture*, 60(2), 133-143.
- Sainz-Costa, N., Ribeiro, A., Burgos-Artizzu, X. P., Guijarro, M., Pajares, G. (2011). *Mapping Wide Row Crops with Video Sequences Acquired from a Tractor Moving at Treatment Speed. Sensors*, 11(7), 7095-7109.
- Sogaard, H. T., Olsen, H. J. (2003). *Determination of crop rows by image analysis without segmentation. Computers and Electronics in Agriculture*, 38(2), 141-158.
- Soto A., Agüero, A. (1992). *Combate químico de malezas en el cultivo del arroz*. Editorial de la Universidad de Costa Rica. San José, Costa Rica.
- Tillett, N., Hague, T. (1999). *Computer-vision based hoe guidance for cereals an initial trail*. Journal of Agricultural Engineering Research, 74, 225–236.
- Vidović, I., Scitovski, R. (2014). *Center-based clustering for line detection and application to crop rows detection*. Computers and Electronics in Agriculture, 109, 212-220.
- Vioix, J. B., Douzals, J. P., Truchetet, F., Assemat, L., Guillemain, J. P. (2002). *Spatial and spectral method for weeds detection and localization*. EURASIP JASP, 7, 679–685.
- Woebbecke, D. M., Meyer, G. E., Vonbargen, K., Mortensen, D. A. (1995). *Color indexes for weed identification under various soil, residue, and lighting conditions*. Transactions of the ASAE, 38(1), 259-269
- Xue, J., Ju, W. (2010). *Vision-Based Guidance Line Detection in Row Crop Fields. Proc. Int. Conf. Intelligent Computation Technology and Automation (ICICTA 2010)*, 3, 1140-1143.