UNIVERSIDAD
NACIONAL
DE COLOMBIA

Modelización de la interferencia cultivo-malezas, mediante modelos autorregresivos espaciales, con validación en un cultivo de lechuga

David Alejandro Jamaica Tenjo

Universidad Nacional de Colombia

Facultad de Ciencias Agrarias, Departamento de Agronomía

Bogotá, Colombia

2019

Modelización de la interferencia cultivo-malezas, mediante modelos autorregresivos espaciales, con validación en un cultivo de lechuga

David Alejandro Jamaica Tenjo

Tesis presentada como requisito parcial para optar al título de:
Doctor en Ciencias Agrarias

Director:
Dr. Enrique Darghan
Codirector:
Dr. José Luis González Andújar

Línea de Investigación en Malherbología

Universidad Nacional de Colombia

Facultad de Ciencias Agrarias, Departamento de Agronomía

Bogotá, Colombia

2019

Maleza:

Cualquier planta cuyas virtudes aún no se han encontrado. (Emerson, 1876), pero que más virtud, que sobrevivir a todos los intentos humanos por erradicarlas.

A Gabriela, mi hija. La fuente de la fuerza y la determinación para llevar a cabo esta tesis

A Juliana, mi esposa. Por su infinito apoyo, paciencia y confianza

Agradecimientos

Agradezco a Colciencias y a la Universidad Nacional de Colombia, por la convocatoria de doctorados nacionales 647, que permitió hacer de este sueño una realidad.

A la Facultad de Ciencias Agrarias por recibirme y educarme durante todos mis estudios profesionales.

A Enrique Darghan por mostrarme un camino en el que encontré mucho más que un tema de tesis.

A José Luis González Andújar y a su equipo de trabajo, Verónica, Eva y Valle, por recibirme en su laboratorio del IAS en Córdoba, España, por su apoyo en mi estancia doctoral y por su aporte a la construcción del simulador, la evaluación inicial del modelo y la construcción del documento.

A Cesar Pedraza, Oscar García y especialmente a Andrés Puerto, por su apoyo en el área de la ingeniería y el procesamiento de imágenes.

A Iván Lizarazo por su aporte en los pasos iniciales de la tesis, en el modelado espacial.

A mi mamá, María Tenjo, Laura Jamaica, Ana Chaves, María Hernández, y a toda la familia Mamá Osa. Por su apoyo personal y familiar.

Resumen

La modelización de la competencia maleza-cultivo en general no contempla la heterogeneidad y la dependencia espacial tanto de las malezas como del cultivo, llevando a decisiones sesgadas en la toma de decisiones de manejo. Por esta razón, en esta investigación se propuso y se evaluaron variantes de un modelo autorregresivo espacial que incorpora los supuestos de heterogeneidad y dependencia. Para evaluar estas variantes del modelo en diversos escenarios de abundancia, agregación, distribución, dependencia espacial y la capacidad de competencia de las malezas y el cultivo, se construyó un simulador de campos Gaussianos continuos, herramienta de la geoestadística que en este caso, permite generar datos de malezas y cultivo que, asignando a cada pixel un área determinada, imitan la forma real en la que pueden aparecer en el campo. Luego, para la validación del modelo en un cultivo de lechuga y debido a la gran cantidad de información necesaria, se desarrolló un software que procesa imágenes multiespectrales, el cual permitió calcular la cobertura de malezas con gran precisión en una resolución espacial inferior a 1 mm^2. Finalmente, en la validación del modelo, se incorporó una matriz de pesos que proviene de la distancia y de la cobertura de las malezas presentes entre cada planta de cultivo con sus vecinas más cercanas. Los parámetros de dependencia espacial de las malezas, del cultivo y del error fueron altamente significativos, lo que implica, para las condiciones evaluadas, que el uso de modelos autorregresivos espaciales es justificado y necesario para evaluar la competencia cultivo-malezas.

Palabras clave: regresión espacial, autorregresivos, competencia cultivo malezas, simulación, investigación *in silico*, sensores remotos, procesamiento de imágenes

Abstract

The modeling of weed-crop competition in general does not contemplate the heterogeneity and spatial dependence of both weeds and crops, leading to biased decisions in management decision making. For this reason, this research proposed and evaluated variants of a spatial autoregressive model that incorporates the assumptions of heterogeneity and dependence. To evaluate these variants of the model in various scenarios of abundance, aggregation, distribution, spatial dependence and the competition capacity of weeds and crops, a simulator of continuous Gaussian fields was built, a tool of geostatistics that in this case, allows to generate weed and crop data that, by assigning a given area to each pixel, mimic the real way in which they can appear in fields. Then, for the validation of the model in a lettuce crop and due to the large amount of information needed, a software that processes multispectral images was developed, which allowed calculate the weed coverage with great precision at a spatial resolution of less than 1 mm^2. Finally, in the validation of the model, a matrix of weights was incorporated that comes from the distance and coverage of the weeds present between each crop plant with its closest neighbors. The parameters of spatial dependence of weeds, crop and error were highly significant, which implies, for the conditions evaluated, that the use of spatial autoregressive models is justified and necessary to assess crop-weed competition.

Keywords: spatial regression, autoregressive, weed crop competition, simulation, *in silico* research, remote sensing, image processing.

Contenido

Pág.

Agradecimientos ..... **VII**

Resumen ..... **IX**

Abstract ..... **X**

Contenido ..... **XI**

Lista de figuras ..... **XV**

Lista de tablas ..... **XIX**

Introducción **1**

1. Modelos empíricos de competencia cultivo - mala hierba. Revisión Bibliográfica **7**

1.1. Resumen 7

1.2. Introducción 8

1.2.1. Competencia 8

1.2.2. Modelado de la competencia 8

1.3. Los modelos empíricos de competencia 10

1.3.1. Modelos de regresión lineal 10

1.3.2. Modelos de regresión no lineales 13

1.4. Modelos de competencia que tienen en cuenta la distribución espacial de las malas hierbas 22

1.5. Conclusiones 28

1.6. Literatura citada 29

2. Generación de datos sintéticos de malezas con diversos escenarios de abundancia, distribución, agregación y dependencia espacial..... 37

2.1. Resumen..... 37

2.2. Introducción..... 38

2.3. Metodología..... 39

2.4. Resultados..... 42

2.4.1. Pre-simulación..... 42

2.4.2. Validación..... 45

2.5. Discusión..... 48

2.6. Literatura citada..... 49

3. Uso de modelos de regresión espacial en el estudio de la competencia entre las malezas y el cultivo..... 53

3.1. Resumen..... 53

3.2. Introducción..... 54

3.3. Metodología..... 59

3.3.1. Generación de los escenarios de simulación para la obtención de datos 59

3.3.2. Ajuste de modelos de regresión espacial..... 61

3.4. Resultados y discusión..... 62

3.4.1. Modelos de regresión espacial..... 64

3.4.1.1. Modelo de autocorrelación espacial para los siete escenarios simulados 65

3.5. Conclusiones..... 69

3.6. Literatura citada..... 69

4. Estimación de la cobertura de malezas en un cultivo de lechuga usando k-medias difuso en imágenes multiespectrales..... 73

4.1. Resumen..... 73

4.2. Introducción 74
4.2.1. Muestreo convencional 75
4.2.2. Procesamiento de imágenes en agricultura 75
4.3. Metodología 77
4.4. Resultados 78
4.5. Validación 79
4.6. Discusión y conclusiones 82
4.7. Literatura citada 83
5. Modelado de la competencia entre las malezas y un cultivo de lechuga, mediante regresión espacial y adaptación de la matriz de pesos para asociarla a la abundancia de las malezas 86
5.1. Resumen 86
5.2. Introducción 87
5.3. *Metodología* 94
5.3.1. *Creación de datos sintéticos* 94
5.3.2. *Datos in vivo* 95
5.4. *Resultados y discusión* 97
5.5. Conclusiones 103
5.6. Literatura citada 104
6. Discusión general 109
6.1. Simulación 109
6.2. Modelos de regresión espacial 110
6.3. Teledetección 112
6.4. Transdisciplinariedad en la malherbología 113
7. Literatura citada general 115

Lista de figuras

Pág.

Figura 1-1: Gráfico de los modelos representados en las Ecuaciones 1-2 y 1-3 para los cultivos de cebada, trigo y lino en presencia de *Avena fatua* [basado en Dew (1972)]. .. 11

Figura 1-2: Modelo hiperbólico expresando la pérdida de rendimiento en función de la densidad de malas hierbas..... 14

Figura 1-3: Modelo hiperbólico reflejando el rendimiento del cultivo en función de la densidad de malas hierbas..... 15

Figura 1-4: Cambios en el modelo hiperbólico en función de la diferencia del tiempo de emergencia entre malas hierbas y el cultivo de maíz [Modificado de Bosnic y Swanton (1997)]..... 16

Figura 1-5: Curvas hiperbólicas usando el área foliar de las malas hierbas para dos escenarios de cultivo y maleza, *C. album* con remolacha y *E. crus-galli* con maíz. 18

Figura 1-6: Curva hiperbólica de la relación entre la reducción del rendimiento de trigo y el TCL (carga competitiva total)..... 19

Figura 1-7: Curvas sigmoidales explicativas de la relación entre la densidad de *Sorghum halepense* y el rendimiento del algodón en diferentes años [Modificado de Bridges y Chandler (1987)]. 20

Figura 1-8: Ejemplo de dos curvas del modelo, una de forma hiperbólica para una especie y otra de forma sigmoidal para dos especies [Modificado de Ngouajio *et al.* (1999)] 21

Figura 1-9: Curva exponencial explicativa de la relación entre la densidad de *B. pilosa* y la biomasa del cafeto [Modificado de Ronchi y Silva (2006)]. 22

Figura 1-10: Diferencias de la curva hiperbólica de acuerdo a la distribución espacial de *E. crus-galli*. 23

Figura 2-1. Mapas generados con datos sintéticos mostrando tres niveles de abundancia de las malezas 43

Figura 2-2. Mapas simulados con datos sintéticos mostrando tres niveles de agregación 43

Figura 2-3. Mapas obtenidos con datos sintéticos mostrando tres niveles de dependencia espacial..... 44

Figura 2-4. Mapas creados con datos sintéticos mostrando tres niveles de patchiness .. 44

Figura 2-5. Mapas de cultivo sintetico generados con datos de malezas mostrando tres niveles de competitividad hacia el cultivo 45

Figura 2-6. Diagrama de cajas de las 50 repeticiones de abundancia de malezas sintéticas para los tres niveles programados. 46

Figura 2-7. Diagrama de cajas de las 50 repeticiones de abundancia de malezas y la agregación 46

Figura 2-8. Diagrama de cajas de las 50 repeticiones de datos sintéticos mostrando el efecto de combinado del patchiness, la competitividad y la abundancia sobre el rendimiento del cultivo. 47

Figura 3-1. Taxonomía de los modelos de regresión espacial. Modificado de Elhorst, (2010). 58

Figura 3-2. Procedimiento para la creación de campos de cultivo a partir de los campos de malezas, con la inclusión del error espacial y del error sin dependencia espacial (ruido blanco) 61

Figura 3-3. Ejemplo de un mapa de malezas y de cultivo a partir de la simulación establecida 62

Figura 3-4. Comparativo entre los valores observados (simulados) y estimados del modelo completo para los siete escenarios simulados. 68

Figura 4-1: Diagrama de bloques del procedimiento principal 77

Figura 4-2: a) Imagen original b) Imagen corregida 77

Figura 4-3: a) imagen original, b) imagen segmentada con seis clusters y posterior unión en tres clusters [lechuga (verde), maleza (rojo) y suelo (negro)] 79

Figura 4-4. Diagrama de cajas de la estimación de cobertura por parte de los tres expertos (A, B y C) y software (D y E) 81

Figura 5-1. Esquema de vecindad tipo “Queen” con su matriz de distancias correspondiente 90

Figura 5-2. Matriz de pesos asociada a las distancias entre vecinos mas cercanos 91

Figura 5-3. Operaciones básicas de probabilidad 93

Figura 5-4. Esquema de siembra de lechuga 95

Figura 5-5: Esquema de toma de datos de rendimiento del cultivo (áreas verdes) y de cobertura de malezas (cuadros rojos), en un ejemplo de nueve plantas 96

Figura 5-6: Rendimiento de las plantas de cultivo y cobertura de las malezas 100

XVIII Modelización de la interferencia cultivo-malezas, mediante modelos autorregresivos espaciales, con validación en un cultivo de lechuga

Lista de tablas

Pág.

Tabla 1-1: Definición de los componentes de los diferentes modelos en las ecuaciones 27

Tabla 3-1. Escenarios simulados para evaluar en el modelo completo, abundancia (% cobertura), distribución (% de celdas con presencia de malezas/total de celdas), y competitividad de las malezas (% máxima pérdida de rendimiento cuando malezas tienden a infinito)..... 60

Tabla 3-2. Estadística descriptiva de las malezas y del cultivo para la simulación..... 63

Tabla 3-3. Valor-P de Shapiro-Wilk e I de Moran para los residuales del modelo lineal *y~1* y *y~x*..... 64

Tabla 3-4. Parámetros calculados de los diferentes modelos para el escenario simulado 65

Tabla 3-5. Estadística descriptiva de las malezas y del cultivo para los diferentes escenarios simulados..... 67

Tabla 3-6. Parámetros del modelo completo para los diferentes escenarios simulados . 67

Tabla 4-1: Estimación de la cobertura por parte de los tres expertos y del software para dos alturas de toma de imágenes..... 80

Tabla 5-1. Estadísticas descriptivas del rendimiento del cultivo (gr/pl) y de la cobertura de las malezas (%).....102

Tabla 5-2. Parámetros calculados para las simulaciones para los dos modelos: autorregresivo puro (AP) y el completo (Com), y con las dos matrices usadas Wc: distancias del cultivo y Wt: vinculada con la abundancia de malezas..... 102

Tabla 5-3. Parámetros calculados para el cultivo de lechuga con presencia de malezas, con las dos matrices usadas, Wc: distancias del cultivo y Wt: vinculada con la abundancia de malezas 103

Introducción

Alimentar a más personas de manera sostenible es uno de los mayores desafíos de la humanidad en el próximo siglo (Godfray et al., 2010). La producción agrícola debe aumentar al menos un 60% antes de 2050 para satisfacer las crecientes tendencias de población y consumo (Alexandratos y Bruinsma, 2012). Existen muchos factores que reducen la producción de cultivos, incluida la presencia de plagas, enfermedades y malezas. La competencia de las malezas es el factor biológico más importante que reduce el rendimiento de los cultivos agrícolas. Las malas hierbas compiten con los cultivos por la luz, el agua y los nutrientes, causando graves daños, y se estiman que son responsables del 34% de las pérdidas mundiales de producción (Oerke 2006). Anualmente, las malezas causan una pérdida económica de más de US$ 100 mil millones (Appleby et al. 2000) y los herbicidas por un valor de US$ 25 mil millones se están utilizando para el manejo de malezas a escala global (Agrow 2003).

La importancia económica de las malezas ha llevado a la necesidad de predecir su daño sobre los cultivos (Zimdahl, 2004; Jamaica-Tenjo y González-Andújar, 2019) para ofrecer herramientas de toma de decisión a agricultores y técnicos. A dicho efecto, se han desarrollado dos aproximaciones: los modelos mecanísticos, que se basan en conocimientos biológicos y ecológicos del cultivo y las malezas y los modelos empíricos que se basan en modelos estadísticos de regresión (modelos lineales y no lineales), para inferir el efecto de las malezas sobre los cultivos.

Debido a su facilidad de uso y razonable predicciones, los modelos empíricos de se han constituido como una de las herramientas más usadas para establecer la relación entre la abundancia (biomasa, densidad o cobertura) de malezas y el rendimiento del cultivo.

Sin embargo, estos modelos parten en general del supuesto que variables como rendimiento de cultivo y la medida de abundancia de malezas son homogéneas e independientes en el espacio. No obstante, las evidencias de campo existentes muestran

2 Modelización de la interferencia cultivo-malezas, mediante modelos autorregresivos espaciales, con validación en un cultivo de lechuga

todo lo contrario (Calha et al., 2014). Estas variables son dependientes en el espacio y además heterogéneas, por lo que se consideran “variables regionalizadas”, por lo tanto, en el marco de la agricultura de precisión, el cual asume la heterogeneidad y dependencia espacial de variables en los cultivos, resulta necesario la adaptación, desarrollo y uso de modelos de competencia que tengan en cuenta estos supuestos.

Los modelos autorregresivos espaciales surgen como una alternativa a los modelos empíricos usados, ya que incorporan parámetros que pueden modelan la dependencia espacial del cultivo, de las malezas e incluso del error. Estos modelos se han usado profusamente para análisis econométricos y en el estudio de variables regionalizadas en las ciudades. También, se han empezado a usar en sistemas agrícolas. Teniendo en cuenta lo anterior surge la pregunta: ¿Pueden ser los modelos autorregresivos espaciales una forma más adecuada de estudiar la interacción entre la abundancia de las malezas y el rendimiento del cultivo?

Para responder a esta pregunta, el objetivo general de esta tesis ha sido evaluar el uso de algunas variantes de un modelo autorregresivo espacial, en la estimación del efecto de las malezas al cultivo, teniendo en cuenta su dependencia y heterogeneidad espaciales.

Sin embargo, en la evaluación y validación del modelo autorregresivo espacial se encontraron varios obstáculos, como: i) evaluar un modelo en varios escenarios de malezas contrastantes para constatar su uso y aplicabilidad. ii) validar el modelo autorregresivo espacial requiere una gran cantidad de información, por lo que los métodos convencionales de muestreo de malezas resultan ineficientes, dado el tiempo necesario para su captura y procesamiento, además de la subjetividad del o los evaluadores que pueden sesgar los resultados obtenidos.

Por esta razón, se estructuró cada uno de estos problemas como objetivos específicos en el marco de la tesis, en donde se presentan como capítulos independientes que suponen una aproximación al objetivo general expuesto

En el primer capítulo, se realiza una revisión amplia de los modelos empíricos de competencia cultivo-maleza desarrollados en las últimas décadas, haciendo un análisis de las ventajas y desventajas del uso de estos modelos, y de cómo han respondido a las necesidades de sus respectivas épocas. Finalizando con la presentación de un modelo de regresión espacial, el cual contempla la dependencia espacial de variables como rendimiento de cultivo y abundancia de malezas.

El segundo capítulo muestra el abordaje del primer problema para la evaluación del modelo de regresión espacial: contar con varios escenarios de estructura poblacional de malezas y de cultivo, y que estos sean contrastantes. Ya que esto resultaría costoso tanto en recursos como en tiempo. Esto implica realizar varios experimentos *in vivo,* en donde se encuentren diversas características ecológicas de las malezas y de cultivo como, abundancia, agregación, dependencia espacial o capacidad de competir, que sean diferentes y contrastantes. Para dar solución a este inconveniente, surge la posibilidad de la generación de datos por computador, llamada investigación *in silico* o simplemente simulación. Aunque se encontraron en la literatura algunos avances al respecto en el área de la ecología, no se encontró una herramienta que permitiera crear los escenarios de las malezas como pueden aparecer en la "vida real".

Para dar solución a esto, se expone el desarrollo y uso de un algoritmo en el software R, que, desde una herramienta tomada de la geoestadística, simulando campos Gaussianos continuos, que se pueden adaptar asignando un área específica para cada pixel. De esta forma, se pueden generar los escenarios y las repeticiones necesarias y en los cuales las malezas pueden aparecer en el campo. Esto se logró mediante la configuración de cinco características: abundancia, agregación, dependencia espacial, distribución y capacidad de competencia hacia el cultivo, en donde además se agrega un error sin dependencia espacial (ruido blanco) y uno con dependencia espacial, ya que los modelos de regresión espacial lo contemplan.

En el tercer capítulo se ilustra el uso de los modelos de regresión espacial para el estudio de la interacción del cultivo y las malezas, a partir de diversos escenarios generados por computador. De estos escenarios se escogieron siete, en los cuales se evaluaron diversas

4 Modelización de la interferencia cultivo-malezas, mediante modelos autorregresivos espaciales, con validación en un cultivo de lechuga

variantes del modelo de regresión espacial. Haciendo una comparación entre ellos, destacando sus usos y explicaciones biológicas de sus parámetros.

En el cuarto capítulo, se hace un desarrollo que permite dar solución para el segundo problema encontrado. En el que los modelos autorregresivos espaciales requieren de mucha información para su uso en experimentos *in vivo*. Acá, se optó por desarrollar un software para la obtención de la abundancia de malezas entre las plantas de cultivo. Esto se realizó a través de sensores remotos y el procesamiento de imágenes que permiten estimar la cobertura de las plantas tanto de malezas como de cultivo, en la cantidad, detalle y precisión que lo requería el modelo. Para esto, en asocio con la Facultad de Ingeniería de la Universidad Nacional de Colombia se desarrolló la tesis de maestría "Clasificación y cuantificación de maleza en cultivos de hortalizas por medio de procesamiento de imágenes digitales multiespectrales, la cual se expone en el cuarto capítulo. Este software tiene aplicabilidad para otro tipo de investigaciones, por ejemplo, la evaluación de sensores remotos en un bioensayo de herbicidas pre-emergentes, lo cual se logró en un cultivo de arveja.

En el capítulo cinco, se valida el modelo y se muestra su uso en el contexto de un ensayo *in vivo*, en un cultivo de lechuga, con un esquema de cultivo en el que se variaron las densidades de siembra. Se demostró que la cantidad de malezas, para este caso la cobertura, depende de la densidad de siembra, que ambas tienen influencia en la pérdida de rendimiento por competencia tanto intra como interespecífica y que características no medidas del suelo que afectan el crecimiento de las plantas, tienen influencia sobre la interacción cultivo-maleza, esto visto desde la dependencia espacial de los residuales del modelo. Además, se realizó un avance en el uso de las matrices de pesos que incluyen la abundancia de las malezas dentro de estas, con resultados que abren la puerta al uso de matrices de pesos con configuraciones diferentes al de las distancias entre plantas de cultivo.

Finalmente, en el capítulo 6 se realiza una discusión general de los capítulos presentados. El uso de los modelos autorregresivos espaciales, junto con el desarrollo de plataformas de muestreo remoto y el uso de simuladores, pueden contribuir al avance del estudio de la interacción malezas-cultivo de forma más acertada, ya que tienen en cuenta que el cultivo y variables de abundancia de las malezas, en este caso, su cobertura, son variables que presentan dependencia espacial. Además, también se tiene en cuenta dentro del modelo estructuras del error dependiente del espacio.

1. Modelos empíricos de competencia cultivo - mala hierba. Revisión Bibliográfica

D.A. Jamaica-Tenjo y J.L. González-Andújar

1.1. Resumen

Las malas hierbas son consideradas uno de los mayores problemas en la agricultura, ya que compiten con los cultivos por agua, nutrientes, luz y espacio, reduciendo sustancialmente su rendimiento. Desde un punto de vista práctico es de suma importancia poder predecir el efecto de las malas hierbas sobre el rendimiento del cultivo. Para ello se han desarrollado modelos empíricos de competencia que relacionan la pérdida del rendimiento como respuesta a la densidad o biomasa de las malas hierbas. En este trabajo se presenta una revisión de estos modelos y sus limitaciones, desde los modelos lineales, los no lineales, entre ellos, el modelo hiperbólico, hasta propuestas recientes de modelos que pueden ser utilizados para mejorar el entendimiento de la competencia cultivo-malas hierbas en un contexto espacial.

Palabras clave: arvenses, interferencia, lineales, no lineales, hiperbólicos,

1.2. Introducción

Las malas hierbas o malezas, están definidas como las plantas que crecen en los cultivos y que afectan negativamente el rendimiento o la calidad de estos (Zimdahl, 2004). Otro término usado es el de arvenses, el cual está definido como plantas que crecen con los cultivos, en el cual, entrarían tres grupos de plantas, las malezas, las toleradas y las fomentadas (Rendon-Aguilar et al., 2017). Para otros autores, arvense puede ser sinónimo de maleza (Blanco y Leyva, 2007)

Las malezas, consideradas como uno de los mayores problemas en la agricultura, compiten con los cultivos por agua, nutrientes, luz y espacio, reduciendo su rendimiento (Labrada et al., 1996). Globalmente se estima que reducen la producción un 34% (Oerke, 2006), con algunos casos de cultivos en el que las pérdidas pueden ser hasta del 100% (Zimdahl, 2007).

1.2.1. Competencia

La competencia maleza-cultivo ha sido definida de diferentes formas y desde diferentes perspectivas: (1) dos plantas que comparten nicho compiten cuando los recursos que ambas necesitan son limitados (Radosevich *et al.,* 2007) (2) la reacción de una planta a los factores abióticos del entorno y a su vez, en cómo estos factores que han sido modificados afectan a otra planta adyacente (Clements *et al.,* 1929), (3) la afectación del crecimiento de una planta ocasionada por el tamaño y la proximidad de sus vecinas (Gomez y Gomez, 1984).

1.2.2. Modelado de la competencia

El conocimiento de la medida en que una infestación de malas hierbas reduce el rendimiento de los cultivos es esencial para tomar decisiones adecuadas sobre si una estrategia de control está económicamente justificada y poder anticipar futuros problemas (Renton y Chauhan, 2017). Además de esta justificación económica, también podría

contribuir al establecimiento de estrategias integradas de gestión de malas hierbas que reduzcan la aplicación de herbicidas y el riesgo de desarrollo de resistencias. Por ello es de suma importancia poder predecir el rendimiento del cultivo o su reducción ocasionada por las malas hierbas. Con este objetivo se ha acudido a la modelización, adoptando dos aproximaciones. Por un lado, una aproximación mecanicista, en la cual los modelos buscan interpretar los fenómenos desde los mecanismos biológicos o fisiológicos que los causan (Kropff and van Laar, 1993; Deen et al., 2003). Estos modelos requieren una gran cantidad de datos, y la estimación de una gran cantidad de parámetros biológicos (Holst *et al.,* 2007), lo que hace que sean difíciles de usar en la práctica.

Por otro lado, se han desarrollado modelos empíricos (o descriptivos) de competencia (Swanton et al*.,* 2015) que relacionan la pérdida del rendimiento como respuesta a la densidad o biomasa de las malas hierbas (Rejmánek *et al.,* 1989) que, aunque no profundizan acerca de los mecanismos que los ocasionan, requieren poca información por lo que son fáciles de obtener y tienen una aceptable capacidad predictiva (Swanton et al., 2015). Por ello, son los modelos más utilizados para establecer la respuesta del cultivo a las malas hierbas (González-Andújar et al., 2016) y suelen incluirse en modelos bioeconómicos (Torra *et al.,* 2010; González-Díaz *et al.,* 2015) para construir sistemas de ayuda a la toma de decisiones (González-Andújar *et al.,* 2011).

En Colombia, no se han desarrollado, usado o adaptado modelos empíricos ni mecanísticos para el estudio de la interacción cultivo-maleza. Sin embargo, se ha avanzado en el estudio de épocas críticas de competencia para diversos cultivos. Lo cual permite establecer los momentos del ciclo de cultivo en los cuales se debe priorizar las labores de manejo (Swanton, 2015).

El objetivo de este capítulo es realizar una revisión de los modelos empíricos desarrollados a lo largo de las últimas décadas para el estudio de la competencia de las malas hierbas con el cultivo y sus limitaciones. También se exponen algunos potenciales desarrollos para mejorar su capacidad predictiva.

1.3. Los modelos empíricos de competencia

Los modelos que utilizan la densidad, biomasa o área foliar de malas hierbas como variables explicativas del rendimiento o la reducción del mismo se han utilizado con profusión en Malherbología (Zimdahl, 2004a). Estos sencillos modelos han servido para dar apoyo en la investigación y pautas para la actuación en el manejo.

1.3.1. Modelos de regresión lineal

Los modelos de regresión lineal cuantifican el rendimiento del cultivo o pérdida de rendimiento (*Y*) (ej. kg ha^{-1}) como función de la densidad (*x*) (ej. plantas m^{-2}) o biomasa (ej. g m^{-2}) de las malas hierbas, asumiendo la competencia del cultivo con una sola especie de mala hierba y la sincronización de la emergencia de las mala hierbas y el cultivo (O'Donovan *et al.,* 1985).

Estos son formas particulares o extensiones del modelo general (Ecuación 1-1),

$$\mathbf{Y} = \boldsymbol{a} + \mathbf{b}\mathbf{x}^{\mathbf{d}} + \boldsymbol{\varepsilon} \qquad \textbf{Ecuación 1-1}$$

donde *a* es el rendimiento en ausencia de la mala hierba, *b* es la pendiente (negativa), que indica cuán importante es el incremento de la densidad de las malas hierbas sobre el rendimiento del cultivo, *d* es un parámetro de curvatura, ε corresponde al error del modelo (ver Tabla 1-1 para una definición de todos los componentes de los modelos definidos en el artículo).

Uno de los primeros modelos que se establecieron fue una regresión lineal simple ($d = 1$) en Ecuación 1-1, que da a lugar a la Ecuación 1-2 (Dew, 1972):

$$\boldsymbol{Y} = \boldsymbol{a} + \boldsymbol{b}\boldsymbol{x} + \boldsymbol{\varepsilon} \qquad \textbf{Ecuación 1-2}$$

El mismo autor comenta que la variable *x* puede ser transformada a $\sqrt{x}$ (*d* = 1/2 en Ecuación 1-2), ya que con esta transformación el modelo se ajusta mejor a los datos, dando como resultado el modelo de la Ecuación 1-3:

$$\boldsymbol{Y = a + b\sqrt{x} + \varepsilon} \qquad \textbf{Ecuación 1-3}$$

Como ejemplo de estos modelos anteriores se muestra en la Figura 1-1 el efecto de la presencia de *Avena fatua* L. en los cultivos de cebada, trigo y lino.

Figura 1-1: Gráfico de los modelos representados en las Ecuaciones 1-2 y 1-3 para los cultivos de cebada, trigo y lino en presencia de *Avena fatua* [basado en Dew (1972)].

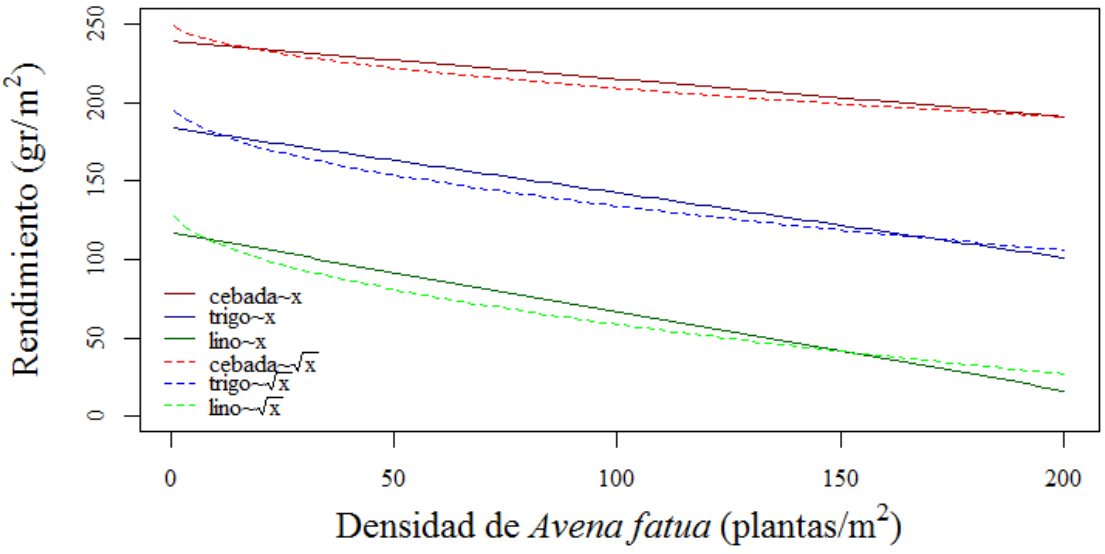

Sin embargo, en la Ecuación 1-1, se asume que el cultivo y las malas hierbas emergen al mismo tiempo. Se han propuesto diferentes modificaciones para incluir la diferencia de tiempos de emergencia que existe normalmente entre el cultivo y la mala hierba. O'Donovan *et al.* (1985) proponen un modelo de regresión múltiple que es una extensión de la Ecuación 1-3:

$$\boldsymbol{Y = a + b\sqrt{x} + b_1 T + \varepsilon} \qquad \textbf{Ecuación 1-4}$$

donde b_1 es un parámetro que indica el efecto de la emergencia de la mala hierbas anterior o posterior a la emergencia del cultivo y T es una variable que refleja alguna medida de tiempo (p.e. días) con valores enteros negativos en caso que la maleza emerja primero, positivos si emerge primero el cultivo, y cero si emergen al mismo tiempo (regresando a la Ecuación 1-3).

Otra de las modificaciones que se han propuesto, es la de incluir el efecto de diferentes especies de malas hierbas, ya que el modelo presentado en la Ecuación 1-1 considera el efecto de una sola especie sobre el cultivo. Diversos autores (Spitters, 1983; Radosevich, 1987) ampliaron el citado modelo usando la ley de rendimiento reciproco para considerar el efecto de la competencia intraespecífica y el efecto de varias especies de malas hierbas:

$$\frac{1}{W} = a + c_0 x_0 + c_1 x_1 + \cdots + c_j x_j + \varepsilon \qquad \textbf{Ecuación 1-5}$$

donde w es el peso (g m^{-2}) de la planta de cultivo, c_0 es el parámetro que indica la competencia intraespecífica del cultivo, x_0 indica la densidad del cultivo, c_i (i= 1,.., j) es un parámetro que indica la cantidad de pérdida de peso del cultivo ocasionada por cada especie de mala hierba presente (desde la especie 1 hasta la especie j).

Estos modelos lineales pueden ser suficientes para algunos problemas agronómicos con bajas densidades de malezas, en las cuales la competencia intraespecífica entre las malas hierbas no es suficientemente fuerte como para alterar la linealidad de la respuesta.

Las principales limitaciones de los modelos lineales son que no pueden ser aplicados a altos valores de densidades de malas hierbas porque pueden implicar pérdidas superiores al 100%, ya que no habría una limitación al crecimiento de la recta, por otra parte, se infieren pérdidas de rendimiento causadas por malas hierbas, en ausencia de estas ($Y = a$ cuando $x = 0$ en Ecuación 1-1).

1.3.2. Modelos de regresión no lineales

Debido a las limitaciones del modelo lineal para explicar la relación mala hierba-cultivo, se plantearon modelos asintóticos (no lineales) que no permiten exceder el 100% de pérdidas de rendimiento (Cousens, 1985a). La asíntota representa la existencia de competencia entre las mismas malas hierbas a medida que su densidad aumenta. Los modelos no lineales son actualmente los modelos empíricos más usados para relacionar la pérdida de rendimiento del cultivo con la densidad (o biomasa) de las malas hierbas. La forma funcional no lineal se elige mediante la representación gráfica de los datos obtenidos en los experimentos (González-Andújar et al., 1993). Los modelos hiperbólicos y sigmoidal han emergido como las formas funcionales más utilizadas en la literatura de la malherbología.

- **Modelo hiperbólico**

Cousens (1985b) comparó 18 modelos que relacionaban la pérdida de rendimiento del cultivo con la densidad de las malas hierbas, y llegó a la conclusión de que el modelo hiperbólico daba una adecuada descripción de la relación de competencia. Cousens, (1985a) parte de las cuatro premisas biológicas que deben incluir los modelos de competencia, con lo cual se le puede dar una interpretación biológica a los parámetros:

- Si no hay malas hierbas presentes, no hay reducción del rendimiento.
- Cada individuo de mala hierba tiene un efecto negativo sobre el rendimiento del cultivo. A bajas densidades de malas hierbas estos efectos son aproximadamente aditivos.
- La pérdida de rendimiento no debe ser superior a 100%, es decir, el modelo debe tener una asíntota.
- A medida que la densidad de malas hierbas aumenta, la distancia entre estas disminuye, por lo tanto empiezan a competir entre ellas (competencia

intraespecífica) y por consiguiente, el efecto de cada planta de mala hierba sobre el cultivo es menor a medida que la densidad aumenta.

Con base en esas premisas, Cousens (1985b) propone el siguiente modelo hiperbólico (Ecuación 1-6 y Figura 1-2**):**

$$Y_L = \frac{Ix}{1+\frac{I}{A}x} + \varepsilon \qquad \textbf{Ecuación 1-6}$$

En este modelo, Y_L representa la fracción de pérdida de rendimiento como consecuencia de la competencia; I es la fracción de pérdida de producción por cada planta de mala hierba cuando $x \rightarrow 0$; A es la pérdida de rendimiento cuando $x \rightarrow \infty$.

La anterior ecuación puede ser expresada en términos del rendimiento del cultivo Y, contemplando la reducción respecto al máximo rendimiento del cultivo sin malas hierbas (Y_{wf}; ej. kg ha^{-1}) de la siguiente forma (Ecuación 1-7, Figura 1-3):

$$Y = Y_{wf}\left[1 - \frac{Ix}{100\left(1+\frac{I}{A}x\right)}\right] + \varepsilon \qquad \textbf{Ecuación 1-7}$$

Figura 1-2: Modelo hiperbólico expresando la pérdida de rendimiento en función de la densidad de malas hierbas.

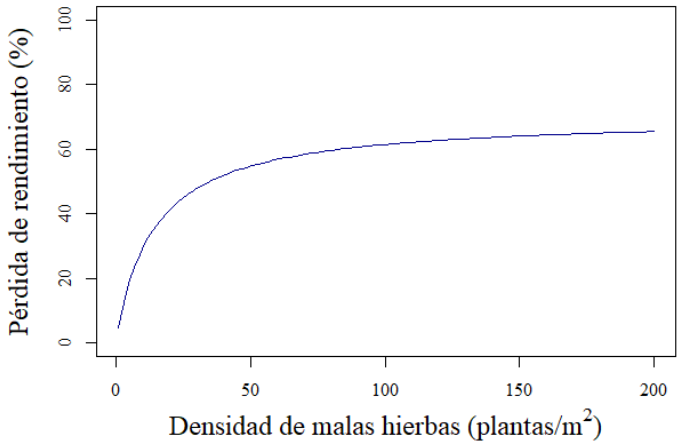

Figura 1-3: Modelo hiperbólico reflejando el rendimiento del cultivo en función de la densidad de malas hierbas.

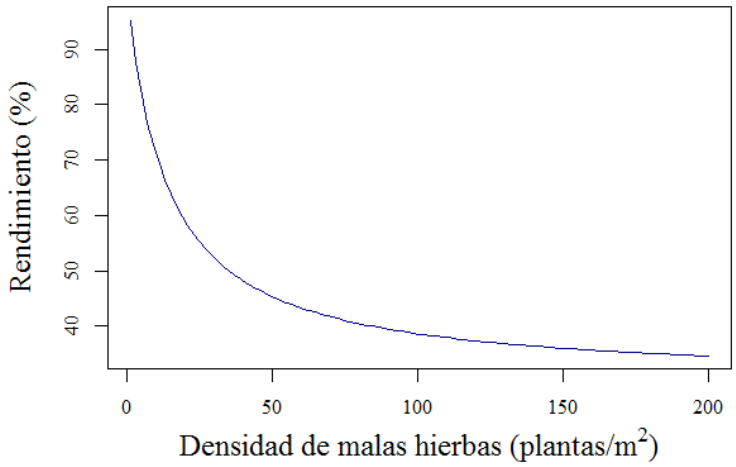

El modelo hiperbólico ha servido como marco de referencia para incluir otros aspectos como los tiempos relativos de germinación del cultivo, el efecto de más de una especie de mala hierba, etc., que han permitido una mejora del mismo.

Una de las mayores limitaciones del modelo es la suposición de que existe una sincronización entre la emergencia del cultivo y la mala hierba. Las malas hierbas que emergen antes que el cultivo, producen un mayor daño en el mismo que las que emergen posteriormente. Cousens *et al.* (1987) propusieron una modificación de la **Ecuación 1-6** para incluir la desincronización de las emergencias del cultivo y la mala hierba. Para ello modificaron el valor de *I* de la siguiente forma (Ecuación 1-8),

$$I = he^{-b_2 T} \qquad \textbf{Ecuación 1-8}$$

asumiendo que *I* declina exponencialmente (*e*) con el tiempo (días o tiempo termal) (*T*) y b_2 es la tasa a la que *I* decrece. Si cultivo y mala hierba tienen sincronizadas sus emergencia ($T = 0$), tenemos que $h = I$ y volvemos a la Ecuación 1-6.

Con este cambio queda modificada como (Ecuacuón 1-9):

$$Y_L = \frac{hx}{e^{b_2 T} + \frac{h}{A}x} + \varepsilon \qquad \textbf{Ecuación 1-9}$$

Un ejemplo de esto se encuentra en Bosnic y Swanton (1997) (Ecuación 1-10). En este caso los autores modelan el rendimiento del maíz en función de la densidad de *Echinochloa crus-galli* L. (P. Beauv.), pero considerando los grados días acumulados (Mcmaster y Wilhelm, 1997) entre el momento de emergencia de la mala hierba y el cultivo. Es conocido que la temperatura es, en general, un mejor predictor de la emergencia de las malas hierbas que los días (González-Andújar *et al.,* 2016), por ello el uso de grados días acumulados como variable explicativa parece una aproximación razonable.

$$Y = Y_{wf}\left[1 - \frac{hx}{100\left(e^{b_2 T} + \frac{h}{A}x\right)}\right] + \varepsilon \qquad \textbf{Ecuación 1-10}$$

La **¡Error! No se encuentra el origen de la referencia.** muestra un ejemplo de la aplicación de la Ecuación 1-10 pero considerando los días de diferencia de la emergencia entre el cultivo de maíz (*Zea mays* L.) y la maleza (*E. cruz-galli*) en lugar de grados días.

Figura 1-4: Cambios en el modelo hiperbólico en función de la diferencia del tiempo de emergencia entre malas hierbas y el cultivo de maíz [Modificado de Bosnic y Swanton (1997)].

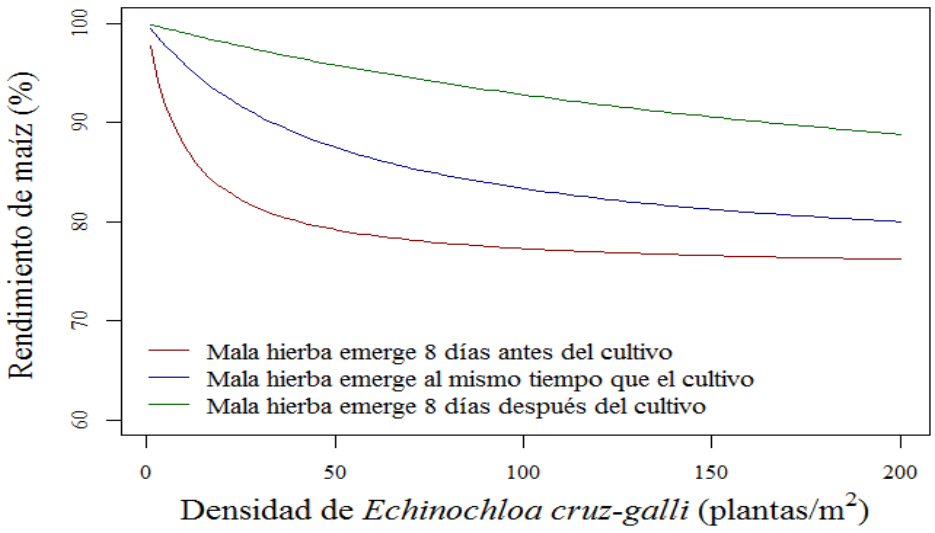

Un enfoque alternativo para tener en cuenta el intervalo de tiempo entre las emergencias de las malas hierbas y del cultivo es considerar las diferencias de tamaño que se establece entre la mala hierba y el cultivo, en tiempos relativos de emergencia. En esta aproximación, la densidad de las malas hierbas es ponderada por su área foliar promedio (Ecuación 1-11) (Kropff y Spitters, 1991).

$$Y_L = \frac{qL_w}{1+(q-1)L_w} + \varepsilon \qquad \textbf{Ecuación 1-11}$$

donde, L_w es el índice de área foliar relativo que se expresa como se muestra en la Ecuación 1-12:

$$L_w = \frac{LAI_w}{LAI_w+LAI_c} \qquad \textbf{Ecuación 1-12}$$

donde LAI_w es el índice de área foliar de las malas hierbas y LAI_c es el índice del área foliar del cultivo.

El coeficiente de daño relativo (q) viene expresado por la Ecuación 1-13:

$$q = g\frac{LA_c}{LA_w} \qquad \textbf{Ecuación 1-13}$$

donde LA_c es el promedio del área foliar por planta de cultivo, LA_w es el promedio del área foliar por planta de las malas hierbas y g es el efecto competitivo de la maleza sobre el cultivo definido en la Ecuación 1-14:

$$g = \frac{c_1 x_0}{f+c_0 x_0} \qquad \textbf{Ecuación 1-14}$$

siendo f un parámetro que da mayor o menor importancia a la relación entre la competencia intraespecífica del cultivo y la interespecífica con la mala hierba.

Un ejemplo del modelo de la Ecuación 1-11, se expone por los mismos autores en el modelado de la competencia entre *Chenopodium album* L. y remolacha azucarera (*Beta vulgaris* L.) (Figura 1-5) con un valor de q de 12 y entre *E. cruz-galli* y maíz con un valor de q de 0,46.

Una mejora del modelo hiperbólico ha sido la inclusión del efecto competitivo de más de una especie de maleza sobre el cultivo. Así, por ejemplo, Gherekhloo *et al*. (2010), definieron un índice llamado la carga competitiva total (*TCL*). Modificando la Ecuación 1-5, se obtiene la Ecuación 1-15:

$$TCL = x_i + \frac{c_1}{c_i}x_1 + \cdots + \frac{c_j}{c_i}x_j \qquad \textbf{Ecuación 1-15}$$

donde x_i ($i=1\ldots j$) es la densidad de la maleza más competitiva, c_i es el parámetro de competencia para la especie de maleza más competitiva.

Figura 1-5: Curvas hiperbólicas usando el área foliar de las malas hierbas para dos escenarios de cultivo y maleza, *C. album* con remolacha y *E. crus-galli* con maíz.

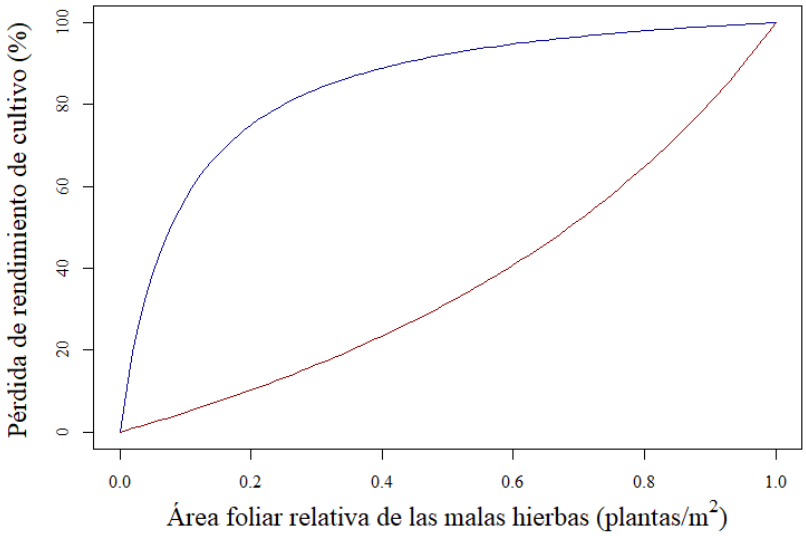

Posteriormente se incluye el *TCL* en el modelo hiperbólico de la forma expresada en la Ecuación 1-16:

$$Y_L = \frac{I(TCL)}{1+\frac{I(TCL)}{A}} + \varepsilon \qquad \textbf{Ecuación 1-16}$$

De esta forma los autores calcularon el TCL en un cultivo de trigo, en donde se encontraron tres especies de malas hierbas: *Avena ludoviciana, Convolvulus* spp. y *C. álbum* y modelaron la competencia como se muestra en la Figura 1-6.

▪ Modelo sigmoidal

El modelo sigmoidal implica que a bajas densidades de malas hierbas no existe competencia con el cultivo y que por esta razón hay un "umbral" de densidad de malas hierbas en el cual no habría competencia (Cousens, 1985b; Ngouajio *et al.,* 1999). En este sentido, los modelos hiperbólico y sigmoidal son excluyentes en cuanto a la descripción de la competencia, no solo desde el punto de vista biológico en donde uno sugiere que existe competencia con la presencia de una sola planta de maleza y el otro establece un umbral de bajas densidades donde no existe competencia, sino también porque la forma de la curva es fundamental para la toma de decisiones en el control de las malas hierbas (Swanton *et al.,* 1999).

Figura 1-6: Curva hiperbólica de la relación entre la reducción del rendimiento de trigo y el TCL (carga competitiva total).

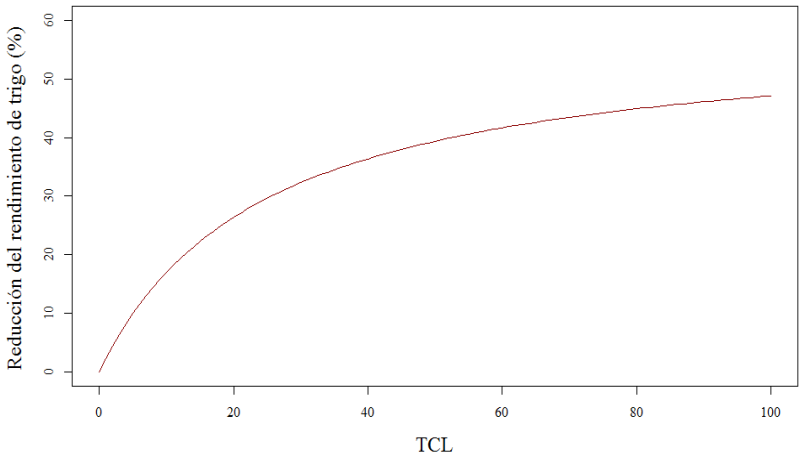

A continuación, se muestran algunas de las formas que han sido utilizadas del modelo sigmoidal (Ecuación 1-17):

$$Y = m + Be^{-\Phi x^2} + \varepsilon \qquad \textbf{Ecuación 1-17}$$

Donde *m*, es el rendimiento mínimo, *B* es un parámetro de curvatura y *Φ* es la tasa de decrecimiento. Un ejemplo del uso de este modelo sigmoidal se encuentra en Bridges y Chandler (1987), (Figura 1-7), en donde se modeliza el rendimiento del algodón en función de la densidad de *Sorghum halepense* (L) Pers.

▪ Otros modelos no lineales

Aunque los dos modelos presentados son los más populares en la literatura, especialmente el hiperbólico, otros modelos no lineales han sido propuestos. Ngouajio *et al*. (1999) presentan un modelo muy flexible que contempla la posibilidad de representar con una sola ecuación modelos hiperbólicos o sigmoidal (Ecuación 1-18), indistintamente:

$$Y = \frac{I + A\left(\frac{L_W}{(1-L_W)\gamma}\right)^{\delta}}{1+\left(\frac{L_W}{(1-L_W)\gamma}\right)^{\delta}} + \varepsilon \qquad \textbf{Ecuación 1-18}$$

Figura 1-7: Curvas sigmoidales explicativas de la relación entre la densidad de *Sorghum halepense* y el rendimiento del algodón en diferentes años [Modificado de Bridges y Chandler (1987)].

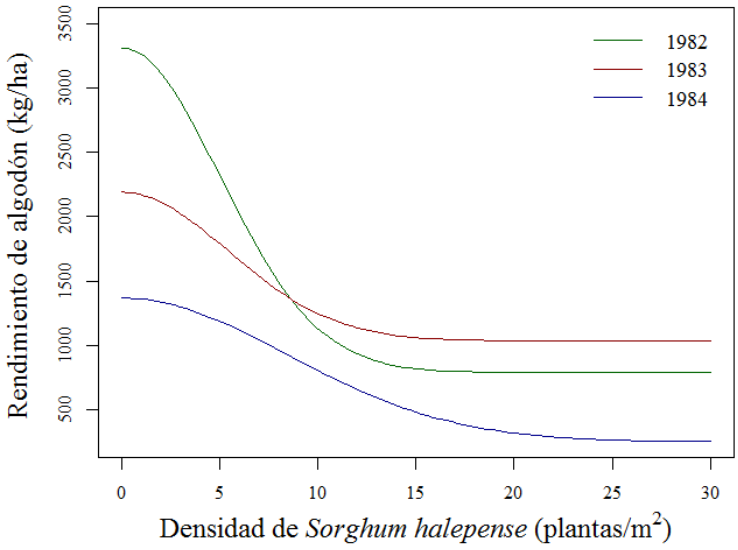

donde, γ indica la pendiente de la curva y δ es la medida de la curvatura que indica en qué punto el rendimiento empieza a disminuir.

La Figura 1-8 presenta un ejemplo de la flexibilidad de este modelo en el cultivo de maíz. La forma sigmoidal representa una combinación del área foliar relativa conjunta de *E. crus-galli y C. album* y la forma hiperbólica representa el área foliar relativa de *C. álbum*

Figura 1-8: Ejemplo de dos curvas del modelo, una de forma hiperbólica para una especie y otra de forma sigmoidal para dos especies [Modificado de Ngouajio *et al.* (1999)]

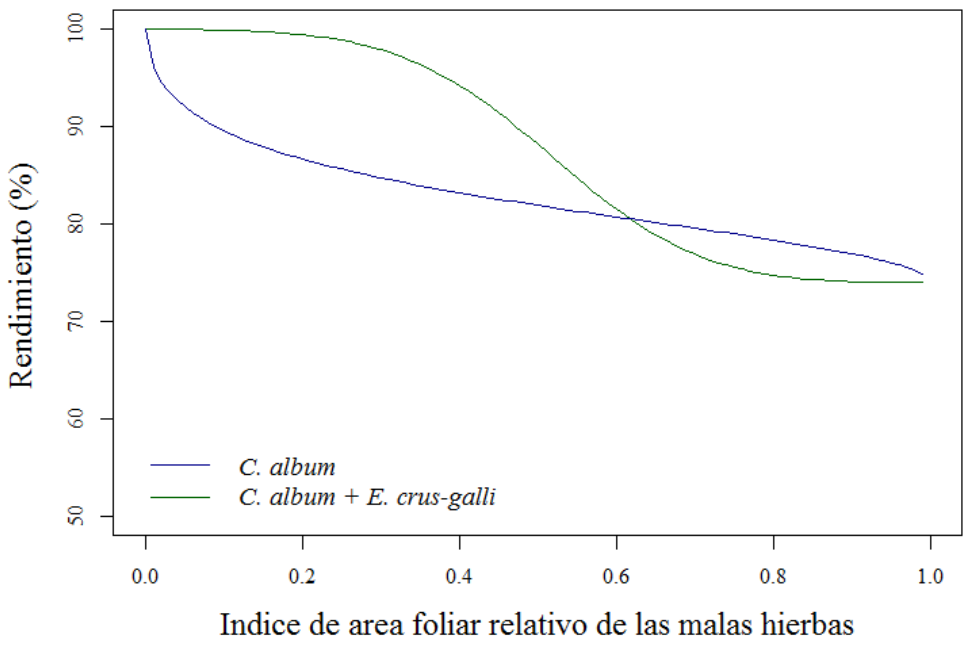

Otro modelo que ha sido utilizado es el modelo exponencial, como el presentado por Torner *et al.* (1991) (Ecuación 1-19).

$$Y = Y_{wf} e^{-\Phi x} + \varepsilon \qquad \textbf{Ecuación 1-19}$$

A manera de ejemplo (Figura 1-9) se expone uno de los resultados de Ronchi y Silva (2006), en donde se relaciona la biomasa seca de arbustos de cafeto en función de la densidad de *Bidens pilosa* L.

Figura 1-9: Curva exponencial explicativa de la relación entre la densidad de *B. pilosa* y la biomasa del cafeto [Modificado de Ronchi y Silva (2006)].

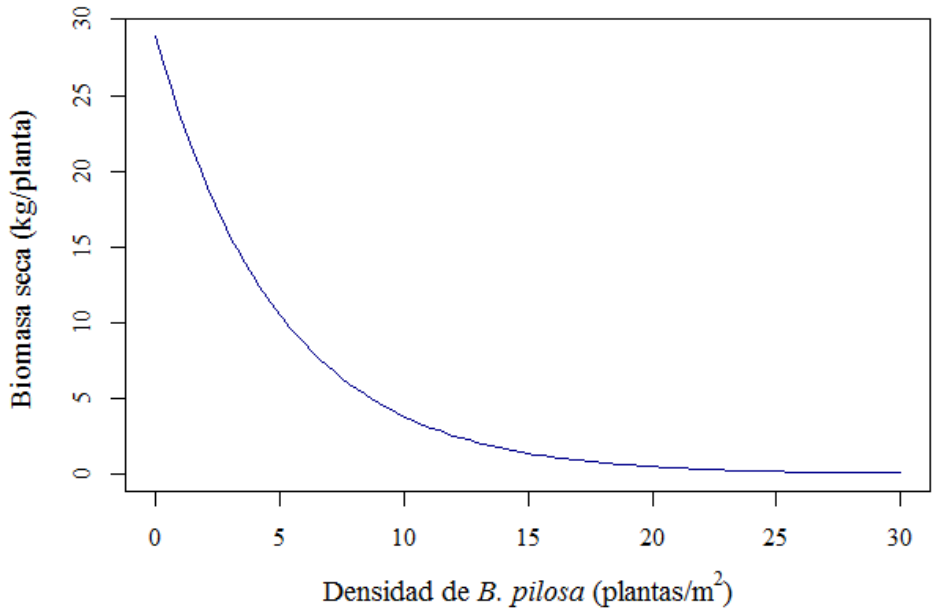

1.4. Modelos de competencia que tienen en cuenta la distribución espacial de las malas hierbas

Las metodologías clásicas de modelado que relacionan la pérdida de rendimiento del cultivo como efecto de la abundancia de malas hierbas, consideran implícitamente que las malas hierbas están distribuidas espacialmente de forma no agregada en el cultivo (Cardina *et al.,* 1997). Sin embargo está ampliamente establecido que las malas hierbas presentan una distribución agregada (Marshall, 1988; González-Andújar y Saavedra, 2003). La no inclusión de la distribución espacial agregada de las malas hierbas en los modelos de competencia puede llevar a una predicción errónea del rendimiento y llevar a

tomar decisiones de manejo equivocadas cuando se usan umbrales de acción o modelos bio-económicos (Zanin *et al.,* 1998; González-Andújar *et al.,* 2011).

Auld y Tisdell (1988) han mostrado que a medida que la distribución de las malas hierbas se aleja de la uniformidad se sobreestima el daño sobre el cultivo. Norris *et al*. (2001) muestran cómo cambia la forma de la curva hiperbólica dependiendo si las malas hierbas se distribuyen de forma agregada, uniforme o aleatoria. La reducción del rendimiento del cultivo para malas hierbas con distribución espacial agregada es menor que para distribuciones uniforme y aleatoria (Figura 1-10).

Figura 1-10: Diferencias de la curva hiperbólica de acuerdo a la distribución espacial de *E. crus-galli*.

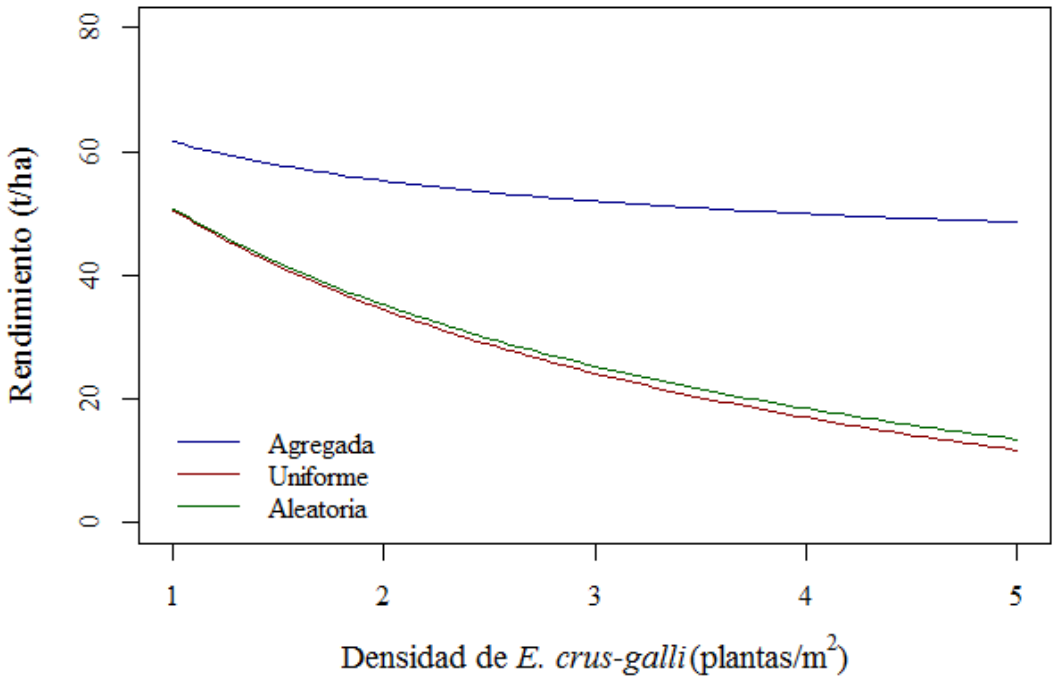

Se han propuesto modificaciones de los modelos de competencia para tener en cuenta la distribución espacial agregada de las malas hierbas. Algunas de ellas se basan en el uso de índices de dispersión o en índices derivados de distribuciones de frecuencias

(González-Andújar y Saavedra, 2003). En este sentido, Hughes (1996), propone usar el índice de Lloyd ($\dot{x}$):

$$\dot{x} = \bar{x} + \frac{s_x^2}{\bar{x}} - 1 \qquad \textbf{Ecuación 1-20}$$

donde, $\bar{x}$ es el promedio de la densidad de malas hierbas y s_x^2 es la varianza e incluirlo en el modelo hiperbólico (**Ecuación 1-6**), dando como resultado la Ecuación 1-21:

$$Y_L = \frac{I\bar{x}}{1+\frac{I}{A}\dot{x}} + \varepsilon \qquad \textbf{Ecuación 1-21}$$

Brain y Cousens (1990) en un cultivo de trigo teniendo como maleza *Bromus sterilis* L. utilizan una aproximación similar incluyendo el parámetro *k* de la distribución Binomial Negativa, que es considerado como una medida de agregación. En este sentido, tambien se puede incorporar en el modelo hiperbólico otros índices de distancia como el índice T-cuadrado (González-Andújar y Navarrete, 1995).

La **Ecuación 1-21** supone la inclusión de la distribución espacial de las malas hierbas implícitamente. Pero, es necesario el desarrollo de modelos que consideren explícitamente la distribución espacial para una aproximación más precisa a la relación competitiva maleza-cultivo y de esa forma establecer una herramienta útil para el desarrollo de la agricultura de precisión. En este sentido, una alternativa puede ser el desarrollo de modelos autorregresivos espaciales (Arbia, 2014), los cuales son modelos que en el contexto de la relación cultivo-malas hierbas, parten del supuesto de la existencia de autocorrelación espacial en el rendimiento de las plantas de cultivo, posiblemente también en la abundancia de las malas hierbas y entre los residuos. Adaptados para estimar el rendimiento en función de la cantidad de malas hierbas se puede expresar de la siguiente forma:

$$\begin{cases} \boldsymbol{Y} = \boldsymbol{\beta X} + \boldsymbol{\alpha WY} + \boldsymbol{u} \\ \mathbf{u} = \boldsymbol{\rho} \mathbf{W} \mathbf{u} + \boldsymbol{\varepsilon} \end{cases} \qquad \textbf{Ecuación 1-22}$$

donde ***Y*** es un vector que representa el rendimiento; ***X*** es una matriz de variables independientes, que pueden ser medidas de abundancia de las malas hierbas (densidad,

biomasa o cobertura) y de otras posibles variables bióticas o abióticas; β son parámetros que en el caso de ser **X** diversas especies de maleza, indicarían que tan competitiva son. En el segundo término: α es un parámetro que cuantifica la competencia intraespecífica del cultivo, evaluado de forma autorregresiva con los rendimientos de las plantas de cultivo, esto se representa con la matriz ***W*** que pondera el efecto de cada planta de cultivo sobre sus vecinos de acuerdo a la distancia a la que se encuentran. El término del error *u* se considera si ρ es diferente de cero, esto sucede si los errores tienen dependencia espacial. Si los errores son independientes se considera el error $\varepsilon \sim N(0, \sigma^2)$.

Existen cinco posibilidades dentro de este modelo de acuerdo a si las variables o el error tienen autocorrelación o dependencia espacial, como lo expone Arbia (2014), en donde:

- $\beta = 0$ y alguna de las siguientes: α o $\rho = 0$, se conoce como modelo autorregresivo puro. En donde no habría efecto de las malas hierbas sobre el cultivo, pero si dependencia espacial del cultivo o del error.

- $\alpha = \rho = 0$ se conoce como el modelo de variable independiente rezagada o retardada. En donde no habría dependencia espacial de las plantas de cultivo (competencia intraespecífica), pero si efecto de las malas hierbas sobre el cultivo (modelo lineal).

- $\alpha = 0$, $\rho \neq 0$ se conoce como modelo espacial retardado. En donde existe dependencia espacial del rendimiento del cultivo y efecto de las malas hierbas.

- $\alpha \neq 0$, $\rho = 0$ se conoce como modelo espacial del error. En donde existe efecto de las malas hierbas sobre el cultivo y dependencia espacial de alguna variable no medida (error) pero no del rendimiento.

- $\alpha \neq 0$, $\rho \neq 0$ se conoce como modelo completo. En donde hay efecto de las malas hierbas y existe dependencia espacial tanto del rendimiento del cultivo como del error.

El modelo, al contemplar la dependencia espacial de las plantas de cultivo, puede describir con más precisión la relación entre densidad de malas hierbas y el rendimiento que los modelos lineales, pero también, dentro de los posibles desarrollos de este tipo de modelos existe la posibilidad de crear y ajustar una matriz de pesos perteneciente a las malas hierbas, por lo cual se tendrían que construir dos matrices ***W***: una para el cultivo $\boldsymbol{W_c}$ y otra para las malas hierbas $\boldsymbol{W_w}$.

La matriz $\boldsymbol{W_w}$ representa la cantidad de malas hierbas (densidad, biomasa o cobertura) que existe entre cada planta de cultivo y cada una de sus vecinas. Por lo que intrínsecamente también contempla las distancias entre estas y por lo tanto su distribución espacial.

Encontrar la relación entre la matriz del cultivo y la matriz de malas hierbas o ajustar un modelo usando ambas podría aportar al entendimiento de la relación entre la abundancia de las malas hierbas y el rendimiento del cultivo, teniendo en cuenta la dependencia espacial del rendimiento, de las malas hierbas y su distribución espacial.

De acuerdo con lo anterior, se proponen dos modelos:

$$\mathbf{Y} = \boldsymbol{\beta}\mathbf{X} + \boldsymbol{\alpha}\mathbf{W_c}\mathbf{Y} + \boldsymbol{\lambda}\mathbf{W_w}\mathbf{Y} + \mathbf{u} \qquad \textbf{Ecuación 1-23}$$

o

$$\mathbf{Y} = \boldsymbol{\beta}\mathbf{X} + \boldsymbol{\alpha}(\mathbf{W_c} \,.\, \mathbf{W_w})\mathbf{Y} + \mathbf{u} \qquad \textbf{Ecuación 1-24}$$

En estos casos, $\beta\boldsymbol{X}$ se puede eliminar o se pueden incluir variables diferentes a las malas hierbas (bióticas o abióticas), incluso términos de efectos fijos como los bloques y repeticiones de un ensayo (Shukla y Subrahmanyam, 1999), y λ es un parámetro que indica el efecto interespecífico autorregresivo de las malas hierbas.

Tabla 1-1: Definición de los componentes de los diferentes modelos en las ecuaciones

a	Intercepto – pérdida de cultivo cuando x = 0
A	Pérdida de rendimiento cuando $x \rightarrow \infty$ (infinito)
b	Pendiente - tasa de decrecimiento
b_1	Tasa del efecto del tiempo en modelo lineal
b_2	Tasa de decrecimiento en función del tiempo en modelo hiperbólico
B	Parámetro de curvatura del modelo sigmoidal
d	Parámetro curvatura curvilínea
c_0	Parámetro competencia intraespecífica del cultivo
c_1	Parámetro competencia interespecífica maleza 1
c_j	Parámetro competencia interespecífica maleza j
f	Parámetro que indica la relación entre la competencia intraespecífica e interespecífica
g	Efecto competitivo de la mala hierba (simplifica la sintaxis del modelo en Eq.13)
I	Fracción de pérdida de producción por cada unidad de maleza cuando la $x \rightarrow 0$
LA_c	Promedio del área foliar por planta de cultivo
LA_w	Promedio del área foliar por planta de las malas hierbas
LAI_c	Índice de área foliar del cultivo
LAI_w	Índice de área foliar de la mala hierba
L_w	Índice de área foliar relativo
m	mínimo rendimiento
q	Coeficiente de daño relativo
s_x^2	Varianza de la densidad de malezas
T	Tiempo
TCL	Carga competitiva total
u	Error con dependencia espacial
w	Peso planta cultivo
Y	Rendimiento del cultivo
Y_L	Pérdida de rendimiento

Y_{wf}	Rendimiento del cultivo sin malezas
W	Matriz de pesos calculada desde las distancias entre plantas de cultivo
W_c	Propuesta de matriz de pesos calculada desde las distancias entre plantas de cultivo
W_w	Matriz de pesos calculada desde la abundancia de maleza entre plantas de cultivo
x	Densidad/biomasa malezas
X	Vector de densidad/biomasa/cobertura de malezas
$\dot{x}$	Índice de Lloyd
$\bar{x}$	Promedio de la densidad de malezas
x_0	Densidad cultivo
x_1	Densidad maleza 1
x_i	Densidad maleza más competitiva
x_j	Densidad maleza j
α	Parámetro competencia intraespecífica autorregresiva del cultivo
Φ	Velocidad de decrecimiento del rendimiento
δ	Parámetro de la curvatura que indica en qué punto el rendimiento empieza a disminuir
γ	Parámetro indica la pendiente a la cual se acerca a la asíntota inferior
β	Vector de parámetros
ε	error
λ	Parámetro que indica el efecto interespecífico autorregresivo de las malezas
ρ	Parámetro dependencia espacial del error

1.5. Conclusiones

Un aspecto clave de la Malherbología es el establecimiento del daño que van a producir las malas hierbas en los cultivos. Los modelos empíricos han sido una de las herramientas que más se han utilizado para predecir la reducción del rendimiento de los cultivos y han sido piezas importantes en los sistemas de ayuda a la decisión. Los modelos lineales

fueron los primeros desarrollados, pero pusieron de manifiesto importantes limitaciones para ser utilizados como modelos explicativos de la relación mala hierba-cultivo. Los modelos no lineales presentan una mejor explicación de dicha relación sobre todo a media y altas densidades de infestación. En las últimas décadas el modelo hiperbólico ha emergido como el más popular, debido a que presenta un buen balance entre capacidad explicativa y simplicidad, además ha sido modificado para corregir las limitaciones que presentaba en su versión inicial como la diferencia en el tiempo de emergencia del cultivo y las malas hierbas. El auge de la agricultura de precisión ha vuelto a poner énfasis en la necesidad de conocer la distribución espacial de las malas hierbas y la necesidad de desarrollo de modelos espaciales de interacción malas hierbas-cultivo que permitan establecer nuevas herramientas de ayuda a la toma de decisiones.

1.6. Literatura citada

Arbia, G. (2014). A Primer for Spatial Econometrics With Applications in R. London: Palgrave Macmillan.

Auld, B., & Tisdell, C. (1988). Influence of spatial distribution of weeds on crop yield loss. Plant Protection Quarterly, 3(January), 81.

Blanco, Y., & Leyva, A. (2007). Las arvenses en el agroecosistema y sus beneficios agroecológicos como hospederas de enemigos naturales. Cultivos tropicales, 28(2),21-28

Bosnic, A., & Swanton, C. (1997). Influence of barnyardgrass (Echinochloa crus-galli) time of emergence and density on corn (Zea mays). Weed Science, 45(2), 276–282.

Brain, P., & Cousens, R. (1990). The Effect of Weed Distribution on Predictions of Yield Loss. Journal of Applied Ecology, 27(2), 735–742. https://doi.org/10.2307/2404315

Bridges, D. C., & Chandler, J. M. (1987). Influence of Johnsongrass (Sorghum halepense) Density and Period of Competition on Cotton Yield. Weed Science, 35, 63–67.

Cardina, J., Johnson, G., & Sparrow, D. (1997). The Nature and Consequence of Weed Spatial Distribution. Weed Science, 45(3), 364–373.

Clements, F., Weaver, J., & Hanson, H. (1929). Plant competition: an analysis of community function. Washington, D.C.: Carnegie Institution of Washington.

Cousens, R. (1985a). A simple model relating yield loss to weed density. Annals of Applied Biology, 107(2), 239–252. https://doi.org/10.1111/j.1744-7348.1985.tb01567.x

Cousens, R. (1985b). An Empirical Model Relating Crop Yield to Weed and Crop Density and A Statistical Comparison with Other Models. The Journal of Agricultural Science, 105(3), 513–521. https://doi.org/10.1017/S0021859600059396

Cousens, R., Brain, P., O'Donovan, J., & O'Sullivan, P. (1987). The use of biologically realistic equations to describe the effects of weed density and relative time of emergence on crop yield. Weed Science, 35(5), 720–725.

Deen, W., Cousens, R., Warringa, J., Bastiaans, L., Carberry, P., Rebel, K., … Wang, E. (2003). An evaluation of four crop: Weed competition models using a common data set. Weed Research, 43(2), 116–129. https://doi.org/10.1046/j.1365-3180.2003.00323.x

Dew, D. A. (1972). An Index of Competition for estimating Crop Loss Due to Weeds. Canadian Journal of Plant Science, 52, 921–927. https://doi.org/10.4141/cjps72-159

Gherekhloo, J., Noroozi, S., Mazaheri, D., Ghanbari, A., Ghannadha, M., Vidal, R., & De Prado, R. (2010). Multispecies weed competition and their economic threshold on the wheat crop. Planta Daninha, 28(2), 239–246.

Gomez, A., & Gomez, K. (1984). Statistical procedures for agricultural research. Statistical Procedures for Agricultural Research, 6, 680.

González-Andújar, J. L., Chantre, G. R., Morvillo, C., Blanco, A. M., & Forcella, F. (2016). Predicting field weed emergence with empirical models and soft computing techniques. Weed Research, 56(6), 415–423. https://doi.org/10.1111/wre.12223

González-Andújar, J. L., Fernández-Quintanilla, C., Bastida, F., Calvo, R., Izquierdo, J., & Lezaun, J. (2011). Assessment of a decision support system for chemical control of annual ryegrass (Lolium rigidum) in winter cereals. Weed Research, 51(3), 304–309. https://doi.org/10.1111/j.1365-3180.2011.00842.x

González-Andújar, J. L., Fernández-Quintanilla, C., & Torner, C. (1993). Competencia entre la avena loca (Avena sterilis) y el trigo de invierno: comparación de modelos empíricos. Investigación Agraria: Producción y Protección Vegetales, 8(3), 425–430.

González-Andújar, J. L., & Navarrete, L. (1995). Aplicación del índice de distancias t-cuadrado al estudio de las distribución espacial de las malas hierbas. Investigación Agraria Producción y Protección Vegetales, 10(2), 295–299.

González-Andújar, J. L., & Saavedra, M. (2003). Spatial distribution of annual grass weed populations in winter cereals. Crop Protection, 22(4), 629–633. https://doi.org/10.1016/S0261-2194(02)00247-8

González-Díaz, L., Blanco-Moreno, J. M., & González-Andújar, J. L. (2015). Spatially explicit bioeconomic model for weed management in cereals: Validation

and evaluation of management strategies. Journal of Applied Ecology, 52(1), 240–249. https://doi.org/10.1111/1365-2664.12359

Holst, N., Rasmussen, I., & Bastiaans, L. (2007). Field weed population dynamics : a review of model approaches and applications. Weed Research, 47, 1–14.

Hughes, G. (1996). Incorporating spatial pattern of harmful organisms into crop loss models. Crop Protection, 15(5), 407–421. https://doi.org/10.1016/0261-2194(96)00003-8

Kropff, M., & Spitters, C. (1991). A simple model of crop loss by weed competition from early observations on relative leaf area of the weeds. Weed Research, 31, 97–105.

Kropff, M., & van Laar, H. (1993). Modelling Crop-Weed Interactions. Modelling Crop-Weed Interactions. Wallingford: CAB INTERNATIONAL.

Labrada, R., Caseley, J., & Parker, C. (1996). Manejo de Malezas para Países en Desarrollo. Estudio FAO Producción y Portección vegetal - 120. Rome: Organización de las Naciones Unidas para la Agricultura y la Alimentación.

Marshall, E. (1988). Field-Scale Estimates of Grass Weed Populations in Arable Land. Weed Research, 28(3), 191–198. https://doi.org/10.1111/j.1365-3180.1988.tb01606.x

Mcmaster, G. S., & Wilhelm, W. (1997). Growing degree-days: one equation, two interpretation. Agricultural and Forest Meteorology, 87, 291–300. https://doi.org/10.1016/j.rhum.2013.05.004

Ngouajio, M., Leroux, G., & Lemieux, C. (1999). A flexible sigmoidal model relating crop yield to weed relative leaf cover and its comparison with nested models. Weed Research, 39(4), 329–343. https://doi.org/10.1046/j.1365-3180.1999.00150.x

Norris, R., Elmore, C., Rejmánek, M., & Akey, W. C. (2001). Spatial arrangement, density, and competition between barnyardgrass and tomato: I. Crop growth and yield. Weed Science, 49(1), 61–68.

O'Donovan, J., de St. Remy, E., O'Sullivan, P., Dew, D., & Sharma, A. (1985). Influence of the relative time of emergence of wild oat (Avena fatua) on yield loss of barley (Hordeum vulgare) and wheat (Triticum aesitvum). Weed Science, 33, 498–503.

Oerke, E. (2006). Crop losses to pests. Journal of Agricultural Science, 144, 31–43. https://doi.org/10.1017/S0021859605005708

Radosevich, S. (1987). Methods to Study Interactions Among Crops and Weeds. Weed Technology, 1, 190–198.

Radosevich, S., Holt, J., & Ghersa, C. (2007). Ecology of weeds and invasive plants: Relationship to agriculture and natural resource management. (3 Ed, Ed.). Hoboken, New Jersey.

Rejmánek, M., Robinson, G., & Rejmánková, E. (1989). Weed-Crop Competition: Experimental Designs and Models for Data Analysis. Weed Science, 37(2), 276–284.

Rendón-Aguilar, B., Bernal-Ramírez, L., & Sánchez-Reyes, GA. (2017). Las plantas arvenses: más que hierbas del campo. Oikos=. Instituto de Ecología. Universidad Nacional Autónoma de México.

Renton, M., & Chauhan, B. (2017). Modelling crop-weed competition: Why, what, how and what lies ahead? Crop Protection, 95, 101–108. https://doi.org/10.1016/j.cropro.2016.09.003

Ronchi, C., & Silva, A. (2006). Effects of weed species competition on the growth of young coffee plants. Planta Daninha, 24(3), 415–423. https://doi.org/10.1590/S0100-83582006000300001

Shukla, G., & Subrahmanyam, G. (1999). A Note on an Exact Test and Confidence Interval for Competition and Overlap Effects. Biometrics, 55(March), 273–276.

Spitters, C. (1983). An alternative approach to the analysis of mixed cropping experiments. Netherland Journal of Agricultural Science, 31, 1–11.

Swanton, C., Nkoa, R., & Blackshaw, R. E. (2015). Experimental Methods for Crop – Weed Competition Studies. Weed Science, (2), 2–11. https://doi.org/10.1614/WS-D-13-00062.1

Swanton, C., Weaver, S., Cowan, P., Van Acker, R., Deen, W., & Shreshta, A. (1999). Weed thresholds: theory and applicability. Journal of Crop Production, 2(1), 9–29. https://doi.org/10.1300/J144v02n01

Torner, C., González-Andújar, J. L., & Fernández-Quintanilla, C. (1991). Wild Oat (Avena-Sterilis L) Competition With Winter Barley - Plant-Density Effects. Weed Research, 31(5), 301–307.

Torra, J., Cirujeda, A., Recasens, J., Taberner, A., & Powles, S. B. (2010). PIM (Poppy Integrated Management): A bio-economic decision support model for the management of Papaver rhoeas in rain-fed cropping systems. Weed Research, 50(2), 127–139. https://doi.org/10.1111/j.1365-3180.2010.00761.x

Zanin, G., Berti, A., & Riello, L. (1998). Incorporation of weed spatial variability into the weed control decision-making process. Weed Research, 38(2), 107–118. https://doi.org/10.1046/j.1365-3180.1998.00074.x

Zimdahl, R. (2004). Weed-Crop Competition. A Review (Second Edi). Blackwell Publishing.

Zimdahl, R. (2007). Fundamentals of Weed Science. Elsevier. https://doi.org/10.1016/0378-4290(95)90065-9

2. Generación de datos sintéticos de malezas con diversos escenarios de abundancia, distribución, agregación y dependencia espacial.

D A. Jamaica-Tenjo, E. Darghan, J L González-Andújar

2.1. Resumen

Para estudiar las poblaciones de malezas y su efecto en los cultivos, conocer sus características o evaluar algún experimento, lo más usual es realizar experimentos o evaluaciones *in situ.* Sin embargo, de esta forma solo se cuenta con un escenario: un grado de abundancia, un tipo de distribución o una dependencia espacial. Pero, sí se pudiera generar una cantidad determinada de escenarios que imiten los escenarios "reales" y posibles, se puede probar simultáneamente varios de ellos y con la cantidad de réplicas que se desee. Esta metodología se conoce como investigación *in silico* o generación de datos sintéticos. En este documento se presenta una metodología que permite generar datos sintéticos de malezas y de cultivo, usando el paquete Gstat en el software R, imitando las condiciones y características de las malezas que pueden ser encontradas en los campos. Se generaron 247 escenarios diferentes, mediante la variación de cinco características de las poblaciones de malezas, en tres diferentes niveles cada uno. Abundancia, distribución, dependencia espacial, agregación y competitividad. Se compararon los parámetros resultantes del simulador con los valores teóricos, encontrando que fueron cercanos y que estas características interactuaban entre sí, de tal forma que imitan a las poblaciones de malezas en campos reales.

2.2. Introducción

Las malezas compiten con el cultivo por luz, agua y nutrientes, llegando a producir pérdidas a nivel global de 34% de la producción (Oerke, 2006). Ha sido ampliamente demostrado que las malezas tienen un distribución espacial agregada en los campo de cultivo (Gonzalez-Andujar et al., 2001; González-Andújar and Saavedra, 2003; Marshall, 1988). No considerar esta circunstancia como determinante de la estructura espacial de las poblaciones implica que independientemente de la variable (densidad/biomasa/cobertura) a evaluar, el promedio de esta no va a representar la realidad y puede tener sesgos como la inadecuada predicción de la competencia entre el cultivo y la maleza (Brain y Cousens, 1990b).

Así pues, conocer la estructura espacial de las poblaciones de malezas (ej. dependencia espacial; patchiness, etc.) es de suma importancia, entre otras cosas, para establecer el efecto de las malezas sobre los cultivos, desarrollar simulaciones sobre su dinámica poblacional y aplicar nuevas estrategias de manejo como es la agricultura de precisión.

Los estudios de malezas en las investigaciones de campo, solo obtienen resultados relacionados con las características de la localidad: una cantidad, una agregación, una dependencia espacial y una distribución específica, además, la cantidad de datos a evaluar va a depender y a estar limitada en gran medida al costo en tiempo o en recursos.

De otro lado, el avance computacional permite simular diversos escenarios en lo que se denomina investigaciones *in silico*, convirtiendo a esta herramienta en una metodología esencial para la investigación ecológica (Puerta et al., 2019), ya que los datos sintéticos permiten comparar los resultados con un parámetro teórico dado que este fue definido en la simulación, que además, permite prácticamente generar una cantidad de datos y de escenarios infinita (Legendre et al., 2002).

Sin embargo, para que los datos generados *in silico* se parezcan a las múltiples formas que se pueden encontrar las malezas *in* situ, se requiere disponer los datos en un espacio bidimensional de tal forma que respeten las condiciones y características antes

mencionadas, sobre todo la de dependencia espacial. Esto se puede lograr mediante la generación de campos Gaussianos continuos con dependencia espacial (Webster y Oliver, 2007), definidos como un conjunto de variables correlacionadas y con distribución normal multivariada en un espacio finito en este caso bidimensional (Cressie, 1993; Osborn et al., 2017).

Por ejemplo, Goslee (2006), desde la perspectiva del análisis de la vegetación realizada por ecólogos, presenta una comparación de diferentes métodos de muestreo buscando el más robusto dentro de diferentes escenarios de dependencia espacial. Para lograr esto se ayuda de la simulación de datos generando diez diferentes niveles de dependencia espacial y ocho niveles de abundancia medida en porcentaje de área cubierta. En contraste Heijting (2007), en su investigación acerca del uso del test de Mead para significancia espacial, usó datos *in situ* y sintéticos para compararlos, sin embargo, los datos sintéticos usados fueron patrones de datos fijos que nunca se van a encontrar en la realidad.

En la simulación de los campos de malezas es posible definir la media y la dependencia espacial como realizó Goslee, (2006), pero también es posible establecer diferentes variaciones de la dispersión de los datos, la distribución (patchiness).

Tener la capacidad de generar tantas variaciones, escenarios y simulaciones, haría posible la evaluación de metodologías de muestreo, evaluaciones de modelos y estudios de dinámica espacial y temporal reduciendo los costos de las evaluaciones *in situ*.

El objetivo de este documento es presentar una metodología que permite generar datos similares a las caracterizaciones de comunidades de malezas encontrados en campo.

2.3. Metodología

Para realizar la simulaciones se utilizó la función gstat del paquete *gstat* (Gräler et al., 2016), ampliando el código usado por Goslee (2006) que se puede encontrar en Begueira (2010), que permite incorporar las siguientes características que determinan la estructura

espacial de las comunidades de malezas: la abundancia, la distribución, dependencia espacial y distribución o en este caso el *patchiness*.

Mediante este código se genera un campo gaussiano continuo a partir de la configuración de un modelo de semivariograma, el cual mediante una técnica MonteCarlo de simulación incondicional (Webster y Oliver, 2007), genera valores alrededor de una media, que para nuestro caso fue la **abundancia** de las malezas. Como la variable generada es continua, esta abundancia puede ser expresada como cobertura (%) o como biomasa (g m^{-2}). Se eligió el tipo de semivariograma exponencial, de acuerdo a lo encontrado por diversos autores en condiciones *in situ* (Heisel et al., 1999; Jurado-Expósito et al., 2003; Walter et al., 2002). De la misma forma, el parámetro silla del semivariograma, se puede ajustar para generar diversos grados de dispersión de los datos (varianza), lo que permite configurar diferentes niveles en el radio de la varianza y la media, la cual es una medida de la **agregación** de las malezas (Dale et al., 2002). El parámetro rango del semivariograma, permite establecer diferentes niveles de **dependencia espacial** (Goslee, 2006) y luego de generar los campos continuos se pueden eliminar los valores más bajos en diferentes proporciones para generar parches (**patchiness**) (Goslee, 2006). Finalmente, utilizando el modelo hiperbólico de competencia cultivo-malezas (Cousens, 1985a; Jamaica-Tenjo y Gonzalez-Andujar, 2019) se puede crear un campo de cultivo a partir del campo de las malezas y establecer diversos niveles de **competitividad,** variando el parámetro correspondiente a la perdida máxima de rendimiento cuando las malezas tienden a infinito (A), del modelo citado en la Ecuación 2-1.

En la simulación se establecieron tres niveles, definidos como bajo, medio y alto, teniendo en cuenta resultados encontrados en observaciones *in situ* (Jamaica, 2013) y también que fueran, en lo posible, equidistantes y contrastantes.

Para la **abundancia** promedio de las malezas se escogieron los niveles 10, 40 y 70 en los niveles bajo, medio y alto respectivamente, que pueden interpretarse como biomasa o como porcentajes de coberturas asociadas a un área determinada.

La **agregación**, medida como el cociente entre la varianza y la media (CVM) *in situ* (Dale et al., 2002), tiene las características de dos elementos diferentes en la simulación: por

una parte la dispersión de los datos *per se*, aquí llamada agregación y por otro la proporción de datos no nulos, llamado en este caso *patchiness* o distribución, que también afecta el CVM y otros índices de agregación como por ejemplo el I de Morisita (Holzner y Numata, 1982). Los niveles se establecieron modificando la silla del semivariogama del simulador así: silla=media, silla=2*media y silla=3*media

La **dependencia espacial** se implementó ajustando en 0.5, 1 y 2 veces la distancia máxima entre puntos. En interpolación y modelado usualmente se ajusta el rango de los semivariogramas a la mitad (0.5) de la distancia máxima entre puntos (Webster y Oliver, 2007). Sin embargo, como este procedimiento de simulación genera un campo continuo y posterior a esto se eliminan los datos inferiores para dar la apariencia de parches, fue necesario implementar estos valores de rango para conseguir la dependencia espacial y los parches deseados. Esto se traduce en varios parches pequeños, algunos parches medianos y pocos parches grandes para asociarlo a los niveles bajo, medio y alto respectivamente (Figura 2-3).

La **distribución** o *patchiness* se implementó como el porcentaje de área cubierta por los parches sobre el área total. Se igualó a “cero” o “sin malezas” el 25%, el 50% y el 75% de los datos inferiores respectivamente para los niveles bajo, medio y alto. En este caso, cada uno de los valores restantes se multiplicó por un factor (el inverso de la cantidad de datos eliminados) que permitió mantener el valor promedio de abundancia en el nivel medio, ya que la cantidad de ceros es diferente para cada una.

Como se mencionó anteriormente, usando el parámetro “A” del modelo de competencia hiperbólico (Ecuación 2-1), se puede generar un campo de rendimiento del cultivo proveniente de los datos de la simulación de las malezas, sin embargo, estos resultados no tienen en cuenta la competencia intraespecífica del cultivo, ni otras fuentes de variación, por esta razón se incluye un ruido con distribución N $(0,\sigma^2)$.

$$Y = 100\left[1 - \frac{Ix}{\left(1+\frac{I}{A}x\right)}\right] + \boldsymbol{\varepsilon} \qquad \text{Ecuación 2-1}$$

siendo *Y* el rendimiento del cultivo, *I* es la fracción de pérdida de producción por cada planta de mala hierba cuando $x \rightarrow 0$, el cual fue fijado en 0.015 de forma que con una abundancia de 50 se llegara a la asíntota inferior del modelo; *A* es la pérdida de rendimiento cuando $x \rightarrow \infty$, y *x* es la densidad/biomasa de las malezas, para el caso de los datos sintéticos es la biomasa/cobertura y $\boldsymbol{\varepsilon}$ es el ruido incluido. El valor de *A* toma los valores de 0.1, 0.4 y 0,7 para los niveles bajo, medio y alto de **competitividad**, respectivamente, los cuales se corresponden con pérdidas de rendimiento entre el 10 y 70%.

Este campo de cultivo puede corresponder a cualquier tipo de cultivo, siempre y cuando se tengan los parámetros del modelo de Cousens calculados *a priori.* Con los pixeles generados, los rendimientos del cultivo se pueden relacionar a áreas (cultivo de cereales o perennes sin patrón de siembra regular), o a individuos (cultivos hortícolas o frutales perennes con patrón de siembra regular)

Para este caso, los datos de malezas se generaron en un campo continuo con dependencia espacial. Se crearon áreas de 19*19 celdas, sin embargo, el simulador permite generar campos más grandes y de cualquier forma, de acuerdo con los requerimientos de la investigación.

Como se tienen cinco características de las malezas y tres niveles de cada una, se obtienen un total de 243 combinaciones que son los diferentes escenarios evaluados. Cada uno de estos escenarios fue simulado 50 veces, para un total de 12150 campos de malezas generados. A cada una de estas simulaciones se les evaluó parámetros descriptivos para confirmar su generación.

2.4. Resultados

2.4.1. Pre-simulación

Para observar de forma gráfica el efecto de los diferentes niveles de cada una de las características en la simulación, se realizó una simulación previa manteniendo la semilla

(seed, para que la simulación se genere con los mismos datos) y las demás características constantes en el rango medio.

▪ Abundancia

En la Figura 2-1 se observan los valores bajos (10), medios (40) y altos (70) de la abundancia, manteniendo la misma distribución, agregación y dependencia espacial

Figura 2-1. Mapas generados con datos sintéticos mostrando tres niveles de abundancia de las malezas

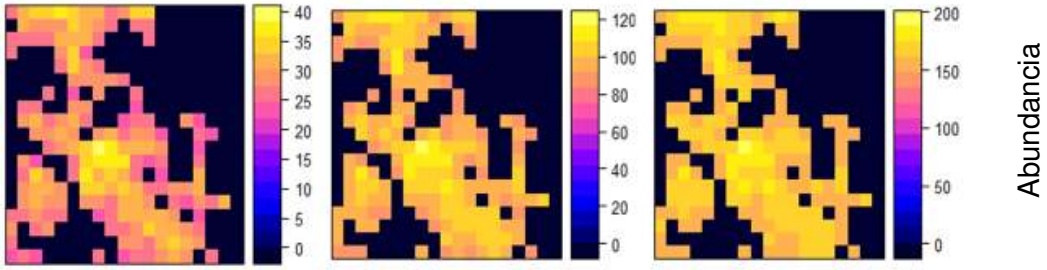

Bajo Medio Alto

▪ Agregación

Se generaron diferentes agregaciones afectadas solo por la varianza de los datos presentes (no ceros), con el mismo promedio de abundancia, distribución y dependencia espacial (Figura 2-2).

Figura 2-2. Mapas simulados con datos sintéticos mostrando tres niveles de agregación

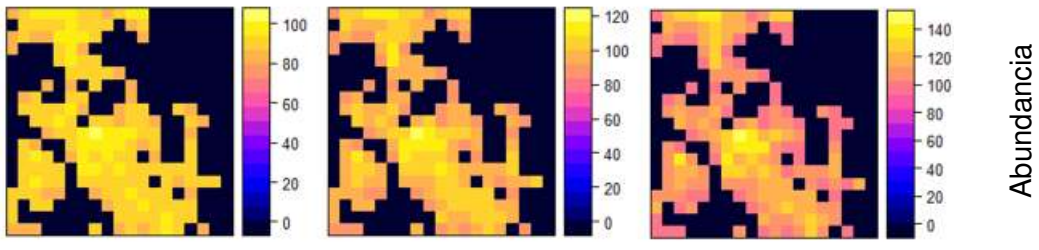

Bajo Medio Alto

▪ Dependencia espacial

Para los tres niveles de dependencia espacial, se crearon varios parches pequeños, algunos parches medianos y un parche grande, para los tres niveles respectivamente (Figura 2-3).

Figura 2-3. Mapas obtenidos con datos sintéticos mostrando tres niveles de dependencia espacial

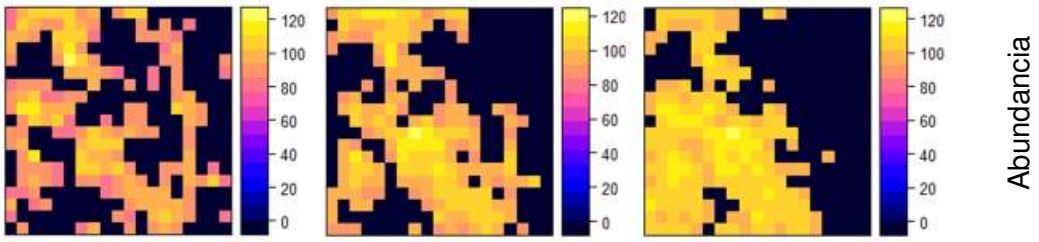

Bajo Medio Alto

▪ Patchiness

La eliminación de los datos inferiores de acuerdo con el nivel de *patchiness* generado también afecta el CVM y por lo tanto su agregación (Figura 2-4). Sin embargo, en este caso se mantiene la varianza de los datos al mismo nivel, al igual que las demás características.

Figura 2-4. Mapas creados con datos sintéticos mostrando tres niveles de patchiness

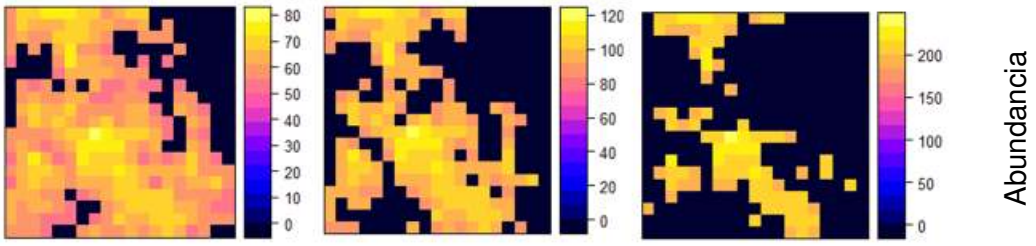

Bajo Medio Alto

- **Competitividad - capacidad de competencia**

La Figura 2-5, corresponde al porcentaje del rendimiento máximo (100%) de cultivo (sintético), por efecto de la competitividad de las malezas presentes. En donde se observa una pérdida máxima de 10, 40 y 70%, del cultivo de acuerdo a los valores fijados para la simulación en el parámetro A.

Figura 2-5. Mapas de cultivo sintetico generados con datos de malezas mostrando tres niveles de competitividad hacia el cultivo

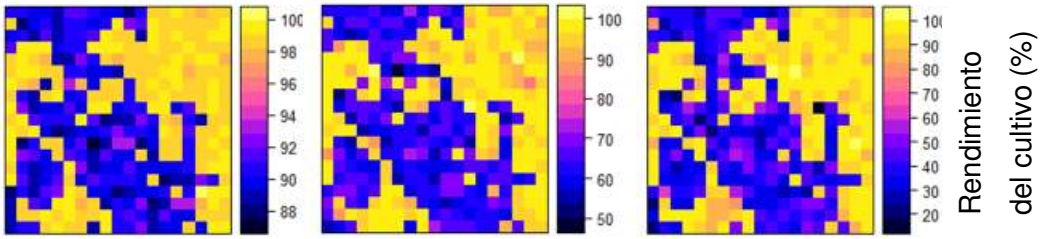

Bajo Medio Alto

2.4.2. Validación

Se calcularon estadísticas descriptivas e índices, para validar que la generación de datos estuviera acorde con lo planteado. En la Figura 2-6 se puede ver que los diferentes niveles de la abundancia (cobertura/biomasa) (10, 40 y 70) están claramente diferenciados y su promedio se encuentra muy cerca de los valores teóricos de abundancia propuestos.

Si a lo anterior se incluye la agregación, se puede observar (Figura 2-7) que ambas interactúan y que a medida que se incrementa la abundancia, la agregación dispersa los datos de mayor forma.

Figura 2-6. Diagrama de cajas de las 50 repeticiones de abundancia de malezas sintéticas para los tres niveles programados.

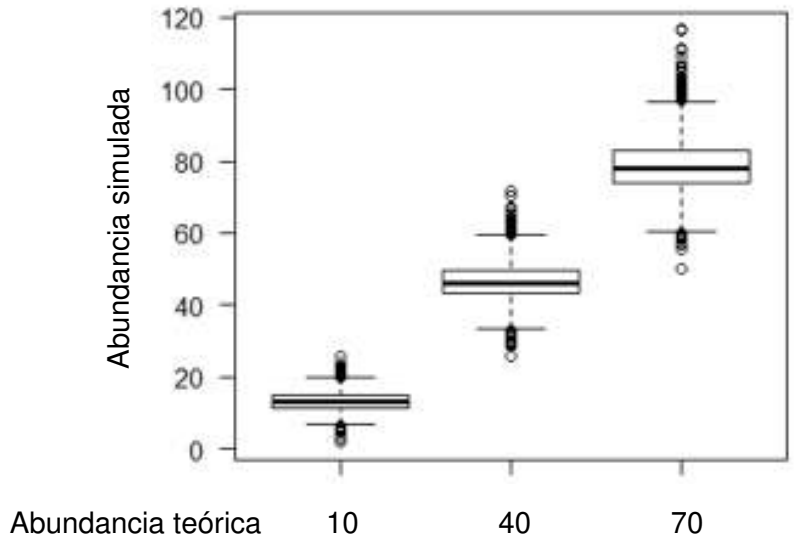

Figura 2-7. Diagrama de cajas de las 50 repeticiones de abundancia de malezas y la agregación

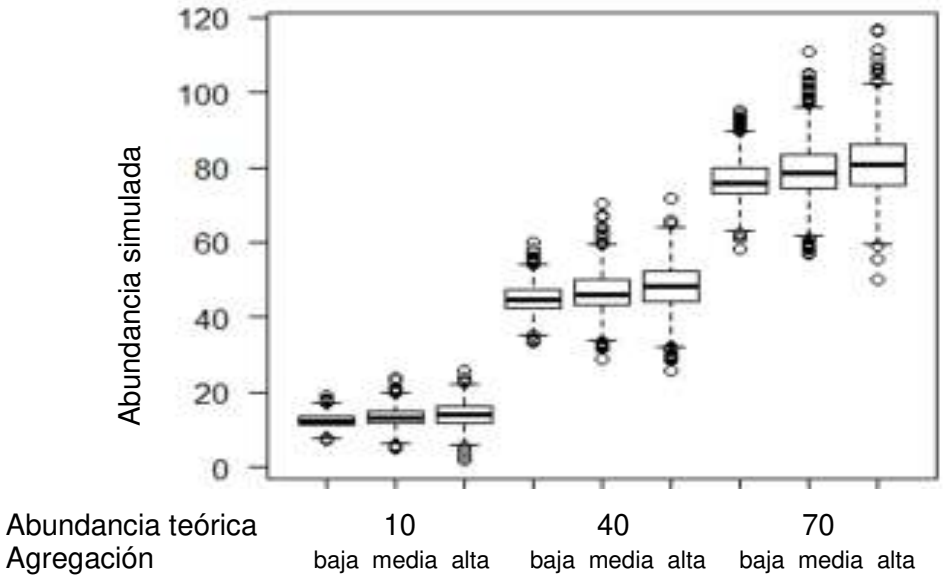

De la misma forma, al evaluar el efecto de las diferentes características de las malezas se encuentran interacciones. Por ejemplo (Figura 2-8) el efecto interactivo del *patchiness*, la competitividad y la abundancia sobre el rendimiento. En donde es razonable que a medida que aumente la abundancia y la competitividad se reduzca el rendimiento; además, las características interactúan. Y el *patchiness*, manteniendo otras características constantes, interactúa con estas haciendo que el rendimiento se reduzca en menor medida. A mayor *patchiness*, menor pérdida de rendimiento, debido a que aunque el promedio de malezas es igual, la proporción de espacio ocupado es menor. Concordando con lo propuesto por Brain y Cousens, (1990) quienes sugieren que a medida que aumenta la agregación-patchiness, el sesgo o error en la estimación del daño al cultivo también lo hace. Esto implica tomar decisiones de manejo incorrectas cuando se usan modelos empíricos de competencia en el proceso de toma de decisiones de manejo.

Figura 2-8. Diagrama de cajas de las 50 repeticiones de datos sintéticos mostrando el efecto de combinado del patchiness, la competitividad y la abundancia sobre el rendimiento del cultivo.

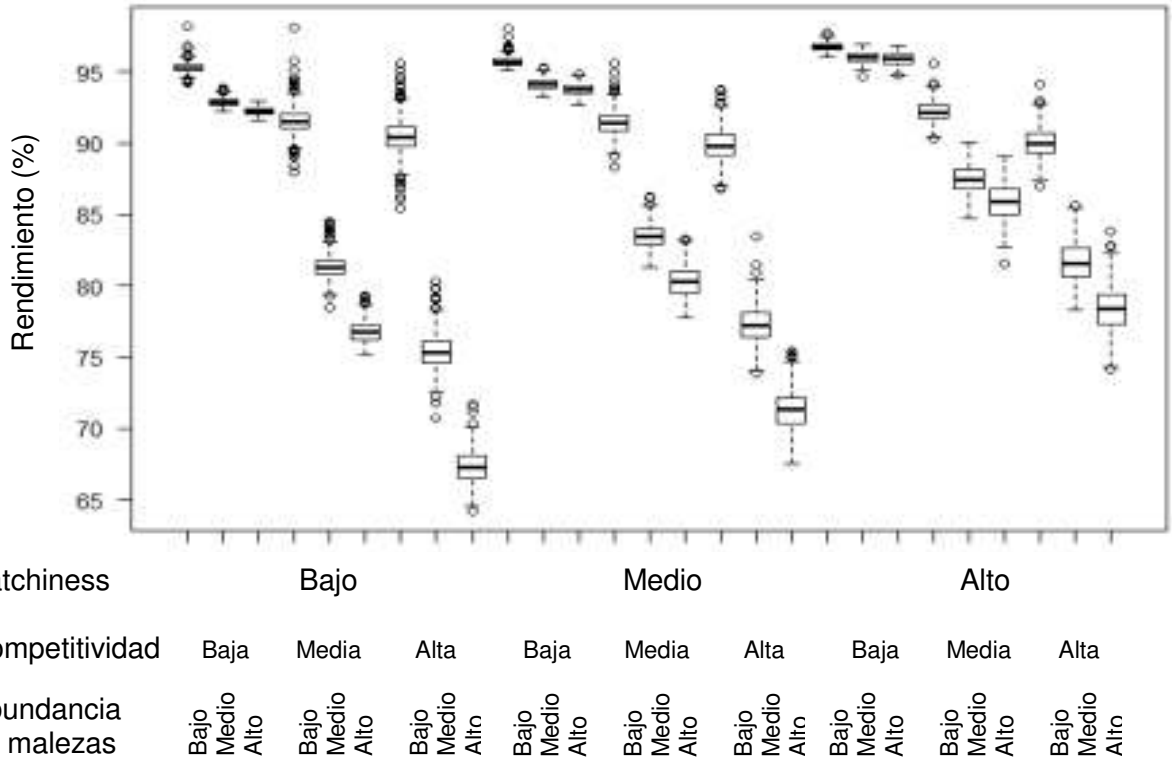

2.5. Discusión

Con la pre-simulación se pudo comprobar de manera visual que los mapas generados corresponden a los diversos escenarios de malezas que pueden encontrarse en evaluaciones *in situ.* Diferentes niveles de abundancia, pocos parches grandes o varios pequeños, diferentes niveles de agregación (CVM) que pueden resultar de variar la dispersión de los datos sobre su media o la proporción de los datos no nulos (patchiness). Escenarios y características que pueden replicarse infinitamente.

Mediante la simulación de las 50 repeticiones se pudo corroborar que los valores de abundancia (biomasa/cobertura) se mantienen estables y muy cerca de los valores teóricos fijados en el simulador, cuando se varían las otras características. Lo que lo vuelve una herramienta precisa al evaluar o comparar ensayos teniendo un valor teórico conocido.

Las cinco características de las malezas desempeñan un papel importante y combinado en el cálculo del rendimiento del cultivo bajo las condiciones de la simulación. Usualmente, los modelos de competencia solo toman la abundancia de las malezas para inferir su efecto en el rendimiento de los cultivos. En algunas ocasiones se toma algún índice de agregación (CVM), como se mencionó en el primer capítulo. Sin embargo, debido a la interacción de las variables ninguna puede tomarse o evaluarse independientemente de las demás.

La generación de un mapa de un campo de cultivo a partir de diferentes características de las malezas puede ser una herramienta valiosa para la evaluación de modelos de competencia o de muestreo. Los cuales podrían evaluarse bajo diversos escenarios de las características de las malezas.

2.6. Literatura citada

Begueira, S. (2010). Generating spatially correlated random fields with R. En: http://santiago.begueria.es/2010/10/generating-spatially-correlated-random-fields-with-r/

Brain, P., & Cousens, R. (1990). The Effect of Weed Distribution on Predictions of Yield Loss. Journal of Applied Ecology, 27(2), 735–742. https://doi.org/10.2307/2404315

Cousens, R. (1985). A simple model relating yield loss to weed density. Annals of Applied Biology, 107(2), 239–252. https://doi.org/10.1111/j.1744-7348.1985.tb01567.x

Cressie, N. (1993). Statistics for spatial data. Hoboken, New Jersey: John Wiley & Sons.

Dale, M. R. T., Dixon, P., Legendre, P., Myers, D. E., & Rosenberg, M. S. (2002). Conceptual and mathematical relationships among methods for spatial analysis. Ecography, 25(5), 558–577. https://doi.org/10.1034/j.1600-0587.2002.250506.x

González-Andújar, J. L., & Saavedra, M. (2003). Spatial distribution of annual grass weed populations in winter cereals. Crop Protection, 22(4), 629–633. https://doi.org/10.1016/S0261-2194(02)00247-8

Goslee, S. C. (2006). Behavior of vegetation sampling methods in the presence of spatial autocorrelation. Plant Ecology, 187(2), 203–212. https://doi.org/10.1007/s11258-005-3495-x

Gräler, B., Pebesma, E., & Heuvelink, G. (2016). Spatio-Temporal Interpolation using gstat. The R Journal, 8(1), 204–218.

Heijting, S. (2007). Spatial analysis of weed patterns. Recuperado de http://library.wur.nl/wda/dissertations/dis4308.pdf

Heisel, T., Ersbøll, A. K., & Andreasen, C. (1999). Weed Mapping with Co-Kriging Using Soil Properties. Precision Agriculture, 1(1), 39–52. https://doi.org/10.1023/A:1009921718225

Jamaica-Tenjo, D. A., & Gonzalez-Andujar, J. L. (2019). Modelos empíricos de competencia cultivo-mala hierba, Revisión bibliográfica. ITEA-Información Técnica Económica Agraria, xx, 1–18. https://doi.org/https://doi.org/10.12706/itea.2019.007

Jamaica, D. (2013). Dinámica espacial y temporal de poblaciones de malezas en cultivos de papa, espinaca y caña de azúcar y su relación con propiedades del suelo en dos localidades de Colombia. Tesis de Maestría en Ciencias Agrarias. Universidad Nacional de Colombia. Pp 82

Jurado-Expósito, M., Lopez-Granados, F., Garcia, L., & Garcia-Ferrer, A. (2003). Multi-Species Weed Spatial Variability and Site-Specific Management Maps in Cultivated Sunflower. Weed Science, 51(3), 319–328. https://doi.org/10.1614/0043-1745(2003)051

Legendre, P., Dale, M. R. T., Fortin, M. J., Gurevitch, J., Hohn, M., & Myers, D. (2002). The consequences of spatial structure for the design and analysis of ecological field surveys. Ecography, 25(5), 601–615. https://doi.org/10.1034/j.1600-0587.2002.250508.x

Marshall, E. (1988). Field-Scale Estimates of Grass Weed Populations in Arable Land. Weed Research, 28(3), 191–198. https://doi.org/10.1111/j.1365-3180.1988.tb01606.x

Osborn, S., Panayot, V., & Villa, U. (2017). A multilevel hierarchical sampling technique for spatially correlated random fields. SIAM Journal on Scientific computing, 39(5), S543–S562. https://doi.org/10.1137/090750688

Puerta, P., Ciannelli, L., & Johnson, B. (2019). A simulation framework for evaluating multi-stage sampling designs in populations with spatially structured traits. PeerJ, 7, e6471. https://doi.org/10.7717/peerj.6471

Walter, A., Christensen, S., & Simmelsgaard, S. (2002). Spatial correlation between weed species densities and soil properties. Weed Research, 42(1), 26–38. https://doi.org/10.1046/j.1365-3180.2002.00259.x

Webster, R., & Oliver, M. (2007). Geostatistics for Environmental Scientists. Wiley. https://doi.org/10.2136/vzj2002.0321

3. Uso de modelos de regresión espacial en el estudio de la competencia entre las malezas y el cultivo

D A. Jamaica-Tenjo, E. Darghan, J L González-Andujar

3.1. Resumen

Los modelos de competencia maleza-cultivo comúnmente usados no contemplan la heterogeneidad y la dependencia espacial tanto de las malezas como del cultivo, llevando a decisiones sesgadas o erróneas en la toma de decisiones de manejo. Por esta razón, en este capítulo se proponen y evalúan algunas variantes de un modelo autorregresivo espacial, que incorporan dichos supuestos. Para ilustrar su uso y evaluar sus posibilidades, se usó un simulador de campos Gaussianos para generar diversos escenarios de las malezas y de cultivo a partir de características como: competitividad, agregación, distribución y abundancia, incluyendo errores, tanto ruido blanco, como dependiente del espacio. Se encontró que los residuales de los modelos lineales presentaron dependencia espacial y los modelos de regresión espacial mostraron significancia para los parámetros autorregresivos, lo que justifica el uso de la regresión espacial para la evaluación de la interferencia de las malezas hacia el cultivo. El modelo completo fue el que tuvo mejor ajuste basado en el criterio de información de Akaike. El parámetro α del modelo fue negativo, por lo que sugiere algún tipo de competencia intraespecífica entre plantas de cultivo y, además, este disminuye a medida que aumenta la cantidad de malezas. Por lo tanto, se concluye que al aumentar la competencia interespecífica, disminuye la intraespecífica, sugiriendo algún tipo de aditividad entre estos.

3.2. Introducción

Las malezas afectan negativamente la producción agrícola, y encontrar modelos que relacionen dicho efecto se vuelve una necesidad al momento de crear herramientas que permitan tomar las mejores decisiones de manejo por parte de los productores (Renton y Chauhan, 2017).

Los modelos que relacionan la pérdida de rendimiento de cultivo con la abundancia de las malezas son utilizados en la práctica para calcular umbrales de acción, con los cuales se pretende maximizar los beneficios de una práctica de manejo relacionando su costo y su beneficio (Zanin et al., 1998; González-Andújar et al., 2011).

Los primeros modelos usados bajo este contexto fueron lineales (Ecuación 3-1), los cuales se expresaron matemáticamente como (Dew, 1972):

$$\boldsymbol{y = a + bx + \varepsilon} \qquad \textbf{Ecuación 3-1}$$

donde *y* se asocia al rendimiento del cultivo, *x* representa la densidad de malezas, siendo *a* y *b* los parámetros del modelo que representan el máximo rendimiento del cultivo y la pérdida de cultivo por cada unidad de maleza, siendo *b* negativa, indicando una pérdida de rendimiento por la presencia de malezas y ε indica el error del modelo.

Posterior al uso de estos modelos lineales simples se desarrollaron modelos no lineales (Ecuación 3-2), donde uno de los más comunes fue el propuesto por (Cousens, 1985), expresado como:

$$\boldsymbol{y = a\left[1 - \frac{Ix}{100\left(1+\frac{Ix}{A}\right)}\right] + \varepsilon} \qquad \textbf{Ecuación 3-2}$$

en el cual *a* es uno de los parámetros del modelo y representa el máximo rendimiento del cultivo, I es otro parámetro del modelo y representa la pérdida de rendimiento cuando m tiende a 0, y A es la pérdida de rendimiento cuando m tiende a infinito, siendo *x* la densidad de malezas.

Cabe mencionar que los efectos de las malezas sobre los cultivos son únicas y dependen del contexto edafoclimático en el cual se desenvuelven, por lo que no siempre un modelo en particular se puede ajustar a todos los escenarios. Por esta razón, las estimaciones de los parámetros de los modelos son inherentes a cada relación ambiente-cultivo-maleza.

Siendo más específicos acerca de la singularidad de estas relaciones: la distribución heterogénea de características del suelo como nutrientes, humedad, pH, entre otras, hace que en cada lugar de un campo la abundancia y diversidad de malezas sea diferente, y todo esto tiene un efecto sobre el rendimiento del cultivo. Por lo tanto, la relación de las malezas con el cultivo (competencia) es única para cada sitio. Es por esta razón que los modelos deben incluir un componente que tenga en cuenta la heterogeneidad espacial de las variables, aun cuando el cultivo sea de ciclo corto y la variabilidad temporal sea relativamente controlada. Lo anterior con el fin de no obtener resultados espurios que generen decisiones equivocadas en cuanto al manejo de las poblaciones de malezas. Sobre todo, estando ahora inmersos en el contexto de la agricultura de precisión, pues el uso de altas tecnologías que capturan con facilidad los datos podría perder su interesante información, solo porque el manejo estadístico no resulta el más conveniente.

Los modelos comúnmente usados, tanto de competencia como bio-económicos para el cálculo de umbrales de acción, asumen la distribución espacial homogénea y la agregación uniforme tanto del cultivo como de las malezas (Auld y Tisdell, 1988; Cardina et al., 1997; Norris et al., 2001). Aunque ha habido algunos avances para tener en cuenta la distribución agregada y en parches de las malezas. Se han usado desde distribuciones estadísticas que toman en cuenta la naturaleza cuantitativa discreta del conteo de malezas (distribución Poisson, Binomial negativa, entre otras), hasta la propia naturaleza multivariable asociada con las diferentes especies de malezas encontradas en los muestreos, así como la creación de índices de distancia asociados a la distribución espacial de las malezas (Brain y Cousens, 1990; González-Andújar y Navarrete, 1995; Hughes, 1996; González-Andújar y Saavedra, 2003).

Sin embargo, en la literatura no se han encontrado modelos que tengan en cuenta la dependencia espacial de las maleza y cultivo de forma explícita involucrando matrices de

distancia dentro de los modelos y una estructura espacial de dependencia de los errores. Por esta razón, el uso de modelos de regresión espacial puede constituir una herramienta valiosa en la estimación de pérdida del rendimiento a causa de las malezas teniendo en cuenta la distribución espacial de las mismas dentro del cultivo (Anselin y Bera, 1998).

La forma general del modelo de regresión espacial (Ecuación 3-3) según Arbia (2014) es:

$$\begin{cases} \boldsymbol{Y} = \boldsymbol{\beta X} + \boldsymbol{\alpha W Y} + \boldsymbol{u} \\ \boldsymbol{u} = \boldsymbol{\rho W u} + \boldsymbol{\varepsilon} \end{cases} \qquad \textbf{Ecuación } \textit{3-3}$$

donde ***Y*** representa al vector de rendimiento, ***X*** es una matriz de variables explicativas que pueden ser medidas de abundancia de las malezas (densidad, biomasa o cobertura) o de otras posibles variables bióticas o abióticas, β representa al vector de parámetros de las variables explicativas. En el segundo término, α es un parámetro que indica que tanto es explicado el rendimiento de una planta de cultivo a partir del rendimiento de las plantas vecinas (coeficiente autorregresivo también conocido como coeficiente de competencia). En el mismo término se define la matriz ***W*** que pondera el efecto de cada planta de cultivo sobre sus vecinos de acuerdo con la distancia a la que se encuentran (matriz de pesos). En este sentido encontrar la variable Y como respuesta y como variable explicativa (afectada por los rezagos espaciales) ha hecho que estos modelos sean llamados como autorregresivos.

La conformación de la matriz de pesos dará la importancia a los vecinos según las distancias o por el simple hecho de tener o no tener un vecino cerca (como sucede en los polígonos de Voronoy), de aquí que suelen disponerse de varios modelos de matrices de pesos, desde aquellas que solo toman los vecinos más cercanos hasta las que consideran todos los vecinos. Finalmente se tiene al término del error *u* asociado a los residuales del modelo, que, en este caso, pueden poseer una estructura de dependencia entre sí definida por la parte inferior de la **Ecuación 3-3**, siendo ρ el coeficiente de autocorrelación espacial de los residuales. Si los errores resultan independientes, es decir $\rho = 0$, se considera que el error *u* es igual a ε, donde $\varepsilon \sim$ i.i.d. $N(0, \sigma^2)$, la cual es la estructura del error más común en los modelos de regresión no espacial. El modelo propuesto tiene variaciones de acuerdo a las características de sus parámetros, la cual puede entenderse claramente desde la

taxonomía de Elhorst (2010), la cual se amplió ligeramente para incorporar el modelo autorregresivo puro (Figura 3-1).

Un ejemplo del uso de modelos de regresión espacial en agricultura se encuentra en Florax et al., (2002), en el que se hace un análisis comparativo del uso de estos modelos contra el análisis OLS (mínimos cuadrados ordinarios) que se usa de forma convencional, en un cultivo de mijo. En este se muestra que el rendimiento del cultivo es una variable con dependencia espacial intrínseca, por lo que el análisis de varianza de ciertos factores puede llevar a conclusiones sesgadas o erróneas cuando la variable respuesta o el error tienen dependencia espacial, poniendo como mejor opción al modelado espacial, pues provee una base más adecuada para manejar la fertilización en el marco de la agricultura de precisión. Otro caso más reciente se puede encontrar en Rodríguez et al., (2019), donde se modeló el contenido de cadmio en un cultivo de cacao a dos profundidades del suelo, encontrando nuevamente dependencia espacial y justificando el uso de modelos de regresión espacial cuando se tienen variables regionalizadas.

Como se mencionó anteriormente, de acuerdo con las variaciones de los modelos de regresión espacial, se puede incluir la abundancia de las malezas como variables independientes en el primer término de la ecuación, como variables rezagadas o como parte de la matriz de pesos, con lo cual se tiene en cuenta su dependencia espacial. De la misma forma se puede hacer con las variables abióticas.

La evaluación de los modelos, se puede realizar con datos *in vivo* o datos *in silico* mediante la simulación de campos Gaussianos continuos (Webster y Oliver, 2007), de esta forma se pueden generar campos de malezas, que imitan las características que se pueden tener en campo como: la abundancia (cantidad de malezas), agregación (agregada, uniforme, aleatoria), distribución (% celdas con maleza del total de celdas), dependencia espacial (pocos parches grandes o varios pequeños) e incluso la competitividad hacia el cultivo (% de pérdida de cultivo cuando maleza tiene a infinito), con lo cual se genera un campo de datos del rendimiento del cultivo. Por lo anterior, el objetivo de este capítulo consiste en explorar el uso de los modelos de regresión espacial en la evaluación de la competencia de malezas y cultivo.

Figura 3-1. Taxonomía de los modelos de regresión espacial. Modificado de Elhorst, (2010).

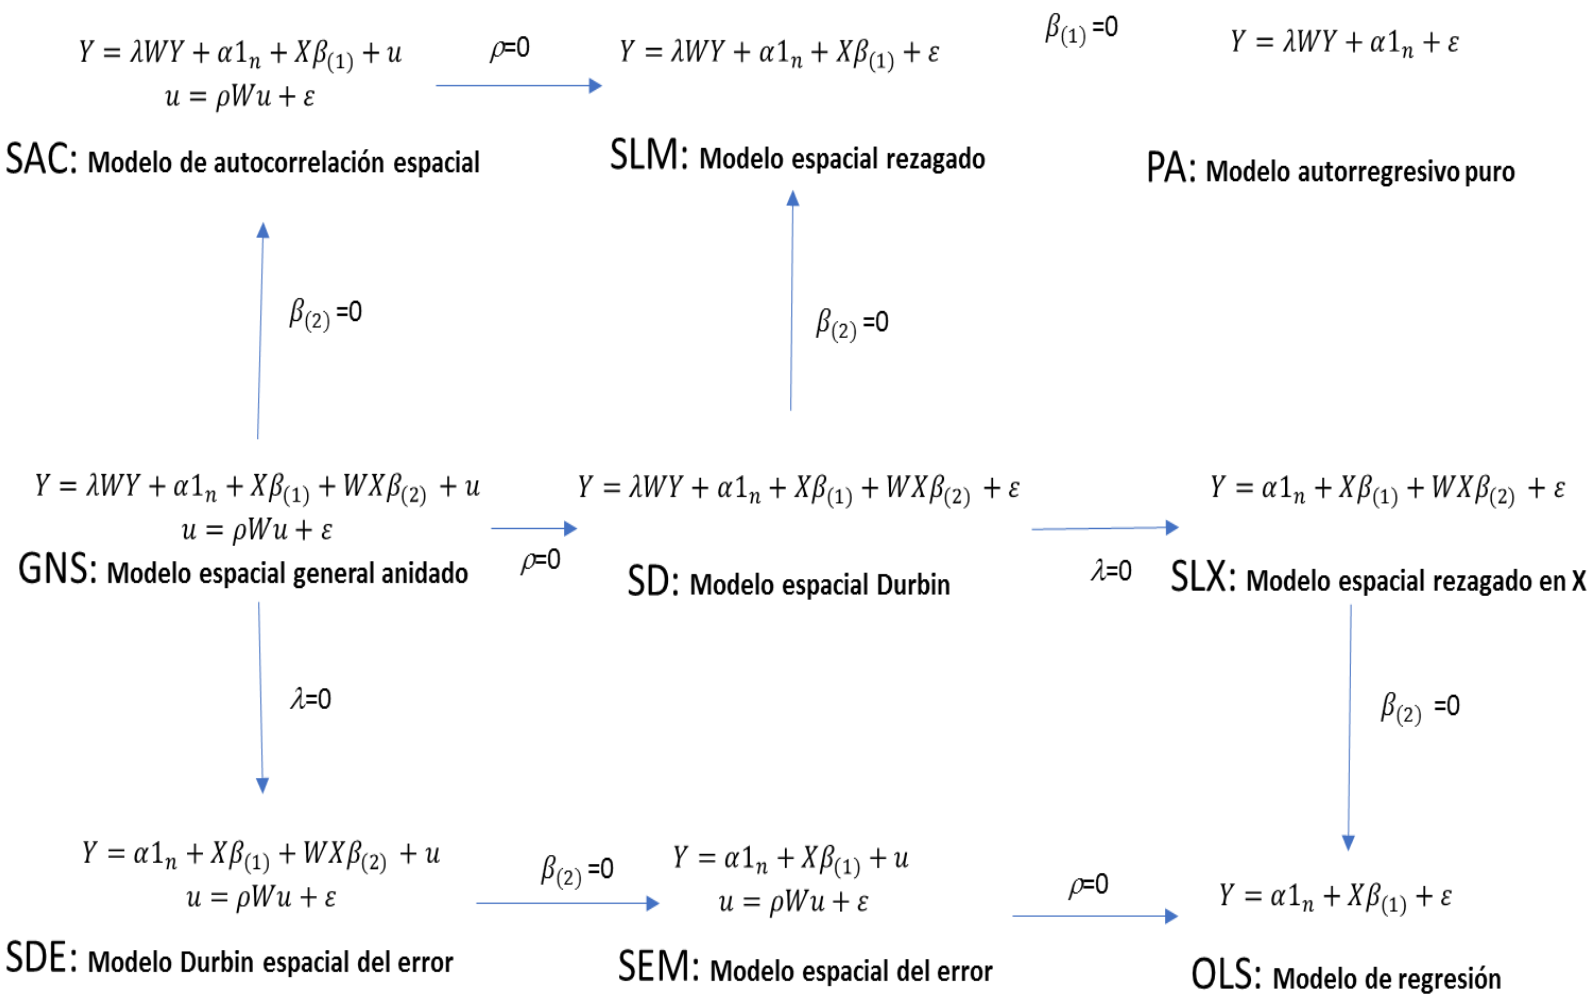

3.3. Metodología

3.3.1. Generación de los escenarios de simulación para la obtención de datos

Mediante un algoritmo con el paquete Gstat de R, inicialmente se generó un escenario para ilustrar el uso de los modelos autorregresivos espaciales, teniendo en cuenta que los valores de las cinco características de malezas y cultivo simulados, no estuvieran en los extremos. En donde, la **abundancia** de malezas, se puede asociar a la cobertura y se ajustó en 40. La **agregación** indica que los datos tienen mayor varianza que media, esto se realiza de forma parcial en el simulador mediante el modelo del semivariograma en donde se ajusta el parámetro silla, en este caso se ajustó para tener un coeficiente de variación de 14.5 que actúa en conjunto con la **distribución**. La cual, se ajustó para que la proporción del campo cubierto con malezas fuera de 75%. La **dependencia espacial,** se ajustó en el simulador mediante el parámetro del rango del semivariograma. Esta, se ajustó para tener uno o dos parches de medianos a grandes. La **competitividad** se ajustó mediante el parámetro A del modelo de competencia de Cousens en un nivel medio, considerando que el efecto competitivo máximo de las malezas hacia el cultivo es de 40% de la pérdida de rendimiento, generando de esta forma, el campo de datos de cultivo. Para un mayor detalle acerca del simulador y sus características, se puede revisar el segundo capítulo.

Como el modelo tiene en cuenta si el error tiene o no dependencia espacial, también se simularon ambos tipos de errores. Para el error con dependencia espacial se incluyó, mediante algebra de mapas, una variable creada con el mismo procedimiento de campos Gaussianos con media cero, rango alto y ajustada para que el efecto de su desviación no fuera superior al 10% del total de la variación del campo de cultivo. Para el error sin dependencia espacial (ruido blanco) se incluyó también mediante algebra de mapas, una variable generada con números aleatorios con distribución normal, media cero y varianza ajustada para que no fuera superior al 10% de total de la variación de los datos, de forma

similar a la descrita en El Sharif et al. (2015) para la inclusión de ruido blanco en las simulaciones. De forma gráfica se muestra en la Figura 3-2.

Posteriormente se generaron diversos escenarios para evaluar solo en el modelo completo. En estos escenarios se varió la abundancia, la distribución y la competitividad en tres niveles (Tabla 3-1), pero sin hacer las combinaciones entre ellos, es decir, se evalúan tres niveles para cada una de las características de las malezas, manteniendo el nivel medio de los demás, para un total de siete escenarios. Para cada escenario se realizó análisis estadístico descriptivo, búsqueda de correlación y de dependencia espacial en los errores

Tabla 3-1. Escenarios simulados para evaluar en el modelo completo, abundancia (% cobertura), distribución (% de celdas con presencia de malezas/total de celdas), y competitividad de las malezas (% máxima pérdida de rendimiento cuando malezas tienden a infinito)

Escenario	Abundancia	Distribución	Competitividad
1	30	70	20
2	30	70	60
3	30	85	40
4	30	55	40
5	10	70	40
6	30	70	40
7	50	70	40

Figura 3-2. Procedimiento para la creación de campos de cultivo a partir de los campos de malezas, con la inclusión del error espacial y del error sin dependencia espacial (ruido blanco)

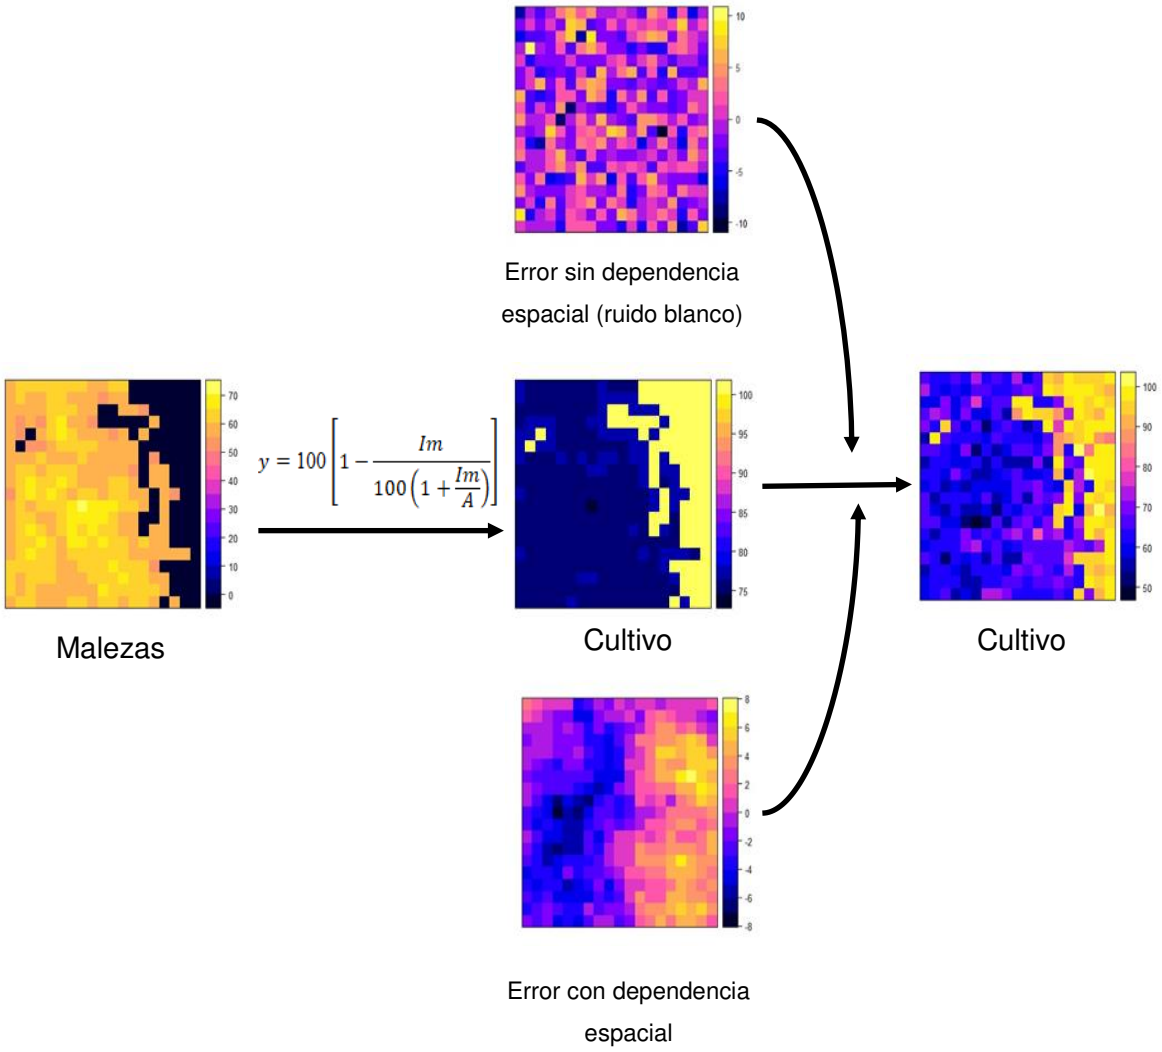

3.3.2. Ajuste de modelos de regresión espacial

En este capítulo se ilustrará el uso de los modelos de regresión espacial y se evalúa en el modelo completo algunas variaciones de las características de las malezas, utilizando el criterio de información propuesto por Akaike (1974) en adelante AIC, como medida de

ajuste de cada modelo, finalmente haciendo una comparación entre los valores generados por el simulador y los predichos por cada modelo. Este procedimiento fue realizado con el paquete Spdep, del software R.

3.4. Resultados y discusión

De acuerdo al procedimiento establecido en la Tabla 3-1 y Figura 3-2, se generaron diversos campos de cultivo y de maleza de los cuales se muestra un ejemplo en la Figura 3-3. En esta, se puede observar que se generó un parche de malezas que ocupa el costado izquierdo del mapa con una abundancia promedio de 45.4 (biomasa/cobertura), siendo un valor cercano a la abundancia teórica, la cual que fue ajustada en 40. El cultivo se calcula en función de las malezas encontradas, por lo tanto, el mayor rendimiento se encuentra en ausencia de las malezas (costado derecho), las variaciones del rendimiento de cultivo se deben tanto a las variaciones en la abundancia de malezas, como a la adición del ruido blanco y al error con dependencia espacial. El índice de Moran, el cual indica dependencia espacial fue significativo tanto para las malezas como para el cultivo. Otras estadísticas descriptivas también se muestran en la Tabla 3-2.

Figura 3-3. Ejemplo de un mapa de malezas y de cultivo a partir de la simulación establecida

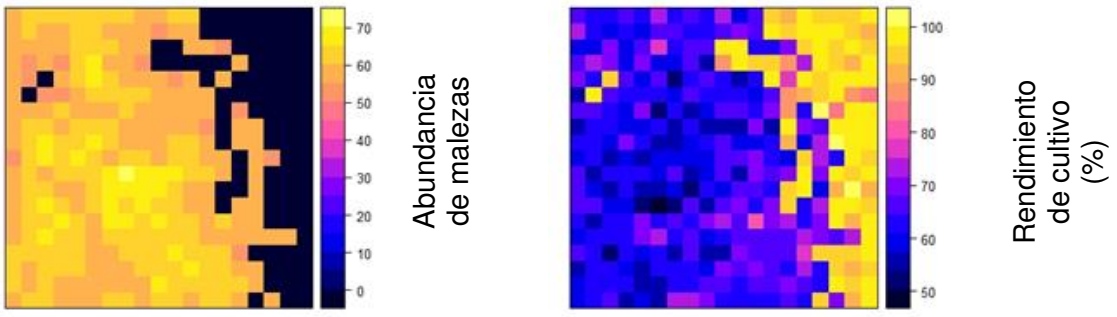

Tabla 3-2. Estadística descriptiva de las malezas y del cultivo para la simulación

Media de la abundancia (%) de las malezas	Media del rendimiento (%) del Cultivo	Varianza de las Malezas	Varianza del Cultivo	Índice de Moran del Cultivo. Global	Índice de Moran de la Maleza. Global
45.40	82.42	695.68	84.62	0.171	0.229

Una de las justificaciones para el uso de modelos de regresión espacial es que en los modelos lineales los residuales presenten dependencia espacial. Por esto, se realizó un modelo de regresión lineal tipo: $y{\sim}1$ o escrito de otra forma: $y = m + \varepsilon$, es decir, donde el modelo ajustado es igual a una constante que es el promedio de *y* (m), para conocer el comportamiento de los residuales que se evaluarían en el modelo autorregresivo puro. También, se realizó un modelo de regresión lineal tipo: $y{\sim}x$ o también: $y = m + x\beta + \varepsilon$, es decir, donde *y* es afectado por la variable independiente *x*, para conocer el comportamiento de los residuales que justificarían el uso de los demás modelos de regresión espacial que tienen a *x* como variable independiente.

Se encontró que los residuales en $y{\sim}1$ no distribuyen normal, y en $x{\sim}y$ si lo hacen, pero ambos modelos presentan dependencia espacial, expresado en el I de Moran (Tabla 3-3). Esto indica que una forma más acertada de relacionar la abundancia de malezas con el rendimiento del cultivo son los modelos de regresión espacial (Anselin et al., 2004; Arbia, 2014; Florax et al., 2002; Heege, 2013; Matheron, 1963).

Tabla 3-3. Valor-P de Shapiro-Wilk e I de Moran para los residuales del modelo lineal *y~1* y *y~x*.

Modelo lineal	Valor-p de Shapiro-Wilk	I de Moran Global	Valor-p de I de Moran Global
y~1	0	0.59	0
y~x	0.13	0.35	0

3.4.1. Modelos de regresión espacial

Una vez justificado su uso, los modelos de regresión espacial evaluados fueron los siguientes:

Autorregresivo puro $\boldsymbol{Y} = m + \alpha \boldsymbol{W}\boldsymbol{Y} + \varepsilon$ *Ecuación* 3-4 (A)

Modelo espacial del error $\begin{cases} \boldsymbol{Y} = m + x\beta + u \\ u = p\boldsymbol{W}u + \varepsilon \end{cases}$ *Ecuación* 3-5 (B)

Modelo espacial rezagado $\boldsymbol{Y} = m + xB + \alpha \boldsymbol{W} y + \varepsilon$ *Ecuación* 3-6 (C)

Modelo de autocorrelación espacial $\begin{cases} \boldsymbol{Y} = m + x\beta + \alpha \boldsymbol{W} y + u \\ u = p\boldsymbol{W}u + \varepsilon \end{cases}$ *Ecuación* 3-7 (D)

En los modelos evaluados se encontró que todos los parámetros fueron altamente significativos (Valor-P inferior a 0.01). También, que los modelos de mejor ajuste según AIC, fueron los que tuvieron en cuenta la dependencia espacial del error (Tabla 3-4). El mejor modelo fue el de autocorrelación espacial.

Los modelos de regresión espacial contemplados mostraron un buen ajuste a pesar de la relación no lineal del cultivo y la maleza, en el sentido de modelar la dependencia espacial y que la correlación entre observados y estimados fue de alrededor 0.9.

En el modelo autorregresivo puro, se logra un ajuste significativo de los parámetros α y *m*, indicando que el rendimiento de las plantas de cultivo puede incluso explicarse solo por el rendimiento de las plantas vecinas, para el escenario simulado.

El modelo espacial rezagado, tuvo todos sus parámetros significativos, aunque su ajuste según AIC fue menor. Esto se debe a que en los otros modelos el parámetro autorregresivo del error fue significativo y este modelo no lo tiene en cuenta.

El parámetro β fue similar para todos los modelos bajo un solo escenario.

Tabla 3-4. Parámetros calculados de los diferentes modelos para el escenario simulado

Modelo	m	α	ρ	β	Correlación entre observados y estimados	AIC
A	82.42	0.693	NA	NA	0.7258	2436
B	97.96	NA	0.518	-0.342	0.9278	1950
C	88.62	0.088	NA	-0.296	0.904	2018
D	117	-0.22	0.658	-0.357	0.938	1926

3.4.2. Modelo de autocorrelación espacial para los siete escenarios simulados

Se simularon siete campos infestados de malezas para evaluar el modelo de autocorrelación espacial. De donde se obtienen las estadísticas descriptivas para

corroborar que la simulación estuvo acorde a los parámetros teóricos planteados (Tabla 3-5).

Como se observó anteriormente, el modelo de autocorrelacion espacial fue el que tuvo mejor ajuste según AIC. También en este caso, los valores observados correlacionan con los valores estimados (0.9) (Figura 3-4). Además, el parámetro autorregresivo del error *p* y el *β*, tuvieron un comportamiento similar a los modelos del error y espacial rezagado respectivamente. Sin embargo, el parámetro α es negativo, por lo que sugiere algún tipo de competencia intraespecífica entre plantas de cultivo y, además, disminuye a medida que aumenta la cantidad de malezas, sugiriendo que, al aumentar la competencia interespecífica, disminuye la intraespecífica.

Esto se corroboró al simular diferentes niveles del parámetro de competencia en el simulador, en donde al aumentar la competencia de las malezas, manteniendo su cantidad, disminuye el efecto negativo (α) de los datos de cultivo con sus vecinas y se incrementa el valor del parámetro *β* en la misma proporción (0.2 a 0.26; 0.4 a 0.48; 0.6 a 0.64), también, en compensación el parámetro ρ disminuye, es decir, el efecto del error espacial se hace menos importante.

Para la característica distribución (Tabla 3-6) (% de celdas con maleza/total de celdas), en la medida que las malezas abarcan una menor superficie, el modelo tiene un menor ajuste según AIC, y todos los parámetros disminuyen, aunque no dejan de ser significativos. Para la abundancia (ind/m^2), a medida que aumenta, los parámetros β y ρ, disminuyen, compensando con una disminución del parámetro α. El parámetro β obviamente disminuye en compensación con un aumento en la cantidad de malezas, para mantener el mismo rendimiento de cultivo.

Tabla 3-5. Estadística descriptiva de las malezas y del cultivo para los diferentes escenarios simulados

Escenario	Media de las malezas	Media del cultivo	Varianza de las malezas	Varianza del cultivo	Índice de Moran del cultivo, global	Índice de Moran de la maleza, global
1	36.75	88.36	587.01	41.23	0.657	0.514
2	36.75	72.95	587.02	238.27	0.657	0.547
3	35.85	77.51	236.95	79.16	0.731	0.593
4	37.63	81.86	1164.01	175.81	0.576	0.477
5	13.89	86.15	85.50	59.88	0.675	0.548
6	36.75	79.6	587.01	132.67	0.657	0.536
7	58.74	77.19	1491	167.25	0.649	0.533

Tabla 3-6. Parámetros del modelo completo para los diferentes escenarios simulados

Escenario	Nivel	m	α	ρ	β	Correlación entre observados y estimados	AIC
1	Comp. baja	115.6	-0.20	0.57	-0.26	0.91	1758
6	Comp. media	107.2	-0.12	0.29	-0.48	0.94	2030
2	Comp. alta	104.2	-0.10*	0.17	-0.64	0.95	2190
3	Dist. alta	114.1	-0.19	0.62	-0.59	0.93	1910
6	Dist. media	107.2	-0.12	0.29	-0.48	0.94	2030
4	Dist. baja	103.3	-0.08*	0.19	-0.38	0.94	2075
5	Abun. baja	111.2	-0.15	0.46	-0.83	0.92	1833
6	Abun. media	107.2	-0.12	0.29	-0.48	0.94	2030
7	Abun. alta	105.9	-0.12	0.24	-0.33	0.94	2091

* No significativo al 0.05, sino al 0.1.

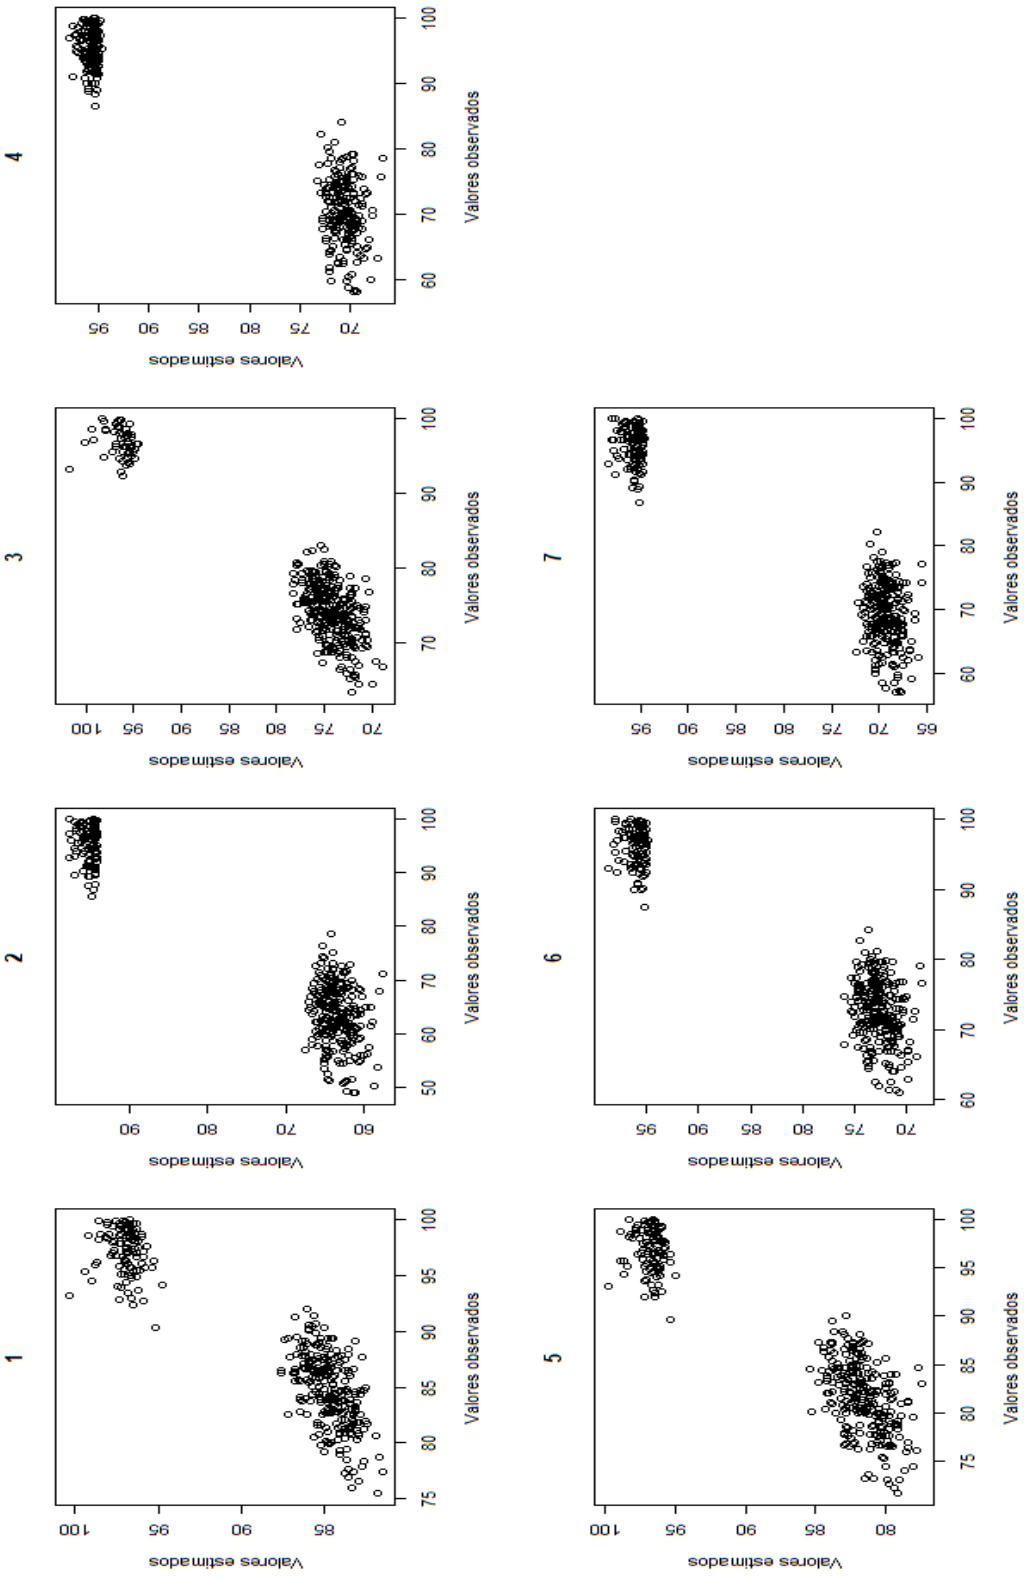

Figura 3-4. Comparativo entre los valores observados (simulados) y estimados del modelo completo para los siete escenarios simulados.

3.5. Conclusiones

Los modelos autorregresivos espaciales son una alternativa interesante y justificada para el modelado de la interacción cultivo-maleza, ya que tiene en cuenta la dependencia espacial de los datos de cultivo. El parámetro β, se puede denominar como el parámetro de competencia interespecífico como se presenta en los modelos lineales de Dew, (1972).

Cuando se incluye la variable independiente malezas, el parámetro α se hace negativo. Esto sugiere que, aunque el simulador no contempla la competencia intraespecífica del cultivo en la generación de los datos, se compensa la competencia interespecífica con la intraespecífica. Esto deberá ser comprobado en ensayos *in vivo*.

La simulación de los campos de cultivo son una herramienta útil para evaluar modelos de competencia, ya que los escenarios simulados tuvieron las características de dependencia espacial presente en las variables regionalizadas, sin embargo, se requiere de un mayor conocimiento de las características estadísticas de las variables generadas para simular datos más acordes a la realidad.

3.6. Literatura citada

Akaike, H. (1974). A new look at the statistical model identification. IEEE Transactions on Automatic Control, 19(6), 716–723. doi:10.1109/tac.1974.1100705

Anselin, L., & Bera, A. (1998). Spatial Dependence in Linear Regression Models with an introduction to spatial econometrics. En Handbook of Applied Economic Studies (pp. 237-289).

Anselin, L., Bongiovanni, R., & Lowenberg-Deboer, J. (2004). A spatial econometric approach to the economics of site-specific nitrogen management in corn production. American Journal of Agriculture economics, 86(August), 675-687.

Arbia, G. (2014). A Primer for Spatial Econometrics With Applications in R. London: Palgrave Macmillan.

Auld, B., & Tisdell, C. (1988). Influence of spatial distribution of weeds on crop yield loss. Plant Protection Quarterly, 3(January), 81.

Brain, P., & Cousens, R. (1990). The Effect of Weed Distribution on Predictions of Yield Loss. Journal of Applied Ecology, 27(2), 735-742. https://doi.org/10.2307/2404315

Cardina, J., Johnson, G., & Sparrow, D. (1997). The Nature and Consequence of Weed Spatial Distribution. Weed Science, 45(3), 364-373.

Cousens, R. (1985). A simple model relating yield loss to weed density. Annals of Applied Biology, 107(2), 239-252. https://doi.org/10.1111/j.1744-7348.1985.tb01567.x

Dew, D. A. (1972). An Index of Competition for estimating Crop Loss Due to Weeds. Canadian Journal of Plant Science, 52, 921-927. https://doi.org/10.4141/cjps72-159

El Sharif, H., Wang, J., & Georgakakos, A. P. (2015). Modeling Regional Crop Yield and Irrigation Demand Using SMAP Type of Soil Moisture Data. Journal of Hydrometeorology, 16(2), 904-916. https://doi.org/10.1175/jhm-d-14-0034.1

Elhorst, J. P. (2010). Applied Spatial Econometrics: Raising the Bar. Spatial Economic Analysis, 5(1), 9-28. https://doi.org/10.1080/17421770903541772

Florax, R. J. G. M., Voortman, R. L., & Brouwer, J. (2002). Spatial dimensions of precision agriculture: A spatial econometric analysis of millet yield on Sahelian coversands. Agricultural Economics, 27(3), 425-443. https://doi.org/10.1016/S0169-5150(02)00068-3

González-Andújar, J. L., Fernández-Quintanilla, C., Bastida, F., Calvo, R., Izquierdo, J., & Lezaun, J. (2011). Assessment of a decision support system for chemical control of annual ryegrass (Lolium rigidum) in winter cereals. Weed Research, 51(3), 304-309. https://doi.org/10.1111/j.1365-3180.2011.00842.x

González-Andújar, J. L., & Navarrete, L. (1995). Aplicación del índice de distancias t-cuadrado al estudio de las distribución espacial de las malas hierbas. Investigación Agraria Producción y protección vegetales, 10(2), 295-299.

González-Andújar, J. L., & Saavedra, M. (2003). Spatial distribution of annual grass weed populations in winter cereals. Crop Protection, 22(4), 629-633. https://doi.org/10.1016/S0261-2194(02)00247-8

Heege, H. J. (2013). Precision in Crop Farming. https://doi.org/10.1007/978-94-007-6760-7

Hughes, G. (1996). Incorporating spatial pattern of harmful organisms into crop loss models. Crop Protection, 15(5), 407-421. https://doi.org/10.1016/0261-2194(96)00003-8

Matheron, G. (1963). Principles of geostatistics. Economic Geology, 58(8), 1246-1266. https://doi.org/10.2113/gsecongeo.58.8.1246

Norris, R., Elmore, C., Rejmánek, M., & Akey, W. C. (2001). Spatial arrangement, density, and competition between barnyardgrass and tomato: I. Crop growth and yield. Weed Science, 49(1), 61-68. https://doi.org/10.1614/0043-1745

Renton, M., & Chauhan, B. (2017). Modelling crop-weed competition: Why, what, how and what lies ahead? Crop Protection, 95, 101-108. https://doi.org/10.1016/j.cropro.2016.09.003

Rodríguez Albarrcín, H. S., Darghan Contreras, A. E., & Henao, M. C. (2019). Spatial regression modeling of soils with high cadmium content in a cocoa producing area of Central Colombia. Geoderma Regional, 16, e00214. https://doi.org/10.1016/j.geodrs.2019.e00214

Webster, R., & Oliver, M. (2007). Geostatistics for Environmental Scientists. Wiley. https://doi.org/10.2136/vzj2002.0321

Zanin, G., Berti, A., & Riello, L. (1998). Incorporation of weed spatial variability into the weed control decision-making process. Weed Research, 38(2), 107-118. https://doi.org/10.1046/j.1365-3180.1998.00074.x

4. Estimación de la cobertura de malezas en un cultivo de lechuga usando k-medias difuso en imágenes multiespectrales

D A., Jamaica-Tenjo, A. Puerto, C. Pedraza,

4.1. Resumen

El muestreo convencional de las poblaciones de malezas presentes en los campos de cultivo es una labor difícil, que requiere de una gran cantidad de tiempo y entrenamiento para proveer la información con la calidad que necesitan los profesionales del agro, tanto para tomar decisiones de campo como para investigaciones. Esto, sumado a la gran cantidad de información que se necesita en el marco de la agricultura de precisión hace inviable el muestreo convencional. Por esta razón, el uso de sensores remotos y los softwares que procesan imágenes multiespectrales, se vuelven una herramienta importante para alimentar modelos o para tomar decisiones de manejo más acertadas. En este trabajo, se desarrolló un software que a través del uso de k-medias, procesa las imágenes provenientes de un sensor Parrot Sequoia de cuatro bandas, dos en el espectro visible, una en el infrarrojo cercano y otra en el borde del rojo, para estimar de forma precisa la cobertura de las malezas presentes entre plantas de cultivo, para su posterior uso en la alimentación de modelos de regresión espacial.

4.2. Introducción

El interés en la agricultura de precisión ha aumentado debido a la necesidad de disminuir los inputs necesarios para el cultivo (e.j. herbicidas) y también, por que mejora y facilita el manejo ambiental, económico y agronómico de los cultivos. Actualmente, la agricultura en Colombia, en su área hortícola, no está suficientemente desarrollada si se compara con el desarrollo en otros países (Junguito et al., 2014), considerando que el 70% no está tecnificada (Rodríguez et al., 2008).

La competencia entre malezas y cultivo representa un gran problema en la agricultura, ya que se estima que causa en promedio un 34% de las pérdidas de producción (Oerke, 2006) y en ciertos cultivos puede llegar hasta el 100% de pérdidas (Zimdahl, 2004). Sin embargo, se hace necesario cuantificar, caracterizar e identificar la abundancia, composición florística, componentes funcionales y distribución espacial de las malezas para proponer métodos de manejo más eficientes y a su vez, información más precisa en las investigaciones.

A través del muestreo convencional se estima la abundancia de malezas con el conteo de individuos, llamado densidad (plantas/m^2) o la cobertura (% área cubierta del suelo por parte de las malezas). Esta última depende de la subjetividad y entrenamiento del evaluador (Nkoa et al., 2015).

Los avances tecnológicos han permitido mejorar muchos procesos en agricultura, como el avance en el uso de drones en la captura de información (Pérez-Ortiz et al., 2015), y el uso de técnicas modernas de interpretación de imágenes con inteligencia artificial como las redes neurales convolucionales (Meyer et al., 2004; Tang et al., 2017). Sin embargo, aunque muchas de estas técnicas se emplean en diferentes tipos de cultivos a gran escala, por ejemplo, para plantear métodos de manejo por sitio especifico. Existen otras necesidades de información más específica y más detallada para diferentes tipos de investigaciones en malezas.

Es por esto que, desarrollar un software que permita calcular la abundancia de las malezas, que sea útil para evaluar bioensayos o investigaciones en donde se necesita una gran cantidad de información de un área relativamente pequeña (e.j. bioensayos que usualmente no superan los 200 m^2), resulta imperativo. En este capítulo se propone una metodología que logra, a través de k-medias difuso en imágenes multiespectrales, calcular la cobertura de malezas entre plantas de cultivo de lechuga.

4.2.1. Muestreo convencional

El muestreo convencional permite identificar y cuantificar las poblaciones de malezas en los cultivos. Se puede evaluar la cobertura (% área cubierta de malezas del área total), la densidad (plantas/m^2), biomasa (kg/m^2) o frecuencia (% de cuadros con maleza del total de cuadros evaluados). Usualmente se emplean una cantidad determinada *a priori* de cuadros de muestreo dispuestos de forma aleatoria, sistemática o por medio de redes rígidas (D Jamaica y Plaza, 2014). Este proceso se realiza de forma visual. Sin embargo, un evaluador puede tener sesgos en la evaluación. En ocasiones depende del entrenamiento, de la experiencia y estado del evaluador, también del clima e incluso de la misma cantidad de malezas.

4.2.2. Procesamiento de imágenes en agricultura

Una solución para la subjetividad y los sesgos en la evaluación visual, es la detección remota a través del procesamiento de imágenes. Por ejemplo, Jadhav y Patil, (2014); Thorp y Tian, (2004) proponen usar cámaras hiperespectrales, tomando ventaja que la huella espectral es fácil de identificar por el amplio número de bandas que estos contienen, pero este tipo de equipos es muy costoso y requiere experiencia muy específica para su operación. En contraste, los multiespectrometros usualmente pueden tomar imágenes RGB y algunas bandas más en el área del infrarrojo cercano (790 nm), lo que permite usar

el índice NDVI (Torres-Sánchez et al., 2015) como identificador de la actividad fotosintética (**Ecuación 4-1**), de gran utilidad para separar el suelo de las plantas en las imágenes.

$$NDVI = \frac{NIR-RED}{NIR+RED} \qquad \textbf{Ecuación 4-1}$$

El procesamiento de las imágenes se ha realizado usando técnicas de inteligencia artificial (redes neurales, adaboost, máquinas de soporte vectorial), para separarlas de las plantas de cultivo (Camps-Valls y Bruzzone, 2005). También, se puede realizar segmentando las imágenes donde se encontraba la línea de siembra del cultivo. Posteriormente se excluye esta linea, separando el cultivo y seguido de esto se extraen las características de las malezas para estimar su abundancia. (Kamilaris y Prenafeta-Boldú, 2018; Lottes et al., 2017).

Otra forma de hacer la segmentación entre plantas de cultivo, malezas y suelo para calcular sus coberturas, es mediante C-medias. Este se basa en la medida de la distancia mínima de un elemento perteneciente a un conjunto hacia un centroide determinado por el promedio de los diferentes integrantes de ese mismo grupo (Tang et al., 2017). Si a esto se adiciona un parámetro basado en una matriz de pertenencia de cada elemento a cierto cluster, es decir obteniendo la probabilidad asociada de cada elemento a su respectivo cluster, la segmentación es más precisa. Este proceso se llama k-medias.

En el procesamiento de las imágenes provenientes de cultivo-malezas, resulta imperativo comparar las estimaciones de abundancia de los softwares desarrollados, con el muestreo convencional, para saber si al menos dan el mismo resultado. Para esto, el software desarrollado en este capítulo se evaluará, comparando los resultados obtenidos con la evaluación visual hecha por profesionales, de exactamente las mismas imágenes de un cultivo.

Las hipótesis a evaluar fueron que la evaluación hecha por humanos tiende a sobreestimar las malezas cuando su abundancia es alta y viceversa, a subestimarlas cuando su abundancia es baja. Y si el resultado con el software es más preciso ya que de este se obtiene una variable continua, mientras que de las personas se obtiene una variable discreta e incluso ordinal redondeando los valores a decenas.

4.3. Metodología

Las imágenes fueron tomadas en un cultivo comercial de lechuga en el Centro Agropecuario Marengo (Mosquera, Colombia), con un sensor Parrot Sequoia, que captura en cuatro bandas: verde (550 nm), rojo (660 nm), borde de rojo (735 nm), infrarrojo cercano (790 nm), con resolución de 1.2 mp.

Las imágenes fueron tomadas con un soporte de aluminio, ajustado a una altura de 80 cm (1127 imágenes) y a 2 m (592 imágenes). Cada imagen se procesó de forma secuencial como se describe en la Figura 4-1.

Figura 4-1: Diagrama de bloques del procedimiento principal

El preprocesamiento incluyó transformación geométrica y de proyección para corregir defectos del lente como ojo de pescado y la desalineación de las imágenes de cada banda como se muestra en la Figura 4-12. Una vez corregida la imagen, se realizó la segmentación de los objetos de interés.

Figura 4-2: a) Imagen original b) Imagen corregida

a) 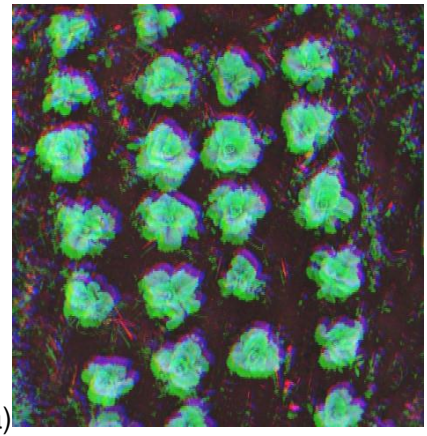 b) 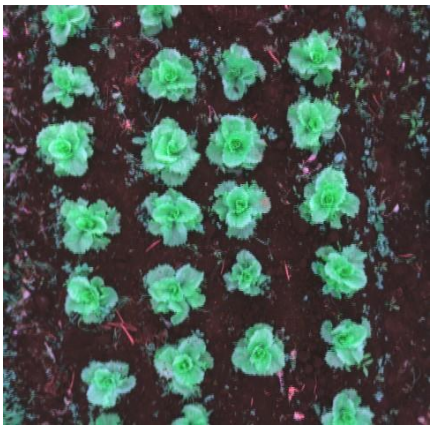

Varios de los agrupamientos en la naturaleza obedecen a ciertas características intrínsecas de ellos, estas características llevan a los elementos individuales hacia el centro que los identifica como integrantes de un grupo. En este caso, las lechugas tienen una huella espectral específica que las agrupan y las malezas otras, a pesar de que solo se registraron cuatro bandas.

Se realiza la segmentación por clusters por medio de k-medias y luego se escogen los clusters que se reagrupan de acuerdo al grupo al que pertenecen (suelo, malezas, cultivo). Finalmente, se realiza el conteo de los pixeles que contienen malezas, del total de pixeles, lo que da una medida de cobertura en (%).

La validación de esta metodología se realizó con 20 imágenes que se escogieron de forma aleatoria del grupo de imágenes. Estas imágenes se procesaron y se comparó el resultado con un grupo de expertos, a los cuales se les mostró cada una de las mismas 20 imágenes, registrando mediante estimación visual la cobertura. Esta comparación se realizó con pruebas no paramétricas de diferencia de medias (Kruskal-Wallis), debido a la ausencia del supuesto de normalidad en la variable cobertura de malezas, lo que indica que las malezas se encontraban de forma agregada.

4.4. Resultados

En la Figura 4-3, se presenta un ejemplo del procesamiento vía k-medias con seis clusters, en donde separó de forma efectiva el suelo, el cultivo y las malezas.

Haciendo una comparación visual de las imágenes a y b, se puede observar que la segmentación fue acertada. Lo cual se comparó con la evaluación realizada por humanos.

Figura 4-3: a) imagen original, b) imagen segmentada con seis clusters y posterior unión en tres clusters [lechuga (verde), maleza (rojo) y suelo (negro)]

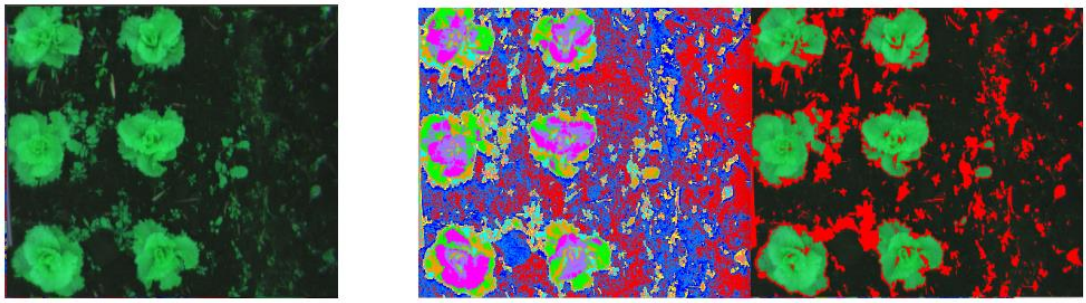

(a) (b)

4.5. Validación

Las estimaciones hechas por los expertos (Tabla 4-1) pueden tener una varianza significativa; sin embargo, es necesario establecer una medida para comparar si los métodos dieron el mismo resultado. Se decidió usar la prueba de Kruskal-Wallis para diferencia de medias, ya que no se cumplió el supuesto de normalidad en la variable (Shapiro Wilks $p= 1.87*10^{-9}$), esta dio como resultado un $p= 0.6688$. Se validó que no hay diferencia significativa entre los evaluadores humanos y el software (Figura 4-4).

Tabla 4-1: Estimación de la cobertura por parte de los tres expertos y del software para dos alturas de toma de imágenes.

		Porcentaje de cobertura			
Imagen	Altura*	Experto 1	Experto 2	Experto 3	Software
1	80 cm	6	5	3	9.1
2	80 cm	18	10	20	14
3	80 cm	20	20	15	11.8
4	80 cm	10	7	10	16.5
5	80 cm	9	10	10	9.3
6	80 cm	12	15	15	11.4
7	80 cm	8	10	10	7.15
8	80 cm	20	15	10	10.7
9	80 cm	8	5	8	7.25
10	80 cm	10	20	25	15.6
11	2 m	5	5	15	6.7
12	2 m	15	15	10	13
13	2 m	12	5	10	8.14
14	2 m	10	10	10	12
15	2 m	25	20	25	18
16	2 m	23	7	30	8.5
17	2 m	20	20	20	18
18	2 m	45	70	40	34
19	2 m	15	35	35	21.3

* Altura sobre la superficie del suelo

Figura 4-4. Diagrama de cajas de la estimación de cobertura por parte de los tres expertos (A, B y C) y software (D y E)

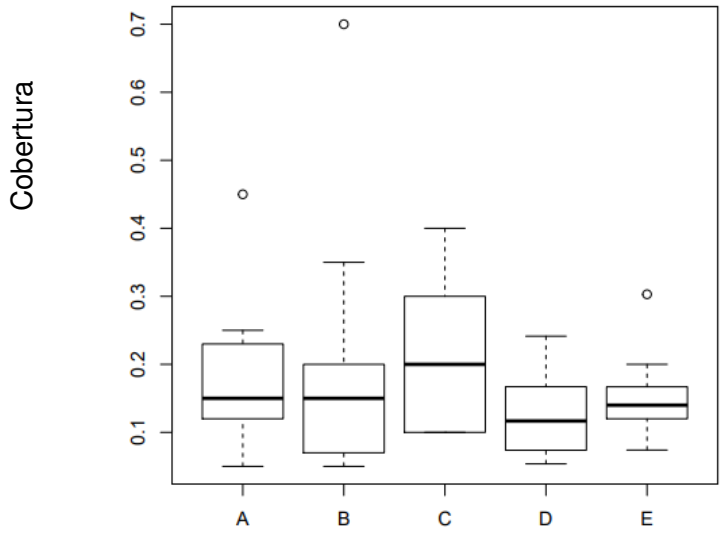

Los datos se separaron por su altura en dos grupos 0.8 y 2m. Y se realizó de nuevo la prueba. Para cada altura los datos no se distribuyeron normalmente (p=0.02864 y $p=9.38*10^{-5}$ respectivamente para las dos alturas) y tampoco se encontró diferencia significativa entre expertos y software (p=0.9446 y p= 0.6401, para las dos alturas respectivamente.

Sin embargo, sí se encontró diferencia en la estimación de la cobertura por parte de los expertos comparando las dos alturas, es decir, a pesar de pertenecer todas las imágenes al mismo lugar, los expertos estimaron la cobertura con resultados significativamente diferentes a 0.8 m vs a 2m (p= 0.0157). Mientras que para el software no hubo diferencia (p=0.5989). Esto indica que a diferentes alturas de la imagen el experto puede sobre estimar o subestimar la cobertura de malezas, mientras que el software no.

4.6. Discusión y conclusiones

Las estimaciones de cobertura por parte de los expertos y por parte del software, no tuvieron diferencias significativas para cada una de las alturas. Pero, si hubo diferencias en la estimación de la cobertura, comparando las dos alturas a las cuales se tomaron las imágenes. Concluyendo que, la percepción a diferentes alturas es diferente para la misma cantidad de malezas. También, que en la estimación visual, las personas tienden a sobreestimar valores altos de cobertura y a subestimar valores bajos.

De acuerdo a Harvey y Wagner, (1994), no es necesario que las diferencias entre evaluadores y en este caso una estimación por computador, sean muy grandes para que la toma de decisiones en cuanto a manejo sea diferente. De hecho, estos mismos autores mencionan que estas diferencias pueden ser amplias, comparando evaluadores entrenados y no entrenados. De este punto de vista el software es efectivo para calcular la cobertura de las malezas, desde que no es significativamente diferente a la estimación hecha por los expertos. Sin embargo, con los avances tecnológicos en la toma de datos y en el desarrollo y uso de modelos que necesitan más información se requiere que los datos sean más precisos y fáciles de tomar en grandes cantidades.

Por esta razón, Andújar et al., (2010), menciona que a medida que aumentan estas necesidades de información, la percepción humana está cada vez más limitada en los rangos en donde los modelos bioeconómicos (González-Andújar et al., 2011) de soporte para la toma de decisiones de manejo suelen ser más sensibles, en los límites entre clases de las variables nominales u ordinales.

El software resultó ser útil, eficaz y consistente en la estimación de la cobertura de las malezas para las condiciones de esta investigación, e incluso para futuras investigaciones en las que se necesite una cantidad muy alta de información a escala detallada para la alimentación de modelos o, por ejemplo, para incluirse en un sistema autónomo de control de malezas.

4.7. Literatura citada

Andújar, D., Ribeiro, A., Carmona, R., Fernández-Quintanilla, C., & Dorado, J. (2010). An assessment of the accuracy and consistency of human perception of weed cover. Weed Research, 50(6), 638-647. https://doi.org/10.1111/j.1365-3180.2010.00809.x

Camps-Valls, G., & Bruzzone, L. (2005). Kernel-based methods for hyperspectral image classification. IEEE Transactions on Geoscience and Remote Sensing, 43(6), 1351-1362. https://doi.org/10.1109/TGRS.2005.846154

González-Andújar, J. L., Fernández-Quintanilla, C., Bastida, F., Calvo, R., Izquierdo, J., & Lezaun, J. (2011). Assessment of a decision support system for chemical control of annual ryegrass (Lolium rigidum) in winter cereals. Weed Research, 51(3), 304-309. https://doi.org/10.1111/j.1365-3180.2011.00842.x

Harvey, R., & Wagner, C. (1994). Using Estimates of Weed Pressure to Establish Crop Yield Loss Equations. Weed Technology, 8(1), 114-118. https://doi.org/doi:10.1017/S0890037X00039294

Jadhav, B. D., & Patil, P. M. (2014). Hyperspectral Remote Sensing For Agricultural Management: A Survey. International Journal of Computer Applications, 106(7), 975-8887.

Jamaica, D., & Plaza, G. (2014). Evaluation of various conventional methods for sampling weeds in potato and spinach crops. Agronomia Colombiana, 32(1). pp.36-43. ISSN 0120-9965. http://dx.doi.org/10.15446/agron.colomb.v32n1.39613.

Jordan, N., Schut, M., Graham, S., Barney, J., Childs, D., Christensen, S., Sønderskov, M. (2016). Transdisciplinary weed research : new leverage on challenging weed problems ?, 56(5), 345-358. https://doi.org/10.1111/wre.12219

Junguito, R., Perfetti, JJ., & Becerra, A. Desarrollo de la agricultura Colombiana. Cuadernos Fedesarrollo No 48. Colombia.

Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. Computers and Electronics in Agriculture, 147, 70-90. https://doi.org/10.1016/j.compag.2018.02.016

López-Granados, F. (2011). Weed detection for site-specific weed management: Mapping and real-time approaches. Weed Research, 51(1), 1-11. https://doi.org/10.1111/j.1365-3180.2010.00829.x

Lottes, P., Khanna, R., Pfeifer, J., Siegwart, R., & Stachniss, C. (2017). UAV-based crop and weed classification for smart farming. Proceedings - IEEE International Conference on Robotics and Automation, 3024-3031. https://doi.org/10.1109/ICRA.2017.7989347

Meyer, G. E., Neto, J. C., Jones, D. D., & Hindman, T. W. (2004). Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images. Computers and Electronics in Agriculture, 42(3), 161-180. https://doi.org/10.1016/j.compag.2003.08.002

Nkoa, R., Owen, M. D. K., & Swanton, C. J. (2015). Weed Abundance, Distribution, Diversity, and Community Analyses. Weed Science, 63(sp1), 64-90. https://doi.org/10.1614/WS-D-13-00075.1

Oerke, E. (2006). Crop losses to pests. Journal of Agricultural Science, 144, 31-43. https://doi.org/10.1017/S0021859605005708

Pérez-Ortiz, M., Peña-Barragán, J. M., Gutiérrez, P. A. A., Torres-Sánchez, J., Hervás-Martínez, C., López-Granados, F., … López-Granados, F. (2015). A semi-supervised system for weed mapping in sunflower crops using unmanned aerial vehicles and a crop row detection method. Applied Soft Computing, 37, 533-544. https://doi.org/10.1016/j.asoc.2015.08.027

Rodríguez, M., Plaza, G., Gil, R., & Chaves, B. (2008). Reconocimiento y fluctuación poblacional arvense en el cultivo de espinaca (Spinacea oleracea L .) para el municipio de Cota , Cundinamarca Recognition and population fluctuation of weeds in spinach crop (Spinacea oleracea L .) in the municipality of Co.

Tang, J. L., Wang, D., Zhang, Z. G., He, L. J., Xin, J., & Xu, Y. (2017). Weed identification based on K-means feature learning combined with convolutional neural network. Computers and Electronics in Agriculture, 135, 63-70. https://doi.org/10.1016/j.compag.2017.01.001

Thorp, K. R., & Tian, L. F. (2004). A review on remote sensing of weeds in agriculture. Precision Agriculture, 5(5), 477-508. https://doi.org/10.1007/s11119-004-5321-1

Torres-Sánchez, J., López-Granados, F., Peña, J. M., Peña-Barragán, J. M., Peña, J. M., & Peña-Barragán, J. M. (2015). An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. Computers and Electronics in Agriculture, 114, 43-52. https://doi.org/10.1016/j.compag.2015.03.019

Zimdahl, R. (2004). Weed-Crop Competition. Blackwell Publising. https://doi.org/10.2135/cropsci2004.2284a

5. Modelado de la competencia entre las malezas y un cultivo de lechuga, mediante regresión espacial y adaptación de la matriz de pesos para asociarla a la abundancia de las malezas

D A. Jamaica-Tenjo, E. Darghan, J L González-Andújar

5.1. Resumen

Se evaluó el uso de algunas variantes de un modelo de regresión espacial para el contexto de un ensayo *in vivo*, en un cultivo de lechuga, con un esquema de cultivo en el que se variaron las densidades de siembra desde 0.1mx0.1m hasta 0.5mx0.5m. Se demostró que la cantidad de malezas que aparecen entre las plantas de cultivo depende de la densidad de siembra. Además, que tanto la densidad de siembra como la cobertura de malezas tienen influencia en la pérdida de rendimiento por competencia, tanto intra como interespecífica de forma parcialmente aditiva. También se encontró que características no medidas del suelo afectan esta interacción, lo cual fue visto desde la significancia del parámetro de dependencia espacial de los residuales del modelo. Además, se propuso e implementó el uso de matrices de pesos que incluyen la abundancia de las malezas dentro de estas, con resultados que abren la puerta al uso de matrices de pesos con configuraciones diferentes al de las distancias entre plantas de cultivo.

5.2. Introducción

Las malezas son consideradas uno de los mayores problemas en la agricultura, ya que compiten con los cultivos por agua, nutrientes, luz y espacio, reduciendo su rendimiento (Labrada *et al*., 1996). Globalmente se estima que reducen la producción un 34% (Oerke, 2006), con algunos casos de cultivos en el que las pérdidas pueden ser hasta del 100% (Zimdahl, 2007).

El cultivo de lechuga en Colombia produjo en 2018, 120.000 tm dedicadas principalmente al consumo local, de las cuales, el 52% se produce en el altiplano cundiboyascence (Agronet, 2018). Este cultivo es muy sensible a la competencia de las malezas, en donde se reportan para la zona, reducciones del rendimiento entre el 40% y el 100% (Cardona, 1971), 63% (Fuentes y Romero, 1991).

La competencia maleza-cultivo puede ser definida desde diferentes perspectivas: dos plantas que comparten nicho compiten cuando los recursos que ambas necesitan son limitados (Radosevich *et al*., 2007), y también, la afectación del crecimiento de una planta ocasionada por el tamaño y la proximidad de sus vecinas (Gomez y Gomez, 1984),

Desarrollar modelos que relacionen el efecto competitivo maleza – cultivo, se vuelve una necesidad al momento de crear herramientas que permitan tomar las mejores decisiones de manejo (Renton y Chauhan, 2017). Entre estos, se han desarrollado modelos empíricos de competencia (Swanton *et al*., 2015; Jamaica y Gonzalez-Andujar, 2019) que relacionan el rendimiento de cultivo como respuesta a la densidad, biomasa o cobertura de las malezas (Rejmánek *et al*., 1989) que, aunque no profundizan acerca de los mecanismos que los ocasionan, requieren relativamente poca información por lo que son fáciles de obtener y tienen una aceptable capacidad predictiva.

Los primeros modelos que se establecieron fueron regresiones lineales simples (Ecuación 5-1) (Dew, 1972; Jamaica y Gonzalez-Andujar, 2019):

$$\boldsymbol{Y = a + bx + \varepsilon} \qquad \textbf{Ecuación 5-1}$$

Posteriormente se desarrollaron modelos no lineales, siendo el modelo hiperbólico el más utilizado (Ecuación 5-2). (Cousens, 1985)

$$Y = Y_{wf}\left[1 - \frac{Ix}{100\left(1+\frac{I}{A}x\right)}\right] + \varepsilon \qquad \textbf{Ecuación 5-2}$$

donde, Y_{wf} representa es el rendimiento máximo del cultivo sin ser afectado por malezas, x es la cantidad de malezas (ind/m^2); I es la fracción de pérdida de producción por cada planta de mala hierba cuando $x \rightarrow 0$; A es la pérdida de rendimiento cuando $x \rightarrow \infty$. ε es el error.

Las metodologías clásicas de modelado que relacionan la pérdida de rendimiento del cultivo como efecto de la abundancia de malas hierbas, consideran implícitamente que las malas hierbas están distribuidas espacialmente de forma no agregada en el cultivo (Cardina et al., 1997). Sin embargo está ampliamente establecido que las malas hierbas presentan una distribución agregada (Auld y Tisdell, 1988; Cardina et al., 1997; Norris et al., 2001; González-Andújar y Saavedra, 2003).

Auld y Tisdell, (1988) han mostrado que a medida que la distribución de las malezas se aleja de la uniformidad se sobreestima el daño sobre el cultivo. Norris *et al*. (2001) muestran cómo cambia la forma de la curva hiperbólica dependiendo si las malezas se distribuyen de forma agregada, uniforme o aleatoria, la reducción del rendimiento del cultivo para malezas agrupadas es menor que para uniformes y aleatorias. Se han propuesto modificaciones de los modelos de competencia para tener en cuenta la distribución espacial agregada de las malas hierbas. Algunas de ellas se basan en el uso de índices de dispersión o en índices derivados de distribuciones de frecuencias (González-Andújar y Saavedra, 2003)

De la misma forma, ha habido avances desde la misma propuesta de los modelos, como variaciones que tienen cuenta la distribución agregada y en parches de las malezas. Diversas investigaciones (Brain y Cousens, 1990; González-Andújar y Navarrete, 1995; Hughes, 1996; González-Andújar y Saavedra, 2003) utilizan por ejemplo, la inclusión del

parámetro k de la distribución Binomial negativa o índices de distancia como el índice T-cuadrado.

De acuerdo con Anselin y Bera, (1998), al realizar el ajuste de un modelo lineal o no lineal, se deben verificar los supuestos de independencia y normalidad de los residuales. Si el de normalidad no se cumple, usualmente se transforman las variables mediante el uso de logaritmo, a pesar de que eso puede llevar a sesgos en la estimación de los valores des-transformados (Smith, 1993), y aunque hayan herramientas para corregir dichos sesgos (Zeng et al., 2011), en ocasiones no se realizan (Manning y Mullahy, 1999).

Pero el supuesto de independencia en variables regionalizadas (Matheron, 1963) como propiedades del suelo o el rendimiento del cultivo (Heege, 2013) es "insostenible" como lo describe Anselin et al. (2004). Si no se consigue, se deben usar regresiones espaciales o modelos autorregresivos espaciales que tengan en cuenta dicha correlación (Arbia, 2014; Florax et al., 2002).

Por esta razón, el uso de modelos de regresión espacial puede constituir una herramienta valiosa en la estimación de pérdida de rendimiento a causa de las malezas teniendo en cuenta las condiciones de dependencia espacial de las variables antes mencionadas (Anselin y Bera, 1998).

En este sentido, los modelos de regresión espacial (Arbia, 2014), los cuales son modelos lineales que en el contexto de la relación cultivo-malezas, parten del supuesto de la existencia de autocorrelación espacial en el rendimiento de las plantas de cultivo, posiblemente también en la densidad de las malezas y entre los residuales. Adaptados para estimar el rendimiento en función de la cantidad de malezas se puede expresar de la siguiente forma (Ecuación 5-3):

$$\begin{cases} \boldsymbol{Y} = \boldsymbol{\beta X} + \boldsymbol{\alpha WY} + \boldsymbol{u} \\ \mathbf{u} = \boldsymbol{\rho \mathbf{W} u} + \boldsymbol{\varepsilon} \end{cases} \qquad \textbf{Ecuación 5-3}$$

Donde $\boldsymbol{Y}$ es el rendimiento, $\boldsymbol{X}$ es una matriz de variables independientes, que pueden ser medidas de abundancia de las malezas (densidad, biomasa o cobertura), β es un vector

de parámetros que indicarían que tan competitiva es una especie. En el segundo término: *α* es un parámetro que cuantifica la autocorrelación o la competencia intraespecífica del cultivo evaluado de forma autorregresiva con los rendimientos de las plantas de cultivo, esto se representa con la matriz ***W*** que pondera el efecto de cada planta de cultivo sobre sus vecinos de acuerdo a la distancia a la que se encuentran. El término del error *u* se considera si ρ es diferente de cero, esto sucede si los errores también tienen dependencia espacial. Si los errores son independientes se considera el error $\varepsilon \sim$ i.i.d.N $(0, \sigma^2)$.

Esta **W**, usualmente consiste en una matriz de (n*n) donde n es la cantidad de elementos, para el caso del análisis del rendimiento de cultivo puede ser el rendimiento de cada planta. Los elementos de la matriz corresponden a la inversa de la distancia de cada planta con los vecinos que se ajusten a los requerimientos, esto puede ser, los vecinos más cercanos en todas las direcciones (queen), los vecinos en diagonal (bishop), los vecinos en lateral (rook) y pueden ser de una capa (los más cercanos) hasta de todos los elementos en la matriz, entre muchas otras configuraciones. Sin embargo, siempre se ha considerado la distancia entre elementos para crear esta matriz de pesos (Arbia, 2014).

Un ejemplo de la matriz de pesos **W** de las plantas de cultivo se muestra en la Figura 5-1:

Figura 5-1. Esquema de vecindad tipo "Queen" con su matriz de distancias correspondiente

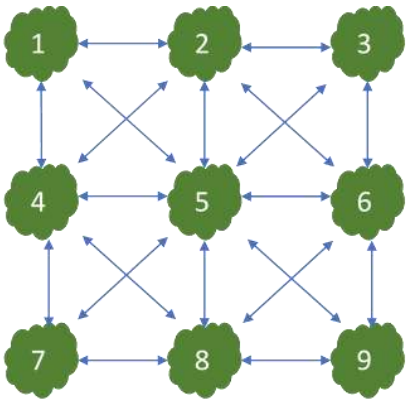

Planta No.	1	2	3	4	5	6	7	8	9
1	0	1	0	1	1,41	0	0	0	0
2	1	0	1	1,41	1	1,41	0	0	0
3	0	1	0	0	1,41	1	0	0	0
4	1	1,41	0	0	1	0	1	1,41	0
5	1,41	1	1,41	1	0	1	1,41	1	1,41
6	0	1,41	1	0	1	0	0	1,41	1
7	0	0	0	1	1,41	0	0	1	0
8	0	0	0	1,41	1	1,41	1	0	1
9	0	0	0	0	1,41	1	0	1	0

Donde se tienen nueve plantas y cada una de las flechas representa la distancia entre cada planta con su vecino más cercano. En un esquema cuadrado, la planta número uno tiene tres vecinos: la planta dos y cuatro se encuentran a una distancia de una unidad, mientras que la planta cinco se encuentra a una distancia de $\sqrt{2}$. Esto está representado en la matriz de distancias en la primera fila. En un principio los demás valores pueden considerarse cero, ya que solo se incluyen los vecinos más cercanos, pero esto puede cambiar si se incluyen más vecinos o incluso todas las interacciones.

La competencia intraespecífica indica que las plantas que están más cerca afectan en mayor medida, por lo tanto, la relación entre distancia y efecto es inversa. Además, cada planta tiene un número limitado de vecinos, por esto el efecto de los vecinos sobre una planta se pondera entre cada uno de ellos de acuerdo a la distancia a la que están, sumando entre todos los vecinos el 100% del efecto de competencia intraespecífica a cada planta.

Esta es la razón del procedimiento para obtener la matriz de pesos **W**, que es la escalada (que la suma de cada fila sea igual a uno) de la inversa de la matriz de distancias.

Para el ejemplo anterior la matriz **W** sería la expuesta en la Figura 5-2:

Figura 5-2. Matriz de pesos asociada a las distancias entre vecinos más cercanos

	1	2	3	4	5	6	7	8	9
1	0,0000	0,3694	0,0000	0,3694	0,2612	0,0000	0,0000	0,0000	0,0000
2	0,2265	0,0000	0,2265	0,1602	0,2265	0,1602	0,0000	0,0000	0,0000
3	0,0000	0,3694	0,0000	0,0000	0,2612	0,3694	0,0000	0,0000	0,0000
4	0,2265	0,1602	0,0000	0,0000	0,2265	0,0000	0,2265	0,1602	0,0000
5	0,1036	0,1464	0,1036	0,1464	0,0000	0,1464	0,1036	0,1464	0,1036
6	0,0000	0,1602	0,2265	0,0000	0,2265	0,0000	0,0000	0,1602	0,2265
7	0,0000	0,0000	0,0000	0,3694	0,2612	0,0000	0,0000	0,3694	0,0000
8	0,0000	0,0000	0,0000	0,1602	0,2265	0,1602	0,2265	0,0000	0,2265
9	0,0000	0,0000	0,0000	0,0000	0,2612	0,3694	0,0000	0,3694	0,0000

En la que la planta uno (fila uno), tiene dos vecinos (planta dos y cuatro) con un efecto de 36.9% cada uno sobre ella y otra planta (5), que tiene un efecto de 26,1%, ya que se encuentra más lejos, para un total de 100% o lo que es lo mismo en la suma de la fila: 1.

Para este caso, serían las distancias y el rendimiento entre plantas de cultivo lo que causa el efecto de competencia como se describió anteriormente (Gómez y Gómez, 1984), pero, las malezas que están presentes entre dos plantas de cultivo son una fuente de competencia y también de interferencia en la relación entre plantas de cultivo. Por esta razón, se propone crear una matriz de pesos que relacione la cantidad de malezas entre cada planta de cultivo y sus vecinos y evaluarla en los modelos de regresión espacial, tanto con datos sintéticos, como con datos tomados *in vivo*.

Esta matriz tendría la misma configuración de la matriz de pesos proveniente de las distancias entre plantas de cultivo, es decir, cada fila y columna corresponden a una planta de cultivo, pero el valor en donde se sitúa la distancia entre una planta y sus vecinas, corresponde a la abundancia de las malezas.

Entre las formas más sencillas de relacionar ambas matrices estaría la aditiva o la multiplicativa, es decir W_c+W_w o W_c*W_w. Sin embargo, entre las circunstancias a considerar están:

- Que existe un efecto del cultivo hacia sí mismo, expresado en Wc. (competencia intraespecífica)
- Que existe un efecto de las malezas hacia el cultivo, que puede ser expresado en un modelo de regresión como una variable independiente. (Dew, 1972)
- Que existe un efecto del cultivo hacia las malezas, por ejemplo, a una distancia de siembra menor, el efecto de supresión hacia las malezas es evidente (Weiner et al., 2001).
- Que existe un efecto de las malezas hacia sí mismas, expresado en la asíntota del modelo hiperbólico de competencia (Cousens, 1985a)

- Que para los contextos de monocultivo existe un efecto negativo, antagónico, con la interacción con otras plantas, o sea, cualquier suma de dos especies en conjunto es menor que lo que pueden rendir por separado (Radosevich, 1987).

Por lo tanto, la carga competitiva total que recibe una planta de cultivo, proviene de la distancia y tamaño de las plantas de cultivo vecinas, **o** de la cantidad de malezas que están entre estas. Por lo tanto, no debe ser solamente aditivo, sino que debe restarse el efecto de la interacción.

Desde la teoría de probabilidades, Grinstead y Snell, (1997) muestran que cuando dos eventos ocurren simultáneamente la unión de ambos se representa por la suma de la probabilidad de los eventos menos la interacción (Figura 5-3 y Ecuación 5-4).

Figura 5-3. Operaciones básicas de probabilidad

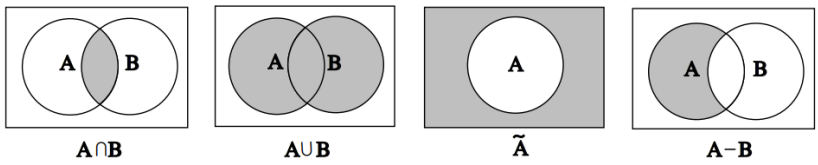

$$\boldsymbol{P(A \cup B) = P(A) + P(B) - P(A \cap B)} \qquad \textbf{Ecuación 5-4}$$

$P(A)$, es la probabilidad de ocurrencia del evento A, $P(B)$ es la probabilidad de ocurrencia del evento B y $P(A \cap B)$ la interacción.

Pero estimar esta interacción puede no ser tan sencillo. Por esto, Montgomery, (2013), sugiere la siguiente forma de calcularla (Ecuación 5-5):

$$\mathbf{E(y_{ij}) = \mu\, \tau_i\, \beta_j} \qquad \textbf{Ecuación 5-5}$$

donde, *E* es la interacción entre dos efectos, μ corresponde al promedio entre los dos efectos, τ las distancias que separan el efecto τ de dicho promedio y *β* las distancias que separan al efecto β del promedio.

Por todo lo anterior, se propuso relacionar la matriz de pesos proveniente de las distancias entre plantas de cultivo con sus vecinas y la matriz que contiene las cantidades de malezas entre cada planta de cultivo y sus vecinas, uniendo la Ecuación 5-4 con la Ecuación 5-5, se obtiene la Ecuación 5-6, con la nomenclatura de las matrices de pesos:

$$\begin{cases} \boldsymbol{W_t = W_c + W_m + \mu_w * (W_c - \mu_w) * (W_m - \mu_w)} \\ \boldsymbol{\mu_w = \left(\frac{W_c + W_m}{2}\right)} \end{cases} \qquad \textbf{Ecuación 5-6}$$

donde W_t es la matriz vinculada, W_c es la matriz de pesos que proviene de las distancias del cultivo, y W_m es la matriz de pesos que proviene de la cantidad de malezas.

5.3. *Metodología*

5.3.1. *Creación de datos sintéticos*

Mediante la simulación incondicional de campos Gaussianos continuos (Webster y Oliver, 2007), se desarrolló un algoritmo con el paquete Gstat en R, en donde se pueden crear datos que respetan las características de dependencia espacial de las malezas y del cultivo. Además, se tiene la capacidad de generar diversos escenarios cuando se varían características de las malezas como la abundancia, que teóricamente puede ir desde cero hasta infinito. Pero se puede considerar alta a partir de 50, ya que se llega a la asíntota de pérdida máxima de rendimiento de cultivo para el parámetro I del modelo de Cousens definido en la **Ecuación 5-2**. Agregación, medida con el coeficiente de variación, que teóricamente puede ir desde cero hasta infinito, pero usualmente se encuentra entre 10 y 300 en los casos más extremos. Patchiness, que contempla la proporción de celdas con valores mayores a cero, sobre el total de datos, teóricamente puede situarse entre 0 y 100. Dependencia espacial, que mediante la manipulación del parámetro "rango" del semivariograma es baja cuando tiene muchos parches de malezas pequeños y alta cuando tiene un solo parche de maleza grande. Finalmente, la competitividad, que usa el parámetro A del modelo de Cousens, para generar un campo de cultivo relacionado a la cantidad de malezas, este valor puede estar entre 0 y 100.

Para este caso, se generó un campo de 10 por 10 plantas de cultivo y un escenario de malezas teniendo en cuenta que sus características no estuvieran en los extremos.

5.3.2. *Datos in vivo*

En los invernaderos de la Facultad de Ciencias Agrarias de la Universidad Nacional de Colombia – Bogotá. N 4°38'08'' W 74°05'25'', a una altura de 2554 metros sobre el nivel del mar. Se realizó una siembra de lechugas (Lactuca sativa L.) variedad crespa verde, con un patrón de diferentes densidades de siembra como se muestra en la Figura 5-4.

Figura 5-4. Esquema de siembra de lechuga

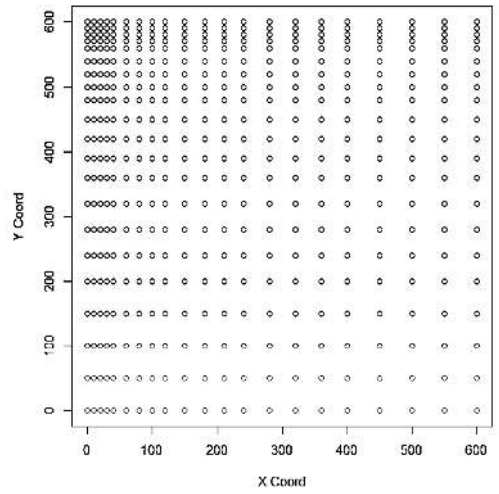

donde las coordenadas están en cm y cada punto representa a una planta de lechuga.

Se escogió el cultivo de lechuga debido a la facilidad de su siembra en plántulas para disponerlas en los patrones espaciales necesarios, la rapidez de su ciclo de cultivo cuando y su sensibilidad a la presencia de malezas (Galon et al., 2016; Khazaei et al., 2013; Yordanova y Nikolov, 2017) Para el establecimiento del ciclo de cultivo de lechuga en el experimento se establecieron dos bloques de 21*21 plantas para un total de 441 plantas por bloque. Uno de ellos se dejó con las malezas durante todo el ciclo de cultivo y en el

otro no se les permitió el crecimiento, para lo cual se desyerbó en tres ocasiones (25, 38 y 51 días después de trasplante (ddt)), durante los 65 días del ciclo de cultivo. Las demás acciones de manejo de cultivo fueron iguales para ambos bloques.

Se realizó el muestreo de malezas mediante un sensor Parrot Sequoia de cuatro bandas, dos en el espectro visible, una en el infrarrojo cercano y otra en el borde del rojo, para su posterior procesamiento mediante un software desarrollado con esta finalidad (Puerto, 2017) y expuesto en el cuarto capítulo, el cual, calcula la cobertura de malezas (% pixeles con malezas / cantidad total de pixeles) entre cada planta de cultivo y sus vecinas (Figura 5-5). Esto se realizó en el día 38 ddt, debido a las limitaciones del sensor en cuanto al traslape de las plantas de maleza con las de cultivo. En la cosecha se pesó cada planta de lechuga.

Figura 5-5: Esquema de toma de datos de rendimiento del cultivo (áreas verdes) y de cobertura de malezas (cuadros rojos), en un ejemplo de nueve plantas.

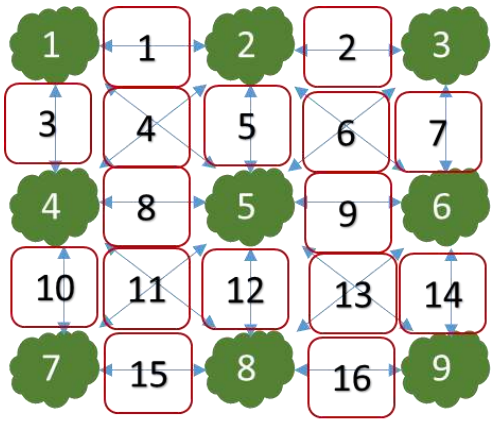

Para ambos escenarios, el del simulador y el de lechugas, se calculó las matrices de pesos de cultivo y de malezas, se escalaron y se relacionaron de acuerdo a lo expuesto anteriormente. Posteriormente, se procedió a ajustar el modelo autorregresivo puro y el de autocorrelacion espacial (**Ecuación 5-3**).

5.4. *Resultados y discusión*

De manera visual (Figura 5-6), se construyó un mapa de puntos, en donde cada uno de estos representa una planta de cultivo, o la cobertura de las malezas cercanas a esa planta de cultivo. En las densidades de siembra más altas tanto el rendimiento de cultivo como la cobertura de maleza es muy baja. También, se observan dos efectos, el círculo rojo indica que en esa área había mayor presencia de malezas y el rendimiento del cultivo fue reducido. Y el círculo azul, indica que en ese lugar había alguna condición no medida del suelo que afectó negativamente el crecimiento tanto de malezas como de cultivo.

El rendimiento promedio del cultivo con malezas fue el 63% del rendimiento del cultivo sin malezas, lo que indica que para las condiciones de la investigación las malezas ejercieron un fuerte impacto sobre las plantas de cultivo (Tabla 5-1). De esta forma, a medida que aumenta la distancia entre plantas de cultivo, estas se hacen más grandes, pero también permiten el crecimiento de más malezas, por lo que el efecto competitivo intra o interespecífico sobre cada planta de cultivo se compensa, como se planteó en el uso de la matriz de pesos combinada y se corroboró con los resultados del modelo completo sobre el cultivo de lechugas, corroborando la aditividad de estos efectos como también concluye Williams II y Boydston, (2013) para el cultivo de maíz. Sin embargo, los autores en su estudio mencionan que la interacción no es significativa, al igual que se observó en la simulación donde aún no se puede modelar la interacción, pero en el ensayo *in vivo*, por la forma espacial en la que se abordó el análisis, los resultados indican que si la puede haber (Tabla 5-3).

Mediante la simulación (Tabla 5-2) se encontró que para el modelo autorregresivo puro, fue significativo el parámetro α, lo que indica la naturaleza autocorrelacionada o de dependencia espacial de la variable rendimiento (Heege, 2013), comprobada también con el I de Moran Global. Como este modelo no tiene más elementos, el total de la variación es explicada por este parámetro. Para el modelo completo, el parámetro α fue significativo y negativo, y aunque fue pequeño, sugiere algún efecto negativo de los vecinos, competencia intraespecífica, a pesar de que el simulador no la contempla explícitamente.

El parámetro ρ fue significativo, lo que indica que los residuales tienen dependencia espacial y que ésta debe modelarse. El parámetro β también fue significativo, lo que indica el efecto de las malezas sobre el cultivo. Finalmente, no hubo diferencia entre el uso de las dos matrices planteadas.

Comparando estos resultados con el ensayo *in vivo* (Tabla 5-3), se evidencia una gran diferencia entre el uso de las dos matrices. En el que se usó solamente con la matriz de pesos de las distancias, se observa que el rendimiento del cultivo es explicado por el rendimiento de las plantas vecinas (parámetro α es positivo y significativo), que se disminuye por alguna variable no medida (parámetro ρ es negativo y significativo) y ésta afecta tanto a las malezas como al cultivo (Figura 5-6), como para que el parámetro β sea positivo, es decir donde hubo menor rendimiento de cultivo, hubo menos malezas.

Sin embargo, el uso de la matriz combinada proveniente de la matriz de pesos del cultivo con la de la abundancia de las malezas, mostró que recoge la información del efecto de la competencia intra e inter específica, al punto que la variable independiente de cobertura de malezas se vuelve no significativa. Esto permitiría, por ejemplo, incluir otras variables bióticas o abióticas (otras plagas o características del suelo) en el vector de parámetros del modelo y dejar en la matriz combinada para el efecto tanto de distancias de siembra como de las malezas. En este caso, el parámetro β fue no significativo como se mencionó anteriormente, el parámetro α fue negativo y significativo, lo que indica un efecto de competencia intraespecífica e interespecífica hacia el cultivo y el parámetro ρ fue significativo y positivo, lo que indica que los residuales tienen dependencia espacial, esto, una vez más, justifica el uso de modelos de regresión espacial.

Entre esto, se encontró un inconveniente en el uso de la regresión espacial que no se tenía contemplado: la matriz de pesos se construye con las distancias a los vecinos más cercanos y se reconoció que al normalizarla (suma de las filas = 1) no importa a que distancia estén estos ocho vecinos (esquema de siembra cuadrado), el efecto ponderado de cada uno es el mismo. Es decir, esta matriz de pesos no puede reconocer a que distancia están los vecinos, solo ponderar su efecto. Mientras que, a mayor distancia, la cantidad de malezas es mayor, por lo que la cantidad de malezas actúa como un indicador

de la distancia a la que pueden estar las plantas de cultivo. Esto también podría solucionarse con el uso de otras matrices de pesos.

Tabla 5-1. La cobertura de malezas fue cercana a cero o cero en donde las distancias de siembra eran inferiores a 20 cm, lo que indica una supresión del cultivo sobre estas. Sin embargo, también hubo una reducción importante del rendimiento (~70%), de forma similar a la encontrada por otros investigadores para lechuga (Khazaei et al., 2013; Yordanova y Nikolov, 2017). A pesar de que en la presente investigación no se realizó un ensayo factorial dado que no era su principal objetivo.

De esta forma, a medida que aumenta la distancia entre plantas de cultivo, estas se hacen más grandes, pero también permiten el crecimiento de más malezas, por lo que el efecto competitivo intra o interespecífico sobre cada planta de cultivo se compensa, como se planteó en el uso de la matriz de pesos combinada y se corroboró con los resultados del modelo completo sobre el cultivo de lechugas, corroborando la aditividad de estos efectos como también concluye Williams II y Boydston, (2013) para el cultivo de maíz. Sin embargo, los autores en su estudio mencionan que la interacción no es significativa, al igual que se observó en la simulación donde aún no se puede modelar la interacción, pero en el ensayo *in vivo*, por la forma espacial en la que se abordó el análisis, los resultados indican que si la puede haber (Tabla 5-3).

Mediante la simulación (Tabla 5-2) se encontró que para el modelo autorregresivo puro, fue significativo el parámetro α, lo que indica la naturaleza autocorrelacionada o de dependencia espacial de la variable rendimiento (Heege, 2013), comprobada también con el I de Moran Global. Como este modelo no tiene más elementos, el total de la variación es explicada por este parámetro. Para el modelo completo, el parámetro α fue significativo y negativo, y aunque fue pequeño, sugiere algún efecto negativo de los vecinos, competencia intraespecífica, a pesar de que el simulador no la contempla explícitamente. El parámetro ρ fue significativo, lo que indica que los residuales tienen dependencia espacial y que ésta debe modelarse. El parámetro β también fue significativo, lo que indica

el efecto de las malezas sobre el cultivo. Finalmente, no hubo diferencia entre el uso de las dos matrices planteadas.

Figura 5-6: Rendimiento de las plantas de cultivo y cobertura de las malezas

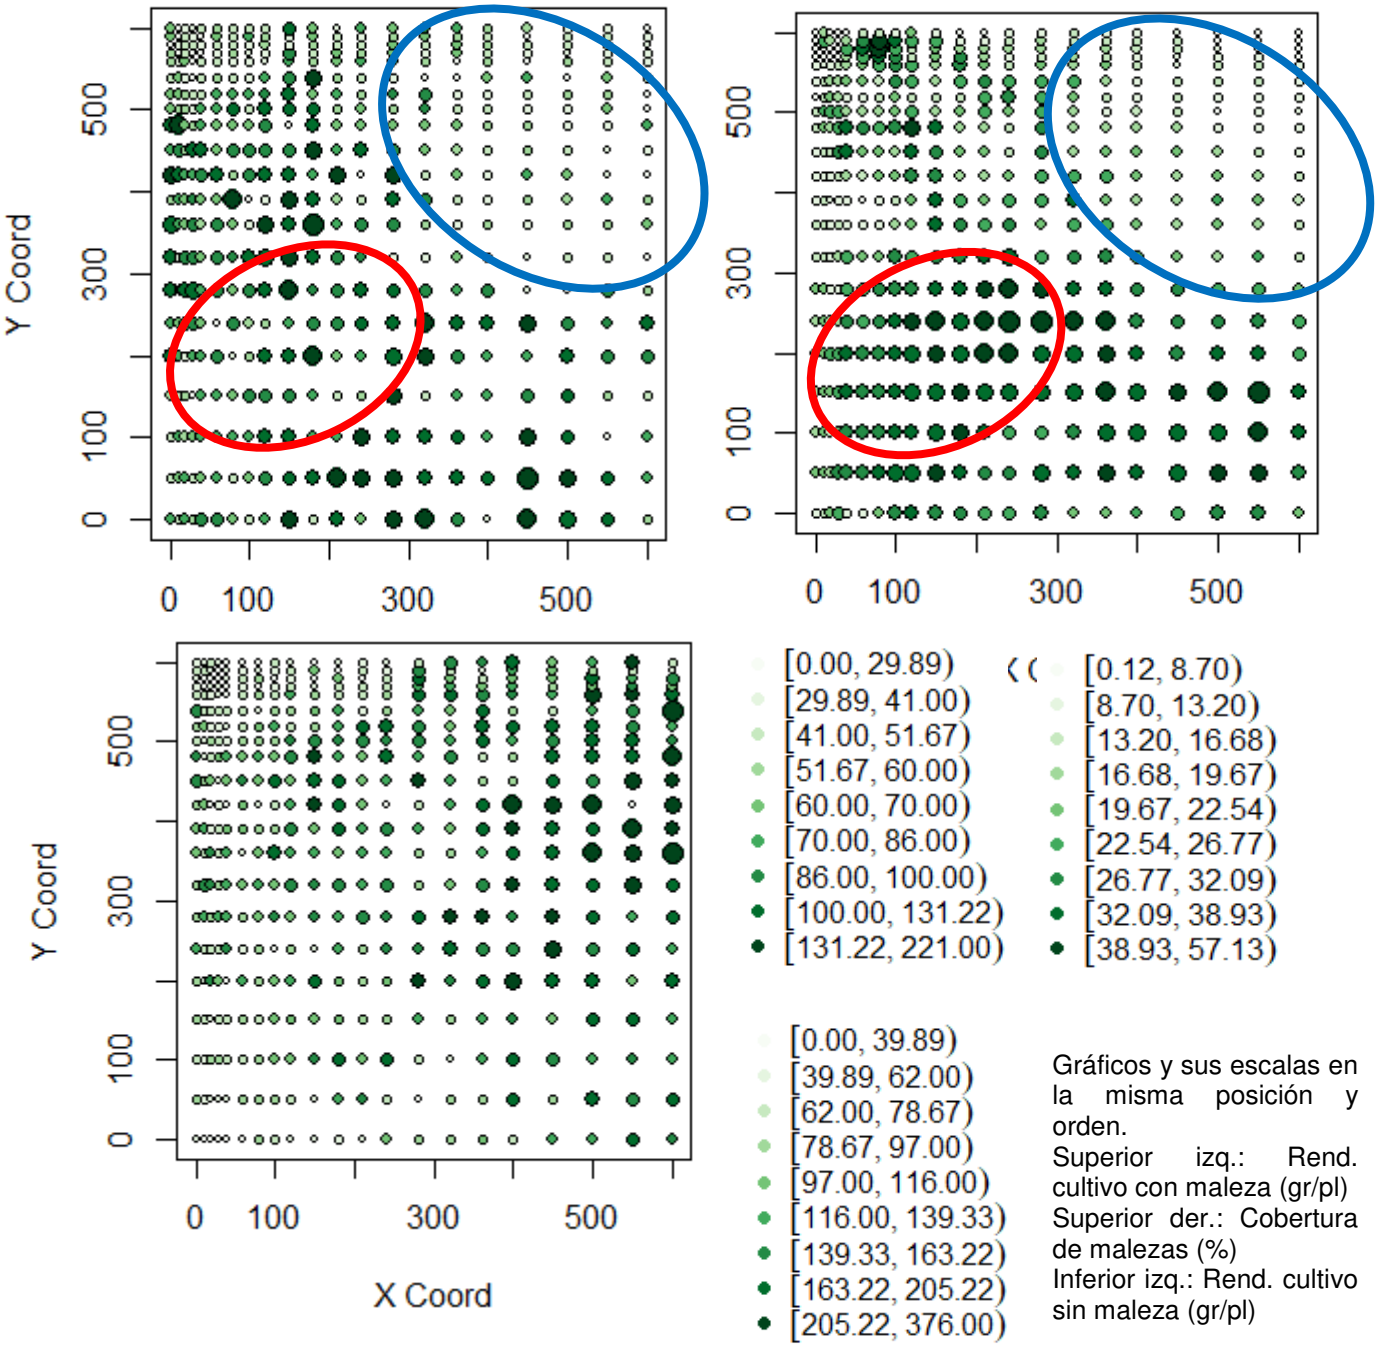

Gráficos y sus escalas en la misma posición y orden.
Superior izq.: Rend. cultivo con maleza (gr/pl)
Superior der.: Cobertura de malezas (%)
Inferior izq.: Rend. cultivo sin maleza (gr/pl)

Comparando estos resultados con el ensayo *in vivo* (Tabla 5-3), se evidencia una gran diferencia entre el uso de las dos matrices. En el que se usó solamente con la matriz de pesos de las distancias, se observa que el rendimiento del cultivo es explicado por el rendimiento de las plantas vecinas (parámetro α es positivo y significativo), que se disminuye por alguna variable no medida (parámetro ρ es negativo y significativo) y ésta afecta tanto a las malezas como al cultivo (Figura 5-6), como para que el parámetro β sea positivo, es decir donde hubo menor rendimiento de cultivo, hubo menos malezas.

Sin embargo, el uso de la matriz combinada proveniente de la matriz de pesos del cultivo con la de la abundancia de las malezas, mostró que recoge la información del efecto de la competencia intra e inter específica, al punto que la variable independiente de cobertura de malezas se vuelve no significativa. Esto permitiría, por ejemplo, incluir otras variables bióticas o abióticas (otras plagas o características del suelo) en el vector de parámetros del modelo y dejar en la matriz combinada para el efecto tanto de distancias de siembra como de las malezas. En este caso, el parámetro β fue no significativo como se mencionó anteriormente, el parámetro α fue negativo y significativo, lo que indica un efecto de competencia intraespecífica e interespecífica hacia el cultivo y el parámetro ρ fue significativo y positivo, lo que indica que los residuales tienen dependencia espacial, esto, una vez más, justifica el uso de modelos de regresión espacial.

Entre esto, se encontró un inconveniente en el uso de la regresión espacial que no se tenía contemplado: la matriz de pesos se construye con las distancias a los vecinos más cercanos y se reconoció que al normalizarla (suma de las filas = 1) no importa a que distancia estén estos ocho vecinos (esquema de siembra cuadrado), el efecto ponderado de cada uno es el mismo. Es decir, esta matriz de pesos no puede reconocer a que distancia están los vecinos, solo ponderar su efecto. Mientras que, a mayor distancia, la cantidad de malezas es mayor, por lo que la cantidad de malezas actúa como un indicador de la distancia a la que pueden estar las plantas de cultivo. Esto también podría solucionarse con el uso de otras matrices de pesos.

Tabla 5-1. Estadísticas descriptivas del rendimiento del cultivo (gr/pl) y de la cobertura de las malezas (%)

Fuente	Media	Varianza	I de Moran Global
Rendimiento del cultivo sin maleza (gr/pl)	116.18	4718	0.52*
Rendimiento del cultivo con maleza (gr/pl)	74.32	1846	0.38*
Cobertura de las malezas (%)	22.81	140.9	0.72*

* p-valor = 0

Tabla 5-2. Parámetros calculados para las simulaciones para los dos modelos: autorregresivo puro (AP) y el completo (Com), y con las dos matrices usadas Wc: distancias del cultivo y Wt: vinculada con la abundancia de malezas

Modelo	Matriz usada	m	α	ρ	β	Correlación entre observados y estimados	AIC
AP	Wc	84	0.85	NA	NA	0.79	609
AP	Wt	87	0.84	NA	NA	0.80	615
Com	Wc	102	-0.06	0.68	-0.36	0.96	439
Com	Wt	102	-0.06	0.65	-0.36	0.96	439

Tabla 5-3. Parámetros calculados para el cultivo de lechuga con presencia de malezas, con las dos matrices usadas, Wc: distancias del cultivo y Wt: vinculada con la abundancia de malezas

Modelo	Matriz usada	m	α	ρ	β	Correlación entre observados y estimados	AIC
Com	Wc	6.7*	0.81	-0.46	0.33	0.63	4403
Com	Wt	149	-0.38	0.45	0.1	0.68	4415

* No significativo. P-valor = 0.47

5.5. Conclusiones

El uso de la regresión espacial es justificado dado el carácter autocorrelacionado de las variables como rendimiento de cultivo, abundancia de malezas y más importante aún, la dependencia de los residuales.

La simulación de campos Gaussianos continuos para la creación de campos de datos de malezas y cultivos, probó ser de utilidad para el ensayo de modelos de regresión espacial, ya que permite estandarizar procesos y tener puntos de comparación con los datos *in vivo,* por lo que sirven de apoyo para el modelado de estos últimos.

La matriz de pesos combinada recoge la información de la competencia inter e intra especifica hacia las plantas de cultivo, solucionando el problema de la normalización de la matriz de pesos de distancias cuando se evalúan varias distancias de siembra en el mismo ensayo. Además, reconoce la aditividad de la competencia intra e interespecífica y la interacción de ambas.

5.6. Literatura citada

Anselin, L., & Bera, A. (1998). Spatial Dependence in Linear Regression Models with an introduction to spatial econometrics. En Handbook of Applied Economic Studies (pp. 237-289).

Anselin, L., Bongiovanni, R., & Lowenberg-Deboer, J. (2004). A spatial econometric approach to the economics of site-specific nitrogen management in corn production. American Journal of Agriculture economics, 86, 675-687.

Arbia, G. (2014). A Primer for Spatial Econometrics With Applications in R. London: Palgrave Macmillan.

Auld, B., & Tisdell, C. (1988). Influence of spatial distribution of weeds on crop yield loss. Plant Protection Quarterly, 3(January), 81.

Brain, P., & Cousens, R. (1990). The Effect of Weed Distribution on Predictions of Yield Loss. Journal of Applied Ecology, 27(2), 735-742. https://doi.org/10.2307/2404315

Cardina, J., Johnson, G., & Sparrow, D. (1997). The Nature and Consequence of Weed Spatial Distribution. Weed Science, 45(3), 364-373.

Cardona, F. (1971), Competencia de malezas en lechuga (Lactuca sativa var. Capitata). Tesis de Maestría. Universidad Nacional de Colombia. Pp 150.

Cousens, R. (1985). A simple model relating yield loss to weed density. Annals of Applied Biology, 107(2), 239-252. https://doi.org/10.1111/j.1744-7348.1985.tb01567.x

Dew, D. A. (1972). An Index of Competition for estimating Crop Loss Due to Weeds. Canadian Journal of Plant Science, 52, 921-927. https://doi.org/10.4141/cjps72-159

Florax, R. J. G. M., Voortman, R. L., & Brouwer, J. (2002). Spatial dimensions of precision agriculture: A spatial econometric analysis of millet yield on Sahelian coversands. Agricultural Economics, 27(3), 425-443. https://doi.org/10.1016/S0169-5150(02)00068-3

Fuentes, C. & Romero, C. Una visión del problema de las malezas en Colombia. Agronomía Colombiana. 1991. 8(2), 364 - 378

Galon, L., Forte, C. T., Giacomini, J. P., Rreichert Jr, F. W., Scariot, M. A., David, F. A., & Perin, G. F. (2016). Competitive Ability of Lettuce with Ryegrass. Planta Daninha, 34(2), 239-248. https://doi.org/10.1590/S0100-83582016340200005

Gomez, A., & Gomez, K. (1984). Statistical procedures for agricultural research. Statistical procedures for agricultural research, 6, 680.

González-Andújar, J. L., & Navarrete, L. (1995). Aplicación del índice de distancias t-cuadrado al estudio de las distribución espacial de las malas hierbas. Investigación Agraria Producción y protección vegetales, 10(2), 295-299.

González-Andújar, J. L., & Saavedra, M. (2003). Spatial distribution of annual grass weed populations in winter cereals. Crop Protection, 22(4), 629-633. https://doi.org/10.1016/S0261-2194(02)00247-8

Grinstead, C. M., & Snell, J. L. (1997). Introduction to Probability: Second Revised Edition. American Mathematical Society, 1-520. Recuperado de http://www.dartmouth.edu/~chance/teaching_aids/books_articles/probability_book/book.html

Heege, H. J. (2013). Precision in Crop Farming. https://doi.org/10.1007/978-94-007-6760-7

Hughes, G. (1996). Incorporating spatial pattern of harmful organisms into crop loss models. Crop Protection, 15(5), 407-421. https://doi.org/10.1016/0261-2194(96)00003-8

Khazaei, I., Salehi, R., Abdolkarim, K., & Mirjalili, S. (2013). Improvement of lettuce growth and yield with spacing, mulching and organic fertilizer. International Journal of Agriculture and Crop Sciences, 6(16), 1137-1143. http://ijagcs.com/wp-content/uploads/2013/12/1137-1143.pdf

Labrada, R., Caseley, J., & Parker, C. (1996). Manejo de Malezas para Países en Desarrollo. Estudio FAO Producción y Protección vegetal - 120. Rome: Organización de las Naciones Unidas para la Agricultura y la Alimentación.

Manning, W. G., & Mullahy, J. (2001). Estimating log models: to transform or not to transform? J Health Econ 20 (4) 461-94.

Matheron, G. (1963). Principles of geostatistics. Economic Geology, 58(8), 1246-1266. https://doi.org/10.2113/gsecongeo.58.8.1246

Montgomery, D. (2013). Design and Analysis of Experiments (8.a ed.). John Wiley & Sons.

Norris, R., Elmore, C., Rejmánek, M., & Akey, W. C. (2001). Spatial arrangement, density, and competition between barnyardgrass and tomato: I. Crop growth and yield. Weed Science, 49(1), 61-68. https://doi.org/10.1614/0043-1745

Oerke, E. (2006). Crop losses to pests. Journal of Agricultural Science, 144, 31-43. https://doi.org/10.1017/S0021859605005708

Puerto, A. (2017). Clasificación y cuantificación de maleza en cultivos de hortalizas por medio de procesamiento de imágenes digitales. Universidad Nacional de Colombia.

Radosevich, S. (1987). Methods to Study Interactions Among Crops and Weeds. Weed Technology, 1, 190-198.

Radosevich, S., Holt, J., & Ghersa, C. (2007). Ecology of weeds and invasive plants: Relationship to agriculture and natural resource management. (3 Ed, Ed.). Hoboken, New Jersey.

Rejmánek, M., Robinson, G., & Rejmánková, E. (1989). Weed-Crop Competition: Experimental Designs and Models for Data Analysis. Weed Science, 37(2), 276-284.

Renton, M., & Chauhan, B. (2017). Modelling crop-weed competition: Why, what, how and what lies ahead? Crop Protection, 95, 101-108. https://doi.org/10.1016/j.cropro.2016.09.003

Smith, R. J. (1993). Logarithmic transformation bias in allometry. American Journal of Physical Anthropology, 90(2), 215-228. https://doi.org/10.1002/ajpa.1330900208

Swanton, C., Nkoa, R., & Blackshaw, R. E. (2015). Experimental Methods for Crop – Weed Competition Studies. Weed Science, (2), 2-11. https://doi.org/10.1614/WS-D-13-00062.1

Webster, R., & Oliver, M. (2007). Geostatistics for Environmental Scientists. Wiley. https://doi.org/10.2136/vzj2002.0321

Weiner, J., Griepentrog, H.-W., & Kristensen, L. (2001). Suppression of weeds by spring wheat. Journal of Applied Ecology, 38, 784-790.

Williams II, M. M., & Boydston, R. A. (2013). Intraspecific and interspecific competition in sweet corn. Agronomy Journal, 105(2), 503-508. https://doi.org/10.2134/agronj2012.0381

Yordanova, M., & Nikolov, A. (2017). Influence of plant density and mulching on weed infestation in lettuce (Lactuca sativa var . romana Hort .). Journal of Agriculture and Veterinary Science, 10(10), 71-76. https://doi.org/10.9790/2380-1010017176

Zeng, W. S., & Tang, S. Z. (2011). Bias Correction in Logarithmic Regression and Comparison with Weighted Regression for Nonlinear Models. Nature Precedings, 1-11. https://doi.org/10.1038/npre.2011.6708

Zimdahl, R. (2007). Fundamentals of weed science. Elsevier. https://doi.org/10.1016/0378-4290(95)90065-9

6. Discusión general

Desde los inicios de la agricultura las malas hierbas o malezas, han sido un constante problema para los agricultores, surgiendo la necesidad de cuantificar su efecto sobre los cultivos. La predicción de la reducción de la producción por parte de las malezas ha generado una gran cantidad de literatura en malherbología (Jamaica-Tenjo y González-Andújar, 2019) que ha permitido disponer de modelos de decisión para numerosos cultivos. Sin embargo, en Colombia son pocos los desarrollos en este sentido, estando limitados al cálculo de épocas críticas de competencia para diversos cultivos, principalmente hortícolas.

Una de las principales limitaciones de los modelos predictivos desarrollados, es que no han considerado la distribución espacial de las malezas y el cultivo. Actualmente, está bien asentado en la malherbología que las malezas presentan una distribución agregada en los cultivos (González-Andújar y Saavedra, 2003). La irrupción de la Agricultura de Precisión (AP) en el mundo agrícola (Lutman et al., 2007) ha traído un énfasis en la necesidad de considerar los aspectos espaciales en la relación competitiva entre las malezas y el cultivo. Además, el desarrollo de nuevos modelos se ha visto impulsado por los avances en estadística espacial, sistema de información geográfica y computación.

6.1. Simulación

Los modelos de regresión espacial, tienen en cuenta la dependencia espacial del cultivo, de las malezas y del entorno. Para este caso y gracias al uso del simulador, se logró evaluar variantes de un modelo de regresión espacial, en diversos escenarios de estructura poblacional de las malezas, dando como resultado que los parámetros autorregresivos del modelo fueron significativos, lo cual, valido el uso del simulador y el uso del modelo. Sin embargo, se debe tener en cuenta que los resultados del simulador deben ser

caracterizados a profundidad, además de que se necesitan más evaluaciones *in vivo* para acotar los parámetros de los escenarios posibles y probables. Además, se requiere conocer el efecto del error (ruido blanco) y de los errores dependientes del espacio tanto en los modelos lineales, no lineales como autorregresivos.

Estas simulaciones, a pesar de sus obvias limitaciones resultaron ser muy útiles no solo para evaluar los modelos de regresión espacial, sino que constituyen una herramienta para generar infinidad de escenarios y repeticiones de acuerdo a los objetivos que puedan plantearse los investigadores de diversas áreas. Este simulador, puede generar datos no solo para malezas, sino para otras plagas o variables abióticas. De gran utilidad sobre todo, en la evaluación de metodologías de muestreo, evaluación de modelos o caracterización de variables regionalizadas. También, se puede usar para la generación de variables de cultivos hortícolas, cereales, perennes, industriales y forestales. Sin embargo, deben contarse con una serie de parámetros *a priori* para integrarlos a la simulación.

Para este caso, la simulación permitió conocer e interpretar la interacción entre las características de las malezas y su efecto en el rendimiento del cultivo, en donde se encontró que interactúan y que por lo tanto se deben considerar en su conjunto al relacionarla con el rendimiento de cultivo, y no solamente la abundancia promedio como se hace usualmente.

6.2. Modelos de regresión espacial

Esta, es otra limitación de los modelos que se han usado en las últimas décadas, incluso los que han hecho avances para su uso en agricultura de precisión (Keller, 2014), quien

evalúa el uso de umbrales de acción diferenciales para áreas subdivididas del campo, pero no incluye parámetros de dependencia espacial para el cultivo, para las malezas o para el entorno, que, como se mencionó anteriormente, se encontraron parámetros autorregresivos significativos.

Lo anterior implica que para establecer una relación entre el rendimiento de cultivo y la abundancia de malezas, se debe contar con modelos que incluyan la dependencia implícitamente. De no ser así, se pueden llegar a resultados sesgados con lo cual, se puede llegar a la toma de decisiones equivocadas frente al efecto de las malezas sobre el cultivo y sobre todo en decisiones de manejo.

En el modelo de regresión espacial evaluado, se logró tener en cuenta la dependencia espacial del cultivo, mediante el uso de la matriz de pesos que proviene de las distancias entre las plantas de cultivo. También, la dependencia espacial de las malezas se tuvo en cuenta mediante dos formas: la inclusión de la variable de abundancia de malezas como variable independiente, la cual vincula el rendimiento del cultivo de forma lineal a la abundancia de malezas, usando la matriz de pesos del cultivo como indicadora de su dependencia espacial. La otra forma, tuvo en cuenta la dependencia espacial de las malezas, esta vez de forma implícita, mediante la construcción de una matriz de pesos que proviene de la abundancia de malezas entre cada planta de cultivo con sus vecinas.

La comparación entre ambas formas dio como resultado que: el uso de la matriz de pesos proveniente de las malezas reúne más información de la estructura espacial de la interacción cultivo-malezas que incluir a las malezas como variable independiente. Además, de esta forma se incluye dentro del modelo el efecto de las densidades de siembra hacia el cultivo y hacia las malezas. También, deja disponible la matriz de variables independientes para incluir otras variables bioecológicas, como características del suelo, del clima o de otras plagas. Esto, abre posibilidades acerca del uso de otras conformaciones o configuraciones de las matrices de pesos, además de demostrar que la

competencia intra e interespecífica es aditiva. Sin embargo, es necesario evaluar distintas formas de relacionar las matrices de pesos, ya que esta aditividad debe evaluarse a profundidad.

Sin embargo, el uso de la matriz de pesos de las malezas, tuvo implicación en el aumento de la cantidad de información a obtener, por lo que fue necesario el desarrollo de sistemas más automáticos para la obtención de la información, ya que los métodos de muestreo convencionales resultan insuficientes e ineficientes.

6.3. Teledetección

El software desarrollado para el procesamiento de imágenes multiespectrales mediante k-medias fue suficiente para realizar la segmentación entre las plantas de maleza y del suelo. Sin embargo, puede ser mejorado en su capacidad de uso en escenarios de malezas más difíciles de procesar, por ejemplo, cuando existe traslape entre malezas y cultivos, a partir de su procesamiento mediante histogramas de gradiente orientado, máquinas de soporte vectorial o redes neuronales convolucionales, Además, puede ser usado para la evaluación de bioensayos de cultivos en donde se evalúen malezas (ej. Ensayos de herbicidas o de competencia)

Los modelos de regresión espacial en el estudio de la interacción malezas-cultivo y de acuerdo con las condiciones expuestas de esta investigación, pueden usarse para cultivos hortícolas principalmente. Cultivos como cereales y pasturas requerirían de un desarrollo mayor en las técnicas de toma de información, ya que el software por ahora tiene dificultades para segmentar malezas y cultivo cuando existen traslapes. Otro tipo de cultivos como frutales perennes, requerirían de un desarrollo adicional del muestreo de

malezas, ya que usualmente estas se encuentran por debajo del dosel, en donde resulta difícil el registro de la información para el sensor usado. Sin embargo, en lo que resulta intrínseco al modelo no tendría inconvenientes para su uso en todo tipo de cultivos.

6.4. Transdisciplinariedad en la malherbología

Esta tesis ha sido posible gracias a la interacción de múltiples disciplinas: ingeniería, electrónica, programación, interpretación de señales, botánica, en el desarrollo del software que estima la abundancia de las malezas en forma de cobertura (%) y que permitió validar el modelo. Geoestadística, modelado espacial, programación, agronomía y malherbología en el desarrollo del simulador de datos que imitan las características poblacionales de las malezas que se presentan en los campos de cultivo. Estadística, estadística espacial, ecología, agronomía y malherbología en la evaluación de los modelos de regresión espacial y en la conformación de nuevas formas de matrices de pesos. Por lo que se pone de manifiesto la necesidad de integrar equipos transdiscipinares en el futuro de la malherbología, de acuerdo a lo sugerido por Jordan et al, (2016), quienes inspiraron la aproximación metodológica a este documento.

7. Literatura citada general

Agrow (2003) Agrochemical sales flat in 2002. Agrow: World Crop Protection News. http://ipm.osu.edu/trans/043_141.htm

Akaike, H. (1974). A new look at the statistical model identification. IEEE Transactions on Automatic Control, 19(6), 716–723. doi:10.1109/tac.1974.1100705

Alexandratos, N, Bruinsma, J (2012). World agriculture towards 2030/2050: the 2012 revision, ESA Working Papers 288998, Food and Agriculture Organization of the United Nations, Agricultural Development Economics Division (ESA).

Andújar, D., Ribeiro, A., Carmona, R., Fernández-Quintanilla, C., & Dorado, J. (2010). An assessment of the accuracy and consistency of human perception of weed cover. Weed Research, 50(6), 638–647. https://doi.org/10.1111/j.1365-3180.2010.00809.x

Anselin, L., & Bera, A. (1998). Spatial Dependence in Linear Regression Models with an introduction to spatial econometrics. En Handbook of Applied Economic Studies (pp. 237–289).

Anselin, L., Bongiovanni, R., & Lowenberg-Deboer, J. (2004). A spatial econometric approach to the economics of site-specific nitrogen management in corn production. American Journal of Agriculture economics, 86(August), 675–687.

Appleby AP, Muller F, Carpy S (2000) Weed control. In: Muller F (ed) Agrochemicals, Wiley, New York, p 687–707

Arbia, G. (2014). A Primer for Spatial Econometrics With Applications in R. London: Palgrave Macmillan.

Auld, B., & Tisdell, C. (1988). Influence of spatial distribution of weeds on crop yield loss. Plant Protection Quarterly, 3(January), 81.

Begueira, S. (2010). Generating spatially correlated random fields with R. Recuperado de http://santiago.begueria.es/2010/10/generating-spatially-correlated-random-fields-with-r/

Blanco, Y., & Leyva, A. (2007). Las arvenses en el agroecosistema y sus beneficios agroecológicos como hospederas de enemigos naturales. Cultivos tropicales, 28(2),21-28

Bosnic, A., & Swanton, C. (1997). Influence of barnyardgrass (Echinochloa crus-galli) time of emergence and density on corn (Zea mays). Weed Science, 45(2), 276–282.

Brain, P., & Cousens, R. (1990a). The Effect of Weed Distribution on Predictions of Yield Loss. Journal of Applied Ecology, 27(2), 735–742. https://doi.org/10.2307/2404315

Brain, P., & Cousens, R. (1990b). The Effect of Weed Distribution on Predictions of Yield Loss. Journal of Applied Ecology, 27(2), 735–742. https://doi.org/10.2307/2404315

Bridges, D. C., & Chandler, J. M. (1987). Influence of Johnsongrass (Sorghum halepense) Density and Period of Competition on Cotton Yield. Weed Science, 35, 63–67.

Calha IM, Sousa E, Gonzalez-Andujar JL (2014). Infestation maps and spatial stability of main weed species in maize culture. Planta Daninha 32: 275-282

Camps-Valls, G., & Bruzzone, L. (2005). Kernel-based methods for hyperspectral image classification. IEEE Transactions on Geoscience and Remote Sensing, 43(6), 1351–1362. https://doi.org/10.1109/TGRS.2005.846154

Cardina, J., Johnson, G., & Sparrow, D. (1997). The Nature and Consequence of Weed Spatial Distribution. Weed Science, 45(3), 364–373.

Cardona, F. (1971), Competencia de malezas en lechuga (Lactuca sativa var. Capitata). Tesis de Maestría. Universidad Nacional de Colombia. Pp 150.

Clements, F., Weaver, J., & Hanson, H. (1929). Plant competition: an analysis of community function. Washington, D.C.: Carnegie Institution of Washington.

Cousens, R. (1985a). A simple model relating yield loss to weed density. Annals of Applied Biology, 107(2), 239–252. https://doi.org/10.1111/j.1744-7348.1985.tb01567.x

Cousens, R. (1985b). An Empirical Model Relating Crop Yield to Weed and Crop Density and A Statistical Comparison with Other Models. The Journal of Agricultural Science, 105(3), 513–521. https://doi.org/10.1017/S0021859600059396

Cousens, R., Brain, P., O'Donovan, J., & O'Sullivan, P. (1987). The use of biologically realistic equations to describe the effects of weed density and relative time of emergence on crop yield. Weed Science, 35(5), 720–725.

Cressie, N. (1993). Statistics for spatial data. Hoboken, New Jersey: John Wiley & Sons.

Dale, M. R. T., Dixon, P., Legendre, P., Myers, D. E., & Rosenberg, M. S. (2002). Conceptual and mathematical relationships among methods for spatial analysis. Ecography, 25(5), 558–577. https://doi.org/10.1034/j.1600-0587.2002.250506.x

Deen, W., Cousens, R., Warringa, J., Bastiaans, L., Carberry, P., Rebel, K., … Wang, E. (2003). An evaluation of four crop: Weed competition models using a common data set. Weed Research, 43(2), 116–129. https://doi.org/10.1046/j.1365-3180.2003.00323.x

Dew, D. A. (1972). An Index of Competition for estimating Crop Loss Due to Weeds. Canadian Journal of Plant Science, 52, 921–927. https://doi.org/10.4141/cjps72-159

El Sharif, H., Wang, J., & Georgakakos, A. P. (2015). Modeling Regional Crop Yield and Irrigation Demand Using SMAP Type of Soil Moisture Data. Journal of Hydrometeorology, 16(2), 904–916. https://doi.org/10.1175/jhm-d-14-0034.1

Elhorst, J. P. (2010). Applied Spatial Econometrics: Raising the Bar. Spatial Economic Analysis, 5(1), 9–28. https://doi.org/10.1080/17421770903541772

Florax, R. J. G. M., Voortman, R. L., & Brouwer, J. (2002). Spatial dimensions of precision agriculture: A spatial econometric analysis of millet yield on Sahelian coversands. Agricultural Economics, 27(3), 425–443. https://doi.org/10.1016/S0169-5150(02)00068-3

Fuentes, C. & Romero, C. Una visión del problema de las malezas en Colombia. Agronomía Colombiana. 1991. 8(2), 364 - 378

Galon, I., Forte, C. T., Giacomini, j. P., Reichert Jr, f. W., Scariot, M. A., David, F. A., & Perin, G. F. (2016). Competitive Ability of Lettuce with Ryegrass. Planta Daninha, 34(2), 239–248. https://doi.org/10.1590/S0100-83582016340200005

Gherekhloo, J., Noroozi, S., Mazaheri, D., Ghanbari, A., Ghannadha, M., Vidal, R., & De Prado, R. (2010). Multispecies weed competition and their economic threshold on the wheat crop. Planta Daninha, 28(2), 239–246.

Godfray HC et al., (2010) Food security: The challenge of feeding 9 billion people. Science 327, 812–818

Gomez, A., & Gomez, K. (1984). Statistical procedures for agricultural research. Statistical procedures for agricultural research, 6, 680.

González-Andújar, J. L., Chantre, G. R., Morvillo, C., Blanco, A. M., & Forcella, F. (2016). Predicting field weed emergence with empirical models and soft computing techniques. Weed Research, 56(6), 415–423. https://doi.org/10.1111/wre.12223

González-Andújar, J. L., Fernández-Quintanilla, C., Bastida, F., Calvo, R., Izquierdo, J., & Lezaun, J. (2011). Assessment of a decision support system for chemical control of annual ryegrass (Lolium rigidum) in winter cereals. Weed Research, 51(3), 304–309. https://doi.org/10.1111/j.1365-3180.2011.00842.x

González-Andújar, J. L., Fernández-Quintanilla, C., & Torner, C. (1993). Competencia entre la avena loca (Avena sterilis) y el trigo de invierno: comparación de modelos empíricos. Investigación Agraria: Producción y Protección Vegetales, 8(3), 425–430.

González-Andújar, J. L., & Navarrete, L. (1995). Aplicación del índice de distancias t-cuadrado al estudio de las distribución espacial de las malas hierbas. Investigación Agraria Producción y protección vegetales, 10(2), 295–299.

González-Andújar, J. L., & Saavedra, M. (2003). Spatial distribution of annual grass weed populations in winter cereals. Crop Protection, 22(4), 629–633. https://doi.org/10.1016/S0261-2194(02)00247-8

González-Díaz, L., Blanco-Moreno, J. M., & González-Andújar, J. L. (2015). Spatially explicit bioeconomic model for weed management in cereals: Validation and evaluation of management strategies. Journal of Applied Ecology, 52(1), 240–249. https://doi.org/10.1111/1365-2664.12359

Goslee, S. C. (2006). Behavior of vegetation sampling methods in the presence of spatial autocorrelation. Plant Ecology, 187(2), 203–212. https://doi.org/10.1007/s11258-005-3495-x

Gräler, B., Pebesma, E., & Heuvelink, G. (2016). Spatio-Temporal Interpolation using gstat. The R Journal, 8(1), 204–218.

Grinstead, C. M., & Snell, J. L. (1997). Introduction to Probability: Second Revised Edition. American Mathematical Society, 1–520. Recuperado de http://www.dartmouth.edu/~chance/teaching_aids/books_articles/probability_book/book.html

Harvey, R., & Wagner, C. (1994). Using Estimates of Weed Pressure to Establish Crop Yield Loss Equations. Weed Technology, 8(1), 114–118. https://doi.org/doi:10.1017/S0890037X00039294

Heege, H. J. (2013). Precision in Crop Farming. Springer Science. https://doi.org/10.1007/978-94-007-6760-7

Heijting, S. (2007). Spatial analysis of weed patterns. Tesis de Doctorado.Universidad de Wageningen. Recuperado de http://library.wur.nl/wda/dissertations/dis4308.pdf

Heisel, T., Ersbøll, A. K., & Andreasen, C. (1999). Weed Mapping with Co-Kriging Using Soil Properties. Precision Agriculture, 1(1), 39–52. https://doi.org/10.1023/A:1009921718225

Holst, N., Rasmussen, I., & Bastiaans, L. (2007). Field weed population dynamics : a review of model approaches and applications. Weed Research, 47, 1–14.

Holzner, W., & Numata, M. (1982). Biology and ecology of weeds. (Springer, Ed.). The Hague.

Hughes, G. (1996). Incorporating spatial pattern of harmful organisms into crop loss models. Crop Protection, 15(5), 407–421. https://doi.org/10.1016/0261-2194(96)00003-8

Jadhav, B. D., & Patil, P. M. (2014). Hyperspectral Remote Sensing For Agricultural Management: A Survey. International Journal of Computer Applications, 106(7), 975–8887.

Jamaica-Tenjo, D. A., & González-Andújar, J. L. (2019). Modelos empíricos de competencia cultivo-mala hierba, Revisión bibliográfica. ITEA-Información Técnica Económica Agraria, xx, 1–18. https://doi.org/https://doi.org/10.12706/itea.2019.007

Jamaica, D. (2013). Dinámica espacial y temporal de poblaciones de malezas en cultivos de papa, espinaca y caña de azúcar y su relación con propiedades del suelo en dos localidades de Colombia. Tesis de Maestría. Facultad de Ciencias Agrarias. Universidad Nacional de Colombia. Pp 82

Jamaica, D., & Plaza, G. (2014). Evaluation of various conventional methods for sampling weeds in potato and spinach crops. Agronomia Colombiana, 32(1). pp.36-43. ISSN 0120-9965. http://dx.doi.org/10.15446/agron.colomb.v32n1.39613.

Jordan, N, Schut, M, Graham, S, Barney, JN, Childs, DZ, Christensen, S, Cousens, RD, Davis, AS, Eizenberg, H, Ervin, DE, Fernandez-Quintanilla, C, Harrison, LJ, Harsch, MA, Heijting, S, Liebman, M, Loddo, D, Mirsky, SB, Riemens, M, Neve, P, Peltzer, DA, Renton, M, Williams, M, Recasens, J, Sonderskov, M (2016). Transdisciplinary weed research: new leverage on challenging weed problems? Weed Research 56 345–358.

Jurado-Expósito, M., López-Granados, F., García, L., & García-Ferrer, A. (2003). Multi-Species Weed Spatial Variability and Site-Specific Management Maps in Cultivated Sunflower. Weed Science, 51(3), 319–328. https://doi.org/10.1614/0043-1745(2003)051

Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. Computers and Electronics in Agriculture, 147, 70–90. https://doi.org/10.1016/j.compag.2018.02.016

Keller, M. 2014. Effects of weeds on yield and determination of economic thresholds for site-specific weed control using sensor technology. PhD Dissertation. University of Hohenheim. Pp 54.

Khazaei, I., Salehi, R., Abdolkarim, K., & Mirjalili, S. (2013). Improvement of lettuce growth and yield with spacing, mulching and organic fertilizer. International Journal of Agriculture and Crop Sciences, 6(16), 1137–1143.

Kropff, M., & Spitters, C. (1991). A simple model of crop loss by weed competition from early observations on relative leal area of the weeds. Weed Research, 31, 97–105.

Kropff, M., & van Laar, H. (1993). Modelling Crop-Weed Interactions. Modelling Crop-Weed Interactions. Wallingford: CAB INTERNATIONAL.

Labrada, R., Caseley, J., & Parker, C. (1996). Manejo de Malezas para Países en Desarrollo. Estudio FAO Producción y Portección vegetal - 120. Rome: Organización de las Naciones Unidas para la Agricultura y la Alimentación.

Legendre, P., Dale, M. R. T., Fortin, M. J., Gurevitch, J., Hohn, M., & Myers, D. (2002). The consequences of spatial structure for the design and analysis of ecological field surveys. Ecography, 25(5), 601–615. https://doi.org/10.1034/j.1600-0587.2002.250508.x

Lottes, P., Khanna, R., Pfeifer, J., Siegwart, R., & Stachniss, C. (2017). UAV-based crop and weed classification for smart farming. Proceedings - IEEE International Conference on Robotics and Automation, 3024–3031. https://doi.org/10.1109/ICRA.2017.7989347

Lutman PJ. Wand Miller PCH (2007) Spatially variable herbicide application technology; opportunities for herbicide minimisation and protection of beneficial weeds. Research Review No. 62, Home-Grown Cereals Authority (HGCA), UK

Manning, W. G., & Mullahy, J. (1999). Estimating log models: to transform or not to transform? (No. 246). Cambridge.

Marshall, E. (1988). Field-Scale Estimates of Grass Weed Populations in Arable Land. Weed Research, 28(3), 191–198. https://doi.org/10.1111/j.1365-3180.1988.tb01606.x

Matheron, G. (1963). Principles of geostatistics. Economic Geology, 58(8), 1246–1266. https://doi.org/10.2113/gsecongeo.58.8.1246

Mcmaster, G. S., & Wilhelm, W. (1997). Growing degree-days: one equation, two interpretation. Agricultural and Forest Meteorology, 87, 291–300. https://doi.org/10.1016/j.rhum.2013.05.004

Meyer, G. E., Neto, J. C., Jones, D. D., & Hindman, T. W. (2004). Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images. Computers and Electronics in Agriculture, 42(3), 161–180. https://doi.org/10.1016/j.compag.2003.08.002

Montgomery, D. (2013). Design and Analysis of Experiments (8a ed.). John Wiley & Sons.

Ngouajio, M., Leroux, G., & Lemieux, C. (1999). A flexible sigmoidal model relating crop yield to weed relative leaf cover and its comparison with nested models. Weed Research, 39(4), 329–343. https://doi.org/10.1046/j.1365-3180.1999.00150.x

Nkoa, R., Owen, M. D. K., & Swanton, C. J. (2015). Weed Abundance, Distribution, Diversity, and Community Analyses. Weed Science, 63(sp1), 64–90. https://doi.org/10.1614/WS-D-13-00075.1

Norris, R., Elmore, C., Rejmánek, M., & Akey, W. C. (2001). Spatial arrangement, density, and competition between barnyardgrass and tomato: I. Crop growth and yield. Weed Science, 49(1), 61–68. https://doi.org/10.1614/0043-1745

O'Donovan, J., de St. Remy, E., O'Sullivan, P., Dew, D., & Sharma, A. (1985). Influence of the relative time of emergence of wild oat (Avena fatua) on yield loss of barley (Hordeum vulgare) and wheat (Triticum aesitvum). Weed Science, 33, 498–503.

Oerke, E. (2006). Crop losses to pests. Journal of Agricultural Science, 144, 31–43. https://doi.org/10.1017/S0021859605005708

Osborn, S., Panayot, V., & Villa, U. (2017). A multilevel hierarchical sampling technique for spatially correlated random fields. SIAM Journal on Scientific computing, 39(5), S543–S562. https://doi.org/10.1137/090750688

Pérez-Ortiz, M., Peña-Barragán, J. M., Gutiérrez, P. A. A., Torres-Sánchez, J., Hervás-Martínez, C., López-Granados, F., … López-Granados, F. (2015). A semi-supervised system for weed mapping in sunflower crops using unmanned aerial vehicles and a crop row detection method. Applied Soft Computing, 37, 533–544. https://doi.org/10.1016/j.asoc.2015.08.027

Puerta, P., Ciannelli, L., & Johnson, B. (2019). A simulation framework for evaluating multi-stage sampling designs in populations with spatially structured traits. PeerJ, 7, e6471. https://doi.org/10.7717/peerj.6471

Puerto, A. (2017). Clasificación y cuantificación de maleza en cultivos de hortalizas por medio de procesamiento de imágenes digitales. Universidad Nacional de Colombia.

Radosevich, S. (1987). Methods to Study Interactions Among Crops and Weeds. Weed Technology, 1, 190–198.

Radosevich, S., Holt, J., & Ghersa, C. (2007). Ecology of weeds and invasive plants: Relationship to agriculture and natural resource management. (3 Ed, Ed.). Hoboken, New Jersey.

Rejmánek, M., Robinson, G., & Rejmánková, E. (1989). Weed-Crop Competition: Experimental Designs and Models for Data Analysis. Weed Science, 37(2), 276–284.

Rendon-Aguilar, B., Bernal-Ramirez, L., & Sánchez-Reyes, GA. (2017). Las plantas arvenses: más que hierbas del campo. Oikos=. Instituto de Ecología. Universidad Nacional Autónoma de México.

Renton, M., & Chauhan, B. (2017). Modelling crop-weed competition: Why, what, how and what lies ahead? Crop Protection, 95, 101–108. https://doi.org/10.1016/j.cropro.2016.09.003

Rodríguez Albarrcín, H. S., Darghan Contreras, A. E., & Henao, M. C. (2019). Spatial regression modeling of soils with high cadmium content in a cocoa producing area of Central Colombia. Geoderma Regional, 16, e00214. https://doi.org/10.1016/j.geodrs.2019.e00214

Rodríguez, M., Plaza, G., Gil, R., & Chaves, B. (2008). Reconocimiento y fluctuación poblacional arvense en el cultivo de espinaca (Spinacea oleracea L .) para el municipio de Cota , Cundinamarca Recognition and population fluctuation of weeds in spinach crop (Spinacea oleracea L .) in the municipality of Co.

Ronchi, C., & Silva, A. (2006). Effects of weed species competition on the growth of young coffee plants. Planta Daninha, 24(3), 415–423. https://doi.org/10.1590/S0100-83582006000300001

Shukla, G., & Subrahmanyam, G. (1999). A Note on an Exact Test and Confidence Interval for Competition and Overlap Effects. Biometrics, 55(March), 273–276.

Smith, R. J. (1993). Logarithmic transformation bias in allometry. American Journal of Physical Anthropology, 90(2), 215–228. https://doi.org/10.1002/ajpa.1330900208

Spitters, C. (1983). An alternative approach to the analysis of mixed cropping experiments. Netherland Journal of Agricultural Science, 31, 1–11.

Swanton, C., Nkoa, R., & Blackshaw, R. E. (2015). Experimental Methods for Crop – Weed Competition Studies. Weed Science, (2), 2–11. https://doi.org/10.1614/WS-D-13-00062.1

Swanton, C., Weaver, S., Cowan, P., Van Acker, R., Deen, W., & Shreshta, A. (1999). Weed thresholds: theory and applicability. Journal of Crop Production, 2(1), 9–29. https://doi.org/10.1300/J144v02n01

Tang, J. L., Wang, D., Zhang, Z. G., He, L. J., Xin, J., & Xu, Y. (2017). Weed identification based on K-means feature learning combined with convolutional neural network. Computers and Electronics in Agriculture, 135, 63–70. https://doi.org/10.1016/j.compag.2017.01.001

Thorp, K. R., & Tian, L. F. (2004). A review on remote sensing of weeds in agriculture. Precision Agriculture, 5(5), 477–508. https://doi.org/10.1007/s11119-004-5321-1

Torner, C., González-Andújar, J. L., & Fernández-Quintanilla, C. (1991). Wild Oat (Avena-Sterilis L) Competition With Winter Barley - Plant-Density Effects. Weed Research, 31(5), 301–307.

Torra, J., Cirujeda, A., Recasens, J., Taberner, A., & Powles, S. B. (2010). PIM (Poppy Integrated Management): A bio-economic decision support model for the management of Papaver rhoeas in rain-fed cropping systems. Weed Research, 50(2), 127–139. https://doi.org/10.1111/j.1365-3180.2010.00761.x

Torres-Sánchez, J., López-Granados, F., Peña, J. M., Peña-Barragán, J. M., Peña, J. M., & Peña-Barragán, J. M. (2015). An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. Computers and Electronics in Agriculture, 114, 43–52. https://doi.org/10.1016/j.compag.2015.03.019

Walter, A., Christensen, S., & Simmelsgaard, S. (2002). Spatial correlation between weed species densities and soil properties. Weed Research, 42(1), 26–38. https://doi.org/10.1046/j.1365-3180.2002.00259.x

Webster, R., & Oliver, M. (2007). Geostatistics for Environmental Scientists. Wiley. https://doi.org/10.2136/vzj2002.0321

Weiner, J., Griepentrog, H.-W., & Kristensen, L. (2001). Suppression of weeds by spring wheat. Journal of Applied Ecology, 38, 784–790.

Williams II, M. M., & Boydston, R. A. (2013). Intraspecific and interspecific competition in sweet corn. Agronomy Journal, 105(2), 503–508. https://doi.org/10.2134/agronj2012.0381

Yordanova, M., & Nikolov, A. (2017). Influence of plant density and mulching on weed infestation in lettuce (Lactuca sativa var . romana Hort .). Journal of Agriculture and Veterinary Science, 10(10), 71–76. https://doi.org/10.9790/2380-1010017176

Zanin, G., Berti, A., & Riello, L. (1998). Incorporation of weed spatial variability into the weed control decision-making process. Weed Research, 38(2), 107–118. https://doi.org/10.1046/j.1365-3180.1998.00074.x

Zeng, W. S., Zeng, W. S., & Tang, S. Z. (2011). Bias Correction in Logarithmic Regression and Comparison with Weighted Regression for Nonlinear Models. Nature Precedings, 1–11. https://doi.org/10.1038/npre.2011.6708

Zimdahl, R. (2004). Weed-Crop Competition. A Review (Second Edi). Blackwell Publishing.

Zimdahl, R. (2007). Fundamentals of weed science. Elsevier. https://doi.org/10.1016/0378-4290(95)90065-9