

Escuela Agrícola Panamericana, Zamorano
Departamento de Ambiente y Desarrollo
Ingeniería Ambiente y Desarrollo



Proyecto Especial de Graduación
**Estudio de la mancha de asfalto en maíz usando índices de vegetación
multiespectrales**

Estudiante

Alex Geovanny Acosta Guatemal

Asesores

Lenin Henríquez, Mtr.

Carolina Avellaneda, Ph.D.

Honduras, noviembre 2021

Autoridades

TANYA MÜLLER GARCÍA

Rectora

ANA MARGARITA MAIER

Vicepresidenta y Decana Académica

ERIKA TENORIO MONCADA

Directora Departamento Ambiente y Desarrollo

HUGO ZAVALA MEMBREÑO

Secretario General

Contenido

Índice de Cuadros.....	6
Índice de Figuras	7
Índice de Anexos.....	8
Resumen	9
Abstract.....	10
Introducción.....	11
Materiales y Métodos	15
Diseño de la Parcela de Puerto (2020).....	15
Datos Recolectados.....	17
Imágenes Multiespectrales	17
Campaña de Evaluación de Severidad	18
Rendimiento.....	19
Índices de Vegetación	20
Índice de Vegetación de Diferencia Normalizado.....	20
Índice de Vegetación de Diferencia Renormalizado	21
Índice de Vegetación de Área Normalizada.....	21
Índice de Vegetación Optimizada al Suelo.....	22
Índice de Reflectancia y Absorción de Clorofila Modificado 2	23
Procesamiento de Imágenes.....	23
Georreferenciación de Imágenes.....	23
Cálculo de los Índices de Vegetación	24

Máscara de Vegetación Efectiva	24
Descripción de la Mancha de Asfalto.....	24
Análisis Estadístico	24
Correlación Pearson.....	25
Correlogramas.....	25
Mapa de Severidad de la Mancha de Asfalto	25
Resultados y Discusión.....	26
Evolución Visual de la Parcela con Mancha de Asfalto.....	26
Evolución Visual de la Parcela con Mancha de Asfalto en MCARI-2.....	27
Evolución Visual de la Parcela con Mancha de Asfalto en NDVI.....	30
Estadística Descriptiva de las Diferentes Sub-parcelas.....	31
Correlaciones	34
Correlación entre las Campañas de Severidad y las Medias de los Índices de Vegetación	34
Correlación entre los Índices de Vegetación y la Severidad Reportada en los Doseles de las Subparcelas	35
Mancha de Asfalto en Etapas Fenológicas.....	37
Mancha de Asfalto en Etapa Fenológica R1-R2	37
Mancha de Asfalto en Etapa Fenológica R5-R6	39
Mancha de Asfalto y Rendimiento.....	41
Mapa de Severidad de la Mancha de Asfalto en NDVI	43
Índices de Vegetación y Mancha de Asfalto	45
NDVI y Mancha de Asfalto	45
NAVI y la Mancha de Asfalto.....	47

Conclusiones	48
Recomendaciones	49
Referencias.....	Error! Bookmark not defined.
Anexos.....	59

Índice de Cuadros

Cuadro 1 Fechas de vuelo de imágenes multiespectrales	18
Cuadro 2 Fechas de las campañas de evaluación de severidad.....	19
Cuadro 3 Coordenadas de los puntos de control	23
Cuadro 4 Estadística descriptiva de NDVI a los 116 DDS de las parcelas sin fungicida	32
Cuadro 5 Estadística descriptiva de NDVI a los 116 DDS de las parcelas con fungicida	32
Cuadro 6 Valor p de los Índices de Vegetación en el dosel intermedio	34
Cuadro 7 Correlación de Pearson del índice NAVI y la severidad del dosel intermedio a los 88 DDS.	35
Cuadro 8 Correlación de Pearson entre la severidad de la MA del dosel inferior y las medias de los índices de vegetación para la variedad DK390RR sin fungicida.....	36
Cuadro 9 Correlación de Pearson entre la severidad de la MA del dosel intermedio y las medias de los índices de vegetación para la variedad DK390RR sin fungicida.....	37
Cuadro 10 Correlación de Pearson entre la severidad de la MA del dosel superior y las medias de los índices de vegetación para la variedad DK390RR sin fungicida.....	37
Cuadro 11 Correlación de Pearson entre el rendimiento y la severidad de la MA en los doseles	41
Cuadro 12 Correlación de Pearson entre el rendimiento y las medias de los índices de vegetación ..	42

Índice de Figuras

Figura 1 Esquema de distribución de la metodología.....	15
Figura 2 Esquema de distribución de la parcela experimental de Puerto (2020).....	16
Figura 3 Imagen de los Índices de Vegetación (NDVI, RDVI, NAVI, OSAVI, MCARI2) a los 116 DDS de la parcela.....	26
Figura 4 Imagen temporal del Índice de Reflectancia y Absorción de Clorofila Modificado 2 (MCARI-2) de la parcela.....	28
Figura 5 Imagen temporal del Índice de Vegetación de Diferencia Normalizada (NDVI) de la parcela	30
Figura 6 Evolución de las parcelas #1, #8 (sin fungicida) y #22, #24 (con fungicida) en el índice NDVI	33
Figura 7 Correlograma de la severidad de la MA del dosel intermedio y las medias de los IV	38
Figura 8 Correlograma entre el rendimiento y las medias de los IV.....	43
Figura 9 Mapa de la severidad de la MA en NDVI en las parcelas DK390RR sin fungicida a los 88 DDS	44

Índice de Anexos

Anexo A Distribución de los genotipos en las parcelas con y sin fungicida	59
Anexo B Evolución de la parcela con MA en el índice NAVI	60
Anexo C Evolución de la parcela con MA en el índice RDVI.....	61
Anexo D Evolución de la parcela con MA en el índice OSAVI	62
Anexo E Estadística descriptiva del índice NDVI en los 74 días después de siembra	63
Anexo F Estadística descriptiva del índice NDVI en los 88 días después de siembra	65
Anexo G Estadística descriptiva del índice NDVI en los 108 días después de siembra.....	67
Anexo H Estadística descriptiva del índice NDVI en los 113 días después de siembra.....	69
Anexo I Estadística descriptiva del índice NDVI en los 116 días después de siembra	71
Anexo J Estadística descriptiva del índice NDVI en los 130 días después de siembra	73
Anexo K Mapa de severidad de la MA en NDVI de la parcela número 1 en el genotipo DK390RR sin fungicida a los 88 DDS.....	75

Resumen

La mancha de asfalto (MA) es una enfermedad que afecta al maíz, uno de los cultivos más importantes del mundo. Esta enfermedad es causada principalmente por un patógeno fúngico (*Phyllachora maydis* Maubl.), que provoca pérdidas del cultivo y afecta al rendimiento y calidad del grano. Utilizando datos de un estudio anterior, en esta investigación se llevó a cabo la caracterización de la mancha de asfalto y su evolución en las distintas etapas fenológicas del maíz usando evaluaciones de severidad en campo e índices de vegetación derivado de imágenes multiespectrales. Los índices NAVI (Índice de Vegetación de Área Normalizada) y NDVI (Índice de Vegetación de Diferencia Normalizado) obtuvieron altas correlaciones con la severidad, en el dosel intermedio de -0.81 y -0.80 respectivamente, para el genotipo DK390RR de las parcelas sin fungicida a los 88 días después de siembra (DDS). Las etapas de mayor incidencia con MA quedaron definidas en la etapa fonológica R1-R2 (etapa del estigma-etapa del blíster). La distribución de la enfermedad de la MA comenzó en la zona Norte, y en las parcelas ubicadas en los extremos. La alta correlación del NDVI con la severidad permitió generar un mapa de la distribución de la enfermedad a los 88 DDS.

Palabras clave: Agricultura de precisión, fitopatología, índices de vegetación.

Abstract

Tar Spot (TS) is a disease that affects corn, one of the most important crops in the world. This disease is mainly caused by a fungal pathogen (*Phyllachora maydis* Maubl.), Which causes crop losses and affects grain yield and quality. Using data from a previous study, this research carried out the characterization of the asphalt stain and its evolution in the different phenological stages of corn using field severity evaluations and vegetation indices derived from multispectral images. The NAVI and NDVI index obtained high correlations with severity, in the intermediate canopy of -0.81 and -0.80 respectively, for the DK390RR genotype of the plots without fungicide at 88 days after planting (DAP). The stages of highest incidence with TS were defined in the R1-R2 phenological stage. The distribution of the TS disease began in the North zone, and in the plots located in the extremes. The high correlation of NDVI with severity made it possible to generate a map of the distribution of the disease at 88 DAP.

Keywords: Phytopathology, precision agriculture, vegetation index.

Introducción

El maíz (*Zea mays* L.) es uno de los cultivos más antiguos e importantes del mundo, con una producción mundial de 1.12 mil millones de toneladas en la cosecha 2019-2020 (United States Department Agriculture [USDA], 2020). Solo en Brasil se pronostica una producción de 110 millones de toneladas en la siguiente cosecha, donde su exportación representará el 20% a nivel mundial (Martinez y Fernandez, 2019; USDA, 2020). Se espera que para mediados del siglo XXI, la demanda del maíz crezca en respuesta a una población mundial que pasará de 6.9 mil a 9 mil millones en 2050 (Senker, 2011). El crecimiento constante de la población mundial intensificará la producción agrícola. Dado el limitado potencial en la actualidad, existe una gran necesidad de aumentar la producción de granos en el mundo (Baldos y Hertel, 2014).

Los países centroamericanos como Honduras, El Salvador, Guatemala, y Nicaragua producen maíz en un acumulado de 2.4 millones de hectáreas (Eash et al., 2019). Latinoamérica alcanza un rendimiento de 6.19 t/ha, y crece a un promedio anual de 3.3% desde 1970 (Hengsdijk y Langeveld, 2009). El maíz es uno de los alimentos principales en Honduras, donde representa el 48% y 26% de las calorías consumidas entre sus habitantes en áreas rurales y urbanas, respectivamente (Eash et al., 2019). Ocupa el 35% de su área sembrada y la producción nacional únicamente alcanza a satisfacer las necesidades del 53% de la demanda nacional (Derlagen et al., 2019; Instituto Nacional de Estadística Honduras [INE], 2018). Estos rendimientos se ven afectados por la presencia de plagas y enfermedades, deficiencia de nutrientes y factores climáticos que producen estrés en los cultivos (Harvey et al., 2018).

La mancha de asfalto es una enfermedad fúngica del maíz que afecta a muchas regiones de América Latina. Los primeros síntomas que se observan son pequeños estromas ovalados oscuros de forma irregular en las hojas inferiores y centrales, que provocan la muerte de la hoja y finalmente de la planta. El efecto de esta enfermedad se ha visto reflejado con los bajos rendimientos de los cultivos,

la calidad del grano, así como los rastrojos y la cascarilla de maíz (Bajet et al., 1994; Hock et al., 1989; Maublanc, 1904; Telenko et al., 2020). Esta enfermedad es causada por *Phyllachora maydis* Maubl., un hongo endémico de América Latina, que se identificó por primera vez en 1904 en México (Maublanc, 1904). *Phyllachora maydis* estaría asociado en Latinoamérica, con otros dos patógenos fúngicos, un necrófilo *Monographella maydis* Müller y Samuels., y un hiperparásito fúngico *Coniothyrium phyllachorae* Maubl (Hock et al., 1995).

A pesar de que la enfermedad es más común en las áreas tropicales y subtropicales de América Latina, en 2015 la enfermedad fue detectada por primera vez, en varios lugares del Medio Oeste de los Estados Unidos (Dalla Lana et al., 2019; Malvick et al., 2020; Ruhl et al., 2016). En Estados Unidos, *M. maydis* parece no estar asociado con ningún tipo de lesión y únicamente *P. maydis* se ha documentado en asociación con la mancha de asfalto (McCoy et al., 2019). En la actualidad, no se ha esclarecido el ciclo de la enfermedad y se desconoce las circunstancias en las que apareció *P. maydis* en los Estados Unidos (Valle-Torres et al., 2020).

La caracterización del fenotipo de la mancha de asfalto hasta ahora se ha estado realizando únicamente en campo. *Phyllachora maydis* ha sido diagnosticado principalmente a través de síntomas y características morfológicas (Hock et al., 1995; Maublanc, 1904). Debido a la ausencia de una técnica confiable para la detección, no existe ningún estándar que nos permita realizar una evaluación clara y evitar sesgos de los evaluadores (Bock et al., 2010; Parker et al., 1995; Steddom et al., 2005). En consecuencia, pronosticar la incidencia de enfermedades de manera clara, permitiría crear estrategias de prevención importantes para la producción de maíz. El control de esta enfermedad podría ser más eficiente, si se pudiera identificar las áreas infectadas de manera temprana. El desarrollo reciente de tecnologías como la teledetección, el estudio de la espectroscopia y los sensores ópticos, tienen el potencial de permitir la detección directa de enfermedades foliares en condiciones de campo (West et al., 2003).

La teledetección ha sido una disciplina prometedora desde los años 80. Los vehículos aéreos no tripulados (UAS, siglas en inglés) o las aeronaves tripuladas a distancia (RPAS, siglas en inglés), junto con los avances en el desarrollo de los sensores remotos, son una respuesta a la detección remota del estrés biótico y abiótico (Heim et al., 2019). La espectroscopia ha sido utilizada recientemente para detectar enfermedades en diferentes cultivos (Kuska et al., 2015; A-K. Mahlein et al., 2017). En el campo de la teledetección, la espectroscopia ha permitido determinar enfermedades como la roya en el trigo (Franke y Menz, 2007; Zheng et al., 2018), el mildiú polvoroso en el pepino (Atanassova et al., 2019) y la flecha seca en la palma africana (Martínez-Barbáchano y Solís-Miranda, 2018). También, ha servido para la detección rápida del hongo *Phymatotrichum* que afecta a las raíces del algodón, y el virus “Y” o el tizón tardío de la papa (Franceschini et al., 2019; Polder et al., 2019; Yang et al., 2010).

A menudo se han utilizado un grupo de bandas y combinaciones del infrarrojo cercano y del rojo para extraer información vegetal (Xue y Su, 2017). La extracción o interpretación de esta información vegetal han creado un grupo de bandas únicas para el análisis de datos, llamados índices de vegetación. Estos índices de vegetación a menudo están limitados a los objetivos específicos de los investigadores y se les puede atribuir características que van más allá de la cuantificación del crecimiento y vigor de las plantas. Uno de los índices más conocidos y utilizados con relación a las bandas rojo e infrarrojo cercano es el Índice de Vegetación de Diferencia Normalizada (NDVI). Éste se emplea para caracterizar el crecimiento y vigor del dosel, y fue propuesta por Rouse et al. (1973).

Loladze et al. (2019) utilizaron el NDVI y muchos otros índices de vegetación multiespectrales, para el fenotipado de la mancha de asfalto en maíz demostrando así el potencial que tienen los sensores remotos para la evaluación de enfermedades. De esta manera, la capacidad de detectar y monitorear las enfermedades de las plantas es importante para prevenir y minimizar las pérdidas de productos agrícolas o forestales (Anne-Katrin Mahlein, 2016). En la era de revolución digital y “big data” en la agricultura (Heim et al., 2019), las herramientas de teledetección, así como la inteligencia

artificial, resultan ser más accesibles gracias a la evolución del “hardware” y “software”. Esto hace que los costos en el estudio de la teledetección se reduzcan. Por ello el estudio de sistemas de detección temprana de fitopatógenos resulta ser importante, dada la relevancia que tiene la producción mundial de alimentos y el aumento simultáneo de nuevos patógenos.

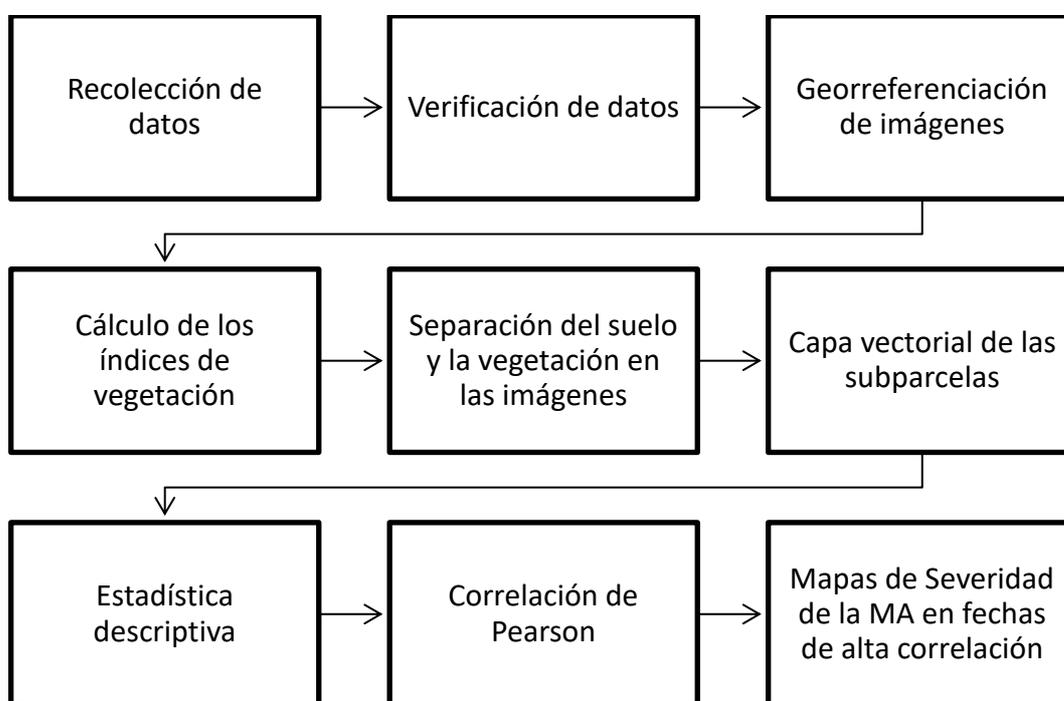
El presente estudio se enfoca en analizar la relación entre el avance de la severidad de la mancha de asfalto con distintos índices de vegetación derivados de imágenes multiespectrales para validar su uso en la detección de enfermedades en zonas tropicales. Se plantearon los objetivos específicos de evaluar la evolución temporal de los diferentes índices de vegetación en distintas etapas fenológicas del maíz; evaluar el avance espacial de la mancha de asfalto a lo largo del tiempo en que se ejecutó el experimento y de generar imágenes de distribución espacial de la mancha de asfalto en la parcela de estudio a lo largo de las etapas fenológicas del maíz.

Materiales y Métodos

En este estudio se utilizaron datos del experimento de Puerto (2020), realizado en la Escuela Agrícola Panamericana, Zamorano, entre el 3 de septiembre del 2019 y el 20 de marzo del 2020. Además, para una adecuada comprensión de este estudio, en la Figura 1 se observa el proceso llevado a cabo en el presente experimento.

Figura 1

Esquema de distribución de la metodología



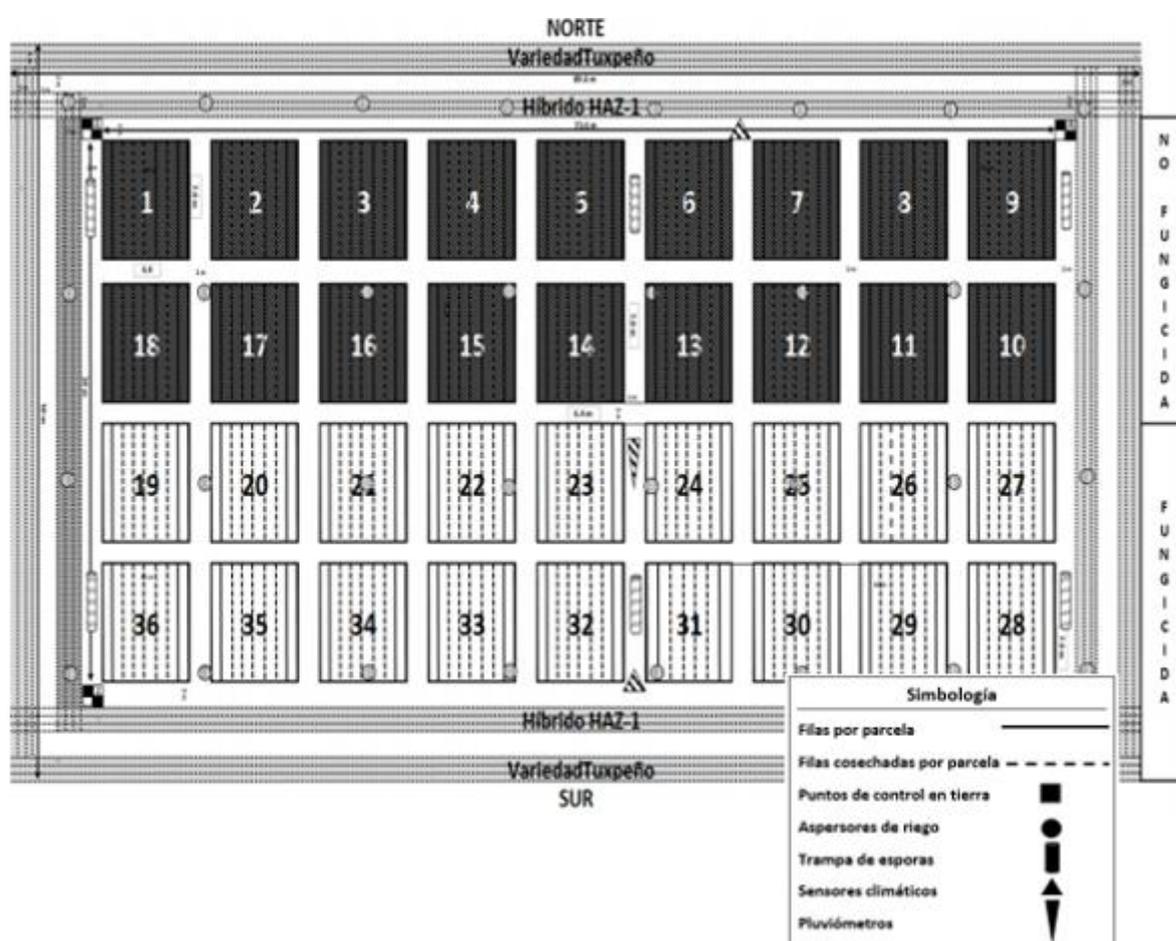
Diseño de la Parcela de Puerto (2020)

En este estudio se utilizaron los datos de severidad, rendimiento e imágenes multiespectrales obtenidas del experimento de Puerto (2020), el cual consistió en evaluar los daños de la Mancha de Asfalto en condiciones controladas en campo. Se caracterizó dos especies híbridas; el híbrido convencional DICTA96 y el híbrido transgénico DK390RR, en un terreno ubicado en la localidad de Santa Inés con un área de 4,985 m², entre el 3 de septiembre del 2019 y el 20 de marzo del 2020.

La siembra de las parcelas experimentales las realizó el 4 de noviembre del año 2019, y consistió en un diseño bifactorial 2×2 de parcelas divididas, con nueve repeticiones. Los niveles con y sin fungicidas estuvieron distribuidos en las parcelas y los niveles de variedades (el híbrido transgénico DK390RR y el híbrido convencional DICTA96) en las sub-parcelas (Figura 2). Las variedades DK390RR y DICTA96 se distribuyeron aleatoriamente en toda la parcela según el Anexo A.

Figura 2

Esquema de distribución de la parcela experimental



Nota. Tomada de Puerto (2020)

Su diseño contó con 36 unidades experimentales, las unidades de 1 a 18 no recibieron ninguna aplicación de fungicida, y de la 19 a la 36 recibieron dos aplicaciones foliares del fungicida Amystar®

Xtra 28 SC (azoxystrobina/ciproconazol) a los 46 y 70 días después de la siembra (DDS). Cada unidad experimental constó de 9 surcos con 49 plantas/surco y un total de 441 plantas/unidad. Las condiciones meteorológicas durante el experimento de Puerto (2020) incluyeron una temperatura promedio de 23 °C, mínima de 19 °C y máxima de 31 °C, y una humedad relativa promedio de 76%, mínima de 40% y máxima de 93%. Según Hock et al. (1992) son condiciones propicias para el desarrollo de la MA.

El inóculo primario utilizado para infectar la plantación con MA se recolectó de la aldea de Talgua, municipio de Catacamas, departamento de Olancho, Honduras. Se sembraron 270 m² de barreras alrededor del terreno que funcionaron como hospederas de la MA. Las variedades utilizadas en sus barreras fueron las variedades Tuxpeño y HAZ-1. La inoculación se realizó a los 47 DDS en las barreras, y a los 3 DDS en las parcelas experimentales, siguiendo el método desarrollado en el Departamento de Botánica y Patología Vegetal de la Universidad de Purdue (Puerto, 2020).

Datos Recolectados

Imágenes Multiespectrales

Se seleccionaron de la base de datos de Puerto (2020), 30 imágenes multiespectrales de un total de 90 imágenes, correspondientes a 15 vuelos de un RPAS (Remotely Pilot Aircraft System) tomadas con un sensor multiespectral, realizados entre el 11 de enero y 13 de marzo del 2020. Las imágenes fueron capturadas por la aeronave pilotada de forma remota (RPA por sus siglas en inglés) Matrice 200 V2 tetracóptero (DJI, Zanzhen, China), por medio del sensor multi-espectral Altum™ de Micasense, que proporcionó imágenes espectrales en rojo (668 nm centro, 10 nm ancho de banda), verde (560 nm centro, 20 nm ancho de banda), azul (475 nm centro, 20 nm ancho de banda), infrarrojo (717 nm centro, 10 nm ancho de banda), e infrarrojo cercano (840 nm centro, 40 nm ancho de banda), con una resolución a nivel del suelo de 5.2 cm por píxel.

Las imágenes empleadas correspondieron a 6 vuelos, donde se registraron 5 bandas de imágenes multiespectrales. Las imágenes de los vuelos que no se utilizaron presentaron distorsiones, producto del procesamiento digital que tuvieron. El primer vuelo empleado se realizó a 74 días después de la siembra (DDS) y el último a los 130 DDS (Cuadro 1).

Cuadro 1

Fechas de vuelo de imágenes multiespectrales

Número de vuelo	Fecha ^a	DDS ^b
1	11/01/2020	68
2	15/01/2020	72
3	17/01/2020	74
4	21/01/2020	78
5	24/01/2020	81
6	25/01/2020	82
7	28/01/2020	85
8	31/01/2020	88
9	04/02/2020	92
10	20/02/2020	108
11	22/02/2020	110
12	25/02/2020	113
13	28/02/2020	116
14	07/03/2020	124
15	13/03/2020	130

Nota. ^a Fechas en negrita seleccionadas en el estudio. ^bDDS: Días después de siembra.

Campaña de Evaluación de Severidad

Se emplearon datos de severidad de la MA, recolectados en la parcela durante la fase del experimento de Puerto (2020), quien seleccionó las plantas a evaluar siguiendo el método propuesto por CIMMYT (1995), el cual consistió en realizar un muestreo sistemático en “zigzag” en aproximadamente un 10% de las plantas por parcela. Según este método, se seleccionaron en cada muestreo cinco plantas continuas en cada uno de los nueve surcos de cada parcela (45 plantas por parcela, 1,620 plantas en el experimento). La severidad se define como el porcentaje de la superficie de la planta afectada por la enfermedad, y es la proporción del área foliar enferma en el área foliar total, multiplicada por 100 (Nutter et al., 2006).

Además, el experimento de Puerto (2020) siguió la metodología propuesta por la Universidad de Purdue (Oh et al., 2021), para evaluar la severidad de la MA empleando los doseles bajo, medio y alto de las cinco plantas seleccionadas en su conjunto. Según este método, se considera a la hoja de la mazorca como la hoja 0 (L0), las hojas por debajo o por encima de L0 se identifican con un signo menos (-) o más (+), respectivamente. De esta manera, el dosel inferior corresponde a L - 3 a la hoja más baja (L - n), el dosel medio de L - 2 a L + 1, y el dosel superior de L + 2 a la hoja bandera (L + n) (Oh et al., 2021). La evaluación se realizó durante cinco campañas, a partir de los 77 días después de la siembra y concluyó a los 118 días después de la siembra (Cuadro 2).

Cuadro 2

Fechas de las campañas de evaluación de severidad

Número de evaluación	Fecha	DDS
1	20/01/2020	77
2	27/01/2020	84
3	31/01/2020	88
4	23/02/2020	111
5	01/03/2020	118

Nota. DDS = Días después de la siembra

Rendimiento

Se emplearon los datos de rendimiento de toda la parcela obtenidas por el experimento de Puerto (2020) quien realizó la cosecha a los 125 DDS y a un 34% de humedad del grano. Para la obtención de rendimientos, se siguió la metodología propuesta por CIMMYT (1995), el cual consiste en seleccionar los cinco surcos centrales y cosechar mazorcas de 100 plantas, en un área de 10.16 m², y con base en esos datos estimar el rendimiento por hectárea. Antes de hacer sus evaluaciones de rendimiento y calidad de grano, secó las muestras hasta alcanzar una humedad de 12%.

Índices de Vegetación

Se define un Índice de Vegetación (IV) como la combinación aritmética de dos o más bandas relacionadas con las características de la vegetación (Matsushita et al., 2007), o como un parámetro calculado a partir de los valores de la reflectividad a distintas longitudes de onda (Gilabert et al., 1997). Las longitudes de onda comprenden rangos distintos como las bandas del infrarrojo cercano y medio del espectro electromagnético que se encuentran entre 850 nanómetros (nm) y 1,700 nm, los del espectro visible comprenden las bandas, azul (450 – 495 nm), verde (495 – 570 nm) y roja (620 – 750 nm) (Bin Abdul Rahim et al., 2016).

De los IV se pretende extraer información relacionada con la vegetación y están diseñadas para producir un valor único que indica la cantidad o vigor de la vegetación dentro de un píxel (Campbell, 1987; Pettorelli, 2013). Jackson et al. (1983) describió el índice de vegetación ideal como aquél particularmente sensible a la cubierta vegetal, insensible a los cambios de fondo del suelo, brillo, color y solo levemente influenciado por la perturbación atmosférica, los factores medioambientales y las geometrías de la iluminación.

Índice de Vegetación de Diferencia Normalizado

El Índice de Vegetación de Diferencia Normalizada (NDVI, siglas en inglés) fue propuesta por Rouse et al. (1973) y es uno de los índices más utilizados e implementados para caracterizar el crecimiento o vigor del dosel. Se basa en el contraste entre la máxima absorción en el rojo debido a los pigmentos de clorofila y la máxima reflexión en el infrarrojo provocada por la estructura celular de la hoja (Haboudane et al., 2004).

El NDVI produce valores que van de -1 a 1, con cuerpos de agua que corresponden a valores cercanos a -1, superficies como rocas y nieve tienen valores por debajo de 0.1, áreas cubiertas de hierba que se encuentran en el rango de 0.2-0.3, y vegetación saludable de alta densidad como los bosques que dan como resultado valores superiores a 0.6 (Weier y Herring, 2000). El NDVI es sensible

a los efectos del brillo y color del suelo, la atmósfera, las nubes y la sombra del dosel de las hojas (Xue y Su, 2017). El NDVI se calcula siguiendo la Ecuación 1.

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}} \quad [1]$$

Donde:

NIR = Longitud de banda del infrarrojo cercano

RED = Longitud de banda del rojo visible

Índice de Vegetación de Diferencia Renormalizado

El Índice de Vegetación de Diferencia Renormalizado (RDVI, siglas en inglés) fue propuesta por Roujean y Breon (1995). Este índice se ha desarrollado con el fin de linealizar la relación entre el índice y las variables biofísicas de la vegetación (Haboudane et al., 2004). El RDVI suprime los efectos del suelo y el sol, sin embargo, en áreas con escasa vegetación tiende a no ser tan efectivo (Ecuación 2).

$$\text{RDVI} = \frac{\text{NIR} - \text{RED}}{\sqrt{\text{NIR} + \text{RED}}} \quad [2]$$

Donde:

NIR = Longitud de banda del infrarrojo cercano

RED = Longitud de banda del rojo visible

Índice de Vegetación de Área Normalizada

El Índice de Vegetación de Área Normalizada (NAVI, siglas en inglés) fue propuesta por Carmona et al. (2015). Este índice se desarrolló para estimar el contenido de clorofila (Chl) que es un indicador de la actividad fotosintética, por lo que está relacionado con el estado fenológico y salud de la planta. El índice se deriva y es una construcción simple del índice NAOC (“Normalized Area Over

Reflectance Curve” siglas en inglés), quien requiere de datos hiperespectrales para su cálculo. Sin embargo, el índice NAVI no requiere de ello y se puede calcular utilizando datos multiespectrales, que son más simples (Ecuación 3).

$$\text{NAVI} = \left(1 - \frac{p1}{p2}\right) [3]$$

Donde:

$p1$ = Longitud de banda del rojo visible

$p2$ = Longitud de banda del infrarrojo cercano

Índice de Vegetación Optimizada al Suelo

El Índice de Vegetación Optimizada al Suelo (OSAVI, siglas en inglés), fue propuesta por Rondeaux et al. (1996). Es un índice que no depende de la línea del suelo ya que utiliza un factor de corrección de 0.16 para reducir los efectos del fondo del suelo y aunque puede eliminar dicha influencia, sus aplicaciones no son muy extensas y es principalmente utilizado en el cálculo de la biomasa aérea, contenido de nitrógeno en las plantas y contenido de clorofila (Xue y Su, 2017) (Ecuación 4).

$$\text{OSAVI} = \frac{(1 + 0.16)(R800 - R670)}{(R800 + R670 + 0.16)} [4]$$

Donde:

R800 = Longitud de banda del infrarrojo cercano

R670 = Longitud de banda del rojo visible

Índice de Reflectancia y Absorción de Clorofila Modificado 2

El Índice de Reflectancia y Absorción de Clorofila Modificado 2 (MCARI-2, siglas en inglés), fue propuesta por Haboudane et al. (2004). Es un índice que incorpora un factor de ajuste del suelo, quien es más sensible a la concentración e influencia de clorofila en las hojas (Ecuación 5).

$$MCARI2 = \frac{1.5 * [2.5(R800 - R670) - 1.3(R800 - R550)]}{\sqrt{(2R800 + 1)^2 - (6R800 - 5\sqrt{R670}) - 0.5}} [5]$$

Donde

R800 = Longitud de banda del infrarrojo cercano

R670 = Longitud de banda del rojo visible

R550 = Longitud de banda del verde visible

Procesamiento de Imágenes

Georreferenciación de Imágenes

Se procedió a realizar la georreferenciación de las imágenes multiespectrales, en el “software” geográfico de código abierto QGIS versión 3.8.2. Las coordenadas fueron tomadas dentro de la parcela donde se ubicaron cuatro puntos de control en tierra (Cuadro 3). Las coordenadas geográficas utilizadas fueron la WGS 84 UTM zona 16N referente para Honduras.

Cuadro 3

Coordenadas de los puntos de control

Puntos de control	Coordenada X	Coordenada Y
1	501464.800	1546178.180
2	501458.300	1546146.080
3	501533.110	1546133.990
4	501537.170	1546167.460

Cálculo de los Índices de Vegetación

El cálculo de los índices de vegetación se ejecutó automáticamente en el “software” QGIS® (“Open Source Geographic Information System” siglas en inglés) con el módulo calculadora ráster, donde se incorporó la fórmula de los índices junto con las bandas correspondientes. Para una adecuada visualización de las bandas, se procedió estandarizar las fórmulas dejándolas todas en las bandas del NIR, RED y GREEN. Se generó una imagen ráster con los valores de cada índice de vegetación para cada fecha de estudio.

Máscara de Vegetación Efectiva

Se creó una máscara ráster a partir del NDVI de cada fecha, donde se separó el suelo de las plantas, tomando en cuenta un umbral de $NDVI > 0.4$. Este umbral fue utilizado por Pantazi et al. (2016), en su separación entre el cultivo de maíz y las especies de malezas basadas en su diferencia de reflectancia espectral de NDVI. Posteriormente, se multiplicó la máscara creada, por cada uno de los índices de vegetación utilizados (NDVI, RDVI, OSAVI, NAVI, MCARI-2) creando una nueva serie de imágenes con un rango de valores de 0.4 a 1.

Descripción de la Mancha de Asfalto

La descripción de los síntomas de severidad de la mancha de asfalto se realizó con base al material DK390RR en las parcelas sin fungicida. Este fue el material que presentó una mayor severidad de la enfermedad en comparación con el material DICTA96.

Análisis Estadístico

Se creó una capa vectorial que contuviera las 36 sub-parcelas (Figura 2) para cada fecha. Posteriormente, se utilizó la función estadística de zona de QGIS, que calcula las estadísticas descriptivas (Número, Suma, Media, Mediana, Desviación estándar, Mínima, Máxima, Intervalo, Minoría, Moda, Varianza) de una capa ráster para cada entidad de una capa vectorial de polígono

superpuesta. Se realizó el cálculo estadístico para las 36 parcelas de los cinco índices de vegetación y en las seis fechas. La estadística descriptiva (medidas de tendencia central y dispersión) se llevó a cabo en el software de QGIS®.

Correlación Pearson

Se analizó la correlación entre las evaluaciones de severidad de la MA de cada dosel (inferior, intermedio y superior) y la estadística descriptiva de los índices de vegetación de las parcelas sin fungicida. También, se llevó a cabo la correlación de los rendimientos y la media de los índices de vegetación, además de los rendimientos y la severidad de la MA de cada dosel (inferior, intermedio y superior). Para esto se usó el coeficiente de correlación de Pearson (r) y se llevó a cabo en el software estadístico "InfoStat", con un nivel de significancia de 0.05.

El coeficiente de correlación de Pearson se utiliza para variables cuantitativas, es un índice que mide el grado de covarianza entre distintas variables relacionadas linealmente. El valor del coeficiente de correlación de Pearson oscila entre -1 y $+1$. La magnitud de la relación está especificada por el valor numérico del coeficiente, reflejada en el signo de la dirección de dicho valor. En este caso una relación puede ser tan fuerte en -1 como en $+1$. En el primer caso la relación es perfectamente inversa y en el segundo perfectamente directa (Dagnino, 2014; Díaz y Fernández, 2002).

Correlogramas

Se empleó correlogramas entre los días después de siembra (variable independiente) y el coeficiente de Pearson (variable dependiente). De esta manera, se terminó las fechas donde la severidad estuvo altamente correlacionada con los índices de vegetación.

Mapa de Severidad de la Mancha de Asfalto

Se realizó una regresión lineal simple entre la media de NDVI (variable independiente) y la severidad del dosel intermedio (variable dependiente) a los 88 DDS del genotipo DK390RR de las parcelas sin fungicida. Se utilizó la fecha de mayor correlación y el índice de mayor correlación.

Resultados y Discusión

Evolución Visual de la Parcela con Mancha de Asfalto

El cálculo de los índices de vegetación nos permitió observar la evolución de la parcela con MA a través del tiempo, desde la primera fecha (74 DDS), hasta la última fecha (130 DDS). Para una adecuada visualización de los índices de vegetación, se estandarizó un rango de valores de 0.4 a 0.9. Esto principalmente siguiendo los valores definidos de NDVI, que es el único índice que mantiene los rangos de sus valores bien definidos. En la Figura 3 se presentan todos los índices de vegetación a los 116 DDS ya que es el momento donde la parcela obtuvo la mayor incidencia (severidad > 90%) de la enfermedad de la MA (118 DDS).

Figura 3

Imagen de los Índices de Vegetación (NDVI, RDVI, NAVI, OSAVI, MCARI2) a los 116 DDS de la parcela



Nota. S: Promedio parcelas sin fungicida, C: Promedio parcelas con fungicida

Se observa que todos los índices presentaron diferencias en los valores promedios de las parcelas con y sin fungicida. El promedio de los valores de las parcelas sin fungicida fue menor en comparación con las parcelas con fungicida en todos los índices de vegetación a los 116 DDS. Se puede observar que los índices NDVI, OSAVI y MCARI-2, describen visualmente mejor que RDVI y NAVI las diferencias en las parcelas con y sin fungicida a los 116 DDS. Sin embargo, esta descripción está regida únicamente a los rangos de valores escogidos para nuestra representación (0.4 a 0.9).

El índice NAVI también puede describir visualmente bien la parcela con y sin fungicida a los 116 DDS en un rango de 0.5 a 0.9 (Anexo B). En cambio, el índice RDVI también describe visualmente bien la parcela con y sin fungicida a los 116 DDS en un rango de 0.4 a 0.8 (Anexo C). Estos cambios se pueden dar principalmente al no contar con un rango de valores definidos como en el caso de NDVI, que mantiene su rango de valores de -1 a 1. En el Anexo D se muestra también la parcela con MA en el índice OSAVI a los 116 DDS.

Todos los índices pueden describir visualmente bien las parcelas con y sin fungicida dependiendo de los rangos de valores escogidos. Para nuestro análisis únicamente describiremos la evolución de la parcela con MA en el índice NDVI y MCARI-2. El primero por ser un índice con un rango de valores bien definidos y el segundo por observar que discernía mejor la vegetación.

Evolución Visual de la Parcela con Mancha de Asfalto en MCARI-2

Se describe a continuación la evolución de la parcela con MA en el índice MCARI-2 entre la primera fecha 74 DDS y la última fecha 130 DDS (Figura 4). Se describe su temporalidad a través de las distintas etapas fenológicas del maíz.

Figura 4

Imagen temporal del Índice de Reflectancia y Absorción de Clorofila Modificado 2 (MCARI-2) de la parcela



Nota. S: Promedio parcelas sin fungicida. C: Promedio parcelas con fungicida

Se puede observar que la parcela a los 74 DDS los valores promedios de las parcelas sin y con fungicida se encontraban con un valor de 0.777 y 0.768 respectivamente. En esta etapa el cultivo se encontraba en R1 que es conocido en inglés como “Silking Stage” o etapa de emergencia de estigmas en español. Esta etapa es la primera etapa reproductiva del maíz, donde cada óvulo (grano potencial) de la mazorca desarrollara su propia seda (el estigma funcional de la flor femenina) (Nielsen, 2021).

Entre los 88 DDS y los 116 DDS las parcelas sin fungicida tienen un valor promedio inferior a las parcelas con fungicida. Esta diferencia de valores en las parcelas con y sin fungicida podría atribuírsele al tratamiento que presentaron las parcelas. La primera recibió dos aplicaciones foliares a los 46 y 70 DDS, mientras que la segunda no recibió ninguna aplicación. Solo en la primera fecha (74

DDS) y la última fecha (130 DDS) los valores promedios de las parcelas sin fungicida fueron superior a la parcela con fungicida.

A los 108 DDS se evidencia un gran cambio de los valores en los pixeles de las parcelas respecto a la fecha anterior (88 DDS). Se puede apreciar en esta fecha que las parcelas sin fungicida obtuvieron un valor promedio de 0.616, mientras que en la fecha anterior su valor promedio era de 0.738. Estos valores de MCARI-2 podría atribuírselo al comportamiento natural y senescencia de los cultivos, sin embargo, también podría ser un incremento de la enfermedad y un reflejo del síntoma ojo de pescado que describió Puerto (2020) en las parcelas sin fungicida del genotipo DK390RR entorno a esa fecha.

En la última fecha (130 DDS) los valores promedios de las parcelas con y sin fungicida fueron de 0.456 y 0.463 respectivamente. En esta fecha, la parcela se encontraba en su última etapa fenológica (R6), y aparentemente lo que estaríamos observando sería la senescencia del cultivo y posiblemente un incremento de la enfermedad de la MA.

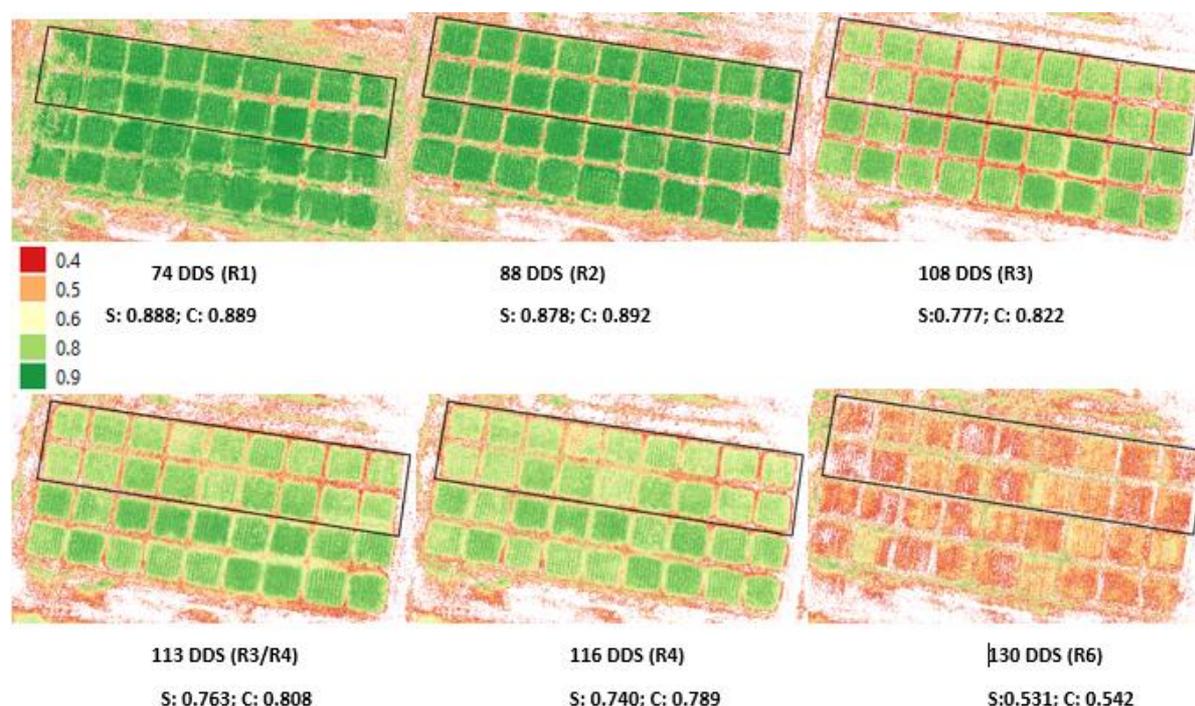
Además, entre los 74 DDS y los 88DDS se aprecia un cambio en los pixeles de los caminos de la parcela, los cuales van desde 0.4 a los 74 DDS, hasta desaparecer a los 88 DDS. Estos pixeles pudieron ser el reflejo de malezas que estuvieron presentes en los caminos de las parcelas a los 74 DDS. En tanto que a los 88 DDS, el control de malezas se había efectuado hace dos días, por lo que para esa fecha los pixeles de los caminos de las parcelas estarían ausentes. Sin embargo, el control de malezas se suspendió a los 106 DDS por lo que deberían estar presentes a los 113 DDS y a los 116 DDS. Lo que sugiere que el índice MCARI-2 estaría describiendo mejor el comportamiento del cultivo de maíz y la presencia de vegetación más cercana al suelo (malezas). MCARI-2 inicialmente está pensado como un índice que determina el contenido de clorofila e incorpora un factor de ajuste al suelo lo que le permite reducir la influencia de los fondos, y tomar en cuenta factores como sombra, reflectancia del suelo, y materiales no fotosintéticos (Jiang et al., 2015; Wu et al., 2008). MCARI-2 ha demostrado también estar altamente relacionado y ser sensible a los cambios estacionales en el crecimiento y la senescencia de las plantas (Badura et al., 2019).

Evolución Visual de la Parcela con Mancha de Asfalto en NDVI

Se analizó que a los 74 DDS las parcelas sin fungicida tienen un valor promedio de NDVI de 0.888, lo que estaría relacionada con el vigor y la salud del cultivo tal como lo menciona Alface et al. (2019) en su estudio, que el conjunto de píxeles de NDVI con valores de 0.69 a 0.90 representa un mayor vigor vegetativo (Figura 5). Puerto (2020) señala que la enfermedad presentó sus primeros síntomas en el segmento medio de la planta a los 75 DDS donde observó lesiones elevadas oscuras, estromáticas de aspecto liso y brillante, de forma oval a circular, con 0.5 a 2.0 mm de diámetro y forma estrías hasta de 10 mm de longitud. Por lo que, para los 74 DDS la imagen de NDVI podría estar relacionada con el posible inicio de la enfermedad y su aparente vigor y salud visual.

Figura 5

Imagen temporal del Índice de Vegetación de Diferencia Normalizada (NDVI) de la parcela



Nota. S: Promedio parcelas sin fungicida. C: Promedio parcelas con fungicida

En MCARI-2 se puede observar que en NDVI las parcelas sin fungicida tienen un cambio de valor en los píxeles de 0.878 a 0.777, a los 88 y 108 DDS respectivamente. Según Puerto (2020) a los

92 DDS observó un cambio notable en el avance de la MA a nivel de la planta y de hoja, debido a que los estromas de la hoja fueron rodeados por un halo necrótico de forma elíptica color verde claro, conocido como ojo de pescado que se dispersó por toda la superficie de la hoja y de la planta (Quiroga-Madrigal et al., 2017). Por lo tanto, el avance de severidad tanto a nivel de hoja y de planta, determinó la senescencia del cultivo alcanzando un pico de severidad mayor al 90% a los 118 DDS. Varios autores mencionan, que en casos severos, los halos necróticos se fusionan, causando una necrosis extensa y tizón foliar que conduce a una senescencia prematura y muerte de las plantas (Ceballos y Deutsch, 1992; Hock et al., 1995). De tal manera, la evolución de la parcela con MA en NDVI para los 130 DDS con un valor promedio en las parcelas sin fungicida de 0.531 estaría mostrando la senescencia natural la planta y probablemente el incremento de la enfermedad, tal como lo menciona Alface et al. (2019) en su estudio que el conjunto de píxeles de NDVI que se encuentran en un rango inferior a 0.69 representando áreas con escasa vegetación, degradación o con déficit hídrico, lo que podría estar atribuido a la salud del cultivo.

Estadística Descriptiva de las Diferentes Sub-parcelas

En el Cuadro 4 y 5 se observa la estadística descriptiva de las parcelas que no recibieron fungicida (1 a la 18) y las que si recibieron fungicida (19 a la 36) del índice NDVI a los 116 DDS. Se elige NDVI al ser un índice bien documentado con rangos de valores definidos, y en la fecha (116 DDS) al ser un periodo donde visualmente hubo un cambio evidente de los valores de los píxeles asociados a las parcelas con y sin fungicida. Toda la estadística descriptiva de NDVI se presenta en el Anexo E.

Cuadro 4*Estadística descriptiva de NDVI a los 116 DDS de las parcelas sin fungicida*

Parcela	Genotipo	Min	Max	Media
1	DK390	0.40004	0.87808	0.71183
2	DICTA96	0.40002	0.90996	0.74525
3	DK390	0.40013	0.91571	0.73167
4	DICTA96	0.40007	0.88453	0.67478
5	DK390	0.40017	0.89173	0.73302
6	DICTA96	0.40029	0.91145	0.75754
7	DK390	0.40009	0.89691	0.72103
8	DICTA96	0.40001	0.90458	0.71459
9	DK390	0.40003	0.87631	0.69052
10	DICTA96	0.40001	0.89823	0.72985
11	DICTA96	0.40044	0.90179	0.73965
12	DK390	0.40752	0.92974	0.79223
13	DK390	0.40072	0.91954	0.79449
14	DICTA96	0.40003	0.89315	0.72917
15	DK390	0.40191	0.91016	0.7886
16	DK390	0.40048	0.91383	0.79809
17	DICTA96	0.40056	0.90347	0.74285
18	DICTA96	0.40004	0.88578	0.7183
Promedio				0.73963
Desviación estándar				0.07455

Nota. Min: mínimo. Max: máximo.**Cuadro 5***Estadística descriptiva de NDVI a los 116 DDS de las parcelas con fungicida*

Parcela	Genotipo	Min	Max	Media
19	DK390	0.40057	0.9193	0.80568
20	DICTA96	0.40003	0.92227	0.75894
21	DK390	0.40011	0.93314	0.81255
22	DK390	0.40083	0.93735	0.81036
23	DK390	0.40704	0.93569	0.82900
24	DICTA96	0.40009	0.92633	0.77703
25	DK390	0.40004	0.93641	0.82503
26	DICTA96	0.40033	0.93132	0.78033
27	DICTA96	0.40000	0.92509	0.76845
28	DK390	0.40001	0.91925	0.76678
29	DICTA96	0.40003	0.92146	0.77344
30	DK390	0.40000	0.93158	0.81575

Parcela	Genotipo	Min	Max	Media
31	DK390	0.40020	0.93023	0.81934
32	DICTA96	0.40403	0.92020	0.77146
33	DICTA96	0.40014	0.90802	0.76708
34	DICTA96	0.40003	0.92464	0.75276
35	DK390	0.40002	0.94002	0.81109
36	DICTA96	0.40040	0.91497	0.76018
Promedio				0.78918
Desviación estándar				0.07174

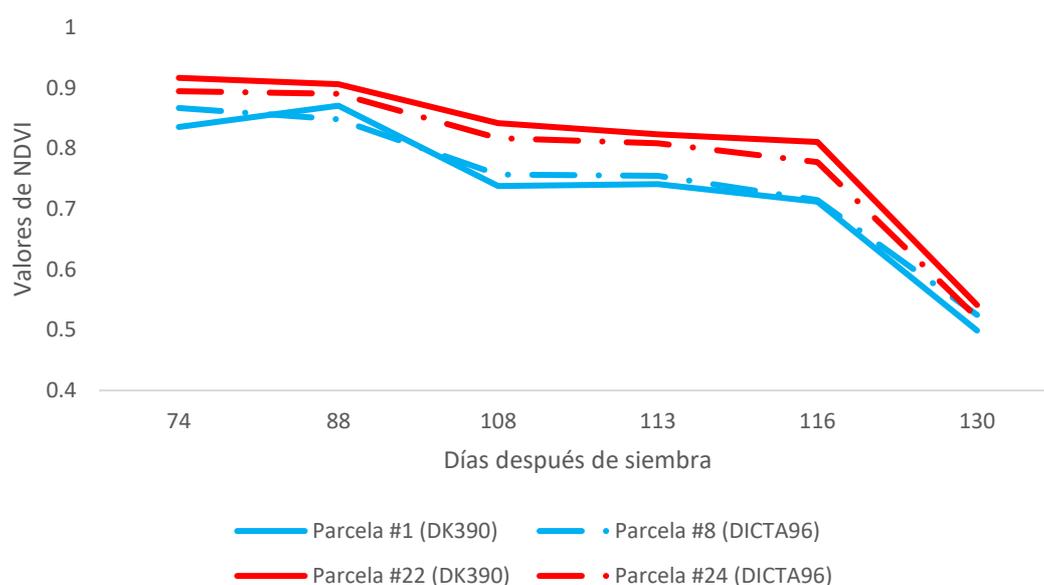
Nota. Min: mínimo. Max: máximo.

Se pueden observar los valores máximos, mínimos y sus medias para cada parcela a los 116 DDS. Se analiza la diferencia de valores que existen entre las parcelas sin y con fungicida con un valor promedio de 0.74 y 0.79 respectivamente. A nivel de genotipo se puede observar cambios como en la parcela 1 con el genotipo DK390RR que obtuvo una media de 0.71, mientras que en la parcela 2 con el genotipo DICTA96 se obtuvo una media de 0.75.

Para una mejor interpretación de los genotipos en las parcelas con y sin fungicida, en la Figura 6 donde se observa la distribución de las parcelas 1, 8, 22 y 24. Se observa como la parcela número uno del genotipo DK390 obtuvo una evolución con rangos inferiores, respecto a las demás parcelas.

Figura 6

Evolución de las parcelas #1, #8 (sin fungicida) y #22, #24 (con fungicida) en el índice NDVI



Correlaciones

Correlación entre las Campañas de Severidad y las Medias de los Índices de Vegetación

Se correlacionaron únicamente las parcelas que no recibieron fungicida al ser los materiales que visualmente presentaron la enfermedad de la MA. Los resultados de la correlación de Pearson entre los datos de severidad y la media de los índices de vegetación de las 18 unidades experimentales no fueron significativos ($P > 0.05$) (Cuadro 6). Por efectos de simplicidad únicamente se presenta a continuación el valor P de la correlación de la media de los índices de vegetación y la severidad del dosel intermedio en las distintas fechas. Solo se muestra el valor P ; ya que nuestro estudio busca encontrar correlaciones significativas ($P < 0.05$). La última fecha (130 DDS) no se correlaciono al no contar con datos cercanos de severidad a esa fecha.

Cuadro 6

Valor P de los Índices de Vegetación en el dosel intermedio

Numero de vuelo			Índices de Vegetación				
	CES*	DDS	NDVI	RDVI	NAVI	OSAVI	MCARI-2
3	1	74	0.99	0.2	0.98	0.29	0.46
8	3	88	0.61	0.06	0.66	0.24	0.50
10	4	108	0.64	0.63	0.71	0.91	0.88
12	4	113	0.23	0.85	0.25	0.67	0.47
13	5	116	0.46	0.66	0.48	0.88	0.94

Nota. *Campañas de evaluación de severidad. DDS: días después de siembra. NDVI: Índice de vegetación de diferencia normalizada. RDVI: Índice de vegetación de diferencia Renormalizada. NAVI: Índice de Vegetación de Área Normalizada. OSAVI: Índice de Vegetación Optimizada al Suelo. MCARI-2: Índice de Reflectancia y Absorción de Clorofila Modificado2.

Se correlacionó la severidad de MA medida en campo y los índices de vegetación, analizando los genotipos por separado (DICTA96 y DK390RR) de las parcelas que no recibieron fungicida. Se observó que para la variedad DICTA96, la relación entre severidad y los índices de vegetación no fue significativa ($P > 0.05$, datos no mostrados). Esto supone un control de la enfermedad dado por el genotipo en particular. Puerto (2020) señala que los síntomas de severidad de la MA se describían mejor con base al material DK390RR, ya que este fue el material que presentó una mayor severidad

de la enfermedad en comparación con el material DICTA96. En cuanto a la variable de DK390RR, la correlación entre la severidad y los índices de vegetación si fue significativa ($P < 0.05$).

En el Cuadro 7 se observan los resultados de la correlación en el genotipo DK390RR, entre la severidad de la MA y el índice NAVI a los 88 DDS. Por efectos de simplicidad únicamente se muestran los datos en el índice NAVI, en el dosel intermedio y a los 88 DDS. Se puede observar que el estadístico con más alta correlación fue la media de los índices de vegetación, de aquí en adelante este será el valor que correlacionaremos con los valores de severidad de la MA.

Cuadro 7

Correlación de Pearson del índice NAVI y la severidad del dosel intermedio a los 88 DDS

Dosel	CES	Número de Vuelo	Estadígrafo	Coefficiente de Pearson	p
Intermedio	3	8	Número	0.64	0.06
Intermedio	3	8	Suma	0.32	0.40
Intermedio	3	8	Media	-0.81	0.01*
Intermedio	3	8	Mediana	-0.73	0.03*
Intermedio	3	8	Desv. esta.	0.81	0.01*
Intermedio	3	8	Mínima	-0.64	0.06
Intermedio	3	8	Máxima	0.10	0.79
Intermedio	3	8	Intervalo	0.22	0.57
Intermedio	3	8	Minoría	-0.64	0.06
Intermedio	3	8	Moda	0.00	1.00
Intermedio	3	8	Variedad	0.79	0.01*
Intermedio	3	8	Varianza	0.80	0.01*

Nota. CES: Campañas de evaluación de severidad. * $p < 0.05$. Desv. esta: Desviación Estándar

Correlación entre los Índices de Vegetación y la Severidad Reportada en los Doseles de las Subparcelas

Se prosiguió a realizar un análisis de la correlación de las medias de los índices de vegetación y la severidad de los doseles en las distintas fechas. En la variable DK390RR, la severidad de la MA y los índices de vegetación presentaron una correlación negativa: cuando la severidad fue mayor, los índices de vegetación fueron menores. Esto indica que los índices de vegetación están inversamente relacionados con la gravedad de la enfermedad de la MA. Resultados similares fueron reportados por

Oh et al. (2021) que obtuvo correlaciones negativas por debajo de $-0,8$ en el dosel intermedio y dosel superior en el índice NDVI, lo que nos permite inferir que los índices de vegetación tienen el potencial de observar la MA.

En el dosel inferior la correlación más alta se obtuvo en NDVI con un valor de -0.92 , seguido de NAVI con -0.90 a los 88 DDS en el genotipo DK390RR (Cuadro 8). Para el dosel intermedio la correlación más alta se obtuvo en NAVI con un valor de -0.81 , seguido de NDVI con -0.80 a los 88 DDS en el genotipo DK390RR (Cuadro 9). Para el dosel superior la correlación más alta se obtuvo en NDVI con un valor de -0.89 seguido de NAVI con -0.88 a los 88 DDS en el genotipo DK390RR (Cuadro 10).

Cuadro 8

Correlación de Pearson entre la severidad de la MA del dosel inferior y las medias de los índices de vegetación para la variedad DK390RR sin fungicida

Número de vuelo	CES	DDS	Índices de Vegetación				
			NDVI	RDVI	NAVI	OSAVI	MCARI2
3	1	74	-0.47	-0.22	-0.45	-0.38	-0.47
8	3	88	-0.92*	-0.68*	-0.90*	-0.84*	-0.83*
10	4	108	-0.84*	-0.86*	-0.84*	-0.87*	-0.88*
12	4	113	-0.79*	-0.73*	-0.78*	-0.74*	-0.86*
13	5	116	-0.52	-0.63	-0.51	-0.57	-0.62

Nota. * $p < 0.05$. CES: Campañas de evaluación de severidad. DDS: días después de siembra. NDVI: Índice de vegetación de diferencia normalizada. RDVI: Índice de vegetación de diferencia Renormalizada. NAVI: Índice de Vegetación de Área Normalizada. OSAVI: Índice de Vegetación Optimizada al Suelo. MCARI-2: Índice de Reflectancia y Absorción de Clorofila Modificado2.

Cuadro 9

Correlación de Pearson entre la severidad de la MA del dosel intermedio y las medias de los índices de vegetación para la variedad DK390RR sin fungicida

Número de vuelo	CES	DDS	Índices de Vegetación				
			NDVI	RDVI	NAVI	OSAVI	MCARI2
3	1	74	-0.24	-0.06	-0.22	-0.15	-0.2
8	3	88	-0.80*	-0.28	-0.81*	-0.55	-0.41
10	4	108	-0.26	-0.4	-0.25	-0.33	-0.41
12	4	113	-0.21	-0.33	-0.2	-0.22	-0.41
13	5	116	-0.68*	-0.78*	-0.68	-0.72*	-0.77*

Nota. * $p < 0.05$. CES: Campañas de evaluación de severidad. DDS: días después de siembra. NDVI: Índice de vegetación de diferencia normalizada. RDVI: Índice de vegetación de diferencia Renormalizada. NAVI: Índice de Vegetación de Área Normalizada. OSAVI: Índice de Vegetación Optimizada al Suelo. MCARI-2: Índice de Reflectancia y Absorción de Clorofila Modificado2.

Cuadro 10

Correlación de Pearson entre la severidad de la MA del dosel superior y las medias de los índices de vegetación para la variedad DK390RR sin fungicida

Número de vuelo	CES	DDS	Índices de Vegetación				
			NDVI	RDVI	NAVI	OSAVI	MCARI2
3	1	74	0.01	0.02	0.04	0.02	-0.09
8	3	88	*-0.89	-0.6	*-0.88	*-0.73	*-0.75
10	4	108	-0.67	*-0.76	-0.67	*-0.72	*-0.77
12	4	113	-0.61	-0.54	-0.59	-0.54	*-0.69
13	5	116	-0.66	*-0.74	-0.65	*-0.69	*-0.76

Nota. * $p < 0.05$. CES: Campañas de evaluación de severidad. DDS: días después de siembra. NDVI: Índice de vegetación de diferencia normalizada. RDVI: Índice de vegetación de diferencia Renormalizada. NAVI: Índice de Vegetación de Área Normalizada. OSAVI: Índice de Vegetación Optimizada al Suelo. MCARI-2: Índice de Reflectancia y Absorción de Clorofila Modificado2.

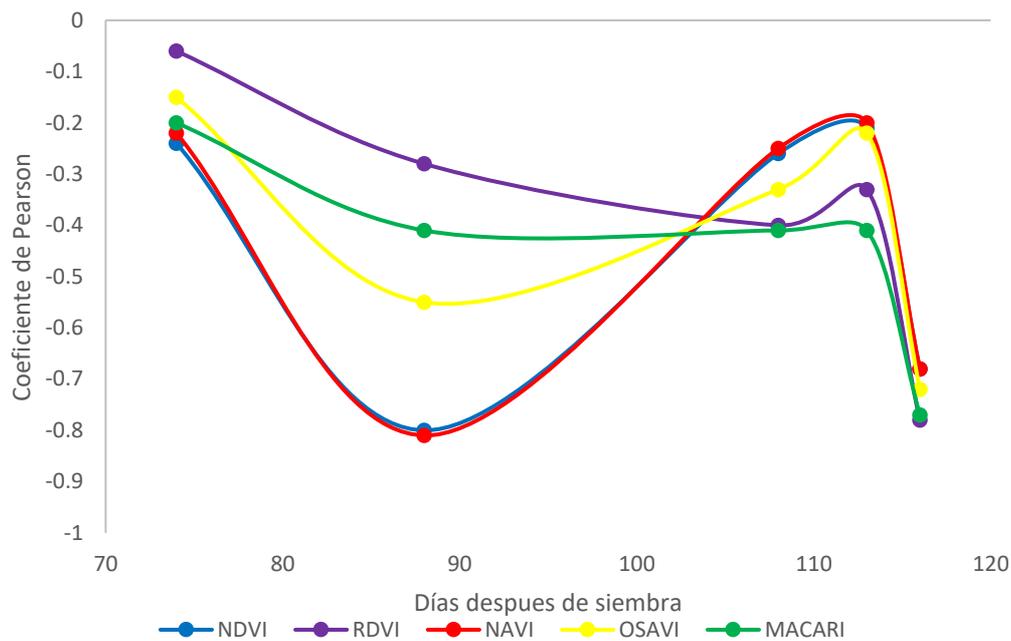
Mancha de Asfalto en Etapas Fenológicas**Mancha de Asfalto en Etapa Fenológica R1-R2**

Para conocer la tendencia de correlación en cada índice de vegetación por el transcurso de los DDS se generó el correlograma (Figura 7) en el dosel intermedio. Se describe el correlograma en el

dosel intermedio ya que esta es la parte de la planta donde se encuentra la hoja de la mazorca (hoja 0) donde la concentración de nutrientes, por ende, la salud de esta hoja explica en mayor al 50% la variación en el rendimiento y la materia seca final (Kovács y Vyn, 2017).

Figura 7

Correlograma de la severidad de la MA del dosel intermedio y las medias de los IV



Se puede observar un mínimo alrededor de los 88 -90 DDS (Figura 7), donde la severidad en el dosel intermedio obtuvo correlaciones negativas cercanas a -1 con los índices NDVI y NAVI. Este periodo coincide con la etapa fenológica R1-R2, la cual es crucial e importante para el desarrollo de los granos y finalmente, para el rendimiento, por lo que es un evento importante que señala el final del crecimiento vegetativo y el comienzo del llenado de granos (Gallo y Flesch, 1989; Nleya et al., 2016). La etapa de R1 es el período más sensible para el cultivo y durante ese momento, y las siguientes dos semanas, el estrés puede reducir significativamente el número de granos por mazorca (Abendroth et al., 2011). Puerto (2020) menciona que observó los primeros síntomas a los 75 DDS (R1) y un incremento de la MA tanto a nivel de hoja como de planta en el día 90 DDS (R2), observando un cambio notable en el avance de la enfermedad de la MA. En esa fecha los estromas fueron rodeados

por un halo de forma elíptica color verde claro, conocido como ojo de pescado, dichos síntomas se dispersaron por toda la superficie de la hoja, y a nivel de la planta. Por lo tanto la etapa R1-R2 se vería afectado por la incidencia del síntoma de ojo de pescado de la MA.

Comúnmente las lesiones de ojo de pescado siempre estuvieron asociadas con la presencia del hongo *Monographella maydis* (Bajet et al., 1994; Ceballos y Deutsch, 1992; Hock et al., 1992). La doble interacción de *M. maydis* con *P. maydis* pueden producir los efectos más devastadores con una necrosis foliar y un aumento significativo de la gravedad de la enfermedad que producen pérdidas de rendimiento de hasta 51% (CIMMYT, 2003; Hock et al., 1989; Hock et al., 1992; Pereyda-Hernández et al., 2009). Sin embargo, se han reportado situaciones en México, Ecuador, Honduras y los EE. UU, donde los síntomas del ojo de pescado estaban presentes, pero *M. maydis* estaba ausente (Ceballos y Deutsch, 1992; McCoy et al., 2019; Ruhl et al., 2016). Estudios recientes de secuenciación de genomas han demostrado que no es necesario el hongo *Monographella maydis* para desarrollar el síntoma ojo de pescado en los cultivos de los Estados Unidos (McCoy et al., 2019).

Muchos modelos de rendimiento de grano de maíz estudian la ocurrencia de etapas tempranas como R1 y R2 porque las condiciones climáticas o enfermedades en esta etapa pueden ser críticas para el rendimiento de grano del cultivo (Claassen y Shaw, 1970; Herrero y Johnson, 1980; Nleya et al., 2016). El ciclo de la enfermedad de la MA y el modo exacto de interacción entre los genotipos de maíz susceptibles y los patógenos aún no se comprende bien (Mottaleb et al., 2019; Valle-Torres et al., 2020). Sin embargo, nuestro análisis indica una correlación muy fuerte en las fechas que se presentó el síntoma de ojo de pescado por lo que NDVI y NAVI posiblemente estarían relacionados con la enfermedad de la MA en dicho periodo.

Mancha de Asfalto en Etapa Fenológica R5-R6

Un máximo se presentó en el correlograma (Figura 7) se presentó alrededor a los 116-125 DDS (R5-R6), esto podría atribuirse a la conjugación del ataque de la enfermedad junto al periodo de madurez fisiológica. Puerto (2020) señala que la mayoría de las hojas evaluadas presentaron una

severidad mayor al 90% a los 118 DDS. Cabe señalar que el riego se suspendió a los 113 DDS al alcanzar las plantas el estado de cosecha, con 25% de humedad en la mazorca (Puerto, 2020). Aunque un estrés severo después de la madurez fisiológica tiene poco efecto sobre el rendimiento del grano (Nielsen, 2019), se presume que la enfermedad de la MA estaba tan avanzada para esa fecha que el rendimiento si se vio afectado. Según Puerto (2020) el genotipo DK390RR presentó rendimientos significativamente mayores en las parcelas con fungicidas respecto a las parcelas sin fungicidas; mientras que, el material DICTA96 no presentó diferencias estadísticamente significativas entre los niveles (con y sin fungicida). Por lo tanto, el máximo de la correlación alrededor a los 116-120 DDS (R5-R6) sugeriría un avance de la MA, sin embargo, dado que estos periodos coinciden con la senescencia de la planta (120 DDS) estas correlaciones significativas podrían atribuirse a este fenómeno en lugar de a la MA.

Puerto (2020) mencionó igualmente que desde el día que aparecieron los primeros síntomas hasta la senescencia total de la hoja transcurrieron 43 días. Desde que comenzaron los primeros síntomas en el segmento medio de la planta, el cultivo se encontraba en su etapa fenológica R1. Cuando el cultivo presentó una severidad mayor al 90% de la enfermedad de la MA, su etapa fenológica se ubicaba en R4-R5. Según Castaño y Del Mendoza. (1994), la severidad de la enfermedad de la MA está altamente relacionada con las etapas fenológicas de la planta. La enfermedad tuvo una presencia más fuerte en las fechas claves del llenado de grano. El llenado de grano es el último conjunto de etapas del ciclo de crecimiento del maíz. En este periodo, la planta dirige sus nutrientes para el crecimiento reproductivo en lugar del crecimiento vegetativo. Si bien el número de granos ya se determinó en etapas anteriores por la planta, el tamaño de los granos se establece durante las etapas de llenado de granos. Las enfermedades o un estrés severo durante el llenado de grano puede matar prematuramente la planta, causar un aborto del grano, ralentizar el secado, lo que reducirá la calidad del grano y el potencial rendimiento final (Nielsen, 2019). Las imágenes de NDVI en la Figura

5 y el correlograma entre la severidad y los índices de vegetación de la Figura 7, se observa este cambio en dichas fechas.

Mancha de Asfalto y Rendimiento

Otra forma de evaluar la evolución de la MA es mediante las correlaciones entre el rendimiento y la severidad de la MA en el genotipo DK390RR. En el Cuadro 11 se presenta la correlación entre el rendimiento y la severidad de la MA en los distintos doseles a lo largo del tiempo de siembra. Se puede observar como a los 88 DDS los tres doseles estaban correlacionados (inferior, intermedio, superior), sin embargo, para los 111 DDS solo el dosel inferior estuvo correlacionado, y para los 118 DDS ningún dosel presentó correlación. Esto nos demuestra como el rendimiento pudo haberse afectado a los 88 DDS que es donde los tres doseles están correlacionados y donde se sugiere estaría presente el síntoma ojo de pescado tal como se analizó.

Cuadro 11

Correlación de Pearson entre el rendimiento y la severidad de la MA en los doseles

Campaña de Evaluación de Severidad	DDS	Dosel	Coefficiente de Pearson	p
1	77	Inferior	-0.82	0.01*
		Intermedio	-0.54	0.13
		Superior	-0.46	0.21
2	84	Inferior	-0.85	0.00*
		Intermedio	-0.74	0.02*
		Superior	-0.62	0.08
3	88	Inferior	-0.89	0.00*
		Intermedio	-0.73	0.03*
		Superior	-0.79	0.01*
4	111	Inferior	-0.88	0.00*
		Intermedio	-0.3	0.43
		Superior	-0.63	0.07
5	118	Inferior	-0.62	0.07
		Intermedio	-0.63	0.07
		Superior	-0.64	0.07

Nota. *P < 0.05

Además, se puede observar como NDVI, OSAVI y NAVI presentan una fuerte correlación positiva a los 88, 108 y 116 DDS, con valores superiores a 0.93 en su coeficiente de Pearson (Cuadro 12).

Cuadro 12

Correlación de Pearson entre el rendimiento y las medias de los índices de vegetación

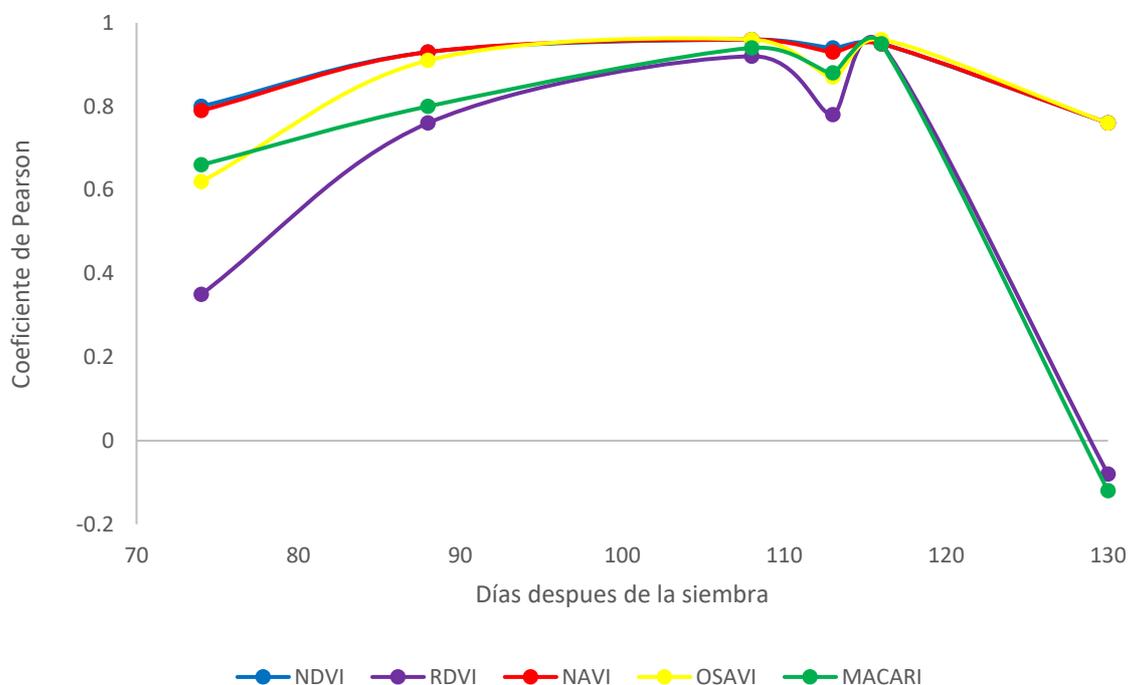
Número de vuelo	DDS	Índices de Vegetación				
		NDVI	RDVI	NAVI	OSAVI	MCARI2
3	74	0.80*	0.35	0.79*	0.62	0.66
8	88	0.93*	0.76*	0.93*	0.91*	0.80*
10	108	0.96*	0.92*	0.96*	0.96*	0.94*
12	113	0.94*	0.78*	0.93*	0.87*	0.88*
13	116	0.95*	0.95*	0.95*	0.96*	0.95*
15	130	0.76*	-0.08	0.76*	0.76*	-0.12

Nota. *p<0.05, DDS: días después de siembra. NDVI: Índice de vegetación de diferencia normalizada. RDVI: Índice de vegetación de diferencia Renormalizada. NAVI: Índice de Vegetación de Área Normalizada. OSAVI: Índice de Vegetación Optimizada al Suelo. MCARI-2: Índice de Reflectancia y Absorción de Clorofila Modificado2.

Se describe mejor la correlación entre el rendimiento y la media de los índices de vegetación en la Figura 8. Se puede observar como NDVI, NAVI presentan una excelente correlación en la distribución temporal del cultivo. El índice OSAVI se observa que mejora su correlación para el día 88 después de siembra y se mantiene relativamente constante con NDVI y NAVI. En tanto que RDVI y MCARI-2 solo logran una buena correlación a los 108 y 116 DDS, bajando notablemente entorno a los 130 DDS. Se puede analizar como NDVI, OSAVI y NAVI estarían fuertemente correlacionados con la severidad a los 88DDS lo que demostraría la incidencia de la MA y el síntoma ojo de pescado, además de estar correlacionados a los 116 y 118 DDS donde el cultivo alcanzó su madurez fisiológica.

Figura 8

Correlograma entre el rendimiento y las medias de los IV



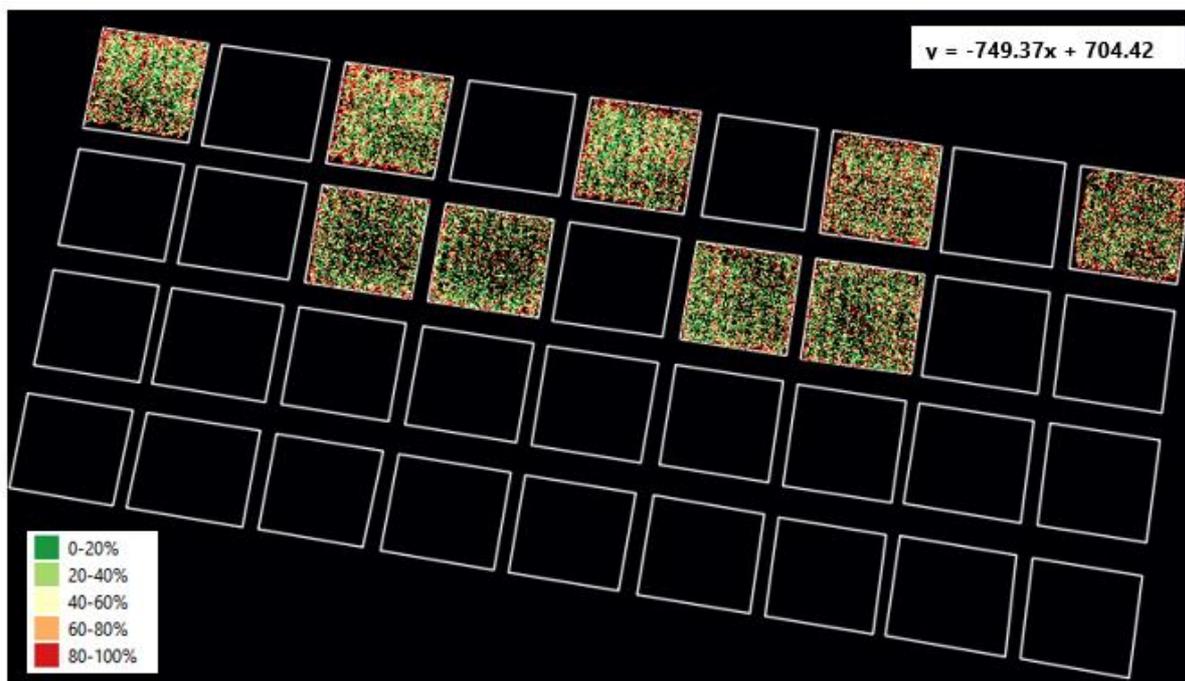
Mapa de Severidad de la Mancha de Asfalto en NDVI

Se procedió a realizar un mapa de severidad de la MA, generando una regresión lineal simple entre la media de NDVI y la severidad en el dosel intermedio a los 88 DDS en el genotipo DK390RR de las parcelas sin fungicida (Figura 9). NAVI fue superior a NDVI con una correlación de -0.81, sin embargo, se seleccionó NDVI al ser un índice ampliamente discutido y obtener también una alta correlación de -0.80. La ecuación quedó definida por la variable independiente (media de NDVI) y la variable dependiente (severidad) (Ecuación 6) y con un valor de R^2 de 0.6381, lo que indica que el NDVI estaría explicando en un 64% la mancha de asfalto.

$$y = -749.37(NDVI) + 704.42 [6]$$

Figura 9

Mapa de la severidad de la MA en NDVI en las parcelas DK390RR sin fungicida a los 88 DDS



En la Figura 9 se analizó como la severidad de la MA estuvo ubicada en el lado Norte de la parcela a los 88 DDS. Además, se puede observar que las subparcelas que estuvieron en los extremos presentaron más severidad que las que estuvieron al centro de la parcela. También se observa que las subparcelas presentaron más severidad en el lado Oeste. Se puede observar mejor esta distribución en el Anexo F de la subparcela número 1. Esta distribución puede deberse al método de inoculación que se llevó a cabo, a la dirección del aire, la temperatura y la concentración de humedad que pudo haber existido en el lugar, que influenciaron a que la MA se distribuyera de esa forma. Aún deben hacerse mayores estudios para verificar esto.

El análisis de la Figura 9, demuestra que el método de inoculación de las barreras posiblemente influenció en las subparcelas, ya que los extremos presentaron mayor severidad que en el centro. El ciclo de enfermedad no se comprende totalmente (Valle-Torres et al., 2020), sin embargo, dado la naturaleza de *P. maydi* posiblemente la enfermedad se dispersó de los extremos al centro, en

una dirección de Norte a Sur y de Oeste a Este. Esta distribución puede atribuirse a la liberación de las ascosporas que son dispersadas ya sea por viento o por lluvia, tal como lo indica Hock et al. (1992).

Índices de Vegetación y Mancha de Asfalto

NDVI y Mancha de Asfalto

La correlación más alta en NDVI se obtuvo en el dosel superior a los 88 DDS con un valor del coeficiente de Pearson de -0.89, resultados similares a los reportados por Oh et al. (2021) en su estudio de la MA utilizando datos de aeronaves no tripuladas (UAS). Varios estudios han demostrado que el NDVI, es de moderado a muy preciso para distinguir los diferentes niveles de gravedad de las enfermedades del maíz, trigo y plagas de insectos, estos incluyeron la roya de la hoja, la roya rayada del trigo y la plaga del sol (Abd El-Ghany et al., 2020; Franke y Menz, 2007; Genc et al., 2008; Pretorius et al., 2017; Rodrigues et al., 2017). NDVI ha demostrado tener altas correlaciones en el fenotipado de la MA (Oh et al., 2021) y ser un índice ideal en el modelamiento de tiempo para la estimación precisa de las distintas etapas de crecimiento del maíz (Yu et al., 2012).

El NDVI también ha sido utilizado para caracterizar enfermedades. La temporalidad del hongo *Fusarium moniliforme* en México, en diferentes etapas de desarrollo del cultivo de trigo (etapa de arranque, floración y llenado de grano), siendo este muy prometedor para detectar problemas patológicos (Limón Ortega et al., 2016). En el arroz el NDVI ha demostrado buenos resultados en la detección del Tizón bacteriano *Xanthomonas oryzae* (Giamerti et al., 2021). El NDVI utiliza la región del NIR que está relacionado con la estructura de la hoja, varios estudios (Yang et al., 2010; M. Zhang et al., 2003; D. Zhang et al., 2018) informaron que el NIR era la región más sensible del espectro en la detección de tizón tardío del tomate y tizón de la hoja del arroz. La región del NIR también se ha correlacionado significativamente con el índice de enfermedad del mildiú polvoroso del trigo (Cao et al., 2013) , por lo que, esta región es susceptible en la detección de enfermedades.

El NDVI también utiliza la región visible del Red, esta región y la región del Red Edge podría cambiar y ser sensible a enfermedades en plantas (West et al., 2003), aunque se han utilizado comúnmente como indicadores de estrés (DeJonge et al., 2016; Helmi y Nasrulhapiza, 2009). La región visible del Red también ha servido para detectar la gravedad de la mancha gris en el maíz, producida por el hongo *Cercospora zea-maydis*, como lo indica en su estudio (Dhau et al., 2018) quien discriminó en tres etapas la severidad (saludable, moderada y severa) durante dos estaciones, utilizando el NDVI y evaluando concretamente las regiones del rojo y del borde rojo del espectro electromagnético.

Loladze et al. (2019) también utilizó el NDVI en su caracterización de la MA, sin embargo, solo logró excelentes relaciones con el índice MCARI-2. En nuestro estudio este índice no presentó la mejor correlación, pero si una buena discriminación visual. La diferencia puede ser atribuida a las características del estudio y la diferencia metodológica en el procesamiento de los datos, además que Loladze et al. (2019) modificó el índice MCARI-2 al realizar un ajuste del suelo, cambiando la Ecuación 5 descrita en la metodología, lo que supondría un valor alto en la correlación.

Entender el ciclo de la enfermedad de la MA en las distintas etapas fenológicas del maíz es importante, sin embargo, pocos estudios han centrado su atención a la temporalidad de la MA, por lo que aún no se ha logrado comprender su interacción (Valle-Torres et al., 2020). Nuestro estudio sería el primer acercamiento a la caracterización de la MA en zonas tropicales y bajo las condiciones controladas de este estudio. Existen alternativas como los fungicidas para manejar la enfermedad, sin embargo, las condiciones y el momento de una o más aplicaciones en las distintas etapas fenológicas para una mejor protección y control no están completamente establecidos por la falta de investigación sobre la biología, ecología y epidemiología de *P. maydis* (Telenko et al., 2020). Baio et al. (2018) demostraron el potencial que tendría NDVI para estimar las tasas de aplicación de productos fitosanitarios, obteniendo correlaciones positivas con la deposición de aspersion en el dosel medio de las plantas de maíz.

NAVI y la Mancha de Asfalto

Nuestra correlación más alta en NAVI se obtuvo en el dosel intermedio a los 88 DDS con un valor del coeficiente de Pearson de -0.81. Bohn et al. (2018) en su estudio para el modelado del contenido de clorofila de una laguna, trabajo con el índice NAVI y NDVI. Sus resultados indicaron que NDVI obtuvo mejores correlaciones que NAVI. En nuestro estudio NAVI presentó una mejor correlación en el dosel medio que NDVI, sin embargo, NDVI también resultó ser bastante cercano en las correlaciones y el comportamiento de NAVI. El índice NAVI estima el contenido de clorofila (Chl) que es uno de los parámetros de la vegetación de mayor importancia. El estudio del Chl en la hoja es de gran interés en la agricultura de precisión, ya que es un indicador de la actividad fotosintética, y por lo tanto está relacionado con el estado fenológico y la salud de las plantas (Carmona et al., 2015).

La clorofila absorbe sobre todo la luz roja, violeta y azul, y refleja la verde. La luz roja es la de mayor eficacia para la fotosíntesis, ya que el espectro de absorción de la clorofila es más amplio en la zona del rojo. En cambio la luz verde carece de acción sobre este proceso (Arelis González et al., 2014). La importancia de la clorofila en las plantas radica en que es un factor importante en el proceso de la fotosíntesis. La clorofila convierte la energía solar en energía química, por lo que, el contenido de clorofila está directamente relacionado con el crecimiento y el rendimiento de los cultivos (Tahir M. et al., 2018).

No existen muchos estudios que utilicen el índice NAVI, salvo el ya citado, para describir alguna enfermedad o crecimiento vegetativo. El presente estudio es el primero en utilizar el índice NAVI y en demostrar la posible viabilidad que tendría este índice en fenotipar la MA y las distintas etapas fenológicas del maíz.

Conclusiones

Los índices de vegetación derivados de imágenes multiespectrales tienen el potencial de evaluar la severidad de la mancha de asfalto en zonas tropicales. El índice NDVI y NAVI, de una serie de 5 índices, demostraron ser efectivos en evaluar la dinámica temporal de la Mancha de Asfalto en distintas etapas fenológicas y estar correlacionado en las etapas tempranas del crecimiento de la mazorca (R1-R2), donde hubo la presencia del síntoma ojo de pescado. Este estudio sería el primer acercamiento a la caracterización de la MA en zonas tropicales y bajo las condiciones controladas de este estudio utilizando NDVI. Además, en ser el primero en utilizar el índice NAVI y en demostrar la posible viabilidad que tendría este índice en fenotipar la MA y las distintas etapas fenológicas del maíz.

Todos los índices presentaron una adecuada visualización de la evolución de parcela con MA dependiendo de los rangos escogidos para su visualización. MCARI-2 fue ligeramente mejor en la visualización de la distribución de las parcelas con y sin fungicida, y posiblemente el avance de la enfermedad de la MA y su posterior senescencia. Esto podría ser atribuido a que la ecuación incorpora un factor de ajuste del suelo, lo que lo hace más sensible a la concentración e influencia de clorofila en las hojas. Sin embargo, sus correlaciones fueron bajas en etapas tempranas de la enfermedad, aunque presentó una alta correlación a los 116 DDS con un valor de -0.77 en el dosel intermedio.

El NDVI describiría un mejor comportamiento de la enfermedad de la MA y de las distintas etapas fenológicas del maíz al ser un índice ampliamente estudiado que el NAVI. Sin embargo, NAVI también demuestra ser efectivo en la caracterización de la MA y las distintas etapas fenológicas del maíz. Más estudios podrían ayudar a discutir la viabilidad de este índice.

La evolución de la MA utilizando NDVI, en el genotipo DK390RR de las parcelas sin fungicida a los 88 DDS (etapa fenológica R2), fue de Norte a Sur y de Oeste a Este. Los extremos de la parcela se vieron más afectados que el centro, sugiriendo un crecimiento de la enfermedad de la MA de afuera hacia adentro. Los factores climáticos y la ubicación del inóculo primario influyeron en la distribución espacial de la enfermedad.

Recomendaciones

Realizar más análisis de los índices de vegetación en la evolución de la MA para validar los resultados obtenidos en este estudio. Otros índices de vegetación que empleen imágenes espectrales térmicas podrían caracterizar la evolución de la MA a nivel de temperatura, generando otro enfoque de la enfermedad.

En futuros estudios podría realizarse un cambio en la ecuación del índice MCARI-2 para mejorar su ajuste al suelo y elevar altamente las correlaciones. Este cambio ayudaría a reducir el ruido del suelo generado por la reflectancia, lo que nos permitiría obtener una mejor caracterización.

Las campañas de severidad y la toma de imágenes espectrales deberían estar sincronizadas para tener una mejor descripción de la evolución de la enfermedad de la MA. Esto ayudaría a generar una distribución más ajustada de la enfermedad, además de elevar nuestras correlaciones.

Las imágenes espectrales de los vuelos deberían ser tratadas previamente al fin de evitar errores en el procesamiento digital de los datos. Un procesamiento adecuado mejoraría la calidad de las imágenes, lo cual permitiría una caracterización más detallada.

Referencias

- Abd El-Ghany, N. M., Abd El-Aziz, S. E. y Marei, S. S. (2020). A review: Application of remote sensing as a promising strategy for insect pests and diseases management. *Environmental Science and Pollution Research*, 27(27), 33503–33515. <https://doi.org/10.1007/s11356-020-09517-2>
- Abendroth, L. J., Elmore, R. W., Boyer, M. J. y Marlay, S. K. (2011). *Corn Growth and Development* (PMR 1009). https://www.researchgate.net/publication/280092215_In_Corn_Growth_and_Development
- Alface, A. B., Pereira, S. B., Filgueiras, R. y Cunha, F. F. (2019). Sugarcane spatial-temporal monitoring and crop coefficient estimation through NDVI. *Revista Brasileira De Engenharia Agrícola E Ambiental*, 23(5), 330–335. <https://doi.org/10.1590/1807-1929/agriambi.v23n5p330-335>
- Arelis González, Henry Briceño, José Chirinos, Renzo Buonocore y Ángel Villarreal (2014). Variación de la concentración de clorofila a, b, clorofila total y tasa de fotosíntesis en *Avicennia germinans* en el manglar de Punta de Palmas, municipio Miranda, estado Zulia, Venezuela. *Revista Investigaciones Científicas UNERMB*, 5(1-2), 67–82. http://150.185.9.18/fondo_editorial/images/pdf/ric/enero%20%20diciembre%20vol%205%202014.pdf#page=67
- Atanassova, S., Nikolov, P., Valchev, N., Masheva, S. y Yorgov, D. (2019). Early detection of powdery mildew (*Podosphaera xanthii*) on cucumber leaves based on visible and near-infrared spectroscopy. *AIP Conference Proceedings*, 2075(1), 160014. <https://doi.org/10.1063/1.5091341>
- Badura, G. P., Bachmann, C. M., Tyler, A. C., Goldsmith, S., Eon, R. S. y Lapszynski, C. S. (2019). A Novel Approach for Deriving LAI of Salt Marsh Vegetation Using Structure From Motion and Multiangular Spectra. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(2), 599–613. <https://doi.org/10.1109/JSTARS.2018.2889476>
- Baio, F. H. R., Silva, E. E., Vrech, M. A., Souza, F. H. Q., Zanin, A. R. y Teodoro, P. E. (2018). Vegetation Indices to Estimate Spray Application Rates of Crop Protection Products in Corn. *Agronomy Journal*, 110(4), 1254–1259. <https://doi.org/10.2134/agronj2017.12.0718>
- Bajet, N. B., Renfro, B. L. y Carrasco, J. M. V. (1994). Control of tar spot of maize and its effect on yield. *International Journal of Pest Management*, 40(2), 121–125. <https://doi.org/10.1080/09670879409371868>
- Baldos, U. L. C. y Hertel, T. W. (2014). Global food security in 2050: The role of agricultural productivity and climate change. *Australian Journal of Agricultural and Resource Economics*, 58(4), 554–570. <https://doi.org/10.1111/1467-8489.12048>

- Bin Abdul Rahim, H. R., Bin Lokman, M. Q., Harun, S. W., Hornyak, G. L., Sterckx, K., Mohammed, W. S. y Dutta, J. (2016). Applied light-side coupling with optimized spiral-patterned zinc oxide nanorod coatings for multiple optical channel alcohol vapor sensing. *Journal of Nanophotonics*, 10(3), 36009. <https://doi.org/10.1117/1.JNP.10.036009>
- Bock, C. H., Poole, G. H., Parker, P. E. y Gottwald, T. R. (2010). Plant Disease Severity Estimated Visually, by Digital Photography and Image Analysis, and by Hyperspectral Imaging. *Critical Reviews in Plant Sciences*, 29(2), 59–107. <https://doi.org/10.1080/07352681003617285>
- Bohn, V. Y., Carmona, F., Rivas, R., Lagomarsino, L., Diovisalvi, N. y Zagarese, H. E. (2018). Development of an empirical model for chlorophyll-a and Secchi Disk Depth estimation for a Pampean shallow lake (Argentina). *The Egyptian Journal of Remote Sensing and Space Science*, 21(2), 183–191. <https://doi.org/10.1016/j.ejrs.2017.04.005>
- Campbell, J. B. (1987). Introduction to remote sensing. *Geocarto International*, 2(4), 64. <https://doi.org/10.1080/10106048709354126>
- Cao, X., Luo, Y., Zhou, Y., Duan, X. y Cheng, D. (2013). Detection of powdery mildew in two winter wheat cultivars using canopy hyperspectral reflectance. *Crop Protection*, 45, 124–131. <https://doi.org/10.1016/j.cropro.2012.12.002>
- Carmona, F., Rivas, R. y Fonnegra, D. C. (2015). Vegetation Index to estimate chlorophyll content from multispectral remote sensing data. *European Journal of Remote Sensing*, 48(1), 319–326. <https://doi.org/10.5721/EuJRS20154818>
- Castaño Z., J. y Del Mendoza., L. R. (1994). *Guía para el diagnostico y control de enfermedades en cultivos de importancia economica* (3ª ed.). Zamorano Academic Press. <https://bdigital.zamorano.edu/handle/11036/3928>
- Ceballos, H. y Deutsch, J. A. (1992). Inheritance of Resistance to Tar Spot Complex in Maize. *Phytopathology*, 82(5), 505. <https://doi.org/10.1094/Phyto-82-505>
- Centro Internacional de Mejoramiento de Maíz y Trigo. (1995). *Manejo de los ensayos e informe de los datos para el Programa de Ensayos Internacionales de Maíz del CIMMYT*. México, D.F. CIMMYT. <https://repository.cimmyt.org/handle/10883/764>
- Centro Internacional de Mejoramiento de Maíz y Trigo. (2003). *Maize Diseases: A guide for field identification* (4ª ed.). *International Maize and Wheat Improvement Center*. CIMMYT. <https://afghanag.ucdavis.edu/grain-field-crops/files/maize-diseases.pdf>
- Claassen, M. M. y Shaw, R. H. (1970). Water Deficit Effects on Corn. Ii. Grain Components 1. *Agronomy Journal*, 62(5), 652–655. <https://doi.org/10.2134/agronj1970.00021962006200050032x>
- Dagnino, J. (2014). Coeficiente de correlacion lineal de pearson. *Chil Anest*, 43, 150–153. http://www.sachile.cl/upfiles/revistas/54e63a1a778ff_15_correlacion-2-2014_edit.pdf

- Dalla Lana, F., Plewa, D. E., Phillippi, E. S., Garzonio, D., Hesterman, R., Kleczewski, N. M. y Paul, P. A. (2019). First Report of Tar Spot of Maize (*Zea mays*), Caused by *Phyllachora maydis* in Ohio. *Plant Disease*, 103(7), 1780. <https://doi.org/10.1094/PDIS-01-19-0070-PDN>
- DeJonge, K. C., Mefford, B. S. y Chávez, J. L. (2016). Assessing corn water stress using spectral reflectance. *International Journal of Remote Sensing*, 37(10), 2294–2312. <https://doi.org/10.1080/01431161.2016.1171929>
- Derlagen, C., Paolo De Salvo, C., Egas, J. y Guillaume, P. (2019). *Análisis de políticas agropecuarias en Honduras*. BID. https://publications.iadb.org/publications/spanish/document/An%C3%A1lisis_de_pol%C3%ADticas_agropecuarias_en_Honduras.pdf
- Dhau, I., Adam, E., Mutanga, O., Ayisi, K., Abdel-Rahman, E. M., Odindi, J. y Masocha, M. (2018). Testing the capability of spectral resolution of the new multispectral sensors on detecting the severity of grey leaf spot disease in maize crop. *Geocarto International*, 33(11), 1223–1236. <https://doi.org/10.1080/10106049.2017.1343391>
- Díaz, P. y Fernández, P. (2002). *Determinación del tamaño muestral para calcular la significación del coeficiente de correlación lineal*. A Coruña. Unidad de Epidemiología Clínica y Bioestadística. <http://www.fisterra.com/mbe/investiga/pearson/pearson2.pdf>
- Eash, L., Fonte, S. J., Sonder, K [K.], Honsdorf, N., Schmidt, A., Govaerts, B. y Verhulst, N. (2019). Factors contributing to maize and bean yield gaps in Central America vary with site and agroecological conditions. *The Journal of Agricultural Science*, 157(04), 300–317. <https://doi.org/10.1017/S0021859619000571>
- Franceschini, M. H. D., Bartholomeus, H., van Apeldoorn, D. F., Suomalainen, J. y Kooistra, L. (2019). Feasibility of Unmanned Aerial Vehicle Optical Imagery for Early Detection and Severity Assessment of Late Blight in Potato. *Remote Sensing*, 11(3), 224. <https://doi.org/10.3390/rs11030224>
- Franke, J. y Menz, G. (2007). Multi-temporal wheat disease detection by multi-spectral remote sensing. *Precision Agriculture*, 8(3), 161–172. <https://doi.org/10.1007/s11119-007-9036-y>
- Gallo, K. P. y Flesch, T. K. (1989). Large-area crop monitoring with the NOAA AVHRR: Estimating the silking stage of corn development. *Remote Sensing of Environment*, 27(1), 73–80. [https://doi.org/10.1016/0034-4257\(89\)90038-2](https://doi.org/10.1016/0034-4257(89)90038-2)
- Genc, H., Genc, L., Turhan, H., Smith, S. E. y Nation, J. L. (2008). Vegetation indices as indicators of damage by the sunn pest (Hemiptera: Scutelleridae) to field grown wheat. *African Journal of Biotechnology*, 7(2). <https://doi.org/10.4314/ajb.v7i2.58347>
- Giamerti, Y., Hongo, C., Saito, D., Caasi, O., Nur Susilawati, P., Shishido, M., Sudiarta, I. P., Sutrisna Wijaya, I. M. A. y Homma, K. (2021). Evaluating Multispectral Imaging for Assessing Bacterial

Leaf Blight Damage in Indonesian Agricultural Insurance. *E3S Web of Conferences*, 232, 3008. <https://doi.org/10.1051/e3sconf/202123203008>

Gilabert, M. A., González Piqueras, J. y García-Haro, F. J. (1997). Acerca de los índices de vegetación. *Revista De Teledeteccion*, 8. https://www.researchgate.net/publication/39195330_Acerca_de_los_indices_de_vegetacion

Haboudane, D., Miller, J. R., Pattey, E., Zarco-Tejada, P. J. y Strachan, I. B. (2004). Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90(3), 337–352. <https://doi.org/10.1016/j.rse.2003.12.013>

Harvey, C. A., Saborio-Rodríguez, M., Martínez-Rodríguez, M. R., Viguera, B., Chain-Guadarrama, A., Vignola, R. y Alpizar, F. (2018). Climate change impacts and adaptation among smallholder farmers in Central America. *Agriculture & Food Security*, 7(1), 1–20. <https://doi.org/10.1186/s40066-018-0209-x>

Heim, R. H. J., Carnegie, A. J. y Zarco-Tejada, P. J. (2019). Breaking down barriers between remote sensing and plant pathology. *Tropical Plant Pathology*, 44(4), 398–400. <https://doi.org/10.1007/s40858-019-00300-4>

Helmi, M. S. y Nasrulhapiza, H. (2009). Hyperspectral imagery for mapping disease infection in oil palm plantation using vegetation indices and red edge techniques. *American Journal of Applied Sciences*, 6(6), 1031–1035.

Hengsdijk, H. y Langeveld, J. (2009). *Yield trends and yield gap analysis of major crops in the world* (núm. 170). Wageningen. Wettelijke Onderzoekstaken Natuur & Milieu. <https://library.wur.nl/WebQuery/wurpubs/fulltext/137509>

Herrero, M. P. y Johnson, R. R. (1980). High Temperature Stress and Pollen Viability of Maize 1. *Crop Science*, 20(6), 796–800. <https://doi.org/10.2135/cropsci1980.0011183X002000060030x>

Hock, J., Dittrich, U., Renfro, B. L. y Kranz, J. (1992). Sequential development of pathogens in the maize tar spot disease complex. *Mycopathologia*, 117(3), 157–161. <https://doi.org/10.1007/BF00442777>

Hock, J., Kranz, J. y Renfro, B. (1989). El complejo “mancha de asfalto” de maíz: Su distribución geográfica, condiciones ambientales e importancia económica en México. *Rev. Mex. Fitopatol*, 7, 129–135. <http://www.sidalc.net/cgi-bin/wxis.exe/?IsisScript=CIMMYT.xis&method=post&formato=2&cantidad=1&expresion=mn=004322>

Hock, J., Kranz, J. y Renfro, B. L. (1995). Studies on the epidemiology of the tar spot disease complex of maize in Mexico. *Plant Pathology*, 44(3), 490–502. <https://doi.org/10.1111/j.1365-3059.1995.tb01671.x>

- Instituto Nacional de Estadística Honduras. (2018). *Comportamiento de las importaciones del maíz 2013-2017*. Honduras. INE. <https://www.ine.gob.hn/V3/imag-doc/2019/06/Boletin-Maiz.pdf>
- Jackson, R. D., Slater, P. N. y Pinter, P. J. (1983). Discrimination of growth and water stress in wheat by various vegetation indices through clear and turbid atmospheres. *Remote Sensing of Environment*, 13(3), 187–208. [https://doi.org/10.1016/0034-4257\(83\)90039-1](https://doi.org/10.1016/0034-4257(83)90039-1)
- Jiang, H. L., Yang H., Chen X.P., Wang SD., Li X.K., Liu K. y Cen Y. (2015). Research on accuracy and stability of inverting vegetation chlorophyll content by spectral index method. *Guang Pu Xue Yu Guang Pu Fen Xi = Guang Pu*, 35(4), 975–981. <https://europemc.org/article/med/26197586>
- Kovács, P. y Vyn, T. J. (2017). Relationships between Ear-Leaf Nutrient Concentrations at Silking and Corn Biomass and Grain Yields at Maturity. *Agronomy Journal*, 109(6), 2898–2906. <https://doi.org/10.2134/agronj2017.02.0119>
- Kuska, M., Wahabzada, M [Mirwaes], Leucker, M., Dehne, H.-W., Kersting, K [Kristian], Oerke, E.-C., Steiner, U. y Mahlein, A.-K [Anne-Katrin] (2015). Hyperspectral phenotyping on the microscopic scale: Towards automated characterization of plant-pathogen interactions. *Plant Methods*, 11(1), 28. <https://doi.org/10.1186/s13007-015-0073-7>
- Limón Ortega, A., Pelaez Cruz, D., Leyva Mir, G. y Espinosa Barreto, C. (2016). *Effect of the dose of N in the incidence of Fusarium spp. in wheat roots under permanent beds*. http://www.scielo.org.mx/scielo.php?pid=S2007-09342016000501155&script=sci_arttext&lng=en
- Loladze, A [Alexander], Rodrigues, F. A [Francelino Augusto], Toledo, F., San Vicente, F [Felix], Gérard, B [Bruno] y Boddupalli, M. P. (2019). Application of Remote Sensing for Phenotyping Tar Spot Complex Resistance in Maize. *Frontiers in Plant Science*, 10, 552. <https://doi.org/10.3389/fpls.2019.00552>
- Mahlein, A.-K [A.-K.], Kuska, M. T., Thomas, S., Bohnenkamp, D., Alisaac, E., Behmann, J., Wahabzada, M [M.] y Kersting, K [K.] (2017). Plant disease detection by hyperspectral imaging: from the lab to the field. *Advances in Animal Biosciences*, 8(2), 238–243. <https://doi.org/10.1017/S2040470017001248>
- Mahlein, A.-K [Anne-Katrin] (2016). Plant Disease Detection by Imaging Sensors - Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping. *Plant Disease*, 100(2), 241–251. <https://doi.org/10.1094/PDIS-03-15-0340-FE>
- Malvick, D. K., Plewa, D. E., Lara, D., Kleczewski, N. M., Floyd, C. M. y Arenz, B. E. (2020). First Report of Tar Spot of Corn Caused by *Phyllachora maydis* in Minnesota. *Plant Disease*, 104(6), 1865. <https://doi.org/10.1094/PDIS-10-19-2167-PDN>
- Martinez, E. L. y Fernandez, F. J. B. (2019). Economics of Production, Marketing and Utilization. En S. R. O. Serna Saldívar (Ed.), *Corn: Chemistry and technology / edited by Sergio O. Serna-Saldivar*

- (3ª ed., pp. 87–107). Woodhead Publishing. <https://doi.org/10.1016/B978-0-12-811971-6.00004-8>
- Martínez-Barbáchano, R. y Solís-Miranda, G. A. (2018). Caracterización Espectral y Detección de Flecha Seca en Palma Africana en Puntarenas, Costa Rica. *Revista Geográfica De América Central*, 2(61), 329. <https://doi.org/10.15359/rgac.61-2.13>
- Matsushita, B., Yang, W., Chen, J., Onda, Y. y Qiu, G. (2007). Sensitivity of the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI) to Topographic Effects: A Case Study in High-density Cypress Forest. *Sensors (Basel, Switzerland)*, 7(11), 2636–2651. <https://doi.org/10.3390/s7112636>
- Maublanc, A. (1904). Espèces nouvelles de champignons inférieurs. *Bulletin Société Mycologie France*, 20, 72–74. <https://ci.nii.ac.jp/naid/10011578887/>
- McCoy, A. G., Roth, M. G., Shay, R., Noel, Z. A., Jayawardana, M. A., Longley, R. W., Bonito, G. y Chilvers, M. I. (2019). Identification of Fungal Communities Within the Tar Spot Complex of Corn in Michigan via Next-Generation Sequencing. *Phytobiomes Journal*, 3(3), 235–243. <https://doi.org/10.1094/PBIOMES-03-19-0017-R>
- Mottaleb, K. A., Loladze, A [Alexander], Sonder, K [Kai], Kruseman, G. y San Vicente, F [Felix] (2019). Threats of Tar Spot Complex disease of maize in the United States of America and its global consequences. *Mitigation and Adaptation Strategies for Global Change*, 24(2), 281–300. <https://doi.org/10.1007/s11027-018-9812-1>
- Nielsen, R. L. (2019). *Grain Fill Stages in Corn (Purdue University)*. Corny News Network. <https://www.agry.purdue.edu/ext/corn/news/timeless/GrainFill.html>
- Nielsen, R. L. (2021). *Grain Fill Stages in Corn*. Purdue University. Corny News Network. <https://www.agry.purdue.edu/ext/corn/news/timeless/GrainFill.html>
- Nleya, T., Chungu, C. y Kleinjan, J. (2016). Chapter 5: Corn growth and development. En *iGrow Corn: Best Management Practices* (pp. 5–8). https://www.researchgate.net/publication/331683778_Corn_Growth_and_Development
- Nutter, F. W., Esker, P. D. y Netto, R. A. C. (2006). Disease Assessment Concepts and the Advancements Made in Improving the Accuracy and Precision of Plant Disease Data. *European Journal of Plant Pathology*, 115(1), 95–103. <https://doi.org/10.1007/s10658-005-1230-z>
- Oh, S., Lee, D.-Y., Gongora-Canul, C [Carlos], Ashapure, A., Carpenter, J., Cruz, A. P., Fernandez-Campos, M., Lane, B. Z., Telenko, D. E. P [Darcy E. P.], Jung, J. y Cruz, C. D. (2021). Tar Spot Disease Quantification Using Unmanned Aircraft Systems (UAS) Data. *Remote Sensing*, 13(13), 2567. <https://doi.org/10.3390/rs13132567>

- Pantazi, X.-E., Moshou, D. y Bravo, C. (2016). Active learning system for weed species recognition based on hyperspectral sensing. *Biosystems Engineering*, 146, 193–202. <https://doi.org/10.1016/j.biosystemseng.2016.01.014>
- Parker, S. R., Shaw, M. W. y Royle, D. J. (1995). The reliability of visual estimates of disease severity on cereal leaves. *Plant Pathology*, 44(5), 856–864. <https://doi.org/10.1111/j.1365-3059.1995.tb02745.x>
- Pereyda-Hernández, J., Hernández-Morales, J., Sandoval-Islas, J. S., Aranda-Ocampo, S., León, C. de y Gómez-Montiel, N. (2009). Etiología y manejo de la mancha de asfalto (*Phyllachora maydis* Maubl.) del maíz en Guerrero, México. *Agrociencia*, 43(5), 511–519.
- Pettorelli, N. (2013). Vegetation indices. En N. Pettorelli (Ed.), *Normalized Difference Vegetation Index*. Oxford University Press. <https://doi.org/10.1093/acprof:osobl/9780199693160.003.0002>
- Polder, G., Blok, P. M., Villiers, H. A. C. de, van der Wolf, J. M. y Kamp, J. (2019). Potato Virus Y Detection in Seed Potatoes Using Deep Learning on Hyperspectral Images. *Frontiers in Plant Science*, 10, 209. <https://doi.org/10.3389/fpls.2019.00209>
- Pretorius, Z. A., Lan, C. X., Prins, R., Knight, V., McLaren, N. W., Singh, R. P., Bender, C. M. y Kloppers, F. J. (2017). Application of remote sensing to identify adult plant resistance loci to stripe rust in two bread wheat mapping populations. *Precision Agriculture*, 18(4), 411–428. <https://doi.org/10.1007/s11119-016-9461-x>
- Puerto, C [Carlos]. (2020). *Caracterización de la mancha de asfalto en maíz (Zea mays L.) mediante el uso de herramientas de detección y control en condiciones de campo* [Tesis de maestría no publicada]. Escuela Agrícola Panamericana, Zamorano, Honduras.
- Quiroga-Madrigal, R., Garrido-Ramírez, E., Rosales-Esquinca, M. y Salazar-Pinacho, W. (2017). *Manual técnico: Manejo integrado del complejo mancha de asfalto del maíz en México*. Tuxtla Gutiérrez, Chiapas, México. Universidad Autónoma de Chiapas. https://www.researchgate.net/publication/317929566_Manual_tecnico_Manejo_integrado_del_complejo_mancha_de_asfalto_del_maiz_en_Mexico
- Rodrigues, F. A [F. A.], Defourny, P., Gérard, B [B.], San Vicente, F [F.] y Loladze, A [A.] (2017). Use of remote sensing technology in the assessment of resistance of maize to tar spot complex. *Advances in Animal Biosciences*, 8(2), 259–263. <https://doi.org/10.1017/S2040470017001212>
- Rondeaux, G., Steven, M. y Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55(2), 95–107. [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)
- Roujean, J.-L. y Breon, F.-M. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3), 375–384. [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)

- Rouse, J. W., Haas, R. H., Schell, J. A. y Deering, D. W. (1973). *Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation*. Greenbelt, MD. USA. NASA/GSFC. <https://ntrs.nasa.gov/citations/19740004927>
- Ruhl, G., Romberg, M. K., Bissonnette, S., Plewa, D., Creswell, T. y Wise, K. A. (2016). First Report of Tar Spot on Corn Caused by *Phyllachora maydis* in the United States. *Plant Disease*, 100(7), 1496. <https://doi.org/10.1094/PDIS-12-15-1506-PDN>
- Senker, P. (2011). Foresight: the future of food and farming, final project report. *Prometheus*, 29(3), 309–313. <https://doi.org/10.1080/08109028.2011.628564>
- Steddom, K., Bredehoeft, M. W., Khan, M. y Rush, C. M. (2005). Comparison of Visual and Multispectral Radiometric Disease Evaluations of *Cercospora* Leaf Spot of Sugar Beet. *Plant Disease*, 89(2), 153–158. <https://doi.org/10.1094/PD-89-0153>
- Tahir M., Naqvi S., Lan Y., Zhang Y., Wang Y., Afzal M., Cheema M. J. y Amir S. (2018). Real time estimation of chlorophyll content based on vegetation indices derived from multispectral UAV in the kinnow orchard. *International Journal of Precision Agricultural Aviation*, 1(1). <https://doi.org/10.33440/j.ijpaa.20180101.0001>
- Telenko, D. E. P [Darcy E. P.], Ross, T. J [Tiffanna J.], Shim, S., Wang, Q. y Singh, R. (2020). Draft Genome Sequence Resource for *Phyllachora maydis*-An Obligate Pathogen That Causes Tar Spot of Corn with Recent Economic Impacts in the United States. *Molecular Plant-Microbe Interactions*[®], 33(7), 884–887. <https://doi.org/10.1094/MPMI-03-20-0075-A>
- United States Department Agriculture. (2020). *World Agricultural Production*. Circular Series WAP 10-20. Washington, DC, USA. United States Department of Agriculture, Foreign Agricultural Service. <https://apps.fas.usda.gov/psdonline/circulars/production.pdf>
- Valle-Torres, J., Ross, T. J [T. J.], Plewa, D., Avellaneda, M. C., Check, J., Chilvers, M. I., Cruz, A. P., Dalla Lana, F., Groves, C., Gongora-Canul, C [C.], Henriquez-Dole, L., Jamann, T., Kleczewski, N., Lipps, S., Malvick, D., McCoy, A. G., Mueller, D. S., Paul, P. A., Puerto, C [C.], . . . Cruz, C. D. (2020). Tar Spot: An Understudied Disease Threatening Corn Production in the Americas. *Plant Disease*, 104(10), 2541–2550. <https://doi.org/10.1094/PDIS-02-20-0449-FE>
- Weier, J. y Herring, D. (2000). *Measuring Vegetation (NDVI & EVI)*. NASA Earth Observatory. https://earthobservatory.nasa.gov/features/MeasuringVegetation/measuring_vegetation_1.php
- West, J. S., Bravo, C., Oberti, R., Lemaire, D., Moshou, D. y McCartney, H. A. (2003). The potential of optical canopy measurement for targeted control of field crop diseases. *Annual Review of Phytopathology*, 41, 593–614. <https://doi.org/10.1146/annurev.phyto.41.121702.103726>
- Wu, C., Niu, Z., Tang, Q. y Huang, W. (2008). Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation. *Agricultural and Forest Meteorology*, 148(8-9), 1230–1241. <https://doi.org/10.1016/j.agrformet.2008.03.005>

- Xue, J. y Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, 2017, 1–17. <https://doi.org/10.1155/2017/1353691>
- Yang, C., Everitt, J. H. y Fernandez, C. J. (2010). Comparison of airborne multispectral and hyperspectral imagery for mapping cotton root rot. *Biosystems Engineering*, 107(2), 131–139. <https://doi.org/10.1016/j.biosystemseng.2010.07.011>
- Yu, G., Di Liping, Yang, Z., Shen, Y., Chen, Z. y Zhang, B. (2012). Corn growth stage estimation using time series vegetation index. *2012 First International Conference on Agro- Geoinformatics (Agro-Geoinformatics)*, 1–6. <https://doi.org/10.1109/Agro-Geoinformatics.2012.6311631>
- Zhang, D., Zhou, X., Zhang, J., Lan, Y., Xu, C. y Liang, D. (2018). Detection of rice sheath blight using an unmanned aerial system with high-resolution color and multispectral imaging. *PLOS ONE*, 13(5), e0187470. <https://doi.org/10.1371/journal.pone.0187470>
- Zhang, M., Qin, Z., Liu, X. y Ustin, S. L. (2003). Detection of stress in tomatoes induced by late blight disease in California, USA, using hyperspectral remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 4(4), 295–310. [https://doi.org/10.1016/S0303-2434\(03\)00008-4](https://doi.org/10.1016/S0303-2434(03)00008-4)
- Zheng, Q., Huang, W., Cui, X., Shi, Y. y Liu, L. (2018). New Spectral Index for Detecting Wheat Yellow Rust Using Sentinel-2 Multispectral Imagery. *Sensors*, 18(3), 868. <https://doi.org/10.3390/s18030868>

Anexos

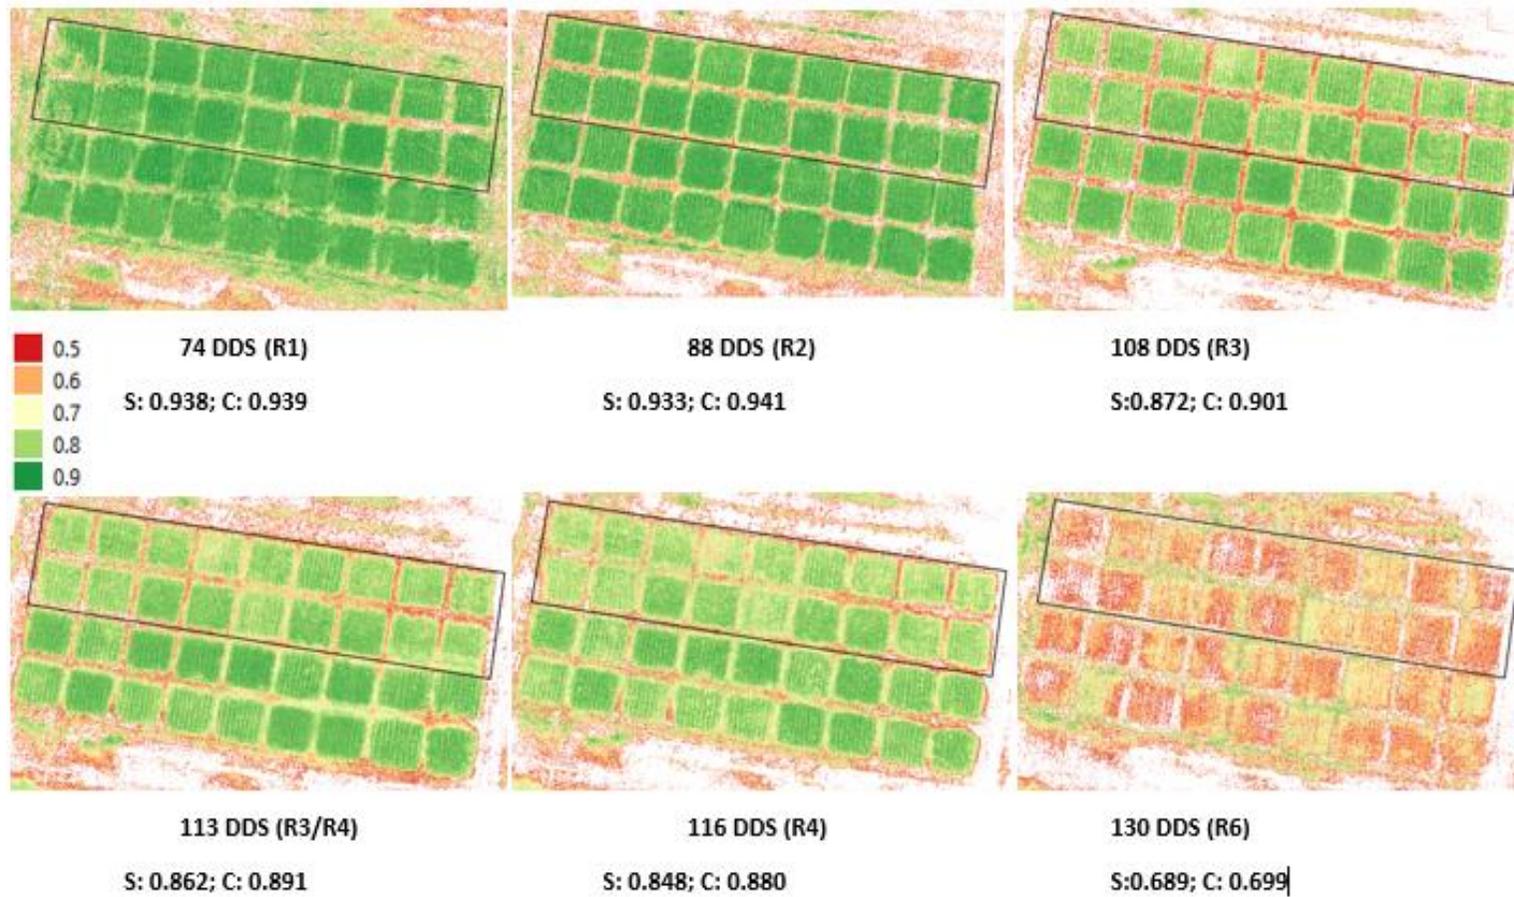
Anexo A

Distribución de los genotipos en las parcelas con y sin fungicida

Parcela	Material	Tratamiento
1	DK390	
2	DICTA96	
3	DK390	
4	DICTA96	
5	DK390	
6	DICTA96	
7	DK390	
8	DICTA96	
9	DK390	
10	DICTA96	Sin fungicida
11	DICTA96	
12	DK390	
13	DK390	
14	DICTA96	
15	DK390	
16	DK390	
17	DICTA96	
18	DICTA96	
19	DK390	
20	DICTA96	
21	DK390	
22	DK390	
23	DK390	
24	DICTA96	
25	DK390	
26	DICTA96	
27	DICTA96	
28	DK390	Con fungicida
29	DICTA96	
30	DK390	
31	DK390	
32	DICTA96	
33	DICTA96	
34	DICTA96	
35	DK390	
36	DICTA96	

Anexo B

Evolución de la parcela con MA en el índice NAVI



Nota. S: Promedio parcelas sin fungicida, C: Promedio parcelas con fungicida

Anexo C

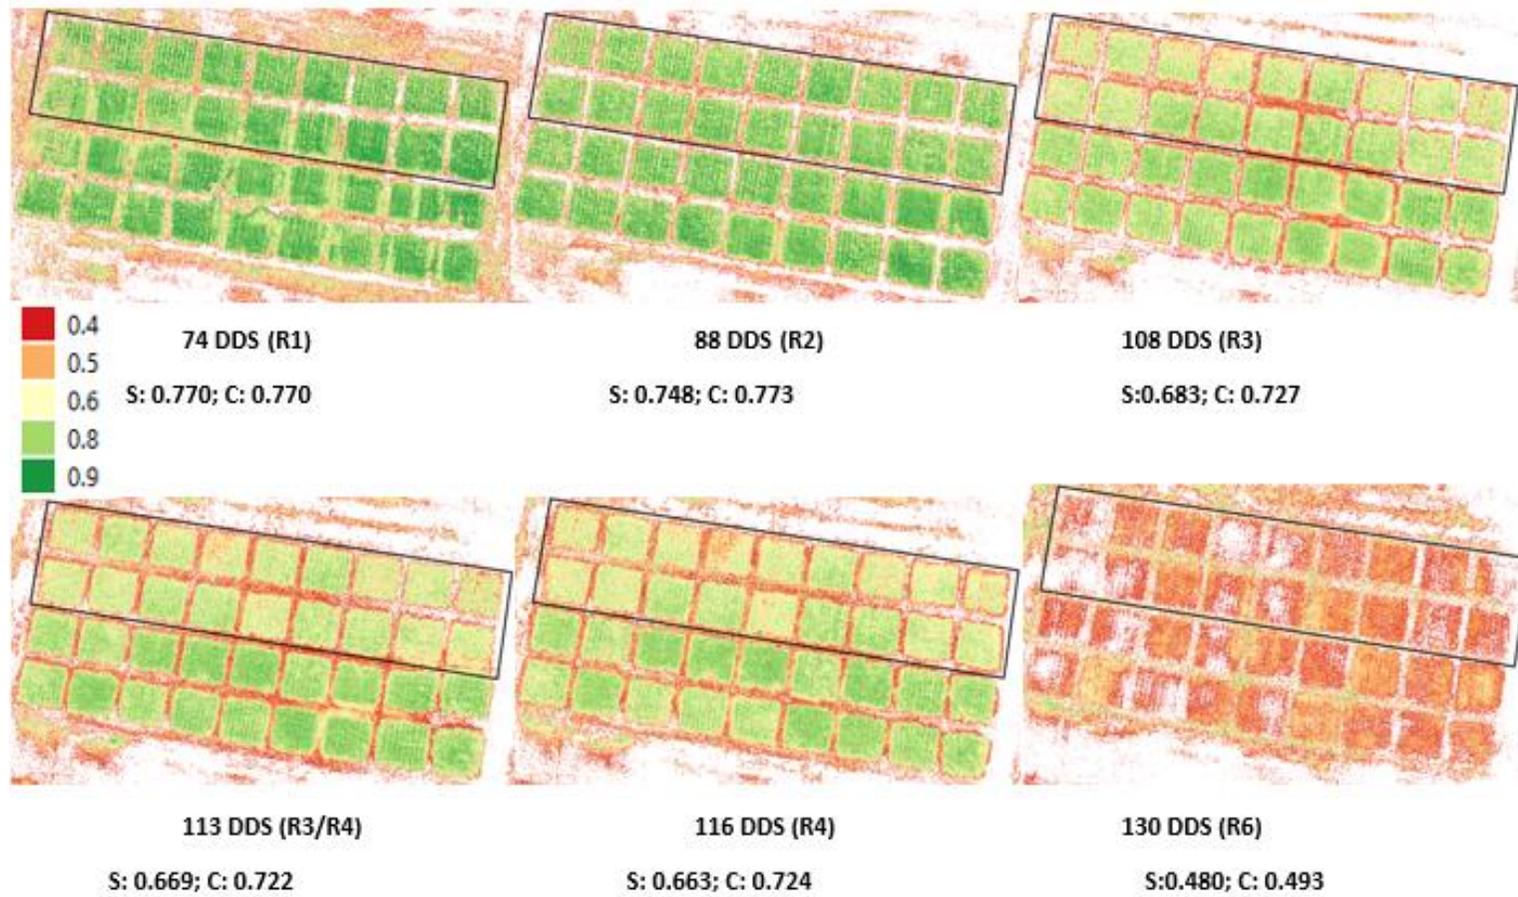
Evolución de la parcela con MA en el índice RDVI



Nota. S: Promedio parcelas sin fungicida, C: Promedio parcelas con fungicida

Anexo D

Evolución de la parcela con MA en el índice OSAVI



Nota. S: Promedio parcelas sin fungicida, C: Promedio parcelas con fungicida

Anexo E

Estadística descriptiva del índice NDVI en los 74 días después de siembra

Numero de parcela	Genotipo	Numero	Suma	Media	Mediana	Desv. est	Mín	Max	Intervalo	Minoría	Moda	Variedad	Varianza
1	DK390	816676	681940.7	0.835	0.873	0.117	0.400	0.998	0.598	0.400	0.870	751326	0.014
2	Dicta96	862384	769819.84	0.893	0.909	0.073	0.400	0.999	0.598	0.400	0.912	751098	0.005
3	DK390	860545	781125.44	0.908	0.921	0.062	0.400	0.997	0.597	0.400	0.942	738979	0.004
4	Dicta96	856176	764444.79	0.893	0.905	0.067	0.400	0.999	0.599	0.400	0.878	753978	0.004
5	DK390	890381	799690.55	0.898	0.914	0.065	0.400	0.998	0.598	0.400	0.941	765582	0.004
6	Dicta96	803334	719071.7	0.895	0.907	0.066	0.400	0.999	0.599	0.400	0.871	713565	0.004
7	DK390	868091	771907.92	0.889	0.906	0.072	0.400	0.999	0.599	0.400	0.927	758854	0.005
8	Dicta96	910167	788539.24	0.866	0.890	0.095	0.400	0.998	0.598	0.400	0.904	816442	0.009
9	DK390	861856	729183.96	0.846	0.882	0.115	0.400	0.999	0.599	0.400	0.885	788546	0.013
10	Dicta96	862925	766957.97	0.889	0.908	0.083	0.400	1.000	0.600	0.400	0.886	766638	0.007
11	Dicta96	907279	816811.72	0.900	0.918	0.070	0.400	0.999	0.598	0.400	0.945	788715	0.005
12	DK390	856246	790676.95	0.923	0.940	0.063	0.400	0.998	0.598	0.400	0.959	715727	0.004
13	DK390	815818	740775.55	0.908	0.925	0.067	0.400	0.997	0.597	0.400	0.934	703541	0.005
14	Dicta96	860556	767431.86	0.892	0.907	0.069	0.400	0.998	0.598	0.400	0.920	757012	0.005
15	DK390	844480	775042.43	0.918	0.930	0.057	0.400	0.998	0.598	0.400	0.925	722511	0.003
16	DK390	825575	747595.4	0.906	0.926	0.074	0.400	0.998	0.598	0.400	0.931	722359	0.005
17	Dicta96	845963	744355.86	0.880	0.897	0.075	0.400	0.998	0.598	0.400	0.877	746914	0.006
18	Dicta96	792048	667362.37	0.843	0.876	0.112	0.400	0.996	0.596	0.400	0.937	727737	0.013
19	DK390	800511	678824.97	0.848	0.882	0.113	0.400	0.999	0.599	0.400	0.959	735776	0.013
20	Dicta96	861755	761886.4	0.884	0.907	0.083	0.400	0.998	0.598	0.400	0.931	762318	0.007
21	DK390	831001	760786.99	0.916	0.936	0.069	0.400	0.999	0.599	0.400	0.976	715983	0.005
22	DK390	870918	797904.08	0.916	0.934	0.065	0.400	1.000	0.600	0.400	0.970	744133	0.004
23	DK390	868611	781949.15	0.900	0.915	0.058	0.400	1.000	0.600	0.400	0.923	738181	0.003
24	Dicta96	860972	769811.19	0.894	0.907	0.058	0.400	0.996	0.596	0.400	0.900	735981	0.003
25	DK390	870768	797633.08	0.916	0.933	0.064	0.401	0.998	0.597	0.401	0.943	739015	0.004
26	Dicta96	921234	802583.85	0.871	0.894	0.090	0.400	1.000	0.600	0.400	0.882	812144	0.008

27	DICTA96	859480	733059.8	0.853	0.889	0.115	0.400	1.000	0.600	0.400	0.928	780535	0.013
28	DK390	871983	772564.16	0.886	0.907	0.080	0.400	1.000	0.600	0.400	0.886	763714	0.006
29	DICTA96	936526	821925.19	0.878	0.894	0.074	0.400	1.000	0.600	0.400	0.913	817469	0.005
30	DK390	841307	751502.93	0.893	0.907	0.064	0.400	1.000	0.600	0.400	0.897	729751	0.004
31	DK390	880346	797409.72	0.906	0.916	0.050	0.400	0.999	0.599	0.400	0.931	732572	0.003
32	DICTA96	852556	756530.16	0.887	0.898	0.059	0.400	0.999	0.599	0.400	0.901	738530	0.004
33	DICTA96	870073	774222.38	0.890	0.902	0.066	0.400	1.000	0.600	0.400	0.915	764085	0.004
34	DICTA96	806345	715397.3	0.887	0.896	0.057	0.400	0.999	0.599	0.400	0.883	702734	0.003
35	DK390	874323	785453.47	0.898	0.915	0.069	0.400	1.000	0.600	0.400	0.902	754332	0.005
36	DICTA96	789178	692163.08	0.877	0.896	0.079	0.400	0.999	0.599	0.400	0.867	702307	0.006

Nota: Desv. est = Desviación Estándar, Mín = Mínimo, Max = Máxim

Anexo F

Estadística descriptiva del índice NDVI en los 88 días después de siembra

Numero de parcela	Genotipo	Numero	Suma	Media	Mediana	Desv. est	Mín	Max	Intervalo	Minoría	Moda	Variedad	Varianza
1	DK390	673961	586450.04	0.870	0.897	0.095	0.400	0.994	0.594	0.400	0.916	605802	0.009
2	DICTA96	701423	611943.11	0.872	0.894	0.087	0.400	0.996	0.596	0.400	0.909	629006	0.008
3	DK390	700220	612432.73	0.875	0.896	0.082	0.400	0.993	0.593	0.400	0.899	625926	0.007
4	DICTA96	696994	599063.86	0.859	0.873	0.075	0.400	0.997	0.597	0.400	0.876	633323	0.006
5	DK390	723865	635897.47	0.878	0.902	0.085	0.400	0.997	0.597	0.400	0.909	643302	0.007
6	DICTA96	654144	578930.08	0.885	0.896	0.070	0.400	0.998	0.598	0.400	0.851	598296	0.005
7	DK390	706663	616508.17	0.872	0.892	0.081	0.400	0.997	0.597	0.400	0.860	640471	0.007
8	DICTA96	742682	629715.92	0.848	0.872	0.097	0.400	0.997	0.597	0.400	0.827	681386	0.009
9	DK390	702787	606614.2	0.863	0.896	0.112	0.400	0.998	0.598	0.400	0.886	646705	0.013
10	DICTA96	672695	560566.73	0.833	0.874	0.130	0.400	0.995	0.595	0.400	0.893	629389	0.017
11	DICTA96	735757	640022.44	0.870	0.889	0.090	0.400	0.996	0.596	0.400	0.912	667147	0.008
12	DK390	697218	631542.06	0.906	0.918	0.059	0.400	0.997	0.597	0.400	0.945	619075	0.003
13	DK390	664331	600152.96	0.903	0.917	0.062	0.400	0.996	0.596	0.400	0.894	589805	0.004
14	DICTA96	700317	620485.44	0.886	0.896	0.070	0.400	0.999	0.599	0.400	0.960	636220	0.005
15	DK390	688154	626967.82	0.911	0.923	0.062	0.400	0.997	0.597	0.400	0.936	611520	0.004
16	DK390	672237	608177.3	0.905	0.919	0.067	0.400	0.998	0.597	0.400	0.911	600983	0.005
17	DICTA96	688652	609655.25	0.885	0.898	0.073	0.400	0.997	0.596	0.400	0.883	626028	0.005
18	DICTA96	658766	580750.34	0.882	0.898	0.082	0.400	0.996	0.596	0.400	0.952	606601	0.007
19	DK390	656941	593853.16	0.904	0.924	0.076	0.400	0.999	0.599	0.400	0.973	592362	0.006
20	DICTA96	701833	620043.91	0.883	0.898	0.078	0.400	0.998	0.598	0.400	0.884	641170	0.006
21	DK390	675396	608548.05	0.901	0.923	0.085	0.400	0.999	0.599	0.400	0.983	609788	0.007
22	DK390	709003	642042.13	0.906	0.919	0.066	0.400	0.998	0.598	0.400	0.937	623438	0.004
23	DK390	707084	644683.29	0.912	0.926	0.064	0.400	0.998	0.598	0.400	0.910	623386	0.004
24	DICTA96	700761	623400.57	0.890	0.904	0.072	0.401	0.998	0.596	0.401	0.876	635630	0.005
25	DK390	708906	641969.17	0.906	0.919	0.063	0.400	0.997	0.596	0.400	0.898	628013	0.004
26	DICTA96	752071	658804.82	0.876	0.896	0.086	0.400	0.993	0.593	0.400	0.902	674483	0.007
27	DICTA96	709177	611332.39	0.862	0.889	0.105	0.400	0.995	0.595	0.400	0.874	655638	0.011

28	DK390	708558	628220	0.887	0.909	0.082	0.400	0.999	0.599	0.400	0.913	627618	0.007
29	DICTA96	759894	668096.78	0.879	0.899	0.088	0.400	0.998	0.598	0.400	0.910	680594	0.008
30	DK390	684839	614790.59	0.898	0.916	0.074	0.400	0.998	0.598	0.400	0.886	601482	0.005
31	DK390	715764	645354.89	0.902	0.914	0.057	0.400	0.996	0.596	0.400	0.920	609702	0.003
32	DICTA96	694889	618737.52	0.890	0.899	0.056	0.402	0.994	0.592	0.402	0.910	616729	0.003
33	DICTA96	708949	624072.18	0.880	0.895	0.076	0.400	0.999	0.599	0.400	0.885	642644	0.006
34	DICTA96	656309	582252.37	0.887	0.901	0.078	0.400	0.999	0.598	0.400	0.874	600325	0.006
35	DK390	712419	644381.66	0.904	0.919	0.065	0.400	0.999	0.599	0.400	0.923	627263	0.004
36	DICTA96	644474	569554.57	0.884	0.901	0.084	0.400	0.999	0.599	0.400	0.925	593721	0.007

Nota: Desv. est = Desviación Estándar, Min = Mínimo, Max = Máxim

Anexo G

Estadística descriptiva del índice NDVI en los 108 días después de siembra

Numero de parcela	Genotipo	Numero	Suma	Media	Mediana	Desv. est	Mín	Max	Intervalo	Minoría	Moda	Variedad	Varianza
1	DK390	266766	196679.12	0.737	0.767	0.102	0.400	0.918	0.518	0.400	0.807	259031	0.010
2	DICTA96	281908	217470.4	0.771	0.792	0.091	0.400	0.936	0.536	0.400	0.778	272403	0.008
3	DK390	281060	210584.81	0.749	0.773	0.095	0.400	0.926	0.526	0.400	0.759	272264	0.009
4	DICTA96	281315	204365.38	0.726	0.736	0.083	0.400	0.928	0.528	0.400	0.688	272721	0.007
5	DK390	292126	223963.72	0.767	0.794	0.095	0.400	0.928	0.528	0.400	0.815	281630	0.009
6	DICTA96	265076	212529.28	0.802	0.810	0.064	0.401	0.942	0.541	0.401	0.826	255521	0.004
7	DK390	284619	214999.24	0.755	0.779	0.090	0.400	0.924	0.524	0.400	0.742	274952	0.008
8	DICTA96	298209	225572.63	0.756	0.773	0.089	0.400	0.934	0.534	0.400	0.743	287722	0.008
9	DK390	278487	204437.82	0.734	0.764	0.103	0.400	0.920	0.520	0.400	0.739	269906	0.011
10	DICTA96	282727	220118.11	0.779	0.794	0.083	0.400	0.948	0.548	0.400	0.789	273390	0.007
11	DICTA96	299110	234033.13	0.782	0.797	0.080	0.400	0.936	0.536	0.400	0.819	288039	0.006
12	DK390	282521	234471.53	0.830	0.838	0.055	0.401	0.957	0.556	0.401	0.798	267752	0.003
13	DK390	269216	223183.9	0.829	0.842	0.063	0.401	0.951	0.550	0.401	0.767	256860	0.004
14	DICTA96	283944	224052.93	0.789	0.799	0.071	0.401	0.943	0.542	0.401	0.786	274019	0.005
15	DK390	278774	228298.31	0.819	0.831	0.066	0.400	0.944	0.544	0.400	0.811	266208	0.004
16	DK390	272205	222865.59	0.819	0.832	0.066	0.400	0.942	0.542	0.400	0.795	259867	0.004
17	DICTA96	278785	216606.64	0.777	0.788	0.078	0.400	0.937	0.536	0.400	0.717	269723	0.006
18	DICTA96	266740	205537.15	0.771	0.782	0.075	0.400	0.935	0.535	0.400	0.771	258040	0.006
19	DK390	265674	220607.76	0.830	0.842	0.063	0.400	0.948	0.548	0.400	0.797	252936	0.004
20	DICTA96	284038	226021.47	0.796	0.809	0.075	0.400	0.950	0.550	0.400	0.824	273571	0.006
21	DK390	273399	227522.39	0.832	0.853	0.082	0.400	0.951	0.551	0.400	0.873	261175	0.007
22	DK390	287197	241643.05	0.841	0.855	0.066	0.400	0.957	0.557	0.400	0.811	272709	0.004
23	DK390	286538	245858.74	0.858	0.869	0.057	0.407	0.959	0.552	0.407	0.880	270964	0.003
24	DICTA96	284033	231983.58	0.817	0.828	0.063	0.407	0.956	0.549	0.407	0.776	272248	0.004
25	DK390	287264	242988.27	0.846	0.856	0.053	0.407	0.954	0.548	0.407	0.819	270810	0.003

26	DictA96	305104	252280.49	0.827	0.839	0.069	0.400	0.962	0.562	0.400	0.796	291341	0.005
27	DictA96	289349	235278.67	0.813	0.830	0.078	0.400	0.952	0.552	0.400	0.805	277632	0.006
28	DK390	283791	228268.16	0.804	0.830	0.096	0.400	0.953	0.553	0.400	0.850	273639	0.009
29	DictA96	308842	253060.55	0.819	0.836	0.078	0.400	0.957	0.557	0.400	0.825	296043	0.006
30	DK390	277511	231128.63	0.833	0.850	0.067	0.400	0.951	0.551	0.400	0.870	263919	0.004
31	DK390	290016	244146.36	0.842	0.857	0.065	0.400	0.955	0.555	0.400	0.881	275607	0.004
32	DictA96	281552	229329.53	0.815	0.826	0.060	0.410	0.944	0.534	0.410	0.840	269316	0.004
33	DictA96	286089	229506.88	0.802	0.816	0.072	0.400	0.948	0.548	0.400	0.698	275109	0.005
34	DictA96	266068	213554.7	0.803	0.815	0.070	0.401	0.943	0.543	0.401	0.811	256571	0.005
35	DK390	287506	238680.65	0.830	0.847	0.072	0.400	0.944	0.544	0.400	0.866	273186	0.005
36	DictA96	260944	207022.29	0.793	0.806	0.071	0.400	0.944	0.544	0.400	0.807	251725	0.005

Nota: Desv. est = Desviación Estándar, Mín = Mínimo, Max = Máxim

Anexo H

Estadística descriptiva del índice NDVI en los 113 días después de siembra

Numero de parcela	Genotipo	Numero	Suma	Media	Mediana	Desv. est	Mín	Max	Intervalo	Minoría	Moda	Variedad	Varianza
1	DK390	266252	197202.09	0.741	0.767	0.095	0.400	0.900	0.500	0.400	0.781	257342	0.009
2	DICTA96	282268	217132.14	0.769	0.789	0.085	0.400	0.924	0.524	0.400	0.824	271866	0.007
3	DK390	281502	212405.11	0.755	0.778	0.087	0.400	0.923	0.523	0.400	0.729	270712	0.008
4	DICTA96	280676	199732.85	0.712	0.722	0.084	0.400	0.906	0.506	0.400	0.804	272662	0.007
5	DK390	291931	222282.81	0.761	0.784	0.083	0.400	0.908	0.508	0.400	0.778	280241	0.007
6	DICTA96	264131	209095.35	0.792	0.804	0.069	0.400	0.928	0.528	0.400	0.800	254894	0.005
7	DK390	284614	213644.04	0.751	0.772	0.083	0.400	0.901	0.501	0.400	0.765	274088	0.007
8	DICTA96	299328	225838.21	0.754	0.773	0.084	0.400	0.915	0.515	0.400	0.779	288447	0.007
9	DK390	271351	197904.49	0.729	0.755	0.095	0.400	0.903	0.503	0.400	0.690	263005	0.009
10	DICTA96	265612	196873.41	0.741	0.759	0.090	0.400	0.924	0.524	0.400	0.725	257527	0.008
11	DICTA96	297489	225638.5	0.758	0.774	0.085	0.400	0.938	0.538	0.400	0.747	287025	0.007
12	DK390	281298	224994.77	0.800	0.823	0.086	0.401	0.945	0.544	0.401	0.814	269059	0.007
13	DK390	268065	213213.83	0.795	0.821	0.089	0.400	0.933	0.533	0.400	0.816	257376	0.008
14	DICTA96	282810	213481.57	0.755	0.767	0.078	0.400	0.920	0.520	0.400	0.718	273441	0.006
15	DK390	277774	222322.49	0.800	0.818	0.074	0.400	0.927	0.526	0.400	0.835	264940	0.005
16	DK390	271077	218416.74	0.806	0.824	0.074	0.400	0.927	0.527	0.400	0.814	258359	0.005
17	DICTA96	277188	211030.93	0.761	0.777	0.081	0.400	0.914	0.514	0.400	0.731	267744	0.007
18	DICTA96	263733	196924.95	0.747	0.761	0.078	0.400	0.905	0.505	0.400	0.750	254928	0.006
19	DK390	264957	217996.13	0.823	0.839	0.070	0.401	0.934	0.533	0.401	0.815	252864	0.005
20	DICTA96	281748	220771.59	0.784	0.799	0.088	0.400	0.946	0.546	0.400	0.783	272877	0.008
21	DK390	272924	225236.68	0.825	0.849	0.086	0.400	0.944	0.544	0.400	0.841	261680	0.007
22	DK390	286263	235549.1	0.823	0.850	0.089	0.401	0.949	0.548	0.401	0.816	274337	0.008
23	DK390	285520	240449.42	0.842	0.865	0.077	0.418	0.946	0.528	0.418	0.850	272205	0.006
24	DICTA96	283005	228716.21	0.808	0.825	0.083	0.401	0.953	0.552	0.401	0.796	273784	0.007
25	DK390	286155	233463.42	0.816	0.850	0.095	0.401	0.951	0.550	0.401	0.834	273712	0.009
26	DICTA96	303576	244241.3	0.805	0.826	0.086	0.400	0.951	0.551	0.400	0.825	290354	0.007
27	DICTA96	280889	221100.28	0.787	0.820	0.108	0.400	0.936	0.536	0.400	0.816	271736	0.012

28	DK390	279696	225181.24	0.805	0.830	0.095	0.400	0.938	0.538	0.400	0.805	268824	0.009
29	DICTA96	308651	248971.79	0.807	0.827	0.082	0.400	0.948	0.548	0.400	0.818	295370	0.007
30	DK390	276145	225382.62	0.816	0.845	0.090	0.400	0.960	0.560	0.400	0.843	263893	0.008
31	DK390	289399	240971.96	0.833	0.846	0.061	0.447	0.944	0.498	0.447	0.846	275675	0.004
32	DICTA96	280478	222208.28	0.792	0.808	0.079	0.400	0.969	0.568	0.400	0.856	271268	0.006
33	DICTA96	286176	223553.95	0.781	0.800	0.084	0.400	0.933	0.532	0.400	0.818	276219	0.007
34	DICTA96	263891	203665.99	0.772	0.793	0.091	0.400	0.931	0.531	0.400	0.823	255457	0.008
35	DK390	285147	236013.23	0.828	0.847	0.081	0.400	0.941	0.541	0.400	0.818	271752	0.007
36	DICTA96	260241	205788.05	0.791	0.803	0.069	0.400	0.940	0.540	0.400	0.787	251192	0.005

Nota: Desv. est = Desviación Estándar, Min = Mínimo, Max = Máxim

Anexo I

Estadística descriptiva del índice NDVI en los 116 días después de siembra

Numero de parcela	Genotipo	Numero	Suma	Media	Mediana	Desv. est	Mín	Max	Intervalo	Minoría	Moda	Variedad	Varianza
1	DK390	269292	191691.22	0.712	0.733	0.087	0.400	0.878	0.478	0.400	0.710	260863	0.007
2	DICTA96	282051	210198.85	0.745	0.760	0.078	0.400	0.910	0.510	0.400	0.765	272029	0.006
3	DK390	281659	206081.9	0.732	0.748	0.076	0.400	0.916	0.516	0.400	0.786	270964	0.006
4	DICTA96	279873	188853.48	0.675	0.681	0.083	0.400	0.885	0.484	0.400	0.691	272005	0.007
5	DK390	291207	213460.98	0.733	0.752	0.078	0.400	0.892	0.492	0.400	0.743	279701	0.006
6	DICTA96	263218	199398.85	0.758	0.767	0.074	0.400	0.911	0.511	0.400	0.716	254586	0.005
7	DK390	282590	203757.18	0.721	0.738	0.079	0.400	0.897	0.497	0.400	0.767	272680	0.006
8	DICTA96	295903	211449.52	0.715	0.730	0.084	0.400	0.905	0.505	0.400	0.751	285455	0.007
9	DK390	271961	187794.92	0.691	0.711	0.092	0.400	0.876	0.476	0.400	0.750	264199	0.009
10	DICTA96	280447	204684.69	0.730	0.747	0.082	0.400	0.898	0.498	0.400	0.728	270505	0.007
11	DICTA96	297472	220025.74	0.740	0.754	0.076	0.400	0.902	0.501	0.400	0.738	286245	0.006
12	DK390	280811	222467.19	0.792	0.803	0.062	0.408	0.930	0.522	0.408	0.770	267541	0.004
13	DK390	267604	212609.95	0.794	0.807	0.063	0.401	0.920	0.519	0.401	0.780	255632	0.004
14	DICTA96	282226	205789.51	0.729	0.736	0.067	0.400	0.893	0.493	0.400	0.694	271986	0.004
15	DK390	277170	218577.55	0.789	0.797	0.055	0.402	0.910	0.508	0.402	0.816	263628	0.003
16	DK390	270747	216080.37	0.798	0.808	0.056	0.400	0.914	0.513	0.400	0.847	257672	0.003
17	DICTA96	277124	205861.39	0.743	0.754	0.073	0.401	0.903	0.503	0.401	0.732	267915	0.005
18	DICTA96	264473	189969.66	0.718	0.731	0.078	0.400	0.886	0.486	0.400	0.735	256151	0.006
19	DK390	264565	213153.72	0.806	0.817	0.060	0.401	0.919	0.519	0.401	0.776	252878	0.004
20	DICTA96	282314	214260.21	0.759	0.771	0.078	0.400	0.922	0.522	0.400	0.752	273135	0.006
21	DK390	272288	221247.27	0.813	0.830	0.073	0.400	0.933	0.533	0.400	0.790	260752	0.005
22	DK390	285575	231419.08	0.810	0.827	0.069	0.401	0.937	0.537	0.401	0.808	272880	0.005
23	DK390	284830	236123.25	0.829	0.840	0.060	0.407	0.936	0.529	0.407	0.822	271027	0.004
24	DICTA96	282314	219365.93	0.777	0.789	0.073	0.400	0.926	0.526	0.400	0.785	272381	0.005
25	DK390	285478	235527.35	0.825	0.837	0.063	0.400	0.936	0.536	0.400	0.796	271177	0.004
26	DICTA96	303268	236648.06	0.780	0.797	0.081	0.400	0.931	0.531	0.400	0.772	292257	0.007

27	Dicta96	283675	217989.81	0.768	0.788	0.088	0.400	0.925	0.525	0.400	0.761	274025	0.008
28	DK390	276470	211991.05	0.767	0.793	0.096	0.400	0.919	0.519	0.400	0.781	267055	0.009
29	Dicta96	306149	236789.09	0.773	0.790	0.080	0.400	0.921	0.521	0.400	0.725	294450	0.006
30	DK390	275628	224842.25	0.816	0.827	0.062	0.400	0.932	0.532	0.400	0.781	263014	0.004
31	DK390	288533	236406.06	0.819	0.830	0.059	0.400	0.930	0.530	0.400	0.818	274576	0.003
32	Dicta96	279856	215896.78	0.771	0.781	0.068	0.404	0.920	0.516	0.404	0.780	269714	0.005
33	Dicta96	284512	218242.68	0.767	0.778	0.071	0.400	0.908	0.508	0.400	0.711	274103	0.005
34	Dicta96	264239	198908.64	0.753	0.765	0.079	0.400	0.925	0.525	0.400	0.769	256462	0.006
35	DK390	286719	232556.31	0.811	0.823	0.063	0.400	0.940	0.540	0.400	0.794	273641	0.004
36	Dicta96	269292	191691.22	0.712	0.733	0.087	0.400	0.878	0.478	0.400	0.710	260863	0.007

Nota: Desv. est = Desviación Estándar, Mín = Mínimo, Max = Máxim

Anexo J

Estadística descriptiva del índice NDVI en los 130 días después de siembra

Numero de parcela	Genotipo	Numero	Suma	Media	Mediana	Desv. est	Mín	Max	Intervalo	Minoría	Moda	Variedad	Varianza
1	DK390	190871	95225.837	0.499	0.485	0.071	0.400	0.816	0.416	0.400	0.412	187681	0.005
2	DICTA96	278960	153091.11	0.549	0.542	0.086	0.400	0.840	0.440	0.400	0.543	272697	0.007
3	DK390	293906	164899.49	0.561	0.553	0.088	0.400	0.855	0.455	0.400	0.523	286773	0.008
4	DICTA96	183253	88806.507	0.485	0.468	0.069	0.400	0.812	0.412	0.400	0.400	179828	0.005
5	DK390	249797	130878.97	0.524	0.500	0.097	0.400	0.869	0.469	0.400	0.403	245239	0.009
6	DICTA96	253514	133166.93	0.525	0.517	0.077	0.400	0.831	0.431	0.400	0.451	248145	0.006
7	DK390	304884	177516.27	0.582	0.582	0.078	0.400	0.848	0.448	0.400	0.569	295201	0.006
8	DICTA96	296728	155720.53	0.525	0.516	0.076	0.400	0.847	0.447	0.400	0.440	289267	0.006
9	DK390	194107	99034.493	0.510	0.495	0.080	0.400	0.827	0.427	0.400	0.400	191117	0.006
10	DICTA96	263777	135007.88	0.512	0.507	0.064	0.400	0.772	0.372	0.400	0.506	257069	0.004
11	DICTA96	269196	136490.3	0.507	0.497	0.070	0.400	0.847	0.447	0.400	0.462	262988	0.005
12	DK390	299179	166313.62	0.556	0.554	0.072	0.400	0.857	0.457	0.400	0.503	289688	0.005
13	DK390	295468	177848.17	0.602	0.606	0.075	0.400	0.862	0.462	0.400	0.592	286148	0.006
14	DICTA96	262209	136280.26	0.520	0.507	0.082	0.400	0.867	0.467	0.400	0.412	256717	0.007
15	DK390	282107	155857.41	0.552	0.539	0.096	0.400	0.882	0.482	0.400	0.614	275731	0.009
16	DK390	292398	169354.31	0.579	0.579	0.082	0.400	0.865	0.465	0.400	0.606	284664	0.007
17	DICTA96	240075	119491.93	0.498	0.484	0.072	0.400	0.849	0.449	0.400	0.500	234848	0.005
18	DICTA96	137603	64072.659	0.466	0.450	0.056	0.400	0.798	0.398	0.400	0.401	135577	0.003
19	DK390	250433	126128.26	0.504	0.496	0.064	0.400	0.779	0.379	0.400	0.501	244597	0.004
20	DICTA96	228153	112137.64	0.492	0.479	0.066	0.400	0.814	0.414	0.400	0.512	223169	0.004
21	DK390	281878	156356.31	0.555	0.553	0.080	0.400	0.832	0.432	0.400	0.524	274859	0.006
22	DK390	263761	142731.06	0.541	0.522	0.098	0.400	0.871	0.471	0.400	0.403	258957	0.010
23	DK390	300448	169582.97	0.564	0.561	0.085	0.400	0.881	0.481	0.400	0.541	292629	0.007
24	DICTA96	281541	146468.46	0.520	0.513	0.071	0.400	0.839	0.439	0.400	0.471	274056	0.005
25	DK390	309857	184050.82	0.594	0.597	0.073	0.400	0.864	0.464	0.400	0.554	299154	0.005
26	DICTA96	312035	169127.05	0.542	0.541	0.075	0.400	0.825	0.425	0.400	0.517	303162	0.006
27	DICTA96	286496	168107.62	0.587	0.589	0.078	0.400	0.832	0.432	0.400	0.634	278404	0.006

28	DK390	246869	131502.72	0.533	0.525	0.080	0.400	0.810	0.410	0.400	0.578	241921	0.006
29	DICTA96	294469	153027.13	0.520	0.514	0.070	0.400	0.856	0.456	0.400	0.501	286460	0.005
30	DK390	281382	151619.87	0.539	0.532	0.080	0.400	0.859	0.459	0.400	0.507	274769	0.006
31	DK390	315828	192560.55	0.610	0.612	0.090	0.400	0.885	0.485	0.400	0.566	307017	0.008
32	DICTA96	247561	126919.43	0.513	0.504	0.074	0.400	0.849	0.449	0.400	0.545	241880	0.005
33	DICTA96	295880	160908.31	0.544	0.535	0.085	0.400	0.880	0.480	0.400	0.484	288749	0.007
34	DICTA96	203029	98958.851	0.487	0.475	0.064	0.400	0.785	0.385	0.400	0.400	198588	0.004
35	DK390	298382	183148.01	0.614	0.624	0.102	0.400	0.875	0.475	0.400	0.478	291034	0.010
36	DICTA96	213165	107469.07	0.504	0.492	0.072	0.400	0.787	0.387	0.400	0.403	209347	0.005

Nota: Desv. est = Desviación Estándar, Min = Mínimo, Max = Máxim

Anexo K

Mapa de severidad de la MA en NDVI de la parcela número 1 en el genotipo DK390RR sin fungicida a los 88 DDS

