



República de Cuba

FACULTAD DE INGENIERÍA INFORMÁTICA

**Estimación espacial de tres agentes nocivos del
cultivo del tomate en la EPP de Lajas**

**TESIS EN OPCIÓN AL TÍTULO ACADÉMICO DE
MÁSTER EN MATEMÁTICA APLICADA**

Autor: Ing. Mailiu Díaz Peña

Tutor: Prof. Tit., Leónides Castellanos González, DrC.

Cienfuegos, 2011

RESUMEN

Resumen

Esta investigación se desarrolla a partir de la información obtenida sobre tres agentes nocivos en el territorio de la Estación de Protección de Plantas (EPP) de Lajas en la Provincia de Cienfuegos que comprende los municipios: Lajas, Cruces y Palmira. En la misma se determinan los modelos para la estimación espacial de la intensidad de *Bemisia tabaci* Guen. y *Alternaria solani* Sor., y la distribución del *Virus del encrespamiento amarillo de la hoja del tomate* (TYLCV), por ser los agentes primarios de mayor interés del cultivo del tomate para las campañas comprendidas entre los años 2003-2004 al 2007-2008. Para el cumplimiento del objetivo planteado se efectúa un análisis del cumplimiento de los requisitos necesarios para el estudio, lo que incluye el ajuste a una distribución normal, la identificación de valores atípicos y la presencia de estacionaridad; se calcula el semivariograma experimental y se ajusta éste a un modelo; se representan los mapas de estimación con los modelos que presentaron un mejor ajuste, los que se validaron a partir de los errores de estimación. Como resultado del estudio se encontraron los modelos de mejor ajuste, con coeficientes de determinación mayores que el 70% y coeficientes de correlación mayores que 0.89, que fueron utilizados para estimar espacialmente la intensidad de la *Alternaria solani* y de *Bemisia tabaci*, y la distribución del *Virus del encrespamiento amarillo de la hoja del tomate*, los que permitirán a los tomadores de decisiones establecer tácticas de control dirigidas hacia los focos específicos de infestación.

TABLA DE CONTENIDO

Tabla de Contenido

Resumen

Introducción	8
Capítulo 1: “Reseña Bibliográfica”	14
1.1 – Definiciones básicas y antecedentes de la geoestadística	14
1.1.1 – Problema que dio origen a la Geoestadística	15
1.1.2 – La geoestadística y su relación con respecto a otras ramas de la estadística	16
1.2 – Aspectos que se analizan en la solución de la geoestadística.....	19
1.2.1 – El semivariograma experimental	20
1.2.1.1 – Consideraciones prácticas para el cálculo del semivariograma.....	21
1.2.1.2 – Parámetros del semivariograma	22
1.2.1.3 – Tipos de anisotropía	23
1.2.1.4 – Ajuste del semivariograma a un modelo.....	24
1.2.1.5 – Problemas más comunes encontrados en el cálculo del semivariograma	25
1.2.2 – Estimación espacial.....	26
1.3 – Aplicaciones de la geoestadística	28
1.3.1 – Geoestadística en procesos naturales.....	29
1.3.2 – Aplicaciones de la geoestadística en Cuba.....	32
1.4 – Importancia del uso de la geoestadística en la Sanidad Vegetal.....	33
Capítulo 2: “Procedimiento para realizar el estudio geoestadístico”	37
2.1 – Análisis del cumplimiento de los requisitos necesarios para el estudio geoestadístico de las variables de tres agentes nocivos.....	38
2.2 – Definición del modelo de mejor ajuste para la estimación espacial de las variables estudiadas.....	45

2.3 – Validación del modelo de mejor ajuste para la estimación	49
Capítulo 3 – Aplicación del procedimiento para el análisis geoestadística.....	52
3.1 – Análisis del cumplimiento de los requisitos necesarios para el estudio geoestadístico de las variables que caracterizan a tres agentes nocivos	52
3.2 – Definición de los modelos de mejor ajuste para la estimación espacial de las variables de los agentes nocivos estudiados.....	59
3.3 – Validación de los modelos de mejor ajuste para cada agente por campaña	81
Conclusiones Generales	86
Recomendaciones	88
Bibliografía	90
Anexos	

INTRODUCCIÓN

Introducción

La utilización de los sistemas de información geográfica (SIG) en diversos campos del quehacer humano, se ha incrementado en los últimos años demostrando ser una herramienta muy útil en la toma de decisiones. En la agricultura se ha aplicado en áreas como el control de enfermedades, contaminación de suelos, entomología, nematología y fertilidad de suelos, entre otras. Uno de los aspectos de mayor utilidad ha sido el estudio de la variabilidad espacial de suelos y la predicción de valores en puntos no muestreados a través del uso de las interpolaciones, herramienta SIG muy utilizada en conjunto con las metodologías de muestreo (Henríquez *et al.*, 2005).

En el campo de las geociencias es común encontrar variables distribuidas espacialmente. Para el estudio de estas variables son usados diversos procedimientos geoestadísticos de estimación y/o simulación. Esto es, a partir de un conjunto de muestras tomadas en localizaciones del dominio en que se manifiesta un fenómeno a estudiar y consideradas representativas de su realidad, que por lo general es siempre desconocida, estos procedimientos permiten la descripción o caracterización de las variables con dos fines diferentes, primero, proporcionar valores estimados en localizaciones de interés y segundo, generar valores que en conjunto presenten iguales características de dispersión que los datos originales (Castaño & Vergara, 2004).

La geoestadística es una rama de la estadística aplicada que se refiere a procedimientos estadísticos que analizan y modelizan la relación espacial de un fenómeno. A diferencia de otros métodos, que caracterizan el modelo espacial basándose en distribuciones estadísticas (e. j. Binomial Negativa) o en índices de dispersión (e.j. ratio media-varianza, índice de Morisista, etc), la geoestadística tiene en cuenta la naturaleza bidimensional de la distribución de los insectos a través de su exacta localización espacial. Además, la geoestadística, a través del kriging, puede proporcionar mapas de la distribución espacial de los organismos (Ramírez *et al.*, 2002).

La Geoestadística ha sido ampliamente utilizada internacionalmente. Se ha extendido en la actualidad a otros campos de las Ciencias Naturales que presentan problemas de estimación. En Cuba el uso de estas técnicas de estimación ha estado limitado a la incursión empírica de especialistas, tomando auge en las empresas geomineras y en las instituciones relacionadas con las Ciencias de la Tierra en general (Cuador, 2005).

El sistema de la sanidad vegetal en Cuba se estructura nacionalmente en determinados territorios atendidos por las Estaciones de Protección de Plantas (EPP), las cuales entre sus

funciones tienen la de realizar las advertencias agrícolas y los pronósticos de plagas y enfermedades (Castellanos *et al.*, 2008), existiendo diferentes servicios de pronósticos establecidos a partir de estimaciones en función del tiempo y la fenología de los cultivos como los de Castellanos *et al.* (2005 a, b).

En la actualidad se conoce poco sobre la distribución espacial de las plagas, enfermedades y malezas de los cultivos en Cuba, a pesar de existir una gran cantidad de datos acumulados en las EPP, lo cual significa un impedimento para perfeccionar los servicios fitosanitarios en el país, por lo que conocer con mayor detalle su comportamiento espacial en el campo resulta de gran importancia. Con tal fin se desarrolla un proyecto financiado por el CITMA en la provincia de Cienfuegos donde se hace necesario la aplicación de las técnicas geoestadísticas para establecer la distribución e intensidad de los agentes nocivos sobre la base de toda la información espacial disponible y elaborar mapas que permitan obtener estimas no sesgadas de los puntos no muestreados. Dichos mapas pueden ser de gran utilidad para establecer tácticas de control más efectivas, haciendo un uso más racional de los plaguicidas, los cuales se pueden dirigir hacia los focos específicos de infestación, con el consiguiente ahorro económico y protección medioambiental.

Problema Científico

Cuál sería el modelo de mejor ajuste para la estimación espacial de los índices que caracterizan los agentes nocivos del tomate, *Virus del encrespamiento amarillo de la hoja del tomate* (TYLCV), *Bemisia tabaci* Guen. y *Alternaria solani* Sor. en el territorio de la Estación de Protección de Plantas de Lajas.

Hipótesis

El análisis geoestadístico de los índices de agentes nocivos más importantes del cultivo del tomate en el territorio de la EPP de Lajas permitirá encontrar los modelos para realizar una estimación espacial con precisión de las variables empleadas para caracterizar los agentes nocivos: *Virus del encrespamiento amarillo de la hoja del tomate* (TYLCV), *Bemisia tabaci* Guen. y *Alternaria solani* Sor.

Objeto de investigación: La intensidad de *Bemisia tabaci* Guen. y *Alternaria solani* Sor., y la distribución del *Virus del encrespamiento amarillo de la hoja del tomate* (TYLCV) en el cultivo del tomate

Campo de acción: Los modelos para realizar la estimación espacial de las variables más empleadas que caracterizan a tres agentes nocivos del tomate en el territorio de la EPP de Lajas.

Objetivo general

Determinar los modelos para la estimación espacial de la intensidad de *Bemisia tabaci* Guen. y *Alternaria solani* Sor., y la distribución del *Virus del encrespamiento amarillo de la hoja del tomate* (TYLCV) en el cultivo del tomate para cinco campañas en la EPP de Lajas.

Objetivos específicos

1. Analizar el cumplimiento de los requisitos necesarios para el estudio geoestadístico de las variables que caracterizan a tres agentes nocivos.
2. Definir los modelos de mejor ajuste para la estimación espacial de las variables de los tres agentes nocivos clave en el cultivo del tomate en la EPP de Lajas.
3. Validar los modelos de mejor ajuste para cada agente por campaña.

Tareas de investigación

1. Confección de una revisión bibliográfica sobre los estudios existentes y los aspectos que se incluyen en un análisis geoestadístico.
2. Análisis del cumplimiento de los requisitos necesarios para el estudio geoestadístico de las variables que caracterizan a tres agentes nocivos.
3. Definición de los modelos de mejor ajuste para la estimación espacial de las variables de tres agentes nocivos en el cultivo del tomate.
4. Validación de los modelos definidos con mejor ajuste para cada agente por campaña.
5. Redacción del informe final.

La investigación se **justifica** por la necesidad de estimar espacialmente la distribución e intensidad de las variables más empleadas en la Sanidad Vegetal para caracterizar tres agentes nocivos que afectan al cultivo del tomate; para obtener una medida del riesgo que se comete posibilitando a especialistas y directivos mayor eficiencia en la toma de decisiones, realizar un uso más racional de los medios e identificar las alternativas más factibles para minimizar la afectación económica y los impactos medioambientales que producen los plaguicidas químicos.

Metodología empleada

- Analítico-Sintético

Para analizar toda la información disponible relacionada con los aspectos abordados en la presente investigación y arribar a conclusiones generales.

- Análisis histórico-lógico

Para estudiar el comportamiento de tres variables que caracterizan a los agentes nocivos clave del cultivo del tomate desde la campaña 2003-2004 a la 2007-2008 en el territorio de la EPP de Lajas.

- Análisis hipotético-deductivo

A partir de la hipótesis planteada y los datos empleados, se estableció un modelo, para cada una de las tres variables estudiadas en cada campaña, para estimar espacialmente el comportamiento de las mismas.

- Modelación matemática

Aplicación del modelo de regresión lineal múltiple para verificar el cumplimiento de las hipótesis de la geoestadística y el uso de modelos propios de la geoestadística como el de la semivarianza, los modelos para el ajuste: esférico, exponencial, gaussiano y cuadrático, y el modelo para la interpolación por el método de kriging ordinario; para lo cual se emplearon los software SPSS v.15 y el Surfer v. 9.

La **novedad** está dada porque el desconocimiento sobre la distribución e intensidad espacial de los agentes nocivos en las diferentes regiones de Cuba significa un serio problema para la planificación de los recursos y la toma de decisiones en el campo de la sanidad vegetal, por lo que conocer con mayor detalle su comportamiento espacial, en el campo con la aplicación de técnicas geoestadísticas, permite estimar la distribución e intensidad de estos en base a toda la información espacial disponible y elaborar mapas de gran utilidad para establecer tácticas de control dirigidas hacia las áreas de mayor o menor riesgo, o sea se va a disponer de métodos predictivos o de advertencias de los agentes nocivos de forma espacial.

El trabajo quedó estructurado en Síntesis, Introducción, tres Capítulos, Conclusiones, Recomendaciones, Bibliografía y Anexos.

En el Capítulo 1 se abordan las definiciones básicas en la solución de un problema con el uso de métodos geoestadísticos, los trabajos que se han realizado con el uso de esta metodología a

nivel mundial y específicamente en Cuba, y por último se fundamenta la importancia que tiene la aplicación de la geoestadística para el manejo y control de plagas en la Sanidad Vegetal.

En el Capítulo 2 se describe el procedimiento empleado para realizar el análisis geoestadístico necesario para la estimación de las tres variables más empleadas para caracteriza a los agentes nocivos clave en el cultivo del tomate y así darle cumplimiento a los objetivos planteados en la presente investigación.

En el Capítulo 3 se analizó el cumplimiento de los requisitos necesarios para el estudio de las tres variables para cada una de las campañas; se ajustaron las variables a los modelos esférico, gaussiano, exponencial y cuadrático, y los modelos que resultaron tener un mejor ajuste fueron validados posterior a la estimación espacial.

CAPÍTULO 1

Capítulo 1: “Reseña Bibliográfica”

En el desarrollo de este capítulo se abordan definiciones básicas y antecedentes de los análisis geoestadísticos; se definen los aspectos que intervienen en la solución de un problema con el uso de esta metodología, las aplicaciones generales que ha tenido a nivel mundial y específicamente los pasos que se han dado en Cuba, y por último se aborda la importancia que tiene la aplicación de esta metodología para el manejo y control de plagas en la Sanidad Vegetal.

En la Figura 1.1 se representa el hilo conductor, donde se organizan todos los temas abordados en este capítulo.

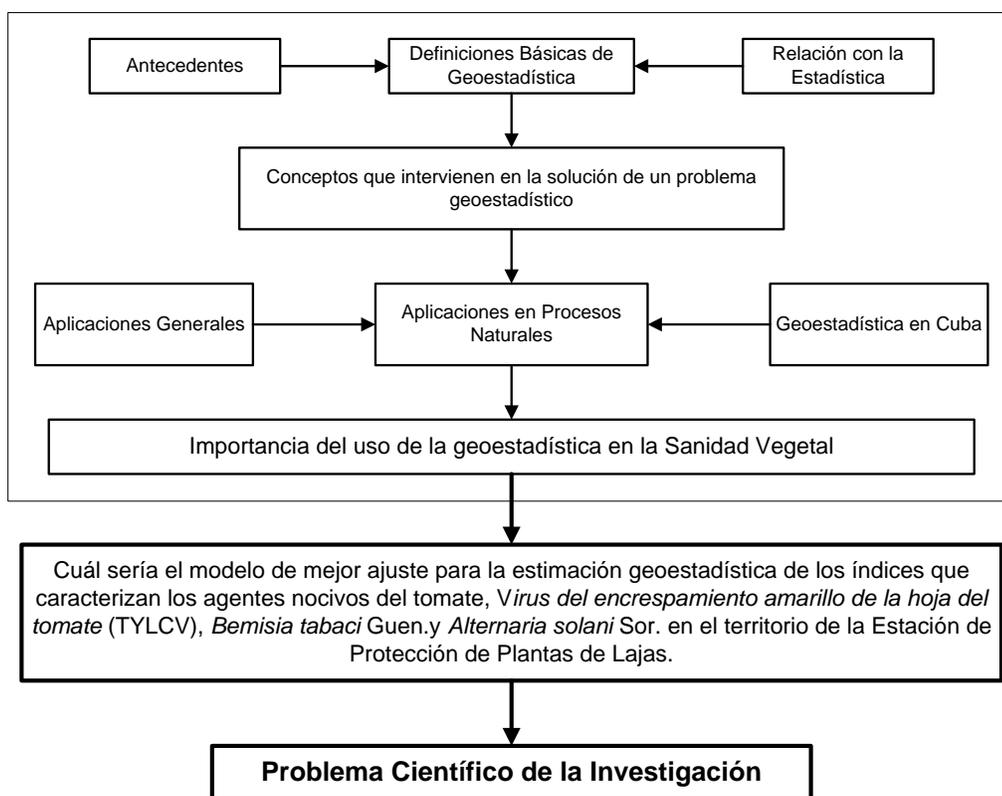


Figura 1.1 – Hilo conductor de la investigación. **Fuente:** Elaboración Propia.

1.1 – Definiciones básicas y antecedentes de la geoestadística

Las definiciones de Sistema de Información Geográfica (SIG) repiten las palabras “datos espaciales” como concepto básico en un SIG. Ente las definiciones halladas, posiblemente la aportada en 1990 por el *National Center for Geographic Information and Analysis* (NCGIA) “sistema de hardware, software y procedimientos elaborados para facilitar la obtención, gestión,

manipulación, análisis, representación y salida de datos espacialmente referenciados” recoge en si una mayor precisión en su concepto. En definitiva un SIG es una herramienta que permite la integración de datos espaciales y la implementación de diversas técnicas de análisis espacial. En la actualidad, existen diverso software que pueden utilizarse en la realización de estudios de distribución superficial, los que ofrecen métodos apropiados para llevar a cabo estudios de análisis espacial de características del suelo y del medio aunque con ciertas limitaciones. Por ello, y con el fin de conseguir una mayor precisión en la estimación de valores, es necesario recurrir a un análisis geoestadístico previo, que ayude a conocer la relación entre los datos, la dependencia espacial, el modelo de interpolación y los parámetros que lo constituyen, así como los errores cometidos al modelizar (Rodríguez & Grau, 2007).

1.1.1 – Problema que dio origen a la Geoestadística

Las primeras manifestaciones de la estadística sobre datos espaciales aparecen en la forma de mapas de datos. Por ejemplo Halley (1686) superpuso sobre un mapa, las direcciones de cambio de los vientos alisos y monzones, entre y en las cercanías de los trópicos, y procuró asignarles causas físicas. Mucho tiempo después aparecen los modelos espaciales. Así en 1907, Student estudió la distribución de partículas a través de los líquidos (Nicolás, 2004).

La Geoestadística surge por los trabajos de G. Matheron en la Escuela Superior de Minas de París, buscando minimizar la varianza del error de estimación, basado en conceptos iniciales de trabajos de H.S. Sichel en 1947 y 1949, en la aplicación de la distribución lognormal en minas de oro, seguido por la famosa contribución de D.G. Krige en 1951, quien fue el primero en observar la naturaleza asimétrica de la distribución del contenido de oro en las minas surafricanas, la equiparó a una distribución de probabilidad lognormal, desarrolló las fórmulas básicas para esta distribución y propuso una variante del método de medias móviles, el cual puede considerarse como el equivalente al krigeado simple que es uno de los métodos de estimación lineal en el espacio con mayores cualidades teóricas. Estos trabajos fijaron la base de la Geoestadística Lineal, además, de la introducción de la teoría de funciones aleatorias por B. Matern en el estudio de la variación espacial de campos forestales (Cuador, 2002).

En los años setenta, los investigadores como Rogowski en 1972 y Nielsen y Biggar en 1976 empezaron los estudios de las propiedades del suelo de una manera más cuantitativa; la mayoría de ellos confió en los métodos estadísticos clásicos. Una suposición implícita en estos análisis es, que las observaciones de una variable del suelo son independientes con respecto a su ubicación en el campo. La primera publicación de Geoestadística apareció en 1978 por

Campbell. En 1980 Webster y sus colegas iniciaron una serie de publicaciones llamadas “interpolación óptima y mapeo isarítmico de propiedades del suelo”, en la que el método kriging era por primera vez usado en la ciencia del suelo. Samra en 1989 realizó estimaciones de alturas en plantaciones de *Melia Azedaeach*, Mandallaz comparó varios métodos de Kriging en la estimación de densidad y área basal. Hock, combinó el uso de sistemas de información geográficos con técnicas geoestadísticas en la estimación de índices de sitio de *Pinus radiata* en Nueva Zelanda (Sopó, 2004).

A finales de la década de los ochenta, gran parte del contenido de los artículos era reiterativo y dogmático. A pesar del importante volumen de trabajo experimental, las críticas al uso inadecuado del método eran escasas. Así, por ejemplo se insistía en señalar que la precisión de un krigeado dependía únicamente del muestreo en un segmento espacial definido por el rango del variograma. Con frecuencia se repetían experiencias similares en lugares geográficos distintos (Ulloa *et al.*, 2003).

La Geoestadística se consolidó y desarrolló en los últimos años como ciencia aplicada casi exclusivamente en el campo minero, existiendo como ciencia aplicada que da respuesta a necesidades prácticas y concretas. Se reconoce como una rama de la estadística tradicional, desarrollándose herramientas matemáticas para el estudio de estas variables dependientes entre sí, llamadas según Matheron variables regionalizadas. En resumen, la aplicación de la teoría de los procesos estocásticos a los problemas de evaluación de reservas de distintos tipos de materias primas en el análisis de datos distribuidos espacial y temporalmente dio origen a lo que hoy se conoce como Geoestadística (Cuador, 2002).

1.1.2 – La geoestadística y su relación con respecto a otras ramas de la estadística

El prefijo “geo” indica la relación estrecha entre el tema en estudio y todo lo perteneciente a la tierra, es decir en este caso la estadística relativa a la tierra, y verdaderamente este fue su significado original. Hart en 1954 le dio un contexto geográfico para denotar las técnicas estadísticas que enfatizan la localización dentro de las distribuciones zonales. Matheron usó el término en un contexto geológico para denotar la teoría y los métodos para inferir las reservas de mineral en bruto desde datos espacialmente distribuidos en un bloque (volumen de tierra y roca que puede ser minado si es suficientemente rico). En Francia bajo el impulso de Matheron, principalmente, emergió antes de 1980 la disciplina Geoestadística como una mezcla de ingeniería en minas, geología, matemática y estadística, que a diferencia de otros enfoques más clásicos, tiene en cuenta la tendencia espacial y la correlación espacial que en

terminología minera corresponden a la variabilidad espacial en gran escala y en pequeña escala respectivamente. Las mismas ideas también fueron desarrolladas en forma independiente por Gandin en la Unión Soviética, pero aplicadas a la Meteorología (Nicolás, 2004).

Journel & Huijbregts (1978) plantean que la geoestadística es una rama de la estadística que trata con fenómenos espaciales. Su interés primordial es la estimación, predicción y simulación de dichos fenómenos. Esta ofrece una manera de describir la continuidad espacial, que es un rasgo distintivo esencial de muchos fenómenos naturales, y proporciona adaptaciones de las técnicas clásicas de regresión para tomar ventajas de esta continuidad. Petitgas (1996), la define como una aplicación de la teoría de probabilidades a la predicción estadística de variables regionalizadas (variables medidas en una región) (Giraldo *et al.*, 2000).

Chica *et al.* (1995) la define como la aplicación de la teoría de las variables regionalizadas a la estimación de procesos o fenómenos espaciales. Desde un punto de vista teórico, la Geoestadística se basa en conceptos y herramientas ya existentes en otros campos de la Estadística como procesos estocásticos estacionarios, técnicas de análisis de la varianza y predicción por mínimos cuadrados, con una extensión al caso de funciones aleatorias en dos o más dimensiones (Tannure *et al.*, 2008).

Muchas de las ideas de la geoestadística han sido inspiradas en su hermana menor: las series cronológicas o series de tiempo. Se puede advertir que los objetivos del Análisis de Series de Tiempo son similares a los de la Geoestadística. Mientras que el Análisis de Series Temporales está orientado al estudio de procesos unidimensionales con datos uniformemente distribuidos, la Geoestadística se ocupa del estudio de fenómenos con datos distribuidos de forma arbitraria en el espacio y tiempo, por lo que la metodología de ésta última tiene un carácter mucho más general. En un marco más amplio, la geoestadística es una disciplina que pertenece a la estadística espacial (Díaz, 2002).

Las diferencias no son tanto de tipo conceptual como de campo de aplicación. Sin embargo, como el desarrollo de ambos ha sido independiente, sus nomenclaturas son bastantes diferentes, de forma que el intercambio de técnicas no es inmediato pese a no revestir dificultades fundamentales. Por otro lado, los tipos de problemas que se plantean son lo suficientemente distintos como para que dicho intercambio no sea todo lo provechoso que cabría esperar. Así, las técnicas Geoestadísticas son más generales pero menos potentes que las del Análisis de Series Temporales (Nicolás, 2004).

Matheron, padre de la Geoestadística, la definió como “la aplicación del formalismo de las funciones aleatorias al reconocimiento y estimación de fenómenos naturales” (Tannure & Mazza, 2003).

Según Amador & Escobedo (2004) es una colección de métodos estadísticos que describen la autocorrelación espacial entre datos de muestras, mientras que los métodos tradicionales usan datos autocorrelacionados y el propósito principal de sus planes de muestreo es evitar correlaciones espaciales. En geoestadística no hay necesidad de evitar autocorrelaciones y el muestreo es menos restrictivo.

Castillo (2005) plantea que es el marco más apropiado para la formulación de problemas en los que la variabilidad espacial afecta mucho al resultado. Además la Geoestadística no permite obtener sólo la estimación del fenómeno natural a partir de un conjunto de medidas, sino también una medida de la incertidumbre. Este hecho es muy importante para casos en que conocer el grado de certeza de un resultado es tan o incluso más importante que el resultado en sí, o simplemente cuando se quieren presentar los resultados como intervalos de confianza.

La geostatística permite responder a las siguientes preguntas: ¿Qué grado de dependencia espacial existe en las variables de interés?, ¿Cuál es el patrón espacial de dichas variables?, ¿A qué escala se repite este patrón espacial?, ¿Existe covariación espacial entre las distintas variables de interés?, ¿Cuál es la mejor representación gráfica de la continuidad de las variables? y ¿Cuál es el grado de incertidumbre de las estimas obtenidas en sitios no muestreados? Las respuestas a estas preguntas son siempre dependientes de la escala espacial elegida (Gallardo, 2008).

El uso de técnicas geoestadísticas de este tipo, gracias al soporte de diversos software para procesamiento automatizado así como de SIG, se ha convertido hoy en día en una herramienta de gran capacidad y aplicabilidad para el estudio de variables espaciales, tal como se desprende de la recopilación de los diferentes trabajos realizados en esta área de investigación. Entre los programas informáticos más utilizados se pueden mencionar: Geo-EAS, GSLIB, GSTAT, VARIOWIN, VESPER, MAPINFO, R+, SADA, WINGSLIB, IDRISI, SURFER, ARCGIS GEOSTATISTICAL ANALIST, entre otros (Guerra *et al.*, 2006).

Los sistemas antes mencionados implementan la aplicación de los métodos geoestadísticos de forma muy variada, ofreciendo posibilidades en algunos casos limitadas para los especialistas

no entrenados en el tema, fundamentalmente en la determinación de los modelos que describen la continuidad espacial y en el uso del krigeaje como interpolador (Cuador, 2005).

1.2 – Aspectos que se analizan en la solución de la geoestadística

La solución de la geoestadística asocia la aleatoriedad con la variable regionalizada. Para ello piensa en un modelo estocástico según el cual se ve a la variable regionalizada como una de las posibles realizaciones de una función aleatoria. Pero los objetos que se requieren analizar son únicos y perfectamente deterministas. Las probabilidades y sus fundamentos experimentales en la ley de los grandes números requieren la posibilidad de repetición, pero ésta es imposible con objetos que son esencialmente únicos (Usandivaras, 2006).

La información y análisis obtenido mediante muestreo es inevitablemente de limitada densidad superficial por el elevado costo de tiempo y dinero, y aunque proporciona datos precisos para cierto número de puntos, no aporta información directa para la mayor parte de la superficie (Rodríguez & Grau, 2007).

En resumen, a groso modo un análisis geoestadístico está compuesto por tres etapas (Moreno, 2009; Sopó & Guerrero, 2009; Vera & Guerrero, 2009; Cañada, 2005):

- 1) análisis exploratorio de los datos, para comprobar la consistencia de los mismos, eliminando los valores erróneos e identificando las distribuciones de las que proceden;
- 2) análisis estructural, mediante el cálculo del semivariograma experimental y el posterior ajuste de una función teórica que mejor explique su variabilidad espacial; y
- 3) predicciones (kriging o simulaciones) en los puntos no muestrales teniendo en cuenta los pesos proporcionados por el modelo, así como la estructura de correlación espacial de los datos.

La primera etapa, conocida como análisis exploratorio de datos, está basada en técnicas estadísticas convencionales que permiten obtener todo un conjunto de información, desconocida a priori sobre la muestra bajo estudio, que es imprescindible para realizar “correctamente” cualquier análisis estadístico y en particular un análisis geoestadístico (Díaz, 2002).

La identificación de valores extremos y su ubicación geográfica, la evaluación de la forma de la distribución y el cálculo de medidas de localización, variabilidad y correlación son muy

importantes en la teoría geoestadística para definir que procedimiento de predicción es el más conveniente (Giraldo, 2005).

Journel y Huijbregts (1978) plantea la definición de variable regionalizada como una variable distribuida en el espacio que es puramente descriptiva y envuelve una interpretación probabilística, refiriéndose a que, desde el punto de vista matemático una variable regionalizada es simplemente una función $f(x)$ que toma valores en todos los puntos x de coordenadas (x_i, y_i, z_i) en el espacio tridimensional. Sin embargo, es muy frecuente que estas funciones, varíen tan irregularmente en el espacio, que impidan un estudio matemático directo, y se hace necesario realizar un análisis de variabilidad de la información disponible. A este conjunto de variables aleatorias se le llama Función Aleatoria y se escribe $Z(x)$ (Ramírez, 2006).

La forma en que se presenta la información es muy diversa, la geoestadística se construye asumiendo condiciones de estacionaridad. Por lo que es necesario aceptar el cumplimiento de ciertas hipótesis sobre el carácter de la función aleatoria o procesos estocásticos estudiados, llamadas Hipótesis de la Geoestadística. Estas son: La Estacionaridad Estricta, La Estacionaridad de Segundo Orden, La Hipótesis Intrínseca y los Procesos Cuasiestacionarios. En la práctica según las hipótesis que más se presentan son: La Estacionaridad de Segundo Orden y la Hipótesis Intrínseca. Estas condiciones de estacionaridad se asumen en el desarrollo teórico, en la práctica deben ser verificadas en los datos antes de comenzar un estudio geoestadístico, por lo que se puede realizar un análisis estadístico de la información, de modo que se refleje el grado de confiabilidad en la aplicación de estos métodos (Pacheco, 2008).

1.2.1 – El semivariograma experimental

El semivariograma posee la potencialidad necesaria para medir la “dependencia espacial” de fenómenos continuos y variantes, dando una descripción de la escala y de los patrones de variabilidad espacial (Viedma *et al.*, 1999).

Éste representa el útil más importante en todo estudio geoestadístico. Su cálculo no consiste en una simple evaluación de su expresión, esta operación está relacionada con los elementos siguientes (Pacheco, 2008):

- La dirección en la que será calculado el semivariograma, el ángulo que define una dirección en el espacio (θ) con tolerancia angular ($d\theta$). El semivariograma calculado

usando tolerancia angular de 90° se denomina “semivariograma medio”, “global” u “omnidireccional”.

- El incremento o paso en el cálculo del semivariograma (h) y su tolerancia lineal (dh), se recomienda que el valor de dh sea la mitad del incremento inicial.
- Una distancia, que representa la distancia máxima a que pueden estar alejados los segundos puntos del par con respecto a la línea que define la dirección de cálculo, conocido como ancho de banda.
- La distancia (L_{max}) hasta la cual será calculado el semivariograma. Se recomienda que ésta sea la mitad de la distancia entre las muestras más alejadas, aunque dependiendo de la geometría del fenómeno regionalizado en algunos casos puede ser calculado hasta una distancia superior.

1.2.1.1 – Consideraciones prácticas para el cálculo del semivariograma

Para llevar a cabo el cálculo del semivariograma se debe tomar en cuenta algunas reglas prácticas para que exista una mejor eficiencia y calidad de la estimación, esto independientemente del tipo de estimador utilizado, las cuales son según Méndez (2008):

- Para la estimación del semivariograma se toma en cuenta el número de parejas que se encuentran en un intervalo $h = \|h\|$ con una tolerancia $\pm \frac{\Delta h}{2}$ y dentro de una dirección θ con una tolerancia $\pm \frac{\Delta \theta}{2}$. Al semivariograma así estimado se le conoce como suavizado o regularizado.
- El semivariograma muestral tiene mejor eficiencia y calidad si se calcula para valores de $\|h\|$ menores que la mitad de la distancia máxima $\left(\|h\| < \frac{d_{max}}{2} \right)$.
- Para determinar con precisión el rango y la meseta del semivariograma se deben tener de 10 a 25 intervalos, esto dependiendo de la cantidad de información con la que se dispone.

- El ancho del intervalo se debe elegir de tal forma que el número de parejas sea relativamente grande, para que la estimación sea estable. Se considera que con más de 30 parejas se obtiene una buena estimación.
- El valor estimado se debe graficar contra el promedio de la distancia de las parejas que se encuentran en dicho intervalo.

1.2.1.2 – Parámetros del semivariograma

Los parámetros del semivariograma caracterizan tres elementos importantes en la variabilidad de un atributo que son: la discontinuidad en el origen (existencia de efecto de pepita), el valor máximo de variabilidad (meseta), y el área de influencia de la correlación (alcance), (ver Figura 1.1) y se describen a continuación (Pacheco, 2008).

- El Efecto Pepita (*Nugget*): El semivariograma por definición es nulo en el origen, pero en la práctica las funciones obtenidas pueden presentar discontinuidad en el origen, a esta discontinuidad se le llama efecto de pepita, en inglés (*Nugget effect*). Puede ser obtenido trazando una línea recta entre los primeros puntos del semivariograma empírico y extender ésta hasta que se intercepte con el eje “y”. Si esta intersección ocurre por debajo de cero, el valor asumido por este efecto es cero, pues valores negativos de $\gamma(0)$ no tienen significado y no es común. El efecto pepita se representa como C_0 .
- La Meseta (*Sill*): Es el valor de $\gamma(h)$ para el cual con el aumento de h su valor permanece constante, se representa como $(CT = C_1 + C_0)$. Puede obtenerse trazando una línea paralela a la abscisa y que se ajuste a los puntos de mayor valor del semivariograma y su valor se lee en la intersección de esta línea con la ordenada.
- El Alcance (*Range*): La distancia h para la cual las variables $Z(x)$ y $Z(x+h)$ son independientes, se denomina alcance y se representa por (a) , es decir, las distancias para la cual los valores de la variable dejan de estar correlacionados, o lo que es lo mismo, la distancia para la cual el semivariograma alcanza su meseta. Éste siempre tiene valor positivo y puede ser obtenido a partir de la intersección de las líneas descritas en los puntos anteriores, ese punto leído en la abscisa es una fracción del propio alcance.

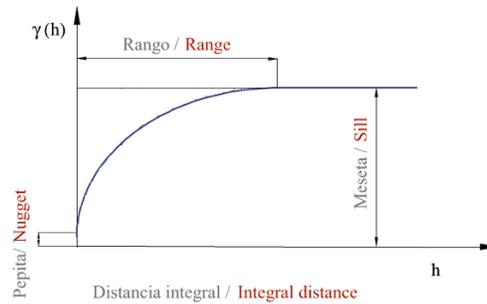


Figura 1.1 – Representación gráfica de un semivariograma y los parámetros que lo definen.
Fuente: (Castillo, 2005)

1.2.1.3 – Tipos de anisotropía

Se conoce que el semivariograma describe las características de continuidad espacial de la variable regionalizada en una dirección, pero este comportamiento puede variar según la dirección que se analice, se exige por este motivo un análisis del comportamiento de la continuidad en distintas direcciones, el Análisis de Anisotropía (Cuador, 2002).

Existen dos tipos de anisotropía:

- Anisotropía Geométrica: Está presente cuando los semivariogramas en diferentes direcciones tiene la misma meseta pero distintos alcances (Figura 1.2a).
- Anisotropía Zonal: Está presente cuando los semivariogramas en diferentes direcciones tiene diferentes mesetas y alcances (Figura 1.2b).

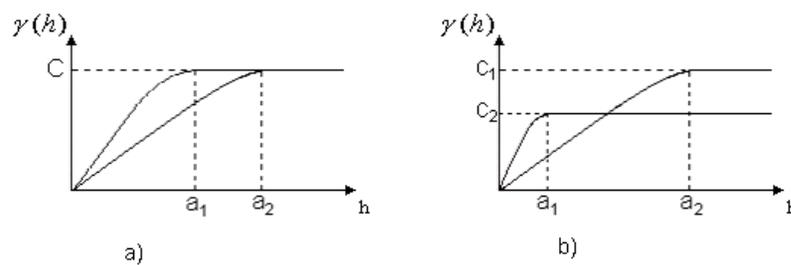


Figura 1.2 – Tipos de anisotropía, a) Anisotropía Geométrica, b) Anisotropía Zonal.

Fuente: (Cuador, 2002)

Otro tipo de anisotropía que existe, es el efecto proporcional que está presente cuando los semivariogramas en diferentes direcciones tienen el mismo alcance pero distintas mesetas (Figura 1.3).

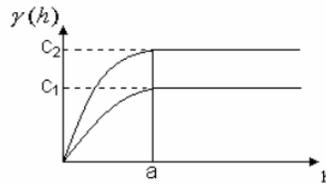


Figura 1.3 –Anisotropía Proporcional. **Fuente:** (Pacheco, 2008)

1.2.1.4 – Ajuste del semivariograma a un modelo

El semivariograma experimental obtenido debe ser ajustado a uno o varios modelos teóricos, obteniéndose un modelo o función analítica que caracteriza la continuidad espacial de la variable estudiada. Los modelos utilizados deben satisfacer ciertas condiciones, es decir tienen que ser “definido positivo” o de “tipo positivo” de lo contrario puede existir el riesgo de encontrar varianzas negativas que no tienen sentido, por lo que se recomienda el uso de modelos autorizados (Cuador, 2002).

En Samper & Ramírez (1990) se presenta una discusión respecto a las características y condiciones que estos deben cumplir. En general dichos modelos pueden dividirse en no acotados (lineal, logarítmico, potencial) y acotados (esférico, exponencial, gaussiano, cuadrático). Los del segundo grupo garantizan que la covarianza de los incrementos es finita, por lo cual son ampliamente usados cuando hay evidencia de que presentan buen ajuste (Giraldo *et al.*, 2000).

Algunos geoestadísticos ajustan los modelos de forma visual, pero esta práctica no es fiable y es preferible usar algún procedimiento estadístico para estos fines. Con frecuencia es usada la aproximación por Mínimos Cuadrados (Díaz, 2002).

La operación de validar un semivariograma teórico ajustado a uno experimental siempre toma mucho tiempo, este se considera como el último de los pasos importantes del análisis de variabilidad, ya que, una vez obtenido este resultado, la estimación es sólo cuestión de cálculos. Se prueban diferentes valores de los parámetros del semivariograma hasta que los errores de validación cumplen los siguientes criterios estadísticos: la media de los errores sea

próxima a cero, mínimo error cuadrático medio, y la correlación entre los valores estimados y los medidos próxima a 1 (Cuador *et al.*, 1997).

1.2.1.5 – Problemas más comunes encontrados en el cálculo del semivariograma

La fuente de problemas que se pueden presentar en la realización de un análisis estructural es muy variada, lo que está en correspondencia con la variedad de casos que se presentan en la naturaleza. Algunos de los problemas más comunes son (Pacheco, 2008):

- El valor idóneo del incremento h : Una inadecuada selección de h puede proporcionar un semivariograma errático, aunque no se puede dar un criterio exacto o aproximado sobre cuál es el mejor valor de h , es recomendable recalcular $\gamma(h)$ para distintos valores de h , hasta encontrar una forma suavizada del mismo.
- Distribuciones con valores extremos: La existencia de valores extremos, altos o bajos, en una distribución, puede conducir a la obtención de un variograma fuertemente errático. En este caso la solución puede ser simple, eliminar los datos extremos, porque pueden ser ocasionados por errores, en otros casos pueden encontrarse en zonas geográficamente distintas y pueden ser tratados de manera separada.

Una herramienta útil para la detección de valores extremos y encontrar el incremento adecuado puede ser calculando la “Nube de Variogramas”, el cual consiste en representar los valores de $\gamma(h)$ contra h , para cada par posible de la información inicial.

- La existencia de poblaciones mixtas: Existen datos que pueden mostrar diferentes poblaciones, los cuales pueden estar estadísticamente diferenciados. En muchos casos las poblaciones están geográficamente diferenciadas, donde se recomienda tratar las zonas por separado. En otros casos las poblaciones se presentan mezcladas geográficamente, en este caso una solución puede ser un cambio de escala, con lo que se logra reducir la diferencia de los valores extremos.

El problema fundamental en la obtención de un semivariograma correcto es, la elección adecuada de los intervalos de distancias para los cuales será calculado el semivariograma, de modo que en éstos la cantidad de pares encontrados sea suficiente desde el punto de vista estadístico (Cuador, 2002).

1.2.2 – Estimación espacial

La interpolación de datos ofrece la ventaja de proyectar mapas o superficies continuas a partir de datos discretos; sin embargo, la utilización de una buena cantidad de puntos del área en estudio limita su utilización. Dependiendo del tipo de datos analizados, su costo y dificultad de obtención determinan que tan valioso es finalmente el uso de la interpolación. Dentro de los interpoladores usados existe un grupo llamado Kriging; todos los interpoladores geoestadísticos están en este grupo (con sus variantes), los cuales ofrecen no solo predicciones y superficies de respuesta requeridas, sino también mapas de probabilidades y cuantiles. La medición de la probabilidad, efectuada por los métodos Kriging, hace la diferencia con respecto a los métodos determinísticos para interpolaciones espaciales, de los cuales los más usados son el de ponderación de distancias inversas (IDW: *Inverse Distance Weighting*) y “splines” o ajuste por curvas (Villatoro *et al.*, 2008).

En general las técnicas geoestadísticas (Kriging y Cokriging) presentan mejores resultados que las técnicas de interpolación tradicionales (Spline, Distancia Inversa Ponderada, Thissen,...). El Kriging, es considerado “el mejor estimador lineal insesgado” por generar los resultados más próximos a las observaciones reales, aunque algunos estudios coinciden en que la inclusión de variables auxiliares mejora las estimaciones (Rodríguez & Grau, 2007).

Inicialmente, Matheron denominó a esta técnica Krigeage (en francés) que en inglés se convierte en Kriging y en español se escribe Krigeaje. Este término procede del nombre del geólogo sudafricano D. G. Krige, cuyos trabajos en la predicción de reservas de oro, realizados en la década del cincuenta, suelen considerarse como pioneros en los métodos de interpolación espacial (Cuador, 2002).

El krigeado consiste en efectuar una ponderación es decir atribuir un peso λ_i a la ley Z_i de cada muestra i :

$$Z_s^* = \lambda_1 Z_1 + \lambda_2 Z_2 + \dots + \lambda_N Z_N \quad (1.1)$$

estos pesos se calculan de manera de hacer mínima la varianza de estimación resultante, considerando las características geométricas del problema (Arrieta *et al.*, 2006).

Las principales características que hacen del krigeado un método de estimación muy superior a los tradicionales, como el inverso ponderado de la distancia, la triangulación, etc., son las siguientes (Moral, 2004):

- 1) Mientras que los métodos tradicionales utilizan el concepto euclidiano de la distancia para el cálculo de los pesos que se aplicarán a cada dato muestral, el krigado considera tanto la distancia como la geometría de la localización de las muestras.
- 2) Mediante el krigado se minimiza la varianza del error esperado (diferencia entre el valor real y el estimado). Como el valor real en un punto no muestral es desconocido, el krigado emplea un modelo conceptual con una función aleatoria asociada a los valores reales.
- 3) Los métodos geoestadísticos muestran una gran flexibilidad para la interpolación, pudiéndose estimar valores puntuales o en bloques, así como métodos para incorporar información secundaria que esté relacionada con la variable principal. Todos estos métodos dan lugar a unas superficies muy suaves, además de una estimación de la varianza en todos los puntos, lo cual no puede realizarse con otros métodos de interpolación.

El primer interés del krigado proviene de su misma definición. Al minimizar la varianza de estimación, se está seguro de sacar el mejor partido posible de la información disponible, o, si se prefiere, de obtener la estimación más precisa posible del panel en estudio. Esta ventaja es a menudo notable, pero no se justificaría siempre, debido a las complicaciones suplementarias que introduce necesariamente una ponderación. El interés práctico más importante del krigado, proviene, no del hecho que asegura la mejor precisión posible, sino más bien porque permite evitar un error sistemático (ver Figura 1.4) (Alfaro, 2008).



Figura 1.4 – Representación gráfica del interpolador de krigado. **Fuente:** (Alfaro, 2008)

Kriging encierra un conjunto de métodos de predicción espacial que se fundamentan en la minimización del error cuadrático medio de predicción. En la Tabla 1.1 se mencionan los tipos de kriging y algunas de sus propiedades (Giraldo, 2005).

Tabla 1.1 – Tipos de kriging y sus propiedades. Fuente: (Giraldo, 2005)

Tipo de Predictor	Nombre	Propiedades
Lineal	<ul style="list-style-type: none"> • Simple • Ordinario • Universal 	<ul style="list-style-type: none"> • Son óptimos si hay normalidad multivariada. • Independiente de la distribución, son los mejores predictores linealmente insesgados.
No Lineal	<ul style="list-style-type: none"> • Indicador • Probabilístico • Log Normal, Trans-Gaussiano • Disyuntivo 	<ul style="list-style-type: none"> • Son predictores óptimos.

Su fortaleza estriba en el conocimiento del comportamiento de la variable en el espacio. Los parámetros del semivariograma elegido tienen una importancia relevante a la hora de asignar diferentes pesos a las muestras que rodean el punto a interpolar. Por ejemplo, el nugget determina como se reparten estos pesos. Si la meseta es muy alta, todas las muestras tenderán a tener el mismo peso en la interpolación. Los puntos más allá del alcance, es decir cuando el semivariograma se vuelve plano, tienen la mínima capacidad predictora. La elección de un modelo isotrópico o anisotrópico también adquiere importancia en la interpolación de puntos en el espacio, ya que, en un modelo anisotrópico, se asignarán coeficientes mayores a las muestras situadas en el eje de mayor variación (Gallardo, 2008).

1.3 – Aplicaciones de la geoestadística

En la actualidad, la ciencia Estadística puede encontrarse en cualquier disciplina científica cuantitativa, de esta manera se producen interesantes variaciones en los temas tradicionales. En áreas tales como geología, ecología y ciencias del medio ambiente, no es a menudo posible o no es apropiado aleatorizar, bloquear y replicar los datos. Existe una necesidad de nuevos modelos y aproximaciones estadísticas que se dirijan a nuevos problemas surgidos desde la tecnología (Nicolás, 2004).

Díaz & Casar (2004) muestra las distintas aplicaciones que tiene la geoestadística:

- Petróleo: en modelos geológico – petrofísicos de yacimientos, análisis de permeabilidad, simulación de facies, caracterización de propiedades petrofísicas y su escalamiento, integración de información de diferentes fuentes, evaluación de reservas, análisis de riesgo.

- Hidrogeología: para la solución de problemas inversos (permeabilidad, transmisividades), estimaciones de los niveles piezométricos, diseño de Redes óptimas de monitoreo, estimación de los límites de la pluma de un contaminante.
- Minería: en estudios de factibilidad económica de un yacimiento, peritaje minero, cálculo de reservas, diseño de métodos de explotación basados en la distribución de la mineralización.
- Medio Ambiente: predicción de la distribución de contaminantes en la atmósfera, suelos, acuíferos, y cuerpos de agua, evaluación de sitios contaminados, estudios de riesgo e impacto ambiental.
- Salud Pública: análisis de la distribución espacial de enfermedades, estimación de la exposición de personas a elementos nocivos (acústicos, químicos, polvos, etc.).
- Ciencias Agrícolas y Forestales: estudio de la distribución espacial y la afectación de plagas, inventarios forestales, estudio cuantitativo de suelos y sus propiedades químicas y mecánicas.
- Industria Pesquera: estimación *in situ* del potencial de pesca, relación entre la distribución espacial de especies de peces y diferentes variables (profundidad, temperatura, salinidad, etc).

1.3.1 – Geoestadística en procesos naturales

Aunque este método se desarrolló para estimar depósitos minerales, muchos aspectos del método geoestadístico se han aplicado en la ciencia del suelo y de cultivos, en respuesta a la variabilidad impuesta por prácticas de manejo del suelo (Amador & Escobedo, 2004).

La distribución espacial de los procesos naturales es en muchas ocasiones continua. El muestreo para cualquier propósito experimental se diseña, en general, para describir el proceso investigado con un número discreto de muestras, y la cantidad total de muestras, se determina a menudo, en función de los recursos económicos y humanos disponibles, teniendo menos en cuenta los aspectos técnicos (Dafonte *et al.*, 2001).

La geostatística ha permitido cuantificar la escala y grado de variación espacial de recursos para plantas y animales, así como su relación con la distribución de los organismos. Esta variación espacial es clave para explicar procesos ecológicos a diferentes escalas espacio-

temporales. Uno de los procesos más claros es la relación entre diversidad y heterogeneidad espacial (Gallardo, 2008).

En el estudio de malezas se ha usado la geoestadística para mapear poblaciones de maleza, y en el estudio de cultivos se ha cuantificado la variabilidad en los patrones espaciales del crecimiento y rendimiento del cultivo. Los factores que contribuyen a la falta de estabilidad temporal en los patrones de rendimiento son: la renovación inapropiada de nutrientes en terrenos cultivados, la influencia de la textura del suelo y prácticas culturales, la variabilidad espacial de la humedad del suelo inducida por el riego, y las propiedades extrínsecas como el clima, malezas, insectos, enfermedades y manejo del cultivo. La distribución espacial irregular de plantas, causada principalmente por la colocación imperfecta de la semilla en el suelo, disminuye la uniformidad del rendimiento del grano (Amador & Escobedo, 2004).

Con el uso de técnicas geoestadísticas, Schotzko y O'Keefe (1989) describen la naturaleza espacial de poblaciones de *Lygus hesperus* y Knight, Rossi *et al.* (1993) estima densidades y riesgos económicos a escalas regionales usando estas técnicas y simulaciones estocásticas con datos muestreados en el noroeste de Iowa (Tannure & Mazza, 2004).

Ramírez *et al.* (2002) presentan resultados obtenidos con técnicas geoestadísticas sobre la distribución espacial, en cinco diferentes fechas, de los huevos de *Jacobiasca lybica* (Bergenin & Zanon) (Homoptera, Cicadellidae) en viñedo del Marco del Jerez. El modelo esférico fue el que mejor se ajustó a los semivariogramas según los criterios aplicados: media de los errores de estimación, error cuadrático medio y error cuadrático medio adimensional. Asimismo, establecen mapas de densidad de los huevos mediante kriging, encontrándose una estabilidad espacio-temporal de algunos de los puntos de puesta.

Amador & Escobedo (2004) utilizan técnicas geoestadísticas para describir y elaborar mapas de la distribución de malezas y rendimiento de grano del maíz. El modelo exponencial proporcionó el mejor ajuste de los datos, basado en el criterio del coeficiente R^2 . Mediante estimaciones hechas con el método de kriging se elaboraron mapas bidimensionales donde se determinaron dos áreas de alta densidad de malezas.

Moral *et al.* (2004) aplican métodos geoestadísticos en una plantación de tomates, para obtener unos mapas de la distribución de capturas de *Helicoverpa armígera* (Hübner) con trampas de feromonas sexuales. Con el uso de técnicas de estimación geoestadística "kriging", a partir de

los modelos esférico y exponencial, representa diariamente las distribuciones espaciales de las capturas, lo que le permite analizar su evolución temporal.

Sopó (2004) obtiene mapas de incidencia, con los modelos esférico y exponencial, de la distribución de la Mosca de la Fruta en el cultivo de mango en la Granja Experimental de Chongón (CEDEGE) y zonas aledañas, para comparar el patrón de disposición espacial de la mosca de la fruta durante los años 2000, 2001, 2002 y 2003.

Arrieta *et al.* (2006) analizan el impacto de algunas prácticas agronómicas sobre los cambios de distribución, densidad y composición espacio-temporal de poblaciones de las especies *Spermacoce tenuior* L. y *Digitaria longiflora* (Retz.) Pers., de la producción maíz-soya en la altillanura plana de los Llanos Orientales de Colombia, utilizando herramientas geoestadísticas (variogramas y 'kriging'). Los modelos que mejor describieron la estructura espacial de dichas poblaciones fueron de tipo lineal, gaussiano y esférico, el ajuste de los valores de la semivarianza se determinó mediante la regresión de cuadrados mínimos.

Ramírez (2006) realiza un análisis de la distribución espacial, mediante el método kriging, de cuatro tipos de plagas (mosca de la fruta, grafolita, roedores de la piel de la manzana y la pera) para tres cultivos (cítricos, manzana y pera) en la provincia de Lérida, España. El modelo esférico fue el que presentó un mejor ajuste, para la validación se usaron los criterios estadísticos: media de los errores de estimación, error cuadrático medio y la correlación existente entre los valores estimados y los medidos.

Smith (2007) caracteriza el patrón de distribución espacial, mediante técnicas geoestadísticas con el modelo exponencial, del Moho Blanco (*Sclerotinia minor* Jagger y *S. sclerotiorum* (Lib.) de Bary) en lechuga batavia (*Lactuca sativa* L. var. *capitata* L.) en la vereda La Moya, Bogotá.

Tannure *et al.* (2008) caracterizan la distribución espacial de *Alabama argillacea* y *Aphis spp.* mediante técnicas geoestadísticas, y estima la densidad de insectos en puntos de lotes no muestreados. Se trabaja con un muestreo sistemático con arranque aleatorio, en el Departamento de Lavalle, provincia de Corrientes, durante la campaña 03/04. Se calculan los semivariogramas para las diferentes fechas de muestreo y seguidamente se realiza el ajuste a los modelos esférico, lineal, lineal con meseta y exponencial, de los cuáles el esférico presentó un mayor valor de R^2 .

Sopó & Guerrero (2009) analizan la distribución de la mosca de la fruta y el impacto que representan las capturas en zonas aledañas en el cultivo del mango, en La granja Experimental

de Chongón (CEDEGE), en la península de Santa Elena. Se realizan las estimaciones de los niveles de concentración de moscas en cada trampa, con el empleo de los modelos exponencial y esférico, y se determinan las zonas calientes y de proliferación para la mosca de la fruta.

Vera & Guerrero (2009) analizan la variabilidad espacial de la incidencia de la plaga *Perkinsiella Saccharicida* en las plantaciones de caña de azúcar del Ingenio San Carlos. Con el uso de técnicas y software geoestadísticos se determinan los semivariogramas omnidireccionales, experimentales y teóricos para cada una de las variables en cada uno de los períodos de la plaga, con el modelo gaussiano con efecto pepita; y se realizan los mapas de estimaciones por medio del kriging ordinario determinándose las zonas de altas incidencias.

Ramírez & Porcayo (2010) obtienen mapas de incidencia de un hemiparásito de coníferas llamado muérdago enano (*Arceuthobium* sp.), y así determina la distribución espacial de éste, en la ladera norte del Parque Nacional Nevado de Toluca, mediante la técnica del krigeado. Para la validación del modelo esférico con efecto pepita seleccionado se usan los criterios estadísticos: media de los errores de estimación cercana a cero, error cuadrático medio, error cuadrático medio adimensional y la varianza de los residuos menor que la varianza muestral.

1.3.2 – Aplicaciones de la geoestadística en Cuba

Cuador (2005) caracteriza los recursos minerales en yacimientos lateríticos ferroniquelíferos a partir de la aplicación de métodos de estimación y simulación geoestadística, tomando como caso de estudio el yacimiento Punta Gorda del noreste de Holguín. El ajuste de los modelos lo realiza mediante el coeficiente de determinación R^2 , determinando así modelos que combinan el modelo esférico y el exponencial.

Interian & Álvarez (2005) presenta un trabajo que constituye la base metodológica de la primera experiencia en Cuba de la aplicación de la Geomática a las actividades vinculadas con la Agricultura de Precisión en la caña de azúcar. El empleo combinado de MapInfo y de su módulo Vertical Mapper, y a través de una programación especializada en Visual Basic para el tratamiento y carga en la Base de Datos que manejan estos programas, con las mediciones llevadas a cabo durante los trabajos con la cosechadora de caña automatizada, le permite realizar las modelaciones y confeccionar mapas de rendimiento de la cosecha cañera con gran exactitud. Esto dió la posibilidad de evaluar la variabilidad espacial del rendimiento de la cosecha con una exactitud adecuada, permitiendo estimar el rendimiento agrícola.

Hernández *et al.* (2006) estima el mapa de rendimiento georreferenciado del cultivo de la papa, mediante el empleo de técnicas de Agricultura de Precisión en áreas de la finca 101, perteneciente a la UBPC La Julia, de la ECV Batabanó. El kriging ordinario con el modelo esférico le permite obtener un mapa de rendimiento que reflejó la variabilidad del mismo, constituyendo el primero en obtenerse de forma georreferenciada para este cultivo en Cuba.

Interian & Álvarez (2008) desarrolla la primera aplicación de la Geomática a la agricultura urbana a nivel municipal, con la misión fundamental de apoyar la gestión, el planeamiento y las reordenaciones de las áreas que son administradas por la Granja Urbana del municipio Playa. Se desarrolla en la Empresa de Proyectos Agropecuarios de Ciudad de La Habana una aplicación SIG para el manejo, análisis, integración y manipulación de informaciones relacionadas con la actividad empresarial del sector agropecuario de un municipio urbano, confeccionándose diversos mapas temáticos sobre formato digital y analógico, en conjunto con especialistas de las dos empresas.

En Cuba se han desarrollado varias tecnologías que se encuentran aplicadas en Brasil y Australia fundamentalmente, para los cultivos de la papa, los cítricos y la caña de azúcar. Se utilizan técnicas de Estadística Univariada como los Coeficientes de Variación, Multivariada más complejas como los Cluster, Análisis de Componentes Principales (ACP), entre otros y métodos Geoestadísticos como la interpolación permiten conocer los valores desconocidos a partir de mediciones realizadas en áreas adyacentes, estando entre los más utilizados el Kriging y la Distancia Inversa (Esquivel, 2009).

1.4 – Importancia del uso de la geoestadística en la Sanidad Vegetal

La agricultura y la sanidad vegetal a nivel mundial han estado influenciadas por diversas corrientes tecnológicas, principalmente después de la Segunda Guerra Mundial, en que se desarrolló el paradigma de la “Revolución Verde” con el auge de los agroquímicos, el mejoramiento genético, la mecanización de la agricultura y la subvención de las producciones, todos para lograr altos rendimientos. En particular, la agricultura cubana no ha escapado de estas influencias y ha transitado del monocultivo a la especialización intensiva y finalmente a la diversificación, lo que contribuye a que los campos sean de menores dimensiones, exista una mayor diversidad de cultivos y un incremento de los métodos sostenibles, lo que influye de manera notable sobre la ocurrencia de plagas y sus enemigos naturales (Vázquez, 2009).

En Cuba el Manejo Integrado de Plagas toma un gran auge, principalmente por las condiciones que se crearan a partir de la organización de las Estaciones Territoriales de Protección de

Plantas (ETPP) en el año 1975, que permitió la generalización de metodologías de señalización de plagas y condujo a una reducción sustancial de la carga tóxica sobre los cultivos. Luego surgieron los programas del Manejo Integrado de Plagas, a partir de las investigaciones que con este propósito se realizan. En sentido general en el país, el uso de agrotóxicos sufrió en más de un 50% desde que se crearon las Estaciones Territorial Protección de Plantas en el año 1975, continuándose en su optimización con el desarrollo de los programas de control biológico y de manejo integrado de plagas (Castellanos *et al.*, 2008).

Las variables que permiten medir los niveles poblacionales del comportamiento de los agentes nocivos en los cultivos se dividen en métodos directos e indirectos. Los directos son aquellos en que se hacen conteos, sobre las plantas, de los insectos, ácaros, o manchas causantes por enfermedades. Los indirectos se hacen con medios complementarios como trampas para la captura de insectos, o trampas caza esporas de semillas de malezas, etc (MINAGRI, 1978).

Las variables empleadas más comúnmente para caracterizar los agentes nocivos de las plantas son la distribución e intensidad, los cuales pueden variar según la forma de medición y de cálculo, para los diferentes grupos: insectos y ácaros, agentes causantes de enfermedades, y las malezas (Castellanos *et al.*, 2008).

Debido a la importancia de la fitosanidad para cualquier sistema agrícola, las perspectivas científicas y tecnológicas respecto a la solución de los problemas de plagas demandan nuevas técnicas de investigación e innovación tecnológica, nuevos enfoques y la búsqueda de soluciones pertinentes para las condiciones específicas de cada sistema agrario en particular (Vázquez, 2006).

Tener organizado de forma sistémica toda la información tanto estadística como espacial de una empresa productiva y poder manejarla en el momento preciso, sitúa a una entidad a la altura del desarrollo mundial en la gestión empresarial, ya que puede aportar soluciones que conlleven al aumento de la productividad, manejo adecuado de los recursos financieros y naturales, a la satisfacción de las necesidades de la sociedad y a la protección del medio ambiente (Interian & Álvarez, 2008).

El conocimiento de la distribución espacial de las poblaciones de insectos plaga es de gran importancia para la elaboración de programas de manejo integrado. Tal conocimiento permite el desarrollo exacto y eficiente de métodos de muestreo, de tácticas de control y de valoraciones de riesgo (por ejemplo: perfil de áreas que probablemente tengan poblaciones altas de insectos

plaga y pérdidas económicas). Las relaciones espaciales de los insectos son a menudo manifestaciones de las características y necesidades biológicas inherentes de la especie, influidas por la planta huésped y el medio ambiente. La densidad de los insectos también puede jugar un papel importante en la determinación del tipo de relación en una cierta distribución espacial. El conocimiento de las densidades de los insectos y sus distribuciones espaciales cambian en el tiempo, puede ser de gran importancia en el desarrollo de métodos precisos de muestreo en el campo y sus consiguientes beneficios (Ramírez *et al.*, 2002).

Una alternativa para describir los patrones de distribución espacial es el uso de la Geoestadística, que emplea información acerca del valor que toma la variable, además de la ubicación espacial de los puntos de muestreo a fin de resumir la correlación entre estos (Tannure & Mazza, 2004).

CAPÍTULO 2

Capítulo 2: “Procedimiento para realizar el estudio geoestadístico”

En este capítulo se describen las etapas a seguir para determinar los modelos que describan con una mayor precisión el comportamiento espacial de las variables estudiadas que caracterizan a tres agentes nocivos clave del cultivo del tomate, y así darle cumplimiento a los objetivos planteados en la investigación.

Las etapas definidas para realizar el análisis geoestadístico, según plantean Díaz (2004), son:

Etapa 1: Análisis del cumplimiento de los requisitos necesarios para el estudio geoestadístico

En esta etapa se realiza la localización geográfica de los puntos que serán utilizados para la estimación, y se determina el valor de las variables estudiadas en cada punto. Posteriormente se hace un estudio de los datos a fin de verificar su exactitud y representatividad. Se realizan análisis a partir de la estadística descriptiva, que incluye ajustes a una distribución normal, identificación de posibles *outliers*, y se comprueba el cumplimiento de las hipótesis de la geoestadística.

Etapa 2: Definición del modelo de mejor ajuste para hacer la estimación espacial

Cumplidas las condiciones anteriores se procede a determinar la tendencia de los datos, presencia o no de anisotropía, se calculan los semivariograma experimentales, los que son ajustados a los modelos más utilizados según el comportamiento de los datos y se selecciona el modelo que mejor explica la variable de respuesta según el valor estimado en cada punto muestreado para cada campaña.

Etapa 3: Validación del modelo de mejor ajuste para la estimación

Luego de haber definido el modelo de mejor ajuste y con la estimación de los datos para los puntos se procede a realizar la validación, teniendo en cuenta para esto la correlación entre los valores estimados y los reales, la media, la desviación estándar y el cuadrado medio de los residuos.

En la Figura 2.1 se muestran las etapas en forma de flujo continuo.

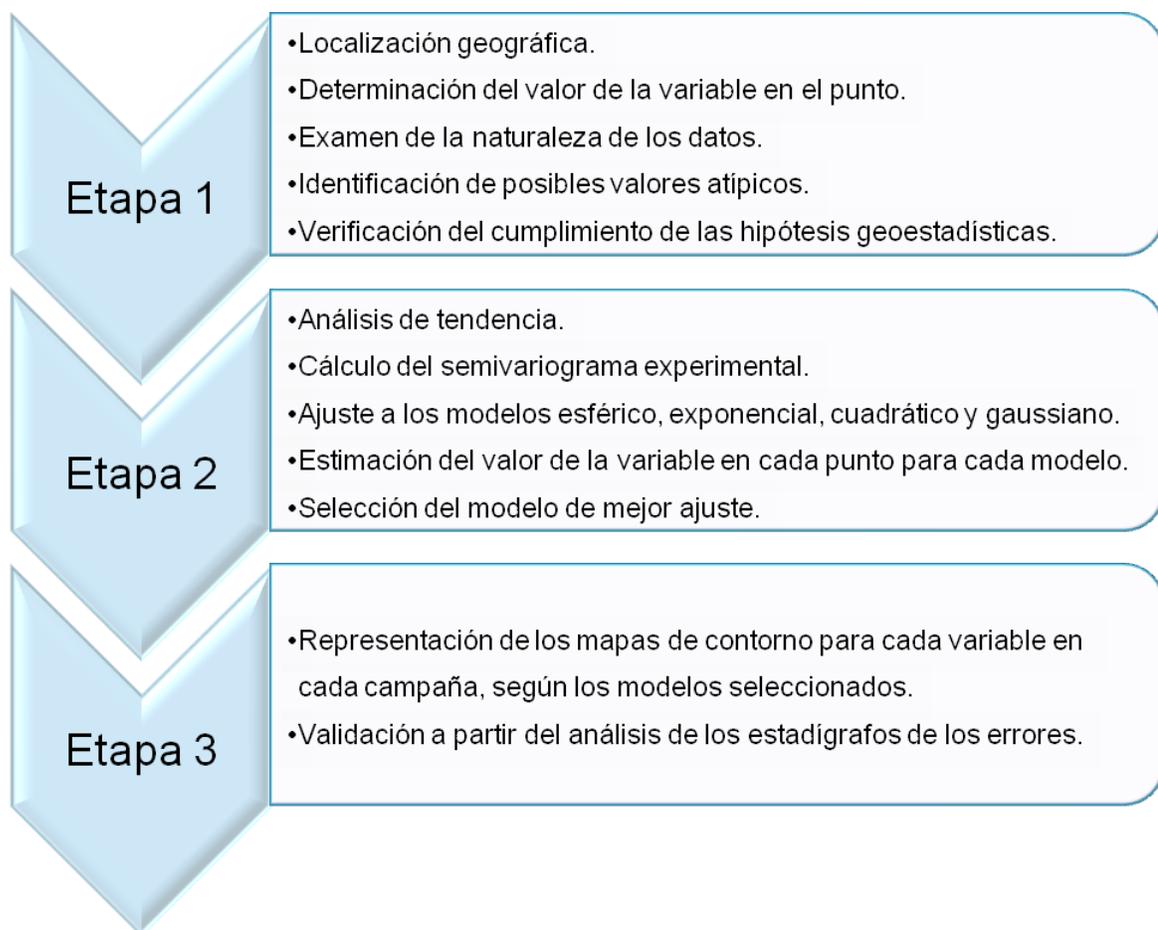


Figura 2.1 – Esquema del procedimiento realizado para el análisis geoestadístico.

Fuente: Elaboración Propia.

2.1 – Análisis del cumplimiento de los requisitos necesarios para el estudio geoestadístico de las variables de tres agentes nocivos

Los datos se obtienen a partir de la incidencia de las plagas y enfermedades del tomate desde la campaña 2003-2004 hasta la campaña 2007-2008 en el territorio de la Estación de Protección de Plantas de Lajas.

Para realizar este trabajo se tuvieron en cuenta los datos de los informes de las campañas, los Registros Territoriales Históricos y los recorridos de itinerario en las fundamentales zonas tomateras de los municipios: La Modelo y Ajuria en Lajas, Mal tiempo en Cruces y Arriete en Palmira. La información se tomó en la etapa fenológica del tomate comprendida entre 60-70 días de plantado el cultivo. Se trabajó con las tres plagas clave del tomate *Alternaria solani*

Sor., *Bemisia tabaci* Guen. y el *Virus del encrespamiento amarillo de la hoja del tomate*, definidas por González (2010).

Para evaluar *Alternaria solani* Sor. se aplica la metodología de señalización para este agente (INISAV, 1979) donde se muestrean 100 plantas en diagonal por campo, chequeando no menos de 10 puntos preferentemente en los lugares más bajos y húmedos del campo dirigiendo las observaciones a las hojas más viejas, determinando la variable intensidad de ataque, para ello a cada una de las plantas evaluadas se le dio un grado de ataque de la enfermedad utilizando la siguiente escala:

- 0- Sin síntomas.
- 1- Algunas manchas en el follaje.
- 2- Menos del 10 % del área foliar con manchas.
- 3- Entre un 11% y 25% del área foliar con manchas.
- 4- Entre un 26% y 50% del área foliar con manchas.
- 5- Con más de un 50 % del área foliar con machas.

Para determinar la intensidad de ataque se aplica la fórmula de Townsend y Henberguer (CIBA GEIGY, 1981).

$$I_a = \sum_{i=1}^n \frac{ab_i}{NK} \times 100 \quad (2.1)$$

Donde:

- a: Grados de la escala.
- b_i: Número de plantas por grado.
- N: Número total de plantas.
- K: Grado mayor de la escala.
- I_a: Intensidad de ataque de *Alternaria solani* Sor.

Para determinar los índices ligeros, medios, e intensos, según la intensidad en campo, se tuvo en cuenta el Manual de Funciones de la Sanidad Vegetal (CNSAV, 2006) donde:

Ligero (L): si $I_a < 10\%$

Medio (M): cuando $10\% \leq I_a < 25\%$

Intenso (I): si $I_a \geq 25\%$

Para *Bemisia tabaci* Guen., se aplica la metodología de señalización recomendada, la cual plantea muestrear en diagonal, 100 hojas que se distribuyen en los niveles inferior, medio y superior, en 33 plantas (99 hojas) y se adiciona una del nivel superior. El recorrido se realiza siguiendo la diagonal del campo y durante el mismo se buscan también los síntomas de la enfermedad viral (INISAV, 1979). Se determinó la variable intensidad de ataque de la mosca blanca *B. tabaci* según la cantidad de individuos presentes por planta utilizando la siguiente fórmula:

$$I_b = \frac{MT}{TPO} \quad (2.2)$$

Donde:

I_b : Intensidad de ataque de *Bemisia tabaci* Guen.

MT: Moscas totales.

TPO: Total de plantas observadas.

Los campos se caracterizaron según el índice de ataque de la plaga (CNSAV, 2006):

Ligero (L): si $I_b < 0.2$

Medio (M): si $0.2 \leq I_b < 1$

Intenso (I): si $I_b \geq 1$

La evaluación de la enfermedad viral se realizó visualmente para síntomas típicos por el especialista, no obstante al inicio de cada campaña fueron enviadas muestras al Laboratorio Provincial de Sanidad Vegetal para confirmar la primera incidencia de las enfermedades virales en el cultivo. Se determinó la variable distribución por campo, utilizando la siguiente fórmula:

$$D = \frac{PE_n}{PE_v} \times 100 \quad (2.3)$$

Donde:

D: Distribución.

PE_n: Cantidad de plantas enfermas.

PE_v: Cantidad de plantas evaluadas.

Los campos se caracterizaron según el porcentaje de plantas enfermas (CNSAV, 2006):

Ligero (L): cuando $D < 15\%$

Medio (M): si $15\% \leq D < 30\%$

Intenso (I): si $D \geq 30\%$

Luego de la determinación de la variable que caracterizó a cada agente nocivo, en cada punto del espacio, se procede a realizar un análisis exploratorio de los datos, que incluye los siguientes aspectos (Díaz, 2004):

A. Examen de la naturaleza de las variables basado en la estadística descriptiva y con el uso del software SPSS versión 15.0, se determinó el número casos, el rango de la distribución, la media, moda mediana, varianza, desviación estándar, coeficiente de asimetría, curtosis, error estándar y coeficiente de variación. A continuación se presentan conceptos que se tuvieron en cuenta para este análisis presentados por Cuador (2002):

Número de casos: Es el número de valores muestreados del fenómeno en estudio, representados por n y los datos por x_i , donde $i = 1, \dots, n$, que se llama distribución.

Rango de la variable: Es la diferencia entre el valor máximo y el mínimo.

Media: Es la media aritmética de la variable, dado por la fórmula, donde X_i en este caso es el valor de la variable estudiada en cada punto muestreado.

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (2.4)$$

Moda: Es el valor más frecuente de la variable.

Mediana: Es el valor para el cual la mitad de los datos son menores y la otra mitad están por encima de este valor.

Si se ordenan los datos de forma ascendente se puede calcular la mediana como.

$$M = \begin{cases} X_{(n+1)/2} & \text{si } n \text{ es impar} \\ (X_{n/2} + X_{n/2+1})/2 & \text{si } n \text{ es par} \end{cases} \quad (2.5)$$

Varianza: Describe la variabilidad de la variable. Es la medida de la desviación o dispersión de la variable y se calcula por:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad (2.6)$$

Desviación estándar: Describe la tendencia o dispersión de la distribución. Es la medida de desviación alrededor de la media. Se calcula por:

$$S = \sqrt{S^2} \quad (2.7)$$

Coefficiente de asimetría: Describe la simetría de la distribución relativa a la distribución normal. Se calcula por:

$$\alpha_3 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^3 / S^3 \quad (2.8)$$

Se tuvo en cuenta que en una distribución normal la asimetría tiene valor cero, un valor negativo indica una cola a la izquierda y un valor positivo indica una cola a la derecha. Este valor informa si se debe o no realizar transformaciones de los datos para poder obtener una mejor estimación (ver Tabla 2.1).

Tabla 2.1 – Coeficiente de asimetría. Fuente: (Díaz, 2004)

Coeficiente de Asimetría	Decisión a tomar
$0 < \alpha_3 \leq 0,5$	No será necesario transformar los datos.
$0,5 < \alpha_3 \leq 1$	Se debe calcular la raíz de los datos.
$\alpha_3 > 1$	Aplicar ln o log a los datos.

En el caso de los datos de la distribución del *Virus del encrespamiento amarillo de la hoja del tomate* que son proporciones o porcentajes, de una distribución binomial, se decidió utilizar transformaciones basadas en $\arcsen \sqrt{p}$ según recomienda Molinero (2003).

Otros indicadores empleados en el análisis exploratorio fueron:

Curtosis: Describe el grado de esbeltez de la distribución, tomado por lo general en relación a una distribución normal, y se puede calcular por:

$$\alpha_4 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^4 / S^4 \quad (2.9)$$

Coeficiente de variación: Es la dispersión relativa al valor medio, es decir, es una medida de la variación relativa de los datos y puede ser calculado por:

$$CV = S / \bar{X} \quad (2.10)$$

La variabilidad espacial está expresada en términos del CV:

- baja si $CV \leq 10\%$,
- media si $10\% < CV \leq 50\%$,
- alta si $CV > 50\%$.

Prueba de hipótesis de normalidad

Para determinar si los datos se ajustan a una distribución normal se usó la Prueba de Kolmogorov Smirnov, por ser más robusta según plantea Cuador *et al.* (1997) teniendo como hipótesis:

H_0 : los datos se ajustan a una distribución normal.

H_1 : los datos no se ajustan a una distribución normal.

Para esto se utilizó un nivel de confianza del 95% y se determinó rechazar la hipótesis nula en el caso de que el valor de probabilidad fuese menor que el nivel de significación (α).

Histogramas: Son usados para ver las características descriptivas de la distribución, representados por un gráfico de barras donde en las abscisas aparecen los límites de las clases y en las ordenadas las frecuencias correspondientes a cada clase.

B. Identificación de los posibles valores atípicos (*outliers*)

El criterio que se usó para clasificar a un dato como posible outliers fue que sea menor al Primer Cuartil -1,5 (Rango intercuartil) o mayor que el Tercer Cuartil +1,5 (Rango intercuartil), esto se determinó con la representación del gráfico de caja.

Además la Tabla 2.2 muestra según el coeficiente de variación si se deben eliminar outliers y aplicar otro tipo de métodos geoestadísticos.

Tabla 2.2 – Pasos a seguir según el valor del CV. **Fuente:** (Díaz & Casar, 2004)

Coeficiente de Variación	Pasos a realizar	Tipo de Técnica
$CV < 1$	No existirán problemas en la estimación de los valores.	Geoestadística Lineal
$1 \leq CV < 2$	Dificultad en obtener una buena estimación debido a la existencia de outliers.	Geoestadística No Lineal
$CV \geq 2$	Mucha dificultad en la estimación por la elevada presencia de outliers.	

Para la determinación de la significación estadística de los valores atípicos se usó la Prueba de Grubs', se plantearon como hipótesis:

H_0 : el valor es un aberrante significativo.

H_1 : el valor no es un aberrante significativo.

Se utilizó un nivel de confianza del 95% y se decidió rechazar la hipótesis nula para valores de probabilidad muy pequeños, menores que α .

C. Verificación del cumplimiento de las hipótesis de la geoestadística

El cumplimiento de las hipótesis principales, estacionaridad e hipótesis intrínseca, donde la primera siempre implica el cumplimiento de la segunda según Cuador (2002), se verificó de acuerdo a la metodología que consiste en el desarrollo de modelos de regresión lineal múltiple de la forma: $Z = a + bX + cY$, en las cuales se describe la relación entre la variable dependiente y dos variables independientes, donde X y Y corresponden a las coordenadas planas, según recomienda Pacheco (2008). Para establecer la estacionaridad a partir de este modelo de regresión se realizó la prueba de significación para determinar si la regresión es no significativa, es decir, si las variables regresoras no aportan nada a la variable de respuesta. Esta prueba de significación se plantea de la siguiente forma:

H_0 : $b = c = 0$

H_1 : $b \neq 0$ ó $c \neq 0$

Se seleccionó un α igual a 0.05, por tanto para valores de probabilidad mayores que este se decidió aceptar la hipótesis nula de que no existe una relación estadísticamente significativa entre las variables y por consiguiente no existen tendencias y se cumple la estacionaridad en las muestras.

2.2 – Definición del modelo de mejor ajuste para la estimación espacial de las variables estudiadas

Para el ajuste del semivariograma a un modelo teórico conocido se realizó primeramente un análisis de tendencia y se calculó el semivariograma experimental. En esta etapa del análisis se emplearon los softwares MapInfo versión 9, para determinar las distancias entre los puntos muestreados, y el Surfer versión 9 para analizar la tendencia y calcular el semivariograma.

A. Análisis de tendencia

En este análisis se calcula inicialmente el semivariograma medio, global u “omnidireccional”, proporcionando una idea inicial de la variabilidad espacial de los datos, por ser éste el más idóneo para representar u obtener una estructura clara y definida. Posteriormente, según recomienda Díaz (2004), se calculan los semivariogramas en 4 direcciones separadas 45° con tolerancia angular de 22.5°, comenzando por 0° hasta encontrar la dirección de máxima o mínima variabilidad.

Luego de haber determinado en el paso anterior la posible existencia de anisotropía geométrica cuando los alcances de los variogramas son significativamente diferentes, se determinan los alcances (radio de correlación) en las direcciones de menor y de mayor valor, con lo cual se construyen los modelos anisotrópicos.

B. Cálculo del Semivariograma

El semivariograma experimental se estimó sobre la base de los datos recolectados para las variables muestreadas: intensidad de *Bemisia tabaci* Guen.y *Alternaria solani* Sor., y distribución del *Virus del encrespamiento amarillo de la hoja del tomate* (TYLCV), para las cinco campañas, a partir de la siguiente expresión definida por Ramírez (2010):

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (2.11)$$

Donde:

$\gamma(h)$: Valor experimental del semivariograma para el intervalo de distancia h.

N(h): Número de pares para el intervalo de distancia h.

Z(x_i): Valor de la variable de interés en el punto muestral x_i.

Z(x_i+h): Valor de la variable en el punto muestral x_i+h.

Para determinar el semivariograma experimental se siguen seis pasos planteados por Cuador (2002):

- 1) Se calcula la cantidad de pares (N) para el número de datos muestreados (n):

$$N = n(n-1)/2 \quad (2.12)$$

- 2) Para cada par, se calcula la distancia entre las localizaciones correspondientes, con el uso del software MapInfo v.9.
- 3) Se ordena ascendentemente el grupo de datos anteriores por la distancia.
- 4) Se calcula la amplitud máxima del semivariograma como $L_{max} = D_{max}/2$, donde D_{max} es la distancia a la que están separadas las localizaciones más lejanas.
- 5) Se fija una distancia h inicial conocida como paso o incremento del semivariograma, de tal manera que la cantidad de intervalos a procesar esté entre 10 y 25 según recomienda Méndez (2008), el cual se puede obtener como L_{max}/h .
- 6) Por último se calcula la expresión del semivariograma para todos los pares almacenados en el paso (2), según el paso seleccionado.

C. Ajuste a un modelo teórico

El semivariograma experimental obtenido es ajustado a cuatro modelos teóricos, combinados con el efecto pepita, que más se ajustan a de los datos muestreados, según el comportamiento de los mismos, para cada variable en cada campaña, obteniéndose así un modelo o función analítica que caracteriza la continuidad espacial de la variable estudiada. Estos modelos son según los plantea Giraldo (2005):

- Efecto de Pepita:

$$\gamma(h) = \begin{cases} 0 & \text{si } h = 0 \\ C_0 & \text{si } |h| > 0 \end{cases} \quad (2.13)$$

- Modelo Esférico:

$$\gamma(h) = \begin{cases} C_0 + C_1 \left[\frac{3h}{2a} - \frac{1}{2} \left(\frac{h}{a} \right)^3 \right], & h \leq a \\ C_0 + C_1, & h > a \end{cases} \quad (2.14)$$

➤ Modelo Exponencial:

$$\gamma(h) = \begin{cases} C_0 + C_1(1 - e^{-3h/a}) & h \leq a \\ C_0, & h > a \end{cases} \quad (2.15)$$

➤ Modelo Gaussiano:

$$\gamma(h) = \begin{cases} C_0 + C_1(1 - e^{-h^2/a^2}) & h \leq a \\ C_0, & h > a \end{cases} \quad (2.16)$$

➤ Modelo Cuadrático:

$$\gamma(h) = \begin{cases} C_0 + C_1[2h - h^2] & h \leq a \\ C_0, & h > a \end{cases} \quad (2.17)$$

Con los modelos antes mencionados se procede a estimar la variable en cada punto, para esto se utiliza el krigeaje ordinario con el uso del software Surfer v. 9, y a continuación se presenta el modelo de este método que se tuvo en cuenta según lo define Usandivaras (2006):

$$\text{Min } F = \sigma_e^2 - 2\mu \left(\sum_{i=1}^n \lambda_i - 1 \right) \quad (2.18)$$

Donde:

F: Función a minimizar.

μ : Multiplicador de Lagrange.

λ_i : Peso para el punto muestral i.

σ_e^2 : Varianza de la estimación.

La varianza de estimación se calcula como:

$$\sigma_e^2 = \text{Var}[Z(x_i) - Z^*(x_i)] = \text{Var}[Z(x_i)] - 2\text{Cov}[Z(x_i), Z^*(x_i)] + \text{Var}[Z^*(x_i)] \quad (2.19)$$

El estimador se determina por el modelo:

$$Z^*(x_i) = \sum_{i=1}^n \lambda_i Z(x_i) \quad (2.20)$$

A partir de los valores estimados de las variables muestreadas que caracterizan a tres agentes nocivos del cultivo del tomate en cinco campañas se selecciona el modelo que mejor explica a cada variable muestreada, según los siguientes criterios:

- ✓ El modelo que tenga el coeficiente de determinación, R^2 , más cercano a uno.

$$R^2 = \left(1 - \frac{\sum_{i=1}^n (Z(x_i) - Z^*(x_i))^2}{\sum_{i=1}^n (Z(x_i) - \bar{Z})^2} \right) \times 100 \quad (2.21)$$

- ✓ El modelo que tenga coeficiente de determinación ajustado, R^2 -ajustado, más cercano a uno.

$$R^2 - ajustado = \left(1 - \left(\frac{n-1}{n-p-1} \right) \frac{\sum_{i=1}^n (Z(x_i) - Z^*(x_i))^2}{\sum_{i=1}^n (Z(x_i) - \bar{Z})^2} \right) \times 100 \quad (2.22)$$

- ✓ El modelo tenga el menor Criterio de información de Akaike (AIC).

Este criterio se usa porque relaciona la bondad de ajuste con el número de parámetros, esta relación esta dada por la siguiente expresión según define Díaz (2002):

$$AIC = \left[n \ln \left(\frac{2\pi}{n} \right) + n + 2 \right] n \ln(R) + 2p \quad (2.23)$$

Donde:

n: Número de valores estimados.

R: Suma de los residuos al cuadrado.

p: Número de parámetros del modelo de semivariograma ajustado.

2.3 – Validación del modelo de mejor ajuste para la estimación

Los modelos seleccionados son utilizados para realizar los mapas de estimación que permiten identificar el comportamiento espacial de las variables estimadas para cada campaña.

Luego se realiza la validación de estos modelos, para lo cual se calculan los n errores de estimación según la expresión:

$$E(x_i) = Z(x_i) - Z^*(x_i) \quad i = \overline{1, n} \quad (2.24)$$

A partir de los residuos se comprobó el cumplimiento de los siguientes criterios planteados por Méndez (2008):

1. La media de los errores de estimación esté próxima a 0:

$$MEE = \frac{1}{n} \sum_{i=1}^n E(x_i) \approx 0 \quad (2.25)$$

2. El error cuadrático medio se aproxime a 0:

$$ECM = \frac{1}{n} \sum_{i=1}^n [E(x_i)]^2 \approx 0 \quad (2.26)$$

3. La correlación entre los valores muestreados y los estimados sea cercana a 1.

$$Cor[Z(x_i), Z^*(x_i)] \approx 1 \quad (2.27)$$

Además se realiza una comparación de muestras pareadas para determinar el comportamiento de la diferencia de los datos, es decir de los residuos, donde se utiliza la Prueba t para determinar con un nivel de confianza del 95% si la media de los residuos es igual a 0, al plantearse como hipótesis:

$$H_0: \mu = 0 \quad H_1: \mu \neq 0$$

También se emplea la Prueba Chi-cuadrado a partir de la cual se determina si la desviación de los residuos es igual a 1 con un nivel de confianza del 95%, al plantearse como hipótesis:

$$H_0: \sigma = 1 \quad H_1: \sigma \neq 1$$

Por último, para visualizar la relación existente entre la variable estimada y la observada, se representan gráficos de dispersión entre estas variables y otro para los residuos.

CAPÍTULO 3

Capítulo 3 – Aplicación del procedimiento para el análisis geoestadística

En este capítulo se desarrolla el procedimiento planteado en el capítulo 2; a partir de los cual se comprobó el cumplimiento de los requisitos necesarios para el estudio en las variables para cada una de las campañas; se analizó la tendencia de los datos; las variables se ajustaron a los modelos esférico, gaussiano, exponencial y cuadrático, y los modelos que resultaron tener un mejor ajuste se utilizaron para la estimación por el método de kriging ordinario puntual; y por último fueron validados estos modelos seleccionados.

3.1 – Análisis del cumplimiento de los requisitos necesarios para el estudio geoestadístico de las variables que caracterizan a tres agentes nocivos

A partir de los datos ya conocidos quedaron ubicados geográficamente con exactitud los puntos de muestreos de los tres agentes nocivos según los centroides calculados (Anexo 1).

Al analizar los gráficos de caja elaborados para cada variable se pudo verificar la existencia de observaciones atípicas (*outliers*). En la Figura 3.1 se muestra el gráfico de caja para la variable intensidad de *Alternaria solani* Sor., a partir del cuál se comprobó que no presenta *outliers* en ninguna de las campañas analizadas y se observó una diferencia entre las medianas siendo mayor en la campaña 03_04.

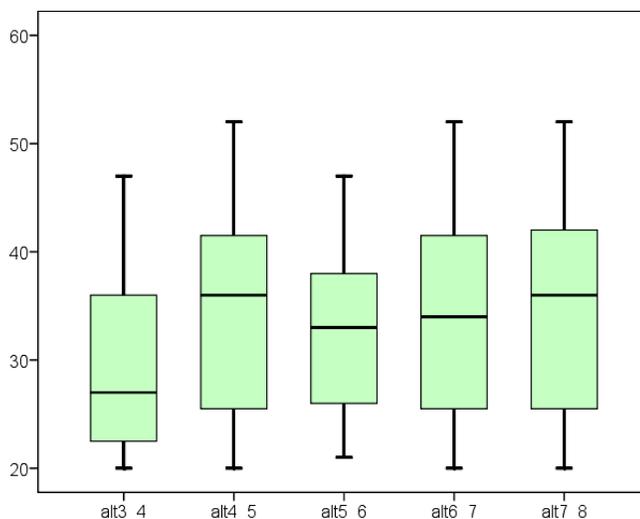


Figura 3.1 – Gráfico de caja para la intensidad de *Alternaria solani* Sor. **Fuente:** Elaboración Propia.

En la Figura 3.2 se muestra el gráfico de caja para la intensidad de *Bemisia tabaci* Guen., donde se determinó la presencia de una observación atípica en la campaña 06_07 y una diferencia en tre las medianas de la variable para cada campaña. La significación estadística

del valor aberrante se comprobó con el uso de la prueba de Grubbs', obteniéndose un valor de probabilidad de 0.036 menor que 0.05.

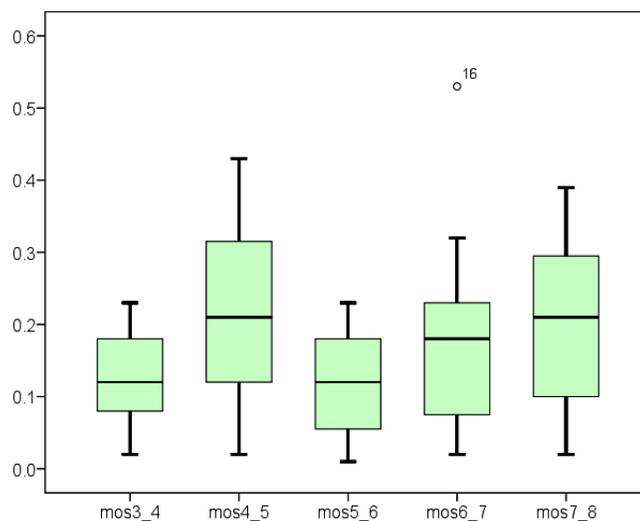


Figura 3.2 – Gráfico de caja para la intensidad de *Bemisia tabaci* Guen. **Fuente:** Elaboración Propia.

Según lo planteado anteriormente y porque el coeficiente de asimetría es de 0.679 mayor que 0.5 se debe realizar alguna transformación, aunque el coeficiente de variación igual a 0.638 indica que no existirán problemas en la estimación de los valores por ser menor que 1. Además esta observación es un *outlier* distribucional y espacial por ser muy distinto al valor más cercano, de aquí que se decidió descluterizar tomando el centroide de estos dos puntos y la media de la distribución, logrando así la no eliminación de valores para la estimación.

En la Figura 3.3 se puede observar el gráfico de caja para la distribución del *Virus del encrespamiento amarillo de la hoja del tomate*, a partir del cuál se determinó que no existen observaciones atípicas, pero existe mucha diferencia entre las medianas de cada campaña. Se realizó la prueba de normalidad Kolmogorov-Smirnov determinándose que las dos primeras campañas, 03_04 y 04_05, no seguían una distribución normal con un valor de probabilidad de 0.004 y 0.036 respectivamente para un nivel de significación del 5%, además la variable en estas campañas presentó un coeficiente de asimetría de 0.855 y 0.755 respectivamente siendo mayor que 0.5; y la variable en la campaña 06_07 presentó un valor de probabilidad según la prueba de normalidad igual a 0.066 el cuál si es comparado con un nivel de significación de un 5% puede aceptarse la hipótesis nula de que la variable se ajusta a la curva normal, pero está en el límite y es pequeño comparado con un nivel del 10%.

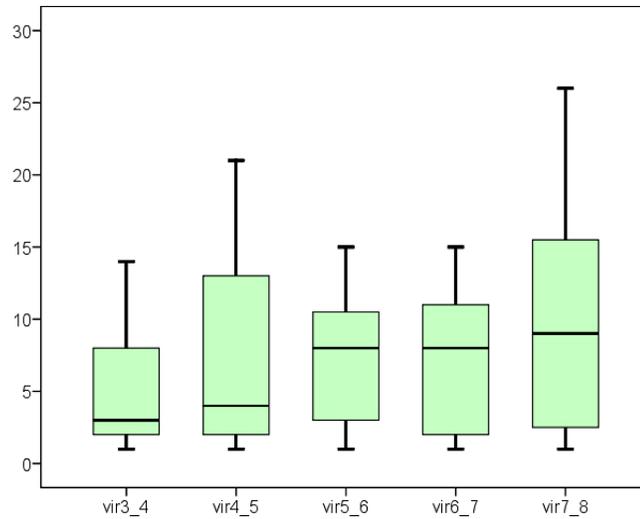


Figura 3.3 – Gráfico de caja para la distribución del *Virus del encrespamiento amarillo de la hoja del tomate*. **Fuente:** Elaboración Propia.

A partir del análisis realizado se procedió a desclusterizar los puntos más cercanos lográndose un ajuste de la variable a la curva normal en cada campaña, pero por estar el coeficiente de asimetría de las dos primeras campañas por encima de 0.5, igual a 0.811 y 0.715 respectivamente, se hizo necesario transformar los datos, con la se logró disminuir el coeficiente de asimetría.

Un nuevo análisis exploratorio de los datos, después de eliminarse los valores atípicos y realizarse las transformaciones necesarias, puso en evidencia que se disminuyó la diferencia entre la media y la mediana, las curvas presentaron mayor simetría y se ajustaron a la curva normal.

En la Tabla 3.1 se aprecia que la intensidad de *Alternaria solani Sor.* tiene coeficientes de asimetría menor que 0.5 y coeficientes de variación menor que uno, éste último por estar en todas las campañas entre un 10 y un 50% indica una media variabilidad espacial, además se observa que los valores de la media y la mediana están cercanos en cada campaña, excepto la primera campaña.

Tabla 3.1 – Análisis de la naturaleza de la intensidad de *Alternaria solani* Sor.

Fuente: Elaboración Propia.

	Campaña 03_04	Campaña 04_05	Campaña 05_06	Campaña 06_07	Campaña 07_08
N	42	41	39	43	42
Media	30.0238	34.4390	32.8974	34.1860	34.3810
Mediana	27.5000	36.0000	33.0000	34.0000	35.5000
Moda	20.00(a)	36.00(a)	36.00	23.00(a)	42.00
Desviación Stándar	8.17637	9.43146	7.30103	9.04554	9.22867
Varianza	66.853	88.952	53.305	81.822	85.168
Coeficiente de variación (%)	27.23	27.38	22.19	26.45	26.84
Asimetría	.438	.017	.062	.119	.176
Curtosis	-1.074	-1.155	-1.071	-1.152	-1.031
Rango	27.00	32.00	26.00	32.00	32.00
Mínimo	20.00	20.00	21.00	20.00	20.00
Máximo	47.00	52.00	47.00	52.00	52.00
Percentiles					
	25	25.5000	26.0000	26.0000	25.7500
	75	37.0000	42.0000	42.0000	42.0000

En la Tabla 3.2 se muestra que la intensidad de *Bemisia tabaci* Guen. tiene coeficientes de asimetría menor que 0.5 y coeficientes de variación menor que uno, el cuál indica una alta variabilidad espacial por estar por encima del 50%.

Tabla 3.2 – Análisis de la naturaleza de la intensidad de *Bemisia tabaci* Guen.

Fuente: Elaboración Propia.

	Campaña 03_04	Campaña 04_05	Campaña 05_06	Campaña 06_07	Campaña 07_08
N	42	41	39	42	42
Media	.1214	.2063	.1133	.1724	.1724
Mediana	.1200	.2100	.1200	.1800	.1800
Moda	.08	.24	.20	.06(a)	.06(a)
Desviación Stándar	.06198	.11668	.06842	.10359	.10359
Varianza	.004	.014	.005	.011	.011
Coeficiente de variación (%)	51.05	56.55	60.38	60.09	60.09
Asimetría	.052	.075	-.034	.143	.143
Curtosis	-1.245	-.950	-1.365	-1.289	-1.289
Rango	.21	.41	.22	.34	.34
Mínimo	.02	.02	.01	.02	.02
Máximo	.23	.43	.23	.36	.36
Percentiles					
	25	.0950	.0500	.0675	.0800
	75	.1800	.1800	.2525	.3025

En la Tabla 3.3 se puede observar que la distribución de la enfermedad viral tiene coeficientes de asimetría menor que 0.5 y coeficientes de variación menor que uno, el cual indica una variabilidad espacial media para las dos primeras campañas y alta para el resto.

Tabla 3.3 – Análisis de la naturaleza de la distribución de la enfermedad viral.

Fuente: Elaboración Propia.

	Campaña 03_04	Campaña 04_05	Campaña 05_06	Campaña 06_07	Campaña 07_08	
N	31	32	39	32	42	
Media	.2226	.2453	7.1538	7.2603	9.7857	
Mediana	.2000	.2300	8.0000	8.0000	9.0000	
Moda	.17	.14	2.00	2.00	1.00	
Desviación Stándar	.09150	.11190	4.39820	4.72441	7.32365	
Varianza	.008	.013	19.344	22.320	53.636	
Coefficiente de variación (%)	41.11	45.62	61.48	65.07	74.84	
Asimetría	.453	.332	.112	.107	.437	
Curtosis	-1.145	-1.260	-1.309	-1.426	-.991	
Rango	.28	.35	14.00	14.00	25.00	
Mínimo	.10	.10	1.00	1.00	1.00	
Máximo	.38	.45	15.00	15.00	26.00	
Percentiles						
	25	.1400	.1400	3.0000	2.1250	2.7500
	75	.3000	.3475	11.0000	10.8325	16.2500

Los resultados obtenidos con la prueba Kolmogorov-Smirnov realizada para cada variable, después de las transformaciones que fueron necesarias realizar, se ofrecen en las Tablas 3.4, 3.5 y 3.6. Según estos resultados se aceptó la hipótesis nula para cada una de las variables, es decir, la distribución de los datos se ajusta a la distribución normal, lo que permitirá que los resultados de la estimación sean más precisos; además esto quedó evidenciado en los histogramas de frecuencia de cada variable en las cinco campañas estudiadas (Anexos 2, 3 y 4).

Tabla 3.4 – Prueba de Kolmogorov-Smirnov la variable intensidad de *Alternaria solani* Sor.

Fuente: Elaboración Propia.

	Campaña 03_04	Campaña 04_05	Campaña 05_06	Campaña 06_07	Campaña 07_08
Kolmogorov-Smirnov Z	.935	.809	.685	.784	.729
Asymp. Sig. (2-tailed)	.347	.530	.736	.570	.662

Tabla 3.5 – Prueba de Kolmogorov-Smirnov la intensidad de *Bemisia tabaci* Guen.**Fuente:** Elaboración Propia.

	Campaña 03_04	Campaña 04_05	Campaña 05_06	Campaña 06_07	Campaña 07_08
Kolmogorov-Smirnov Z	.836	.601	.731	.933	.812
Asymp. Sig. (2-tailed)	.487	.863	.658	.349	.524

Tabla 3.6 – Prueba de Kolmogorov-Smirnov de la distribución de la enfermedad viral.**Fuente:** Elaboración Propia.

	Campaña 03_04	Campaña 04_05	Campaña 05_06	Campaña 06_07	Campaña 07_08
Kolmogorov-Smirnov Z	1.120	1.058	1.005	0.916	1.013
Asymp. Sig. (2-tailed)	0.163	.213	0.265	0.371	0.257

El análisis de regresión lineal múltiple, para el cumplimiento de la estacionaridad, de la variable intensidad de *Alternaria solani* Sor. para cada campaña arrojó bajos coeficientes de determinación (R^2) y los valores de probabilidad fueron mayores que 0.05, como aparece en la Tabla 3.7, lo que indica que los modelos son no significativos, es decir, no existen tendencias y en consecuencia se cumple la estacionaridad en la muestra.

Tabla 3.7 – Prueba de regresión múltiple la intensidad de *Alternaria solani* Sor.**Fuente:** Elaboración Propia.

Campaña	Modelo	R ² (%)	R ² - ajustado(%)	Valor-P
03_04	$Z = 71.4821 + 0.0000450821 * X - 0.000240609 * Y$	4.462	0	0.4106
04_05	$Z = 249.77 - 0.000244375 * X - 0.000269926 * Y$	8.908	4.114	0.1699
05_06	$Z = 49.1273 - 0.000109575 * X + 0.000166527 * Y$	3.153	0	0.5617
06_07	$Z = 5.79036 + 0.000235106 * X - 0.000379959 * Y$	9.629	5.111	0.1320
07_08	$Z = 194.048 - 0.000316323 * X + 0.0000764927 * Y$	4.763	0	0.3861

El análisis de regresión lineal múltiple de la intensidad de *Bemisia tabaci* Guen. para cada campaña presentó bajos coeficientes de determinación y los valores de probabilidad fueron mayores que 0.05, excepto en la campaña 04_05, ver Tabla 3.7, lo que indica que los modelos son no significativos, menos en la campaña 04_05 donde existe una relación estadísticamente significativa entre las variables con un nivel de confianza del 95.0%, lo cual sugiere una ausencia de estacionaridad que posiblemente puede dificultar el análisis geoestadístico.

Tabla 3.7 – Prueba de regresión múltiple de la intensidad de *Bemisia tabaci* Guen.

Fuente: Elaboración Propia.

Campaña	Modelo	R ² (%)	R ² -ajustado(%)	Valor-P
03_04	$Z = -0.630435 + 0.00000112555*X + 3.84184E-7*Y$	1.847	0	0.6952
04_05	$Z = -3.26915 + 0.00000699696*X - 0.00000189925*Y$	14.939	10.463	0.0462
05_06	$Z = 0.845628 - 0.00000198261*X + 0.00000144222*Y$	4.929	0	0.4025
06_07	$Z = 0.31588 - 0.00000134381*X + 0.00000224003*Y$	2.528	0	0.6070
07_08	$Z = -1.62176 + 0.00000336861*X - 3.71564E-7*Y$	3.665	0	0.4828

El análisis de regresión lineal múltiple de la distribución de la enfermedad viral arrojó resultados similares a los de la variable anterior con un nivel de confianza del 95.0%, presentando problemas solamente en la campaña 04_05, lo cual sugiere una ausencia de estacionaridad de la variable en esta campaña, lo que puede dificultar el análisis geoestadístico.

Tabla 3.7 – Prueba de regresión múltiple de la distribución de la enfermedad viral.

Fuente: Elaboración Propia.

Campaña	Modelo	R ² (%)	R ² -ajustado(%)	Valor-P
03_04	$Z = 0.39789 + 0.00000204973*X - 0.00000483114*Y$	15.018	8.948	0.103
04_05	$Z = 3.50509 - 0.00000108358*X - 0.00000939956*Y$	37.359	33.039	0.001
05_06	$Z = 65.5456 - 0.000163901*X + 0.000126915*Y$	8.552	3.471	0.200
06_07	$Z = 88.2251 - 0.0000750299*X - 0.000135585*Y$	5.509	0	0.439
07_08	$Z = 41.5985 + 0.0000188987*X - 0.000152261*Y$	2.513	0	0.609

Para evitar que la falta de estacionariedad afecte la estimación, de las variables intensidad de *Bemisia tabaci* Guen. y distribución de la enfermedad viral en la campaña 04_05 utilizando “kriging”, se restringió el radio de búsqueda de vecinos para interpolar un valor en una zona no muestreada. Esta aproximación se basa en que para la mayoría de los casos la estacionariedad es “global”, pero no se encuentra estacionariedad “local”, con lo que restringiendo el uso de vecinos a distancias convenientemente cortas, se pueden realizar estimaciones robustas de la variable en el espacio según recomienda Gallardo (2008).

Resulta de gran importancia, para futuros análisis geoestadísticos en el campo de la Sanidad Vegetal, que las variables representativas (distribución e intensidad) (Castellanos *et al.*, 2008) de los agentes nocivos analizados hayan cumplido los requisitos para el análisis geoestadístico, ya que uno fue para un insecto haciendo conteos directos (intensidad de *Bemisia tabaci* Guen.), otro fue haciendo observaciones directas para una enfermedad viral, pero solo de presencia o no (distribución del TYLCV), y el otro se estimó de forma indirecta a través de la aplicación de una escala de grado a cada planta (intensidad de *Alternaria solani* Sor.).

Los resultados obtenidos en esta etapa evidenciaron el cumplimiento, por parte de estas variables, de los preceptos exigidos para este tipo análisis según plantea Méndez (2008), Díaz (2004) y Cuador (2002).

Aunque hubo que hacer transformaciones y adecuaciones, lo cual le confiere un valor metodológico a lo realizado para variables similares, las cuáles son muy diferentes a las empleadas en la minería por otros autores como Cuador (2005).

3.2 – Definición de los modelos de mejor ajuste para la estimación espacial de las variables de los agentes nocivos estudiados

La distancia máxima de un par de observaciones de las tres variables en cada una de las campañas fue aproximadamente igual a 30 500m, por esta razón en el análisis variográfico el máximo valor que tomó el paso (h) fue de 15 250m; para la variable distribución de la enfermedad viral en las campañas donde fue necesario transformar la variable, 03_04, 04_05 y 06_07, la distancia máxima fue de 30 440m aproximadamente, por lo que para estos casos el valor máximo de h fue 15 220m. Según esto se trabajó con un total de 10 intervalos para tener la mayor cantidad de pares en el análisis.

A partir de una comparación entre los semivariogramas omnidireccionales con una dirección de 0° y una tolerancia de 90° y los semivariogramas con direcciones de 0°, 45°, 90° y 135° con una

tolerancia de 22.5° se determinó que las variables en todas las campañas tenían anisotropía, para esto se determinó un coeficiente de anisotropía igual a 2 según la relación existente entre las direcciones con mayor y menor alcance para realizar el ajuste. En los Anexos del 5 al 19 se pueden observar los semivariogramas omnidireccionales y direccionales de cada una de las tres variables en estudio en todas las campañas.

Posterior a esto se procedió a realizar el ajuste del semivariograma de las tres variables, en cada una de las campañas, a los modelos definidos en el capítulo anterior.

En la Figura 3.4 se puede observar el ajuste del semivariograma de la variable intensidad de *Alternaria solani* Sor. en la campaña 03_04, para las direcciones de menor y mayor alcance, 45° y 135° , donde se determinó que la meseta está por encima de la varianza de los datos lo que indica que la variación total es mayor, se apreció un efecto pepita y los alcances para distintas direcciones variaron lo que demuestra la existencia de una anisotropía geométrica.

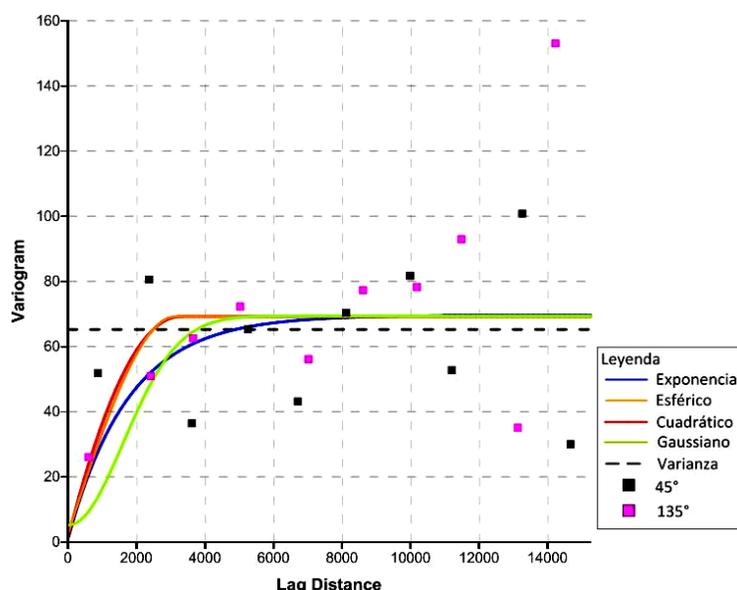


Figura 3.4 – Ajuste del semivariograma de la intensidad de *Alternaria solani* Sor. en la campaña 03_04. **Fuente:** Elaboración Propia.

En la Tabla 3.8 se muestran los parámetros de los modelos ajustados, de aquí se determinó que el efecto pepita es mayor que 1, lo que indica una existencia de error experimental siendo menor para el modelo exponencial, para todos los modelos existe una fuerte dependencia espacial lo que quedó demostrado con la relación efecto pepita/meseta, y el modelo de menor

alcance resultó ser el exponencial, siendo esta entonces la mínima distancia a partir de la cuál no se detecta una dependencia espacial entre las observaciones.

Tabla 3.8 – Parámetros de los modelos ajustados para la intensidad de *Alternaria solani* Sor. en la campaña 03_04. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C ₀)	Meseta (C ₀ +C ₁)	Alcance (a)	(C ₀ /(C ₀ +C ₁))	Anisotropía	
					Coeficiente	Ángulo
Exponencial	1.58	69.58	1770	0.0227	2	135
Esférico	3.27	69.17	3110	0.0473	2	108.1
Cuadrático	1.91	69.21	3260	0.0276	2	120.3
Gaussiano	5.2	69.4	2260	0.0749	2	115.1

El modelo de mejor ajuste encontrado fue el exponencial con un coeficiente de determinación igual a 84.5% y un ajustado de 83.28%, y el menor Criterio de Información de Akaike (AIC) de 223.36, lo que se puede observar en la Tabla 3.9.

Tabla 3.9 – Criterios de selección de los modelos ajustados para la estimación de la intensidad de *Alternaria solani* Sor. en la campaña 03_04. **Fuente:** Elaboración Propia.

Modelo	R ²	R ² Ajustado	AIC
1.58+68Exp(1770)	84.50	83.28	223.36
3.27+65.9Sph(3110)	81.64	80.19	230.47
1.91+67.3Qua(3260)	83.69	82.40	225.51
5.2+64.2Gau(2260)	71.83	69.61	248.46

El ajuste del semivariograma de la variable intensidad de *Alternaria solani* Sor. en la campaña 04_05, para las direcciones de menor y mayor alcance, 0° y 90°, arrojó que la meseta está muy cercana a la varianza de los datos, se identificó un efecto pepita superior a la campaña anterior, ver Figura 3.5.

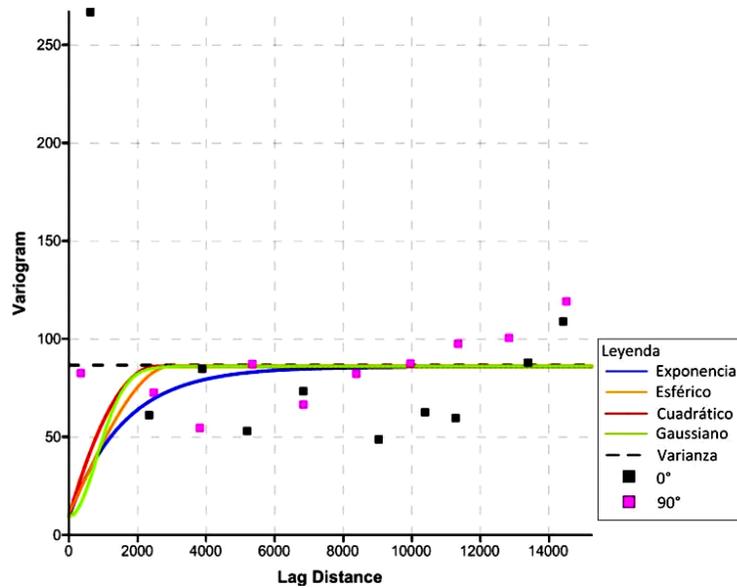


Figura 3.5 – Ajuste del semivariograma de la intensidad de *Alternaria solani* Sor. en la campaña 04_05. **Fuente:** Elaboración Propia.

En la Tabla 3.10 se ofrecen los parámetros de los modelos ajustados, donde se comprobó un efecto pepita mayor que 9, siendo menor para el modelo gaussiano, para todos los modelos existe una fuerte dependencia espacial, y el modelo de menor alcance resultó ser el gaussiano, siendo 1 150m la mínima distancia a partir de la cuál no se detecta una dependencia espacial entre las observaciones.

Tabla 3.10 – Parámetros de los modelos ajustados para la intensidad de *Alternaria solani* Sor. en la campaña 04_05. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C ₀)	Meseta (C ₀ +C ₁)	Alcance (a)	(C ₀ /(C ₀ +C ₁))	Anisotropía	
					Coefficiente	Ángulo
Exponencial	10.2	85.9	1600	0.1187	2	98.66
Esférico	10.9	86.3	2968	0.1230	2	102.27
Cuadrático	9.5	86.2	2530	0.1102	2	103.96
Gaussiano	9.43	86.13	1150	0.1229	2	103.64

El modelo de mejor ajuste encontrado fue el gaussiano el cuál explicó un 75.70% de la variabilidad de la variable analizada, y presentó un menor Criterio de Información de Akaike igual a 248.31, lo que se puede observar en la Tabla 3.11.

Tabla 3.11 – Criterios de selección de los modelos ajustados para la estimación de la intensidad de *Alternaria solani* Sor. en la campaña 04_05. **Fuente:** Elaboración Propia.

Modelo	R ²	R ² Ajustado	AIC
10.2+75.7Exp(1600)	68.13	65.54	259.44
10.9+75.4Sph(2968)	68.86	66.34	258.49
9.5+76.7Qua(2530)	70.84	68.47	255.79
9.43+76.7Gau(1150)	75.70	73.73	248.31

El ajuste del semivariograma de la variable intensidad de *Alternaria solani* Sor. en la campaña 05_06, mostró una meseta superior a la varianza de los datos, se apreció un efecto pepita y una mayor variabilidad que en los casos anteriores, ver Figura 3.6.

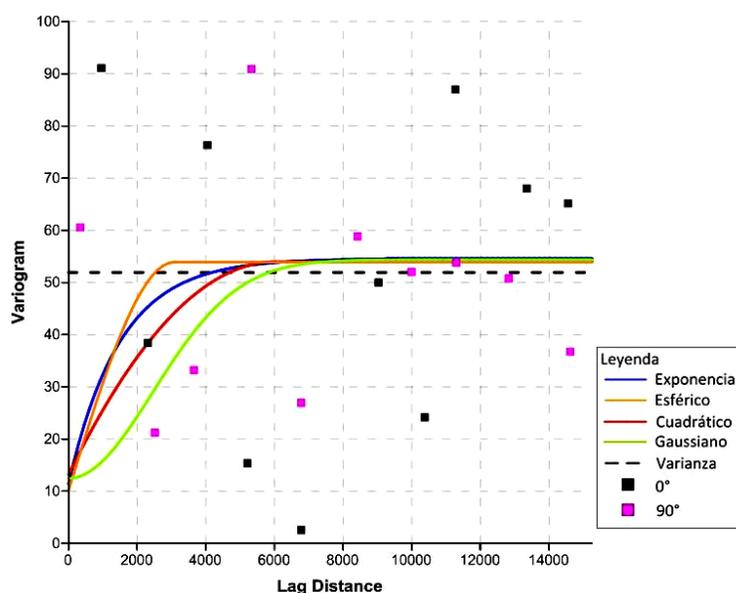


Figura 3.6 – Ajuste del semivariograma de la intensidad de *Alternaria solani* Sor. en la campaña 05_06. **Fuente:** Elaboración Propia.

En la Tabla 3.12 se ofrecen los parámetros de los modelos ajustados, se determinó un efecto pepita mayor que 10, siendo el modelo esférico el de menor valor, para todos los modelos existe una dependencia espacial fuerte, pero la relación efecto pepita/meseta es mayor que en la campaña anterior y para el modelo cuadrático se encuentra en el límite entre una dependencia fuerte y una moderada, además el modelo de menor alcance fue el exponencial, siendo para esta campaña 1 500m la mínima distancia a partir de la cuál no se detecta una dependencia espacial entre las observaciones.

Tabla 3.12 – Parámetros de los modelos ajustados para la intensidad de *Alternaria solani* Sor. en la campaña 05_06. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C ₀)	Meseta (C ₀ +C ₁)	Alcance (a)	(C ₀ /(C ₀ +C ₁))	Anisotropía	
					Coeficiente	Ángulo
Exponencial	11.4	54.6	1500	0.2088	2	33.01
Esférico	10.2	53.9	3070	0.1892	2	17.7
Cuadrático	13.2	54	6050	0.2444	2	140.4
Gaussiano	12.5	54.4	3471	0.2298	2	135.9

El modelo de mejor ajuste encontrado fue el esférico el cuál explicó un 79.52% de la variabilidad, y presentó el menor Criterio de Información de Akaike igual a 209.85, ver Tabla 3.13.

Tabla 3.13 – Criterios de selección de los modelos ajustados para la estimación de la intensidad de *Alternaria solani* Sor. en la campaña 05_06. **Fuente:** Elaboración Propia.

Modelo	R ²	R ² Ajustado	AIC
11.4+43.2Exp(1500)	76.77	74.78	214.76
10.2+43.7Sph(3070)	79.52	77.77	209.85
13.2+40.8Qua(6050)	72.08	69.68	221.94
12.5+41.9Gau(3471)	62.18	58.94	233.77

El ajuste del semivariograma en la campaña 06_07, mostró una meseta muy cercana a la varianza de los datos, se apreció efecto pepita y una variabilidad de los datos para las direcciones de menor y mayor alcance seleccionadas 0° y 90°, ver Figura 3.7.

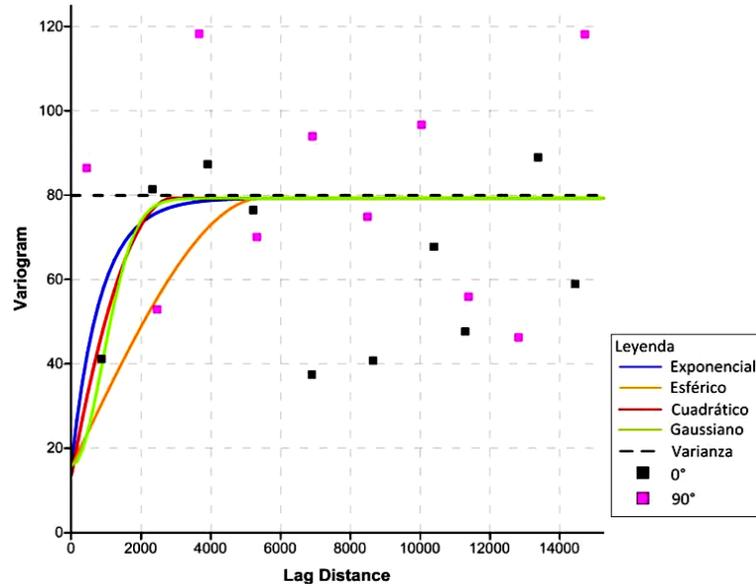


Figura 3.7 – Ajuste del semivariograma de la intensidad de *Alternaria solani* Sor. en la campaña 06_07. **Fuente:** Elaboración Propia.

Según los parámetros de los modelos ajustados, ver Tabla 3.14, se determinó un efecto pepita mayor que en las campañas anteriores, siendo el modelo cuadrático el de menor valor, para todos los modelos existe una dependencia espacial fuerte, además el modelo de menor alcance fue el exponencial con valor de 844m para un ángulo de 110.01°, siendo ésta la mínima distancia a partir de la cuál no se detecta una dependencia espacial entre las observaciones.

Tabla 3.14 – Parámetros de los modelos ajustados para la intensidad de *Alternaria solani* Sor. en la campaña 06_07. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C ₀)	Meseta (C ₀ +C ₁)	Alcance(a)	(C ₀ /(C ₀ +C ₁))	Anisotropía	
					Coefficiente	Ángulo
Exponencial	16.3	79.3	844	0.2055	2	110.01
Esférico	15.62	79.36	5483.5	0.1968	2	41.22
Cuadrático	13.66	79.25	2897.9	0.1724	2	131.9
Gaussiano	15.92	79.24	1267.5	0.2009	2	11

El modelo de mejor ajuste encontrado fue el gaussiano con un coeficiente de determinación igual a 79.13% y un R² ajustado de 77.52%, y también resultó ser el modelo con un menor Criterio de Información de Akaike igual a 250.01, ver Tabla 3.15.

Tabla 3.15 – Criterios de selección de los modelos ajustados para la estimación de la intensidad de *Alternaria solani* Sor. en la campaña 06_07. **Fuente:** Elaboración Propia.

Modelo	R ²	R ² Ajustado	AIC
16.3+63Exp(844)	68.37	65.94	267.88
15.62+63.74Sph(5483.5)	67.32	64.81	269.29
13.66+65.59Qua(2897.9)	72.62	70.51	261.68
15.92+63.32Gau(1267.5)	79.13	77.52	250.01

El ajuste del semivariograma en la campaña 07_08, mostró una meseta mayor que la varianza de los datos, se apreció efecto pepita y una variabilidad de los datos que para la dirección 0° muestra un comportamiento menos suavizado al crecer hasta una distancia a partir de la cuál decrece, ver Figura 3.8.

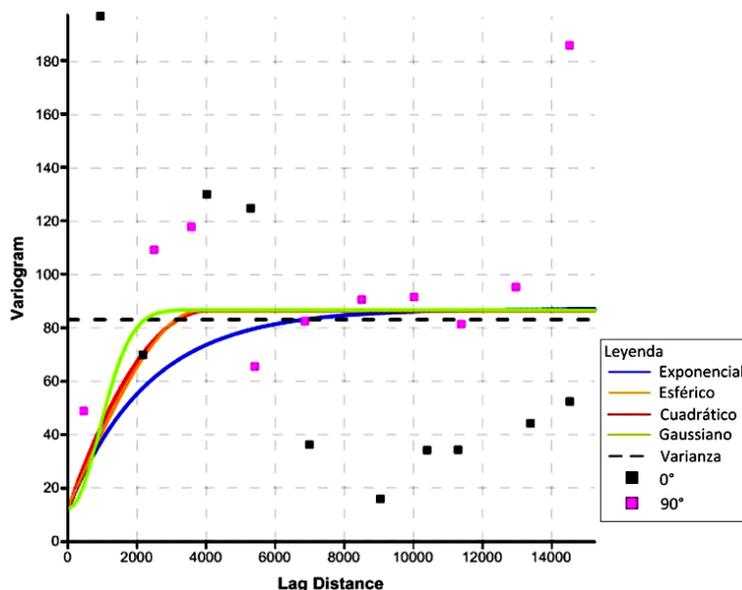


Figura 3.8 – Ajuste del semivariograma de la intensidad de *Alternaria solani* Sor. en la campaña 07_08. **Fuente:** Elaboración Propia.

Según los parámetros de los modelos ajustados, ver Tabla 3.16, se determinó un efecto pepita menor que en la campaña anterior, el modelo gaussiano fue el de menor valor, para todos los modelos existe una dependencia espacial fuerte, además el modelo de menor alcance fue el gaussiano con valor de 1 281m, siendo ésta la mínima distancia a partir de la cuál no se detecta una dependencia espacial.

Tabla 3.16 – Parámetros de los modelos ajustados para la intensidad de *Alternaria solani* Sor. en la campaña 07_08. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C ₀)	Meseta (C ₀ +C ₁)	Alcance (a)	(C ₀ /(C ₀ +C ₁))	Anisotropía	
					Coeficiente	Ángulo
Exponencial	12.3	87.18	2330	0.1411	2	73
Esférico	13.2	86.5	3820	0.1526	2	84.97
Cuadrático	12.44	86.56	4049.6	0.1437	2	128
Gaussiano	12.25	86.84	1281	0.1642	2	81

El modelo de mejor ajuste fue el gaussiano con un coeficiente de determinación igual a 85.19% y un R² ajustado de 77.52%, y también resultó ser el modelo con un menor Criterio de Información de Akaike igual a 250.01, ver Tabla 3.17.

Tabla 3.17 – Criterios de selección de los modelos ajustados para la estimación de la intensidad de *Alternaria solani* Sor. en la campaña 07_08. **Fuente:** Elaboración Propia.

Modelo	R ²	R ² Ajustado	AIC
12.3+74.88Exp(2330)	82.08	80.66	239.62
13.2+73.3Sph(3820)	82.83	81.47	237.82
12.44+74.12Qua(4049.6)	81.95	80.52	239.92
12.25+74.59Gau(1281)	85.19	84.02	231.62

Según el ajuste del semivariograma de la intensidad de *Bemisia tabaci* Guen. en la campaña 03_04, la meseta es mayor que la varianza de los datos, se apreció un efecto pepita cercano a cero y se muestra una menor variabilidad en la dirección de 90°, ver Figura 3.9.

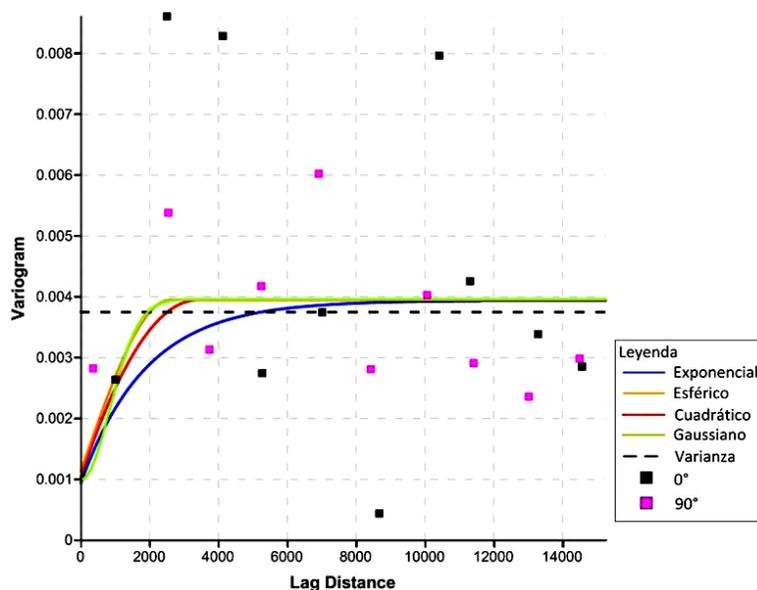


Figura 3.9 – Ajuste del semivariograma de la intensidad de *Bemisia tabaci* Guen. en la campaña 03_04. **Fuente:** Elaboración Propia.

Los parámetros de los modelos ajustados, ver Tabla 3.18, arrojaron un efecto pepita cercano a cero, el modelo exponencial resultó ser el de menor valor, siendo este el único modelo que presentó una dependencia espacial fuerte el resto tiene una dependencia moderada, y el modelo de menor alcance fue el gaussiano con un valor de 1 190m con un ángulo de 44.2°.

Tabla 3.18 – Parámetros de los modelos ajustados para la intensidad de *Bemisia tabaci* Guen. en la campaña 03_04. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C ₀)	Meseta (C ₀ +C ₁)	Alcance (a)	(C ₀ /(C ₀ +C ₁))	Anisotropía	
					Coeficiente	Ángulo
Exponencial	0.00094	0.00394	1898	0.2386	2	109.77
Esférico	0.00114	0.003952	2590.3	0.2885	2	135
Cuadrático	0.001038	0.003951	3403	0.2672	2	55
Gaussiano	0.00099	0.00396	1190	0.3333	2	44.2

El modelo de mejor ajuste resultó ser el gaussiano que explica un 74.08% de la variabilidad y a su vez fue el modelo de menor Criterio de Información de Akaike con un valor de -165.14, ver Tabla 3.19.

Tabla 3.19 – Criterios de selección de los modelos ajustados para la estimación de la intensidad de *Bemisia tabaci* Guen. en la campaña 03_04. **Fuente:** Elaboración Propia.

Modelo	R ²	R ² Ajustada	AIC
0.00094+0.003Exp(1898)	70.04	67.67	-159.05
0.00114+0.002812Sph(2590.3)	68.93	66.47	-157.52
0.001038+0.002913Qua(3403)	69.49	67.08	-158.29
0.00099+0.00297Gau(1190)	74.08	72.03	-165.14

Con el ajuste del semivariograma de la intensidad del agente *Bemisia tabaci* Guen. en la campaña 04_05, se determinó que la meseta es menor que la varianza de los datos y se mostró un efecto pepita cercano a cero, con una mayor variabilidad en la dirección de 45°, ver Figura 3.10.

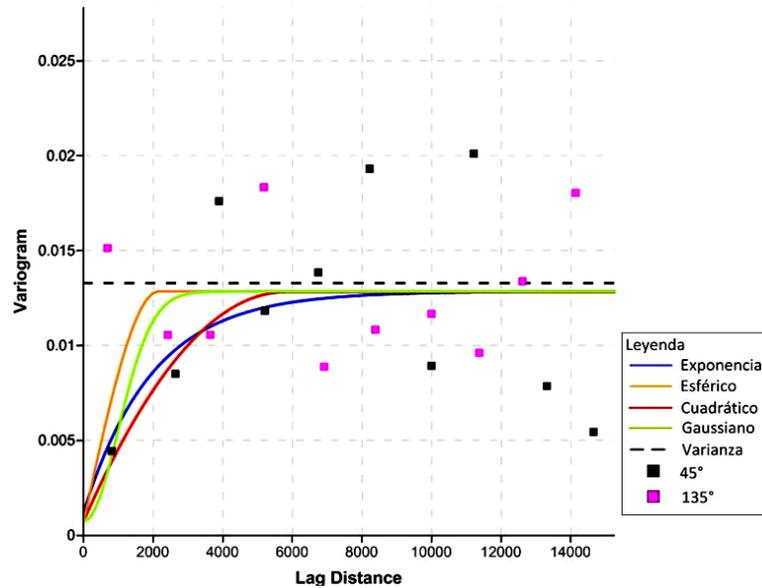


Figura 3.10 – Ajuste del semivariograma de la intensidad de *Bemisia tabaci Guen.* en la campaña 04_05. **Fuente:** Elaboración Propia.

Los parámetros de los modelos ajustados para esta variable en la campaña 04_05, ver Tabla 3.20, arrojaron un efecto pepita próximo a cero, el modelo gaussiano fue el de menor alcance, y todos los modelos presentaron una dependencia espacial fuerte.

Tabla 3.20 – Parámetros de los modelos ajustados para la intensidad de *Bemisia tabaci Guen.* en la campaña 04_05. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C_0)	Meseta (C_0+C_1)	Alcance (a)	Nugget/Sill ($C_0/(C_0+C_1)$)	Anisotropía	
					Coefficiente	Ángulo
Exponencial	0.00124	0.01284	1980	0.0966	2	21.28
Esférico	0.00074	0.01285	2150	0.0576	2	162.35
Cuadrático	0.00076	0.01281	5780	0.0593	2	26.57
Gaussiano	0.000736	0.01284	1390	0.0573	2	164.04

El modelo de mejor ajuste resultó ser el gaussiano que explica un 91.39% de la variabilidad, superior que la campaña anterior, y fue el modelo de menor Criterio de Información de Akaike con un valor de -156.42, ver Tabla 3.21.

Tabla 3.21 – Criterios de selección de los modelos ajustados para la estimación de la intensidad de *Bemisia tabaci Guen.* en la campaña 04_05. **Fuente:** Elaboración Propia.

Modelo	R^2	R^2 Ajustada	AIC
--------	-------	----------------	-----

$0.00124+0.0116\text{Exp}(1980)$	84.31	83.03	-131.79
$0.00074+0.01211\text{Sph}(2150)$	87.90	86.92	-142.47
$0.00076+0.01205\text{Qua}(5780)$	86.86	85.79	-139.07
$0.000736+0.012104\text{Gau}(1390)$	91.39	90.69	-156.42

Con el ajuste del semivariograma en la campaña 05_06, se determinó una meseta mayor que la varianza de los datos y un efecto pepita cercano a cero, con una mayor variabilidad en la dirección de 45°, ver Figura 3.11.

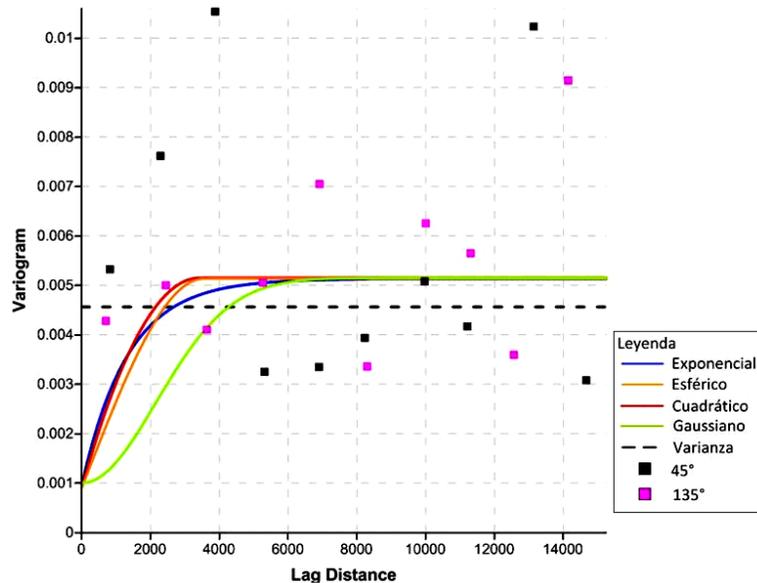


Figura 3.11 – Ajuste del semivariograma de la intensidad de *Bemisia tabaci Guen.* en la campaña 05_06. **Fuente:** Elaboración Propia.

Según los parámetros de los modelos ajustados en la campaña 05_06, ver Tabla 3.22, se determinó un efecto pepita próximo a cero, siendo menor para el modelo esférico, el modelo exponencial resultó ser el de menor alcance, y todos los modelos presentaron una dependencia espacial fuerte entre 17 y 20%.

Tabla 3.22 – Parámetros de los modelos ajustados para la intensidad de *Bemisia tabaci Guen.* en la campaña 05_06. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C_0)	Meseta (C_0+C_1)	Alcance (a)	Nugget/Sill ($C_0/(C_0+C_1)$)	Anisotropía	
					Coefficiente	Ángulo
Exponencial	0.00096	0.00513	1340	0.1871	2	149.3
Esférico	0.000906	0.005134	3530	0.1765	2	139.4
Cuadrático	0.000918	0.005148	3410	0.1783	2	130.6

Gaussiano	0.000999	0.005149	3052	0.1940	2	26.7
-----------	----------	----------	------	--------	---	------

El modelo de mejor ajuste fue el cuadrático con un coeficiente de determinación igual a 76.13% y un ajustado de 74.09%, además fue el modelo de menor Criterio de Información de Akaike con un valor de -148.46, ver Tabla 3.23.

Tabla 3.23 – Criterios de selección de los modelos ajustados para la estimación de la intensidad de *Bemisia tabaci* Guen. en la campaña 05_06. **Fuente:** Elaboración Propia.

Modelo	R ²	R ² Ajustado	AIC
0.00096+0.00417Exp(1340)	73.84	71.59	-144.87
0.000906+0.004228Sph(3530)	75.69	73.61	-147.74
0.000918+0.00423Qua(3410)	76.13	74.09	-148.46
0.000999+0.00415Gau(3052)	66.65	63.79	-135.41

A partir del ajuste del semivariograma en la campaña 06_07, se determinó una meseta mayor que la varianza de los datos y un efecto pepita mayor que en los casos anteriores, con una mayor variabilidad en la dirección de 0°, ver Figura 3.12.

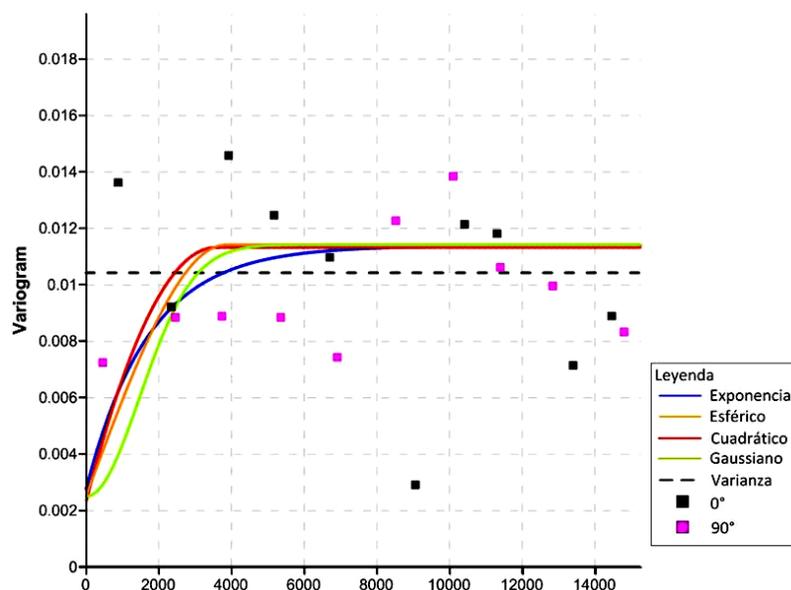


Figura 3.12 – Ajuste del semivariograma de la intensidad de *Bemisia tabaci* Guen. en la campaña 06_07. **Fuente:** Elaboración Propia.

Los parámetros de los modelos ajustados en la campaña 06_07, ver Tabla 3.24, mostraron un efecto pepita próximo a cero, pero mayor que en las campañas anteriores para esta misma

variable; el modelo exponencial resultó ser el de menor alcance con un radio de 1 720m, y todos los modelos presentaron una dependencia espacial fuerte entre 20 y 25%.

Tabla 3.24 – Parámetros de los modelos ajustados para la intensidad de *Bemisia tabaci* Guen. en la campaña 06_07. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C_0)	Meseta (C_0+C_1)	Alcance (a)	Nugget/Sill ($C_0/(C_0+C_1)$)	Anisotropía	
					Coeficiente	Ángulo
Exponencial	0.00277	0.01139	1720	0.2432	2	84.36
Esférico	0.0025	0.0114	3830	0.2193	2	118.29
Cuadrático	0.00234	0.01132	3560	0.2067	2	54.37
Gaussiano	0.00248	0.0114	2080	0.2175	2	113.71

El modelo de mejor ajuste fue el cuadrático con un coeficiente de determinación igual a 73.08% y un ajustado de 70.96%, y fue el modelo de menor Criterio de Información de Akaike con un valor de -120.61, ver Tabla 3.25.

Tabla 3.25 – Criterios de selección de los modelos ajustados para la estimación de la intensidad de *Bemisia tabaci* Guen. en la campaña 06_07. **Fuente:** Elaboración Propia.

Modelo	R^2	R^2 Ajustada	AIC
0.00277+0.00862Exp(1720)	68.79	66.33	-114.41
0.0025+0.0089Sph(3830)	69.63	67.23	-115.54
0.00234+0.00898Qua(3560)	73.08	70.96	-120.61
0.00248+0.00892Gau(2080)	64.86	62.09	-109.42

Según el ajuste del semivariograma en la campaña 07_08, se determinó una meseta mayor que la varianza de los datos, un efecto pepita cercano a cero, y la dirección de 90° mostró una menor variabilidad, ver Figura 3.13.

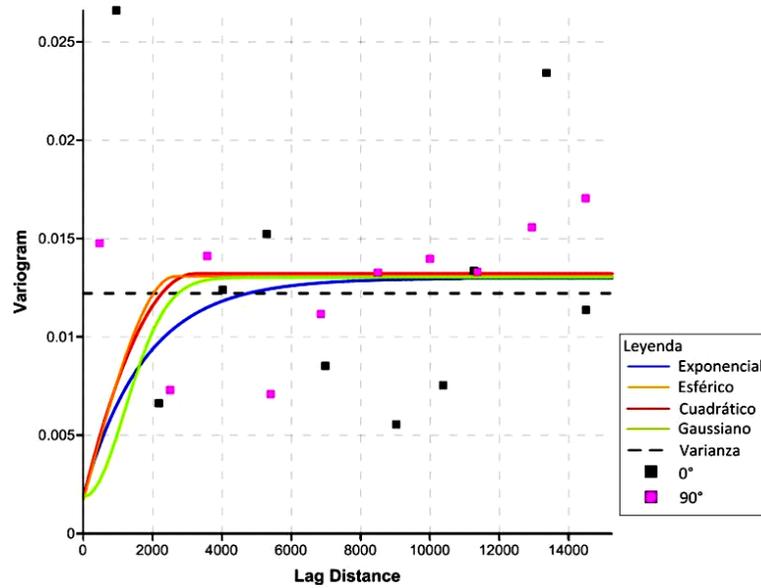


Figura 3.13 – Ajuste del semivariograma de la intensidad de *Bemisia tabaci Guen.* en la campaña 07_08. **Fuente:** Elaboración Propia.

Los parámetros de los modelos ajustados en la campaña 07_08, ver Tabla 3.26, mostraron un efecto pepita próximo a cero; el modelo gaussiano resultó ser el de menor alcance con un radio de 1 685m, y todos los modelos presentaron una dependencia espacial fuerte entre 13 y 15%, mayor que en la campaña anterior.

Tabla 3.26 – Parámetros de los modelos ajustados para la intensidad de *Bemisia tabaci Guen.* en la campaña 07_08. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C_0)	Meseta (C_0+C_1)	Alcance (a)	Nugget/Sill ($C_0/(C_0+C_1)$)	Anisotropía	
					Coefficiente	Ángulo
Exponencial	0.00194	0.01299	1780	0.1493	2	97.39
Esférico	0.00176	0.01308	2640	0.1346	2	101.31
Cuadrático	0.00185	0.01322	3210	0.1399	2	99.87
Gaussiano	0.00187	0.01303	1685	0.1435	2	93.03

El modelo esférico resultó ser el de mejor ajuste, pues explica un 73.28% de la variabilidad de los datos observados, y fue el modelo de menor Criterio de Información de Akaike con un valor de -114.27, ver Tabla 3.27.

Tabla 3.27 – Criterios de selección de los modelos ajustados para la estimación de la intensidad de *Bemisia tabaci Guen.* en la campaña 07_08. **Fuente:** Elaboración Propia.

Modelo	R ²	R ² Ajustado	AIC
0.00194+0.01105Exp(1780)	69.99	67.63	-109.39
0.00176+0.01132Sph(2640)	73.28	71.17	-114.27
0.00185+0.01137Qua(3210)	72.43	70.26	-112.96
0.00187+0.01116Gau(1685)	66.38	63.72	-104.62

En la Figura 3.14 se muestra el ajuste del semivariograma de la distribución de la enfermedad viral para la campaña 03_04, donde se determinó una meseta próxima a la varianza de los datos, un efecto pepita cercano a cero, y la dirección de 45° fue la de mayor variabilidad.

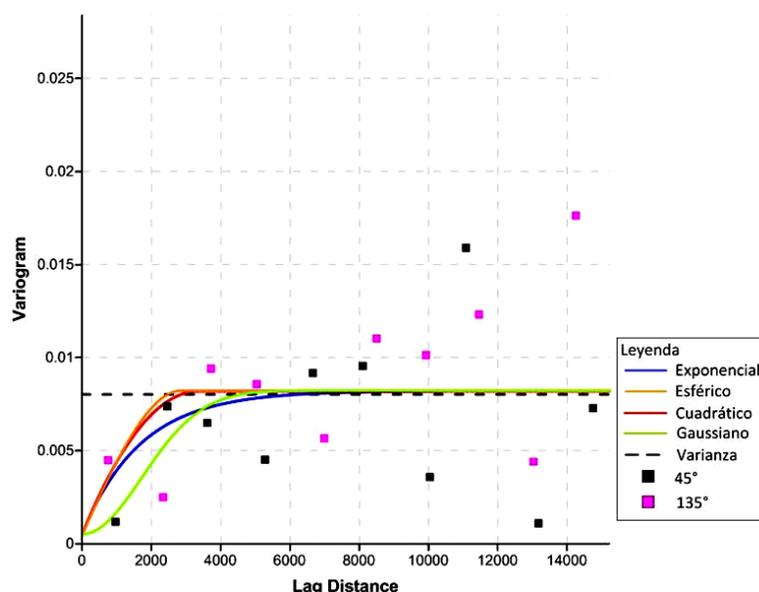


Figura 3.14 – Ajuste del semivariograma de la distribución de la enfermedad viral en la campaña 03_04. **Fuente:** Elaboración Propia.

Los parámetros de los modelos ajustados de la distribución de la enfermedad viral para la campaña 03_04, ver Tabla 3.28, mostraron un efecto pepita próximo a cero; el modelo exponencial resultó ser el de menor alcance con un radio de 1 690m, además todos los modelos presentaron una dependencia espacial fuerte menor que el 10%.

Tabla 3.28 – Parámetros de los modelos ajustados para la distribución de la enfermedad viral en la campaña 03_04. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C ₀)	Meseta (C ₀ +C ₁)	Alcance (a)	Nugget/Sill (C ₀ /(C ₀ +C ₁))	Anisotropía	
					Coeficiente	Ángulo
Exponencial	0.000516	0.008206	1690	0.0629	2	113.1

Esférico	0.000509	0.008217	2850	0.0619	2	40.7
Cuadrático	0.000503	0.008186	3351	0.0614	2	92.01
Gaussiano	0.000453	0.008233	2430	0.0550	2	97.75

El modelo cuadrático fue el de mejor ajuste, pues explica un 94.59% de la variabilidad de los datos, y a su vez resultó ser el modelo de menor Criterio de Información de Akaike con un valor igual a -145.14, ver Tabla 3.29.

Tabla 3.29 – Criterios de selección de los modelos ajustados para la estimación de la distribución de la enfermedad viral en la campaña 03_04. **Fuente:** Elaboración Propia.

Modelo	R ²	R ² Ajustado	AIC
0.000516+0.00769Exp(1690)	93.92	93.24	-141.54
0.000509+0.007708Sph(2850)	93.24	92.48	-138.24
0.000503+0.007683Qua(3351)	94.59	93.99	-145.14
0.000453+0.00778Gau(2430)	92.89	92.10	-136.67

Según el ajuste del semivariograma de la distribución de la enfermedad viral para la campaña 04_05, ver Figura 3.15, la meseta es menor que la varianza de los datos, el efecto pepita está muy próximo a cero, y se observó una mayor variabilidad en la dirección de 45°.

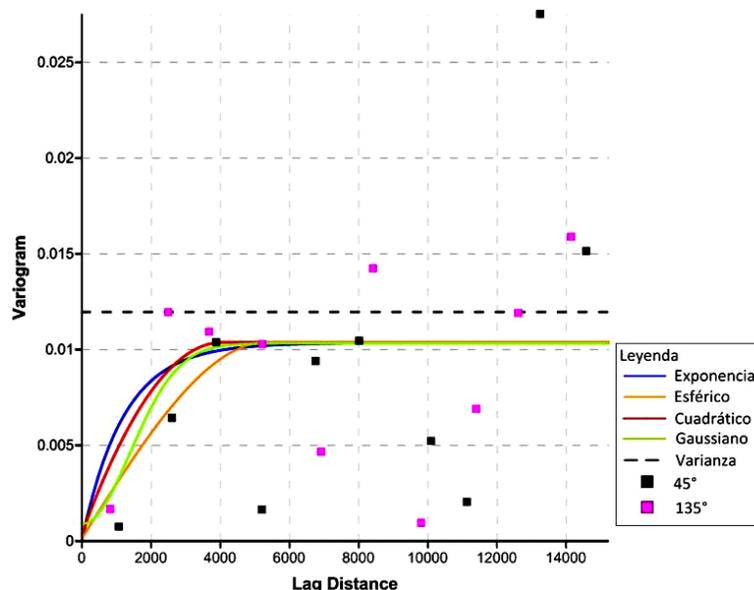


Figura 3.15 – Ajuste del semivariograma de la distribución de la enfermedad viral en la campaña 04_05. **Fuente:** Elaboración Propia.

A partir de un análisis de los parámetros de los modelos ajustados de esta variable para la campaña 04_05, ver Tabla 3.30, se determinó que el modelo exponencial resultó ser el de menor alcance con una distancia de 1 213m, se comprobó que el efecto pepita está próximo a cero, y todos los modelos presentaron una dependencia espacial fuerte.

Tabla 3.30 – Parámetros de los modelos ajustados para la distribución de la enfermedad viral en la campaña 04_05. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C_0)	Meseta (C_0+C_1)	Alcance (a)	Nugget/Sill ($C_0/(C_0+C_1)$)	Anisotropía	
					Coeficiente	Ángulo
Exponencial	0.0001	0.010347	1213	0.0097590	2	73.46
Esférico	0.000176	0.010376	5320	0.0172549	2	45.71
Cuadrático	0.00042	0.010380	4043	0.0421687	2	43.59
Gaussiano	0.000894	0.010324	1960	0.0948038	2	133.31

Se logró un mejor ajuste con el modelo esférico, el cual presentó un coeficiente de determinación de 99.08%, lo que indica un ajuste muy bueno al explicar casi la totalidad de la variabilidad de los datos, y presentó el menor Criterio de Información de Akaike con un valor igual a -194.07, ver Tabla 3.31.

Tabla 3.31 – Criterios de selección de los modelos ajustados para la estimación de la distribución de la enfermedad viral en la campaña 04_05. **Fuente:** Elaboración Propia.

Modelo	R^2	R^2 Ajustado	AIC
0.0001+0.010247Exp(1213)	97.64	97.39	-163.72
0.000176+0.0102Sph(5320)	99.08	98.99	-194.07
0.00042+0.00996Qua(4043)	98.03	97.82	-169.57
0.000894+0.00943Gau(1960)	97.98	97.77	-168.78

A partir del ajuste del semivariograma para la campaña 05_06, ver Figura 3.16, se observó que la meseta es mayor que la varianza de los datos y se observó una mayor variabilidad en la dirección de 135°.

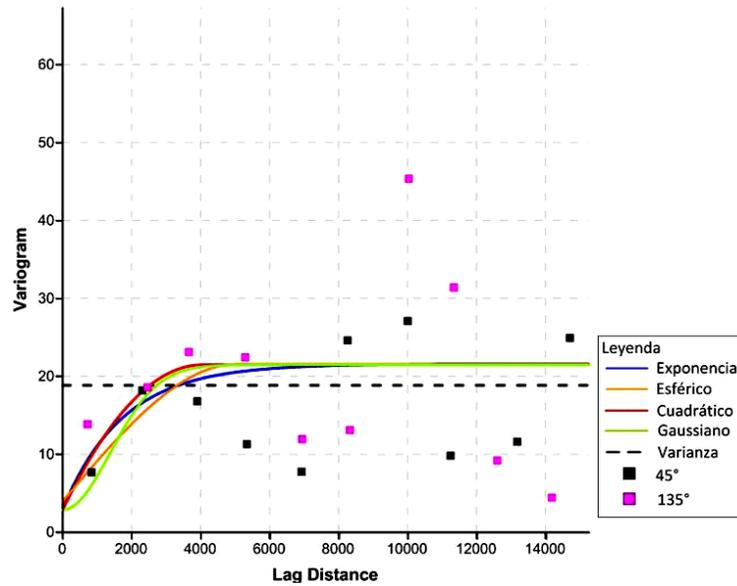


Figura 3.16 – Ajuste del semivariograma de la distribución de la enfermedad viral en la campaña 05_06. **Fuente:** Elaboración Propia.

Según el análisis de los parámetros de los modelos ajustados para la campaña 05_06, ver Tabla 3.32, el modelo exponencial resultó ser el de menor alcance con una distancia de 1 750m con un ángulo igual a 39.34°, los modelos presentaron un error o efecto pepita próximo a cero y menor que 4, y todos los modelos presentaron una dependencia espacial fuerte.

Tabla 3.32 – Parámetros de los modelos ajustados para la distribución de la enfermedad viral en la campaña 05_06. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C_0)	Meseta (C_0+C_1)	Alcance (a)	Nugget/Sill ($C_0/(C_0+C_1)$)	Anisotropía	
					Coeficiente	Ángulo
Exponencial	2.98	21.58	1750	0.16021505	2	39.34
Esférico	3.96	21.56	5040	0.225	2	97.52
Cuadrático	2.88	21.48	4050	0.15483871	2	30.03
Gaussiano	2.87	21.47	1950	0.15430108	2	28.52

El modelo cuadrático presentó un mejor ajuste, pues explica un 82.68% de la variabilidad, y fue el modelo con un menor Criterio de Información de Akaike igual a 163.79, ver Tabla 3.33.

Tabla 3.33 – Criterios de selección de los modelos ajustados para la estimación de la distribución de la enfermedad viral en la campaña 05_06. **Fuente:** Elaboración Propia.

Modelo	R^2	R^2 Ajustado	AIC
--------	-------	----------------	-----

$2.98+18.6\text{Exp}(1750)$	81.43	79.83	166.51
$3.96+17.6\text{Sph}(5040)$	77.74	75.83	173.57
$2.88+18.6\text{Qua}(4050)$	82.68	81.19	163.79
$2.87+18.6\text{Gau}(1950)$	80.84	79.20	167.71

En la Figura 3.17 se muestra el ajuste del semivariograma para la campaña 06_07, donde se identificó que la meseta es mayor que la varianza de los datos y se observó una mayor variabilidad en la dirección de 0°.

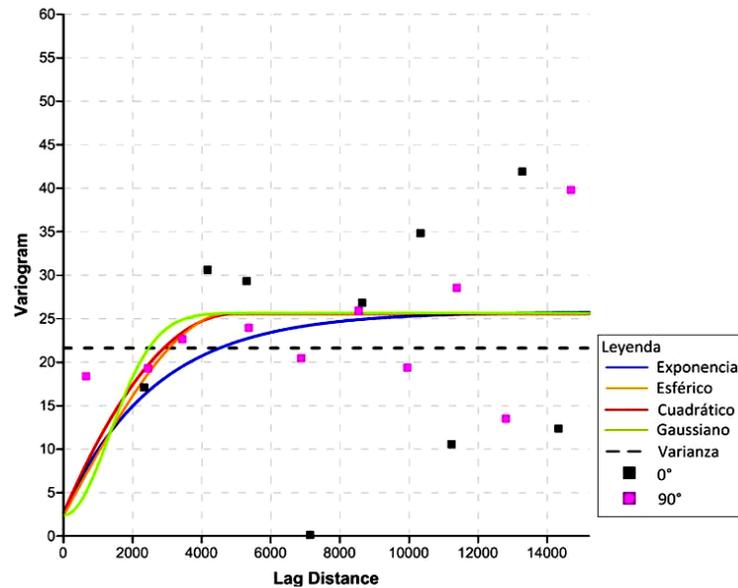


Figura 3.17 – Ajuste del semivariograma de la distribución de la enfermedad viral en la campaña 06_07. **Fuente:** Elaboración Propia.

El análisis de los parámetros de los modelos ajustados para la campaña 06_07, ver Tabla 3.34, arrojó que el modelo gaussiano fue el de menor alcance con una distancia de 1 861m con un ángulo igual a 128.8°, los modelos presentaron un error menor que 3, y todos los modelos presentaron una dependencia espacial fuerte.

Tabla 3.34 – Parámetros de los modelos ajustados para la distribución de la enfermedad viral en la campaña 06_07. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C_0)	Meseta (C_0+C_1)	Alcance (a)	Nugget/Sill ($C_0/(C_0+C_1)$)	Anisotropía	
					Coeficiente	Ángulo
Exponencial	2.71	25.81	2640	0.1173	2	171.5
Esférico	2.42	25.62	4770	0.1043	2	127.2

Cuadrático	2.68	25.58	4956	0.1170	2	123.5
Gaussiano	2.4	25.67	1861	0.1031	2	128.8

El modelo gaussiano presentó un mejor ajuste, pues explica un 90.02% de la variabilidad, y fue el modelo con un menor Criterio de Información de Akaike igual a 122.40, ver Tabla 3.35.

Tabla 3.35 – Criterios de selección de los modelos ajustados para la estimación de la distribución de la enfermedad viral en la campaña 06_07. **Fuente:** Elaboración Propia.

Modelo	R ²	R ² Ajustada	Criterio AIC
2.71+23.1Exp(2640)	84.10	82.40	137.29
2.42+23.2Sph(4770)	87.53	86.19	129.53
2.68+22.9Qua(4956)	87.19	85.82	130.38
2.4+23.27Gau(1861)	90.02	88.95	122.40

Con el gráfico del ajuste del semivariograma para la campaña 07_08, ver Figura 3.18, se obtuvieron resultados similares en comparación con la campaña anterior.

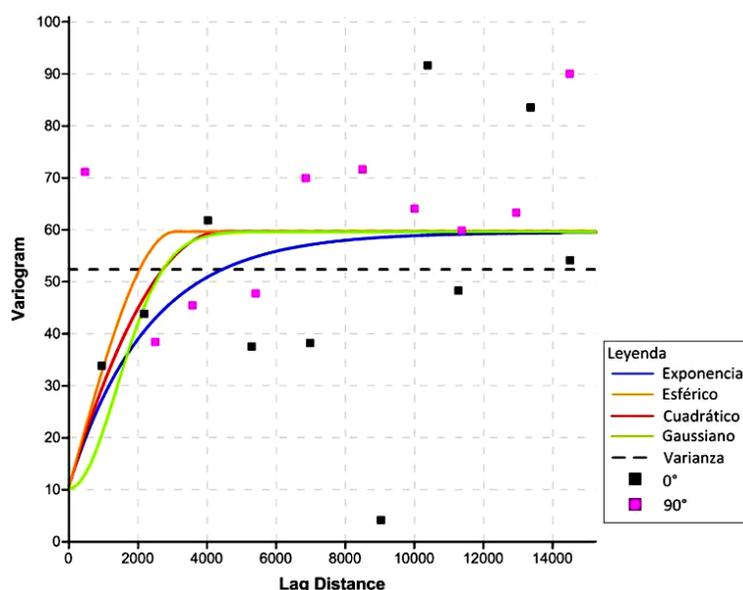


Figura 3.18 – Ajuste del semivariograma de la distribución de la enfermedad viral en la campaña 07_08. **Fuente:** Elaboración Propia.

A partir del análisis de los parámetros de los modelos ajustados para la campaña 07_08, ver Tabla 3.36, se determinó que el modelo gaussiano fue el de menor alcance con una distancia de 1 961m y todos los modelos presentaron una dependencia espacial fuerte entre 20 y 23%.

Tabla 3.36 – Parámetros de los modelos ajustados para la distribución de la enfermedad viral en la campaña 07_08. **Fuente:** Elaboración Propia.

Modelo	Efecto Pepita (C_0)	Meseta (C_0+C_1)	Alcance (a)	Nugget/Sill ($C_0/(C_0+C_1)$)	Anisotropía	
					Coefficiente	Ángulo
Exponencial	10.8	59.5	2310	0.2217	2	50.1
Esférico	10.44	59.64	3060	0.2122	2	2.8
Cuadrático	10.64	59.64	4420	0.2171	2	154.2
Gaussiano	10.2	59.6	1961	0.2065	2	173.8

El modelo esférico presentó un mejor ajuste con un coeficiente de determinación igual a 73.54% y un menor Criterio de Información de Akaike de 236.56, ver Tabla 3.37.

Tabla 3.37 – Criterios de selección de los modelos ajustados para la estimación de la distribución de la enfermedad viral en la campaña 07_08. **Fuente:** Elaboración Propia.

Modelo	R^2	R^2 Ajustado	AIC
10.8+48.7Exp(2310)	71.04	68.75	240.35
10.44+49.2Sph(3060)	73.54	71.45	236.56
10.64+49Qua(4420)	71.89	69.67	239.09
10.2+49.4Gau(1961)	69.79	67.41	242.11

Los resultados obtenidos hasta el momento permitieron verificar la posibilidad de obtener modelos con determinado nivel de precisión para la estimación espacial de las variables analizadas con las implicaciones prácticas que esto podría traer, no sólo en función del tiempo o de la fenología del cultivo o variables meteorológicas como se ha demostrado por otros investigadores (Castellanos *et al.*, 2005a y Castellanos *et al.*, 2005b), sino en función del espacio.

Los criterios de R^2 , R^2 -Ajustado y Criterio de Información de Akaike, se consideran adecuados para aceptar la precisión de los modelos de mayor ajuste, sobre todo este último el cual fue recomendado por Díaz (2002) para la selección del modelo de mejor ajuste en los procesos estadísticos de modelación matemática por ser más fuerte que el coeficiente de determinación ajustado al penalizar en mayor medida el número de parámetros en la ecuación.

Estos resultados demuestran las deficiencias de lo asumido por González (2010) con respecto a emplear, para las tres variables en estudio, el modelo esférico, cuando se ha demostrado que no siempre ese es el de mejor ajuste para esos datos, lo que obliga a hacer todo el análisis

exploratorio de los datos, basado en la estadística, según recomiendan Cuador (2002) y Díaz (2004).

Los presentes resultados de modelación apoyados con los mapas de estimación permiten a la Sanidad Vegetal perfeccionar la estrategia de manejo de estos tres agentes nocivos del tomate en la EPP de Lajas para hacer un uso racional de los plaguicidas y de los recursos a partir de la repetitividad que van teniendo en el espacio o zonas de este territorio los índices más elevados en las diferentes campañas, así como dar recomendaciones con respecto a los riesgos de estas plagas si se van a incrementar las áreas del cultivo.

Se determinó que para una misma variable de un agente nocivo no se ajustó a un solo modelo durante las cinco campañas en estudio, comportamiento que puede ser atribuido a cambios meteorológicos que influyeron sobre los agentes nocivos o a cambios que pudieron realizarse en cuanto al manejo de éstos. Este resultado fue similar al de Sopó (2004) que para una misma variable en una plaga en el cultivo del mango obtuvo cambio de estructura en los modelos de los años 2000-2001 (esférico) con respecto a los de los años 2002-2003 (exponencial), según él por la posible implementación de nuevos métodos de control.

A partir de lo explicado se sugiere profundizar con otras investigaciones sobre esta base de datos para determinar si se pueden ajustar los datos de todos los años a un solo modelo matemático que permita hacer predicciones al futuro y no solo dentro de la misma campaña.

3.3 – Validación de los modelos de mejor ajuste para cada agente por campaña

Los mapas de estimación de la variable intensidad de *Alternaria solani* Sor. mostraron que la mayoría de los valores oscilan entre 30 y 35%, intervalo clasificado como intenso. Los valores más intensos mayores que el 45% se mostraron en todas las campañas excepto en la 03_04 y la 05_06, principalmente al sur del municipio Palmira y en los límites entre el municipio Lajas y Cruces. Los más ligeros entre 20 y 25% se observaron en el municipio de Lajas en la primera campaña (ver Anexos del 20 al 24).

Los mapas de estimación de la intensidad de *Bemisia tabaci* Guen. permitieron determinar que la mayoría de los valores oscilan entre 0.10 y 0.29, siendo este agente considerado como ligero hasta 0.20. Los valores más intensos por encima de 0.33 se observaron en las campañas 04_05 y 07_08 principalmente en el municipio Lajas. Los más ligeros se detectaron entre 0.03 y 0.13 al sur del municipio Palmira, en los límites entre Cruces y Lajas, la estimación más al norte en el municipio Lajas (ver Anexos del 25 al 29).

A partir de los mapas de estimación de la variable distribución del *Virus del encrespamiento amarillo de la hoja del tomate* se determinó que la mayoría de los valores oscilan entre 4 y 13%, valores para los cuáles se clasifica esta enfermedad como ligera. Los valores más intensos estuvieron por encima del 17% en la campaña 07_8 en el municipio de Cruces y los más ligeros entre 0 y 5% se observaron principalmente en el municipio de Lajas (ver Anexos 30 al 34).

La validación de los modelos para la variable intensidad de *Alternaria solani* Sor. permitió comprobar que los datos interpolados tienen una buena correlación con los observados al encontrarse este valor entre 0.90 y 0.94 para cada una de las campañas; la media de los residuos está próxima a cero, lo que quedó demostrado con la prueba t, para una hipótesis nula planteada como la media igual a 0 y lo contrario en la hipótesis alternativa, con una significación mayor que 0.05 con un nivel de confianza del 95%. La prueba de Chi-cuadrado se utilizó para evaluar la hipótesis nula de que la desviación estándar es igual a 1 versus la hipótesis alternativa de que la desviación es distinta de 1, y para todas las campañas se rechazó la hipótesis nula con un valor de probabilidad igual a 0 con un nivel de confianza del 95%. El error cuadrático medio se aproxima a la desviación estándar de los valores muestreados. En la Tabla 3.37 se pueden observar los valores de los parámetros analizados y en los Anexos del 35 al 39 se muestran los gráficos de dispersión de los valores estimados contra los reales y de los residuos, donde se comprueba lo explicado anteriormente.

Tabla 3.37 – Criterios de validación de los modelos ajustados para la intensidad de *Alternaria solani* Sor. **Fuente:** Elaboración Propia.

Campaña	Modelo	Correlación Pearson	MEE	Prueba t	Desviación estándar	ECM
03_04	Exponencial	0.938	-0.0366	0.941	3.1799	9.8724
04_05	Gaussiano	0.903	-0.0066	0.993	4.5919	20.5719
05_06	Esférico	0.931	0.0393	0.940	3.2609	10.3628
06_07	Gaussiano	0.929	-0.0365	0.954	4.0843	16.2945
07_08	Gaussiano	0.939	0.1017	0.852	3.5081	12.0239

El análisis realizado para la validación de los modelos para la variable intensidad de *Bemisia tabaci* Guen. permitió comprobar que los datos interpolados tienen una buena correlación con los observados al encontrarse este valor entre 0.90 y 0.97 para cada una de las campañas; la media de los residuos está próxima a cero, lo que se comprobó con la prueba t al aceptarse la hipótesis nula con un nivel de confianza del 95%. Con la prueba de Chi-cuadrado se determinó

que la desviación estándar de los residuos es distinta de 1 con un nivel de confianza del 95%, pero para esta variable es válido destacar que la desviación de los residuos fue aproximadamente igual a 0; y el error cuadrático medio también se aproximó a 0. En la Tabla 3.38 se pueden observar los valores de los parámetros analizados y en los Anexos del 40 al 44 se muestran los gráficos de dispersión de los valores estimados contra los reales y de los residuos, donde se comprueba lo explicado.

Tabla 3.38 – Criterios de validación de los modelos ajustados para la intensidad de *Bemisia tabaci* Guen. **Fuente:** Elaboración Propia.

Campaña	Modelo	Correlación Pearson	MEE	Prueba t	Desviación estándar	ECM
03_04	Gaussiano	0.907	-0.00016	0.974	0.0312	0.0009
04_05	Gaussiano	0.967	0.00026	0.961	0.0338	0.0011
05_06	Cuadrático	0.923	0.00002	0.997	0.0329	0.0010
06_07	Cuadrático	0.908	-0.00011	0.989	0.0529	0.0027
07_08	Esférico	0.906	-0.00041	0.963	0.0571	0.0032

A partir del análisis de la validación de los modelos ajustados para la variable distribución de la enfermedad viral se comprobó que los datos estimados tenían una buena correlación con los muestreados al ser este valor mayor que 0.89, y los modelos de las dos primeras campañas fueron los de mayor correlación. Con la prueba t se comprobó una media de los residuos igual a 0 al aceptarse la hipótesis nula con un nivel de confianza del 95%, para cada una de las campañas. Según la prueba de Chi-cuadrado se rechazó la hipótesis nula de que la desviación estándar es igual a 1 con un nivel de confianza del 95%, pero en todas las campañas la desviación obtenida y el error cuadrático medio fue próximo a 0 excepto en la última campaña. En la Tabla 3.39 se ofrecen los valores de los parámetros analizados y en los Anexos del 45 al 49 se muestran los gráficos de dispersión de los valores estimados contra los reales y de los residuos, donde se verifica lo explicado anteriormente.

Tabla 3.39 – Criterios de validación de los modelos ajustados para la distribución de la enfermedad viral. **Fuente:** Elaboración Propia.

Campaña	Modelo	Correlación Pearson	MEE	Desviación estándar	Prueba t	ECM
03_04	Cuadrático	0.993	0.00037	0.0208	0.922	0.0004
04_05	Esférico	0.998	-0.00026	0.0105	0.891	0.0001
05_06	Cuadrático	0.935	0.0218	1.8067	0.940	3.1809
06_07	Gaussiano	0.964	0.0014	1.4691	0.996	2.0913

07_08	Esférico	0.896	0.0021	3.7223	0.997	13.5256
-------	----------	-------	--------	--------	-------	---------

Se puede observar que todos los modelos obtenidos, como los de mejor ajuste, para cada agente nocivo y campaña fueron validados con correlaciones mayores que 0.89; con media de los errores próximas a cero, lo cual se comprobó estadísticamente con la prueba t de Student; y el error cuadrático medio osciló entre 0 y 20; siendo los mejores resultados para la variable intensidad de *Bemisia tabaci Guen.*, lo que puede estar relacionado con el hecho de que esta presentó un menor error o efecto pepita, es decir tuvo una mayor continuidad en el origen; además esta última variable fue la que se obtuvo por conteos directos, cuestión que debe observarse para futuros trabajos.

Aunque los análisis geoestadísticos para conocer las estimaciones espaciales de agentes nocivos de las plantas se han utilizado desde hace varios años en diferentes países como los trabajos de Ramírez *et al.* (2002) para la distribución espacial de los huevos del mosquito verde *Jacobiasca líbica* en viñedo, así como para un lepidóptero en algodón (Tannure & Mazza, 2004), no se conocen resultados de este tipo en Cuba, donde si se ha empleado esta herramienta en el campo de la geología (Cuador, 2005). Los presentes resultados constituyen junto a los de González (2010), los primero en el campo de la Sanidad Vegetal y son un punto de partida para lograr las simulaciones que permitan hacer advertencias y pronósticos espaciales de los agentes nocivos de las plantas.

Los resultados obtenidos en esta investigación pueden utilizarse como apoyo al servicio de pronóstico fitosanitario que realiza la EPP de Lajas, los cuales pueden perfeccionarse con la información de los registros de los agentes nocivos y el resto de los estudios que se hagan en años venideros. La información existente en las EPP del Sistema Estatal de Protección de Plantas en el país constituye una gran oportunidad para realizar estudios como éste y perfeccionar los servicios de la Sanidad Vegetal en Cuba.

CONCLUSIONES GENERALES

Conclusiones Generales

1. El análisis exploratorio de los datos permitió comprobar el cumplimiento de los requisitos geoestadísticos de las tres variables en estudio, para lo que fue necesario desclusterizar la variable intensidad de *Bemisia tabaci* Guen. en la campaña 06_07 y la distribución enfermedad viral en la campaña 06_07, y transformar esta última para las campañas 03_04 y 04_05.
2. Las tres variables en cada una de las campañas presentaron anisotropía geométrica y pudieron ajustarse con el menor Criterio de Información de Akaike y coeficientes de determinación mayores que el 70% a diferentes modelos matemáticos: un exponencial, un esférico y tres gaussianos para la variable intensidad de *Alternaria solani* Sor.; dos gaussianos, dos cuadráticos y un esférico para la variable intensidad de *Bemisia tabaci* Guen.; y un gaussiano, dos cuadráticos y dos esféricos para la distribución de la enfermedad viral.
3. Los mapas de estimación obtenidos a partir de los modelos de mejor ajuste para la variable intensidad de *Alternaria solani* Sor. mostraron que la mayoría de los valores oscilan entre 30 y 35%, con la intensidad de *Bemisia tabaci* Guen. se observaron un mayor número de valores entre 0.10 y 0.29 insectos por planta, y la variable distribución del *Virus del encrespamiento amarillo de la hoja del tomate* estuvo principalmente entre 4 y 13%.
4. Los modelos que presentaron un mejor ajuste fueron validados con correlaciones mayores que 0.89; con media de los errores próxima a cero, lo cual se comprobó estadísticamente con la prueba t; y el error cuadrático medio osciló entre 0 y 20, siendo los mejores resultados para la variable intensidad de *Bemisia tabaci* Guen.

RECOMENDACIONES

Recomendaciones

1. Coordinar con la Dirección Fitosanitaria Provincial en Cienfuegos para validar en la práctica, los presentes resultados con respecto a los modelos de mejor ajuste de las variables de los tres agentes nocivos del tomate en la Estación de Protección de Plantas de Lajas.
2. Divulgar los resultados entre técnicos, docentes y científicos, para que se vayan empleando en la toma de decisiones.
3. Continuar profundizando en el uso de la geoestadística para la estimación espacial de agentes nocivos en la Sanidad Vegetal, elaborando una metodología que permita avanzar en este trabajo para esa rama de la agricultura.

BIBLIOGRAFÍA

Bibliografía

- Acevedo, D. C., Álvarez Sánchez, M. E., Hernández Acosta, E., Maldonado Torres, R., Pérez Grajales, M. & Castro Brindis, R. (2008). Variabilidad espacial de propiedades químicas del suelo y su uso en el diseño de experimentos. *Terra Latinoamericana*, 26, 317-324.
- Alfaro, M. A. (2008). El krigeado simple y el krigeado ordinario. Chile: Universidad de Santiago de Chile.
- Amador, M. D., & Escobedo Rosales, J. S. (2004). Distribuciones espaciales de malezas y rendimiento de maíz en labranza reducida y convencional. *Revista Fitotecnia Mexicana*, 27, 223-231.
- Armstrong, M. (1998). *Basic linear geostatistics*. Germany: Springer-Verlag, Berlin Heidelberg.
- Arrieta, J. M., Copote, C., & Sánchez, C. (2006). Estudio geoestadístico de la dinámica de poblaciones de *Spermacoce tenuior* L. y *Digitaria longiflora* (Retz.) Pers., arvenses del sistema rotacional maíz-soya de la altillanura colombiana. *Revista Corpoica-Ciencia y Tecnología Agropecuaria*, 7, 80-88.
- Barbosa, P. M., Caldeira Monteiro, R., & Cristina Corsi, A. (2002). Introdução à confecção de mapas pelo software Surfer® (pp. 22). UNESP/campus de Rio Claro: Departamento de Geologia Aplicada - IGCE
- Barnes, R. (2003). Variogram tutorial. Retrieved from <http://www.goldensoftware.com/variogramTutorial.pdf>
- Bellehumeur, C., Marcotte, D., & Legendre, P. (2000). Estimation of regionalized phenomena by geostatistical methods: lake acidity on the Canadian Shield. *Environmental Geology* 39, 211-220.
- Bohling, G. (2005). Introduction to geostatistics and variogram analysis. 20. Retrieved from <http://www.ecst.csuchico.edu/~juliano/csci693/Presentations/2008w/Materials/Kalkundrikar/DOCS/Variograms.pdf>
- Bohling, G. (2007). S-GeMS tutorial notes. *Hydrogeophysics: Theory, Methods, and Modeling* 26. Retrieved from <http://people.ku.edu/~gbohling/BoiseGeostat/SGeMSTutorial.pdf>
- Bongiovanni, R. (2002). Econometría Espacial: una herramienta clave para el manejo sitio-específico de insumos. In Tercer Taller Internacional de Agricultura de Precisión del Cono Sur de América (Ed.), (pp. 18). Argentina: Programa Cooperativo para el Desarrollo Tecnológico Agroalimentario y Agroindustrial del Cono Sur.

- Cañada, M. R. (2005). Aplicación de la geoestadística al estudio de la variabilidad espacial del ozono en los veranos de la comunidad de Madrid. Madrid: Departamento de Geografía, Universidad Autónoma de Madrid.
- Castaño, A. F., & Vergara Elorza, F. (2004). *Simulación Geoestadística aplicada al modelamiento de yacimientos de petróleo*. Ingeniero de Petróleo, Univeridad Nacional de Colombia, Sede Medellín, Colombia. Retrieved from http://digital.unal.edu.co/dspace/bitstream/10245/1203/1/3474407_15272213_2004.pdf
- Castellanos, L. *et al.* (2005a). Modelación matemática de *Alternaria solani* Sor. en papa en función de las variables meteorológicas y la edad del cultivo. *Fitosanidada*, 9, 27-32.
- Castellanos, L. *et al.* (2005b). Modelación matemática de *Alternaria solani* Sor. en papa en función del tiempo. *Fitosanidada*, 9, 23-26.
- Castellanos, L. *et al.* (2008). El manejo integrado de plagas en la provincia de Cienfuegos In Universo Sur (Ed.).
- Castillo, E. (2005). Capítulo 2: Conceptos Básicos. Retrieved from <http://upcommons.upc.edu/pfc/bitstream/2099.1/3407/5/41239-5.pdf>
- Castro, C. A., Londoño Ciro, L. A. & Valdés Quintero, J. C. (2005). Modelación y simulación computacional usando sistemas de información geográfica con dinámica de sistemas aplicados a fenómenos epidemiológicos. *Revista Facultad de Ingeniería Universidad de Antioquia*, 86-100.
- Chasco, C., & López Hernández, F. A. (2004). Difusión y dinámica temporal de la dependencia espacial (pp. 32): Universidad Autónoma de Madrid, Universidad Politécnica de Cartagena.
- Cheng, T., & Li, P. (2005). Multivariate variogram-based multichannel image texture for image classification (pp. 3). Beijing, P. R. China Institute of Remote Sensing and GIS Peking University.
- Chilès, J. P., & Delfiner, P. (1999). *Geostatistics, modeling spatial uncertainty*. Canada: Interscience Publication.
- CIBA-GEIGY. (1981). *Manual de ensayos de campo en protección vegetal* (2da. ed.). Suiza: Werner Püntener, División Agricultura.
- CNSAV. (2006). Manual de funciones y procedimientos del sistema estatal de protección de plantas para las estaciones territoriales (pp. 83). Ciudad de la Habana, Cuba.

- Cortéz, A., Ovalles, F. A., Rodríguez, M. F., Rey, J. C. & Núñez, M. C. (2005). Análisis Geoestadístico de la variabilidad temporal, a una escala anual y mensual, de parámetros climáticos en un campo experimental, estado Aragua, Venezuela. *Agronomía Trop.*, 55, 327-342.
- Crujeiras, R. M. (2007). Técnicas de Estadística Espacial (pp. 39). Santiago de Compostela: Departamento de Estadística e Investigación Operativa, Universidad de Santiago de Compostela.
- Cuador, J. Q., Quintero Silverio, A., Estévez Cruz, E., & Ramírez Hernández, R. (1997). Elementos de Geoestadística (pp. 40). Cuba: Universidad de Pinar del Río.
- Cuador, J. Q. (2002). Elementos de Geoestadística (pp. 52). Cuba: Universidad de Pinar del Río.
- Cuador, J. Q. (2005). Estudios de Estimación y Simulación Geoestadística para la caracterización de parámetros geólogo-industriales en el Yacimiento Laterítico Punta Gorda. *Minería y Geología*, 21.
- Dafonte, J., Paz González, A., Taboada Castro, M.M. & Rosa Vieira, S. (2001). Variabilidad espacial de la conductividad hidráulica saturada de campo medida con permeámetro Guelph. *Temas de Investigación en Zona no Saturada*, 7. Retrieved from <http://www.unavarra.es/directo/congresos/apoyo/jzns/13.pdf>
- De Souza, L. E. (2002). *Estimativa de incertezas e sua aplicação na classificação de recursos minerais*. Dissertação para obtenção do Título de Mestre em Engenharia Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais (PPGEM), Ministério da Educação e do Desporto, Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Porto Alegre, Brasil.
- Díaz, M. A. (2002). Geoestadística Aplicada. Cuba: Instituto de Geofísica, UNAM, Instituto de Geofísica y Astronomía, CITMA.
- Díaz, M. A., & Casar González, R. (2004). Gesoestadística aplicada. Retrieved from <http://132.248.182.189/cursos/geoest/Presentaciones/2009/>
- Díaz, M. A. (2004). La receta del análisis estructural. Retrieved from <http://132.248.182.189/cursos/geoest/Aplicaciones>
- Durrieu, M., Ruiz, L.A., & Balaguer, A. (2007). Analysis of geostatistical parameters for texture classification of satellite images (pp. 9). Spain: Dept. Cartographic Engineering, Geodesy

- and Photogrammetry, Dept. Applied Mathematics, Polytechnic University of Valencia.
- Echeverría, J. C., Molinero, H. B., Serra, J. A., & Peña Zubiato, C. (1996). Evaluación de recursos naturales con geoestadística y kriging. In IV Jornadas cuidemos nuestro mundo (CNM) para contribuir a la implementación de un modelo ambiental para San Luis (Ed.).
- EPP-Lajas. (2007). Estación de Protección de Plantas. Informe de campaña del cultivo del tomate desde la campaña 2006-2007. Cuba.
- Esquivel, M. A. (2009). La Agricultura de Precisión: una alternativa sostenible en los tiempos de crisis *Evento de Difusión y Sensibilización para Promover la Cooperación en I+D+I con Latinoamérica: "Innovación Sostenible para la Inclusión Social"* (pp. 21). Cuba: Centro Nacional para la Producción de Animales de Laboratorio (CENPALAB).
- Fernández, O., Pérez, R., Gubinelli, A., & Matheus, J. (2007). Influencia de la variabilidad espacial del suelo sobre parámetros de la caña de azúcar (*Saccharum officinarum*) en Monay, Estado Trujillo. *Agricultura Andina*, 13, 39-52.
- Filzmoser, P., & Reimann, C. (2002). Robust Multivariate Methods in Geostatistics. Vienna, Austria: Department of Statistics, Probability Theory, and Actuarial Mathematics, Vienna University of Technology, Geological Survey of Norway.
- Flores, J. G., Mendoza B., M. A., & Aguirre Bravo, C. (2007). Monitoreo de ecosistemas con estrategias geoestadísticas, una aplicación de gran escala en Jalisco, México. *Madera y Bosques*, 13, 97-104.
- Freeman, E. A., & Moisen, G. G. (2006). Evaluating Kriging as a Tool to Improve Moderate Resolution Maps of Forest Biomass (pp. 16). USA: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station, Forestry Sciences Laboratory.
- Freund, J. E. (1983). *Estadística Elemental Moderna* (3ra. ed.). Ciudad de La Habana, Cuba: Editorial Pueblo y Educación.
- Galeana, J. M. (2008). *Estimación del contenido y captura potencial de carbono, su valoración económica, en la cuenca del río Magdalena, Distrito Federal, México*. Licenciado en Geografía, Universidad Nacional Autónoma de México, México. Retrieved from <http://educacionparalaconservacion.conanp.gob.mx/tesis/tesis2008/i1.pdf>
- Gallardo, A. (2008). Métodos Geoestadísticos para el análisis de datos ecológicos espacialmente explícitos *Ecología Espacial* (pp. 215-272). España. Retrieved from <http://www.escet.urjc.es/biodiversos/espainvestigacion/intercambio/doc/publicaciones/E>

- García, F. (2009). Fundamentos de geoestadística. Retrieved from <http://webs.uvigo.es/bastante/PDF/GEOESTADISTICA.pdf>
- Genton, M. G. (2000). The correlation structure of Matheron's classical variogram estimator under elliptically contoured distributions. *Mathematical Geology*, 32, 127-137.
- Giraldo, R., Walberto Troncoso, M. P., & Méndez, N. (2000). Geoestadística: una herramienta para la modelación en estuarios. *Rev. Acad. Colomb. Cienc.*, 24, 20-72.
- Giraldo, R. (2005). Introducción a la geoestadística. Teoría y Aplicación. Facultad de Ciencias Departamento de Estadística, Universidad Nacional de Colombia (Ed.) Retrieved from http://www.reddeagriculturaprecision.unal.edu.co/doc/Publicaciones/LIBRO_%20DE%20_GEOESTADISTICA-R%20Giraldo.pdf
- Giraldo, R. (2007). Análisis exploratorio de variables regionalizadas con métodos funcionales. *Revista Colombiana de Estadística*, 30, 115-127.
- González, E. M. (2010). *Niveles de incidencia de las principales plagas y enfermedades del tomate (Lycopersicon esculentum Mill.) en relación a las variedades, condiciones meteorológicas, y distribución espacial del cultivo en el territorio de la Estación de Protección de Plantas de Lajas, Cienfuegos*. Máster en Agricultura Sostenible, Universidad de Cienfuegos, Cuba.
- González, J., Guerra, F., & Gómez, H. (2007). Conceptos básicos de geoestadística en geografía y ciencias de la tierra: manejo y aplicación. *Geoenseñanza*, 12, 81-90.
- Guerra, F., Gómez, H., Gonzáles, J., & Zambrano, Z. (2006). Uso actual de métodos y técnicas para el estudio de la precipitación incluyendo plataformas SIG. *Geoenseñanza*, 11, 97-106.
- Henríquez, C., Killorn, R., Bertsch, F., & Sancho, F. (2005). La geoestadística en el estudio de la variación espacial de la fertilidad del suelo mediante el uso del interpolador kriging. *Agronomía Costarricense*, 29, 73-81.
- Hernández, P. M., Hernández Piedra, P. L., Díaz Suárez, J., Zamora Hernández, Y., & Dopico Valdés, Y. (2006). Obtención del mapa de rendimiento georreferenciado del cultivo de la papa mediante el empleo de técnicas de agricultura de precisión. *Revista Ciencias Técnicas Agropecuarias*, 15, 37-41.
- INISAV. (1979). Metodología de señalización y pronóstico de plagas y enfermedades en los

cultivos. Cuba: MINAGRI.

- Interian, S., & Álvarez Portal, R. (2005). Algunas consideraciones sobre la geomática y su papel en la agricultura de precisión. Retrieved from http://www.mappinginteractivo.com/plantilla-ante.asp?id_articulo=903
- Interian, S., & Álvarez Portal, R. (Ed.). (2008). *Sistema digital de información georreferenciada para la agricultura urbana de un municipio de la capital cubana*. Cuba: Empresa de Proyectos Agropecuarios Ciudad Habana del Ministerio de la Agricultura de Cuba.
- Izquierdo, T., & Márquez, A. (2007). Estudio comparativo de diferentes métodos de interpolación para la realización de mapas de precipitación en la isla de la Gomera (Islas Canarias): Evaluación de la incorporación de la altura. *Geogaceta*, 42, 131-134.
- Köhn, J., Kruse, E. E. & Santos, J. E. . (2001). Transporte de cloruro en acuíferos aluviales. (Universidad Nacional de La Plata, Argentina), 7. Retrieved from http://www.math.purdue.edu/~santos/papers/contaminant_transport/cuba.pdf
- León, A., Pino, M., González, C., & del Pozo, E. (2000). Evaluación comparativa de fitófagos y enemigos naturales en policultivo tomate-maíz. *Cultivos Tropicales*, 21, 53-60.
- Lerch, G. (1977). *La experimentación en las ciencias biológicas y agrícolas* (1ra. ed.). La Habana, Cuba: Editorial Científico-Técnica.
- MapInfo. (2007). MapInfo Professional (Version 9.0). US: LizardTech and/or the university of California
- Martínez, J. (2009). Un análisis de la variabilidad espacial: aplicación a variables edáficas. Salamanca: Departamento de Geografía, Universidad de Salamanca.
- Matheron, G. (2005). Curso de Geoestadística. Paris: Centro de Geoestadística de la Escuela de Minas.
- Méndez, J. (2008). *Modelación de la distribución espacial de la precipitación en el Valle de la Ciudad de México usando técnicas geoestadísticas* Máster en Ciencias, Institución de Enseñanza e Investigación en Ciencias Agrícolas, Colegio de Postgraduados, México. Retrieved from <http://132.248.182.189/mdiaz/Tesis/2008/>
- Mezher, R., & Mercuri, P. (2009). Análisis geoestadístico de la distribución de eventos de granizo en Argentina. Argentina: Instituto de Clima y Agua, Centro de Investigaciones de Recursos Naturales, Instituto Nacional de Tecnología Agropecuaria.

- MINAGRI. (1978). Sistema de registro e información estadística para el pronóstico de las principales plagas y enfermedades de importancia económica. Instrucciones Metodológicas para los modelos. *Sección de Bioestadística*. Cuba: Departamento de Control y Servicios Técnicos. Dirección General de Sanidad Vegetal.
- Molinero, L. M. (2003). ¿Y si los datos no siguen una distribución normal? (pp. 6). España: Asociación de la Sociedad Española de Hipertensión, Liga Española para la lucha contra la Hipertensión Arterial.
- Moral, F. J. (2004). Aplicación de la geoestadística en las ciencias ambientales. *Revista Científica y Técnica de Ecología y Medio Ambiente*, XIII.
- Moral, F. J., Rodríguez Bernabé, J. A., Arranz Romero, A., De la Cruz Blanco, J. I., & Honorio Guisado, F. (2004). Técnicas geoestadísticas aplicadas al análisis de la distribución de capturas de *Helicoverpa armigera* (Hübner) (Lepidoptera: Noctuidae) mediante trampas con feromonas sexuales en una plantación de tomate. *Bol. San. Veg. Plagas*, 733-744.
- Moreno, J. L. (2009). Introducción a la geoestadística y su aplicación. Retrieved from http://www.chapingo.mx/dicifo/tesislic/2009/moreno_lopez_jose_luis_2009.pdf
- Nicolás, H. (2004). *Métodos estadísticos en problemas espaciales*. Máster en Estadística Aplicada, Universidad Nacional de Tucumán, San Miguel de Tucumán. Retrieved from http://ediblio.unsa.edu.ar/42/1/TESIS_FINAL.pdf
- Olea, R. A. (1999). *Geostatistics for engineers and earth scientists*. Lawrence, Kansas, USA: Kluwer Academic Publishers.
- Ortiz, R., & Cobos Gutiérrez, C. (2005). Metodología para la mejora de los levantamientos topográficos asistidos por satélites artificiales (pp. 14). España: Escuela Superior de Ingenieros, Departamento de Ingeniería Gráfica, Universidad de Sevilla.
- Pacheco, P. (2008). *Análisis estadístico de datos de contaminación ambiental del Lago de Valencia*. Máster en Modelos Aleatorios, Universidad Central de Venezuela, Venezuela. Retrieved from http://www.matematica.ciens.ucv.ve/modelos/tesis/MS_PedroPacheco.pdf
- Pérez, A., Obregón Neira, N., & García Cabrejo, O. (2009). Análisis de metodologías geoestadísticas alternativas en la modelación del acuífero Morroa (Sucre-Colombia). *Rev. Fac. Ing. Univ. Antioquia* 63-79.
- Ramírez, C. (2006). *Gestión de plagas con métodos geoestadísticos*. Master en Sistemas de

Información Geográfica, Universidad Politécnica de Cataluña, Cataluña. Retrieved from <http://132.248.182.189/mdiaz/Tesis/2006/Gestindeplagas>

- Ramírez, J. F., González Andújar, J. L., Ocete, R., & López Martínez, M.A. (2002). Descripción geoestadística de la distribución espacial de los huevos del mosquito verde *Jacobiasca lybica* (Bergenin & Zanon) (Homoptera: Cicadellidae) en viñedo: modelación y mapeo. *Bol. San. Veg. Plagas*, 28, 87-95.
- Ramírez, J. F., & Porcayo Camargo, E. (2010). Estudio comparativo de la distribución espacial del muérdago enano (*Arceuthobium sp.*) en la ladera norte del Parque Nacional Nevado de Toluca, México. *Bosque*, 31, 28-38.
- Ribes, M., Bascuñana, M., & Avilla, J. (1998). Estudio de la distribución espacial de *Cydia pomonella* (L.) y *Pandemis heparana* (Denis & Schiffermüller) en Torregrossa (Lleida) mediante métodos geoestadísticos. *Bol. San. Veg. Plagas*, 24, 935-948.
- Rodríguez, J. A., & Grau Corbí, J. M. (2007). El GIS como herramienta en el estudio de la variación espacial del contenido de metales pesados en suelos agrícolas de España. España: Instituto de Investigación y Tecnología Agraria y Alimentaria (INIA).
- Saito, H., & Goovaerts, P. (2003). Selective remediation of contaminated sites using a two-level multiphase strategy and geostatistics. *Environmental Science & Technology*, 37, 1912-1918.
- Schaffrin, B., & Uzun, S. (2008). Surface reconstruction via total least-squares adjustment of the semi-variogram (pp. 8). Columbus: School of Earth Sciences, The Ohio State University.
- Segura, S., Vargas, V., & Galvis, A. (2008). *Metodología geoestadística para proponer estaciones de muestreo en el Río Cauca en el Tramo Salvajina - La Virginia*. Paper presented at the Seminario Internacional La Hidroinformática en la Gestión Integrada de los Recursos Hídricos, Colombia. <http://www.bvsde.paho.org/bvsacd/agua2003/salvaj.pdf>
- Smith, A. (2007). *Caracterización, análisis espacial y manejo integrado del Moho Blanco (Sclerotinia minor Jagger y S. sclerotiorum (Lib.) de Bary) en lechuga batavia (Lactuca sativa L. var. capitata L.) en la vereda La Moya*. Título de Microbiólogo Agrícola y Veterinario, Pontificia Universidad Javeriana, Bogotá. Retrieved from <http://www.javeriana.edu.co/biblos/tesis/ciencias/tesis292.pdf>
- Sopó, G. (2004). *Análisis geoestadístico de la distribución de plagas en el cultivo de mango*.

- Caso de Estudio: Granja Experimental de Chongón (CEDEGE). Título de Ingeniero en Estadística Informática, Escuela Superior Politécnica del Litoral, Guayaquil, Ecuador. Retrieved from <http://192.188.59.56/bitstream/123456789/6092/5/Anal.%2520Geoestadistico%2520de%2520Plagas.pdf>
- Sopó, G., & Guerrero, C. (2009). Geoestadística en la determinación de la distribución de plagas. 7. Retrieved from <http://192.188.59.56/bitstream/123456789/6092/11/Articulo.pdf>
- SPSS. (2009). SPSS for Windows Evaluation (Version 15.0.0). USA.
- Surfer. (2009). Surfer for Windows. Contouring and 3D Surface Mapping Software (Version 9.1.352). Golden CO. USA.
- Tannure, C. L., & Mazza, S. M. (2003). Geoestadística: una apreciación global. Argentina: Universidad Nacional del Nordeste.
- Tannure, C. L., & Mazza, S. M. (2004). Caracterización Geoestadística de la distribución espacial de *Alabama argillacea* Hübner (Lepidoptera: Noctuidae) en el cultivo del algodón (pp. 4). Argentina: Facultad de Ciencias Agrarias, Universidad Nacional del Nordeste.
- Tannure, C. L., Mazza, S. M., Contreras, G. B., Schroeder, J. A., Polak, M. G., & Avanza, M. M. (2008). La geoestadística en el comportamiento de la variabilidad espacial de *Aphis spp.* y *Alabam argillacea* en el cultivo de algodón (pp. 4). Argentina: Facultad de Ciencias Agrarias - UNNE.
- Ulloa, M., Vidal Vázquez, E., Ingaramo, O. E., Morales, L. A., & Paz González, A. (2003). Aplicación de la geoestadística al estudio de las propiedades del suelo (pp. 4). Argentina: Universidad Nacional del Nordeste.
- Usandivaras, J. C. (2006). Introducción a la Geoestadística. Nociones de Geoestadística.
- Valera, A., Coronado Longa, J., & Ferrer Espy, J. (2008). Estudio de la variabilidad espacial del suelo en el centro de producción de ovinos y caprinos, San Juan de los Morros, Estado Guárico. Retrieved from http://investigacion.unerg.edu.ve/ciesa/documents/2003/variabilidad_rumiantes.pdf
- Vázquez, L. L. (2006). *Tendencias y percepciones acerca del manejo de plagas en la producción agraria sostenible*. Paper presented at the Conferencia ofrecida en el XV Congreso Científico del Instituto Nacional de Ciencias Agrícolas (INCA), Ciudad de La

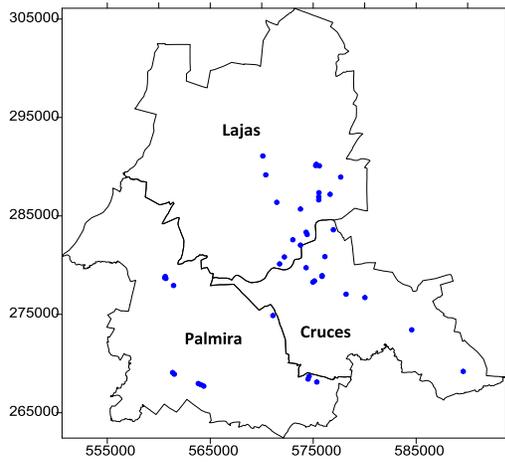
Habana, Cuba.

- Vázquez, L. L. (2009). Adopción de prácticas agroecológicas para el manejo de plagas por los agricultores cubanos. 4. Retrieved from http://www.actaf.co.cu/revistas/revista_ao_95-2010/Rev%202007-2/18-Adopcion%20practicass.pdf
- Vera, A. Rossana, & Guerrero, C. (2009). Análisis geoestadístico de la variabilidad espacial de plagas. Retrieved from <http://www.dspace.espol.edu.ec/bitstream/123456789/319/1/520.pdf>
- Viedma, O., Meliá, J. & Chica-Olmo, M. (1999). Análisis espacial de los efectos del fuego sobre matorrales mediterráneos mediante semivariogramas aplicados a imágenes LANDSAT 5 TM VIII Congreso de Teledetección (pp. 239-243). España: Universidad de Valencia, Universidad de Granada.
- Villatoro, M., Henríquez, C., & Sancho, F. (2008). Comparación de los interpoladores IDW y Kriging en la variación espacial de pH, Ca, Cice y P del suelo. *Agronomía Costarricense* 32, 95-105.
- Ying, Z. (2001). Specification of variogram structures with geometric anisotropy (pp. 11): Stanford Center for Reservoir Forecasting, Department of Petroleum Engineering, Stanford University.

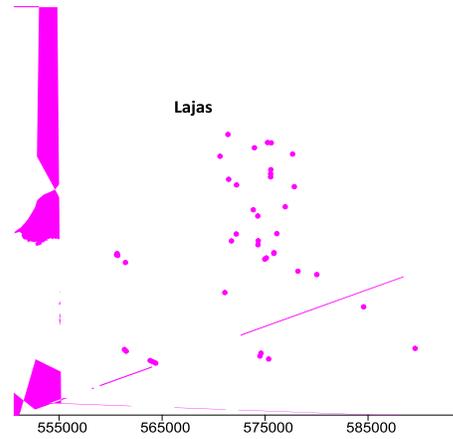
ANEXOS

Anexo 1: Localización espacial de las áreas de tomate de la EPP de Lajas.

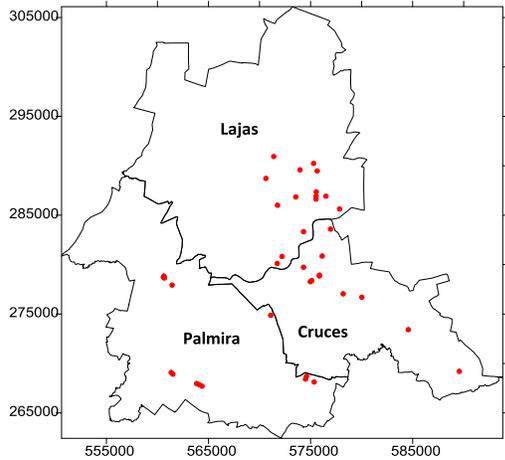
Fuente: Elaboración Propia.



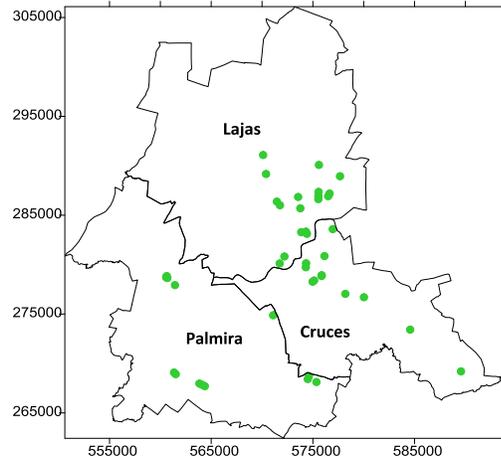
Campaña 03_04



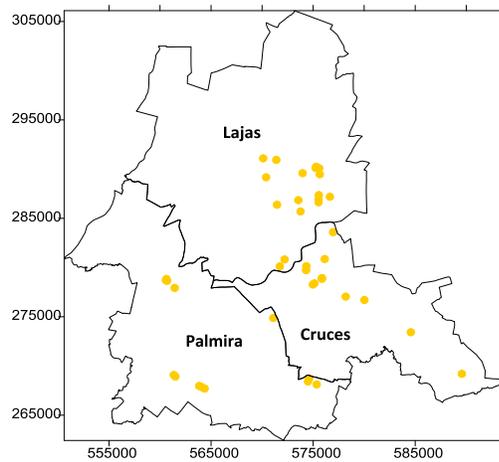
Campaña 04_05



Campaña 05_06

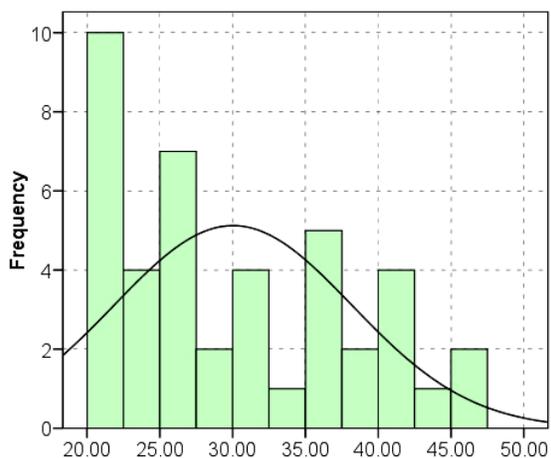


Campaña 06_07

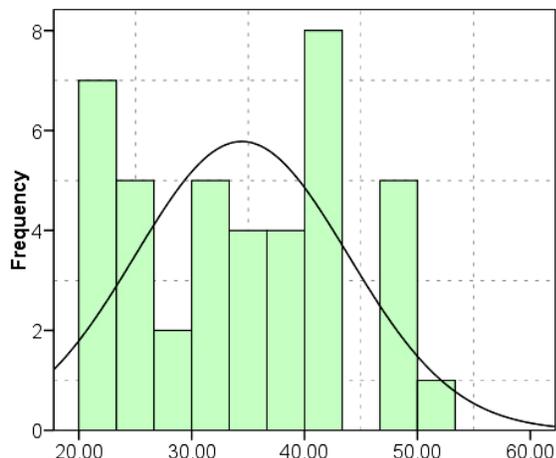


Capaña 07_08

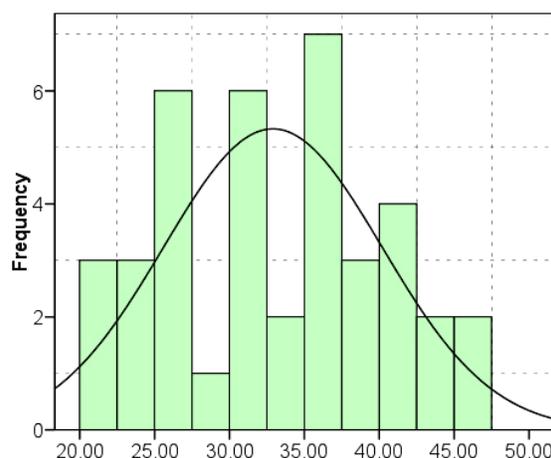
Anexo 2: Histogramas de la intensidad de *Alternaria solani* Sor.. Fuente: Elaboración Propia.



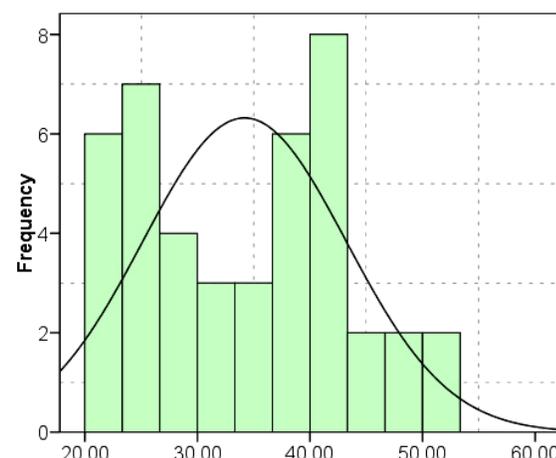
Campaña 03_04



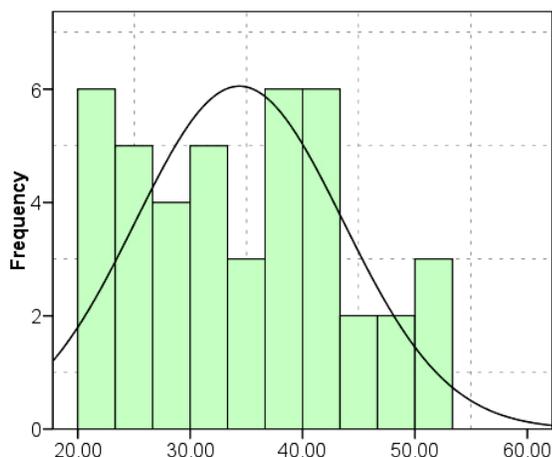
Campaña 04_05



Campaña 05_06

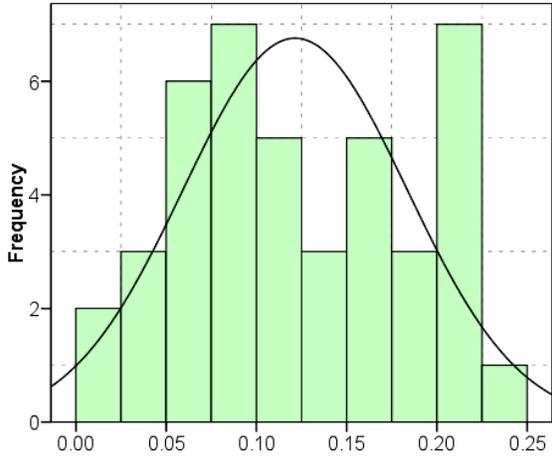


Campaña 06_07

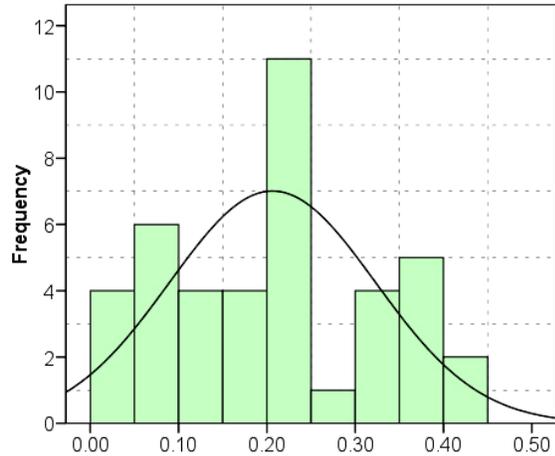


Capaña 07_08

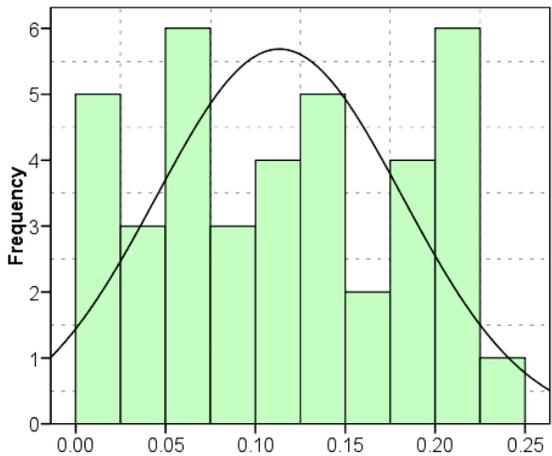
Anexo 3: Histogramas de la intensidad de *Bemisia tabaci* Guen.. Fuente: Elaboración Propia.



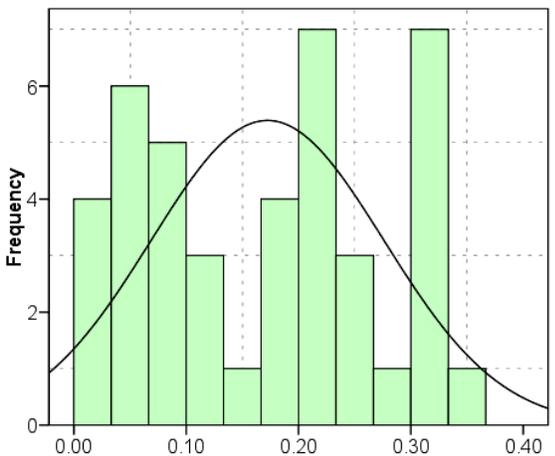
Campaña 03_04



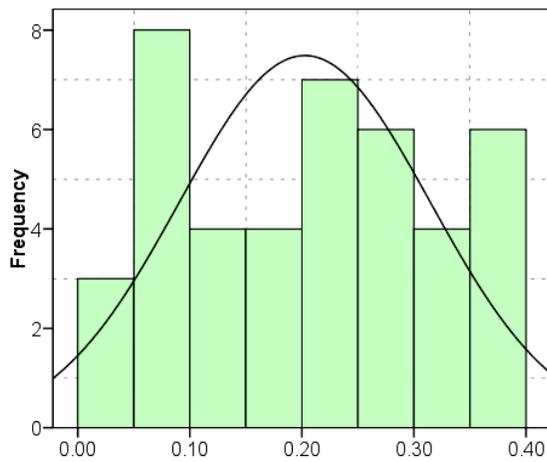
Campaña 04_05



Campaña 05_06

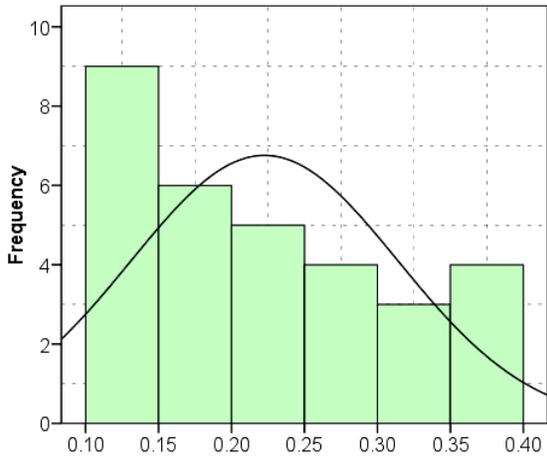


Campaña 06_07

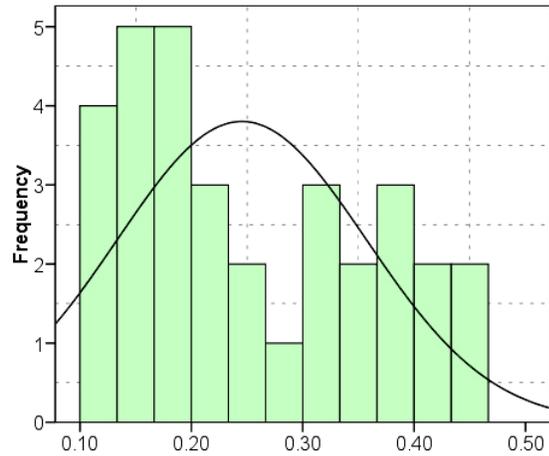


Capaña 07_08

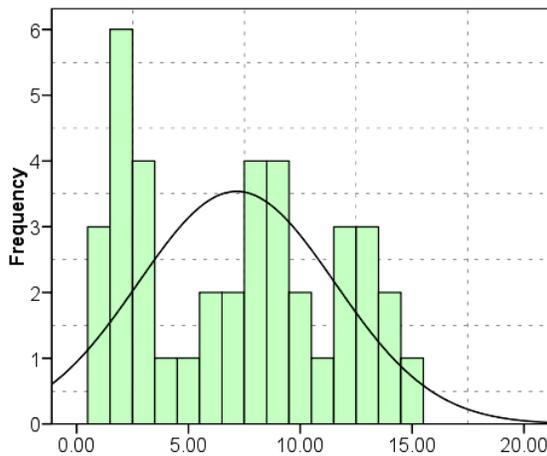
Anexo 4: Histogramas de la distribución de la enfermedad viral. **Fuente:** Elaboración Propia.



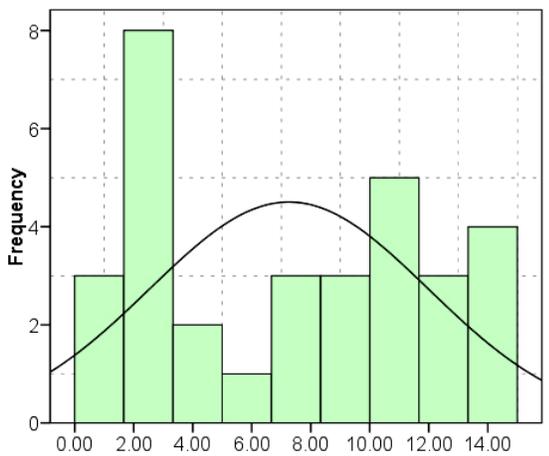
Campaña 03_04



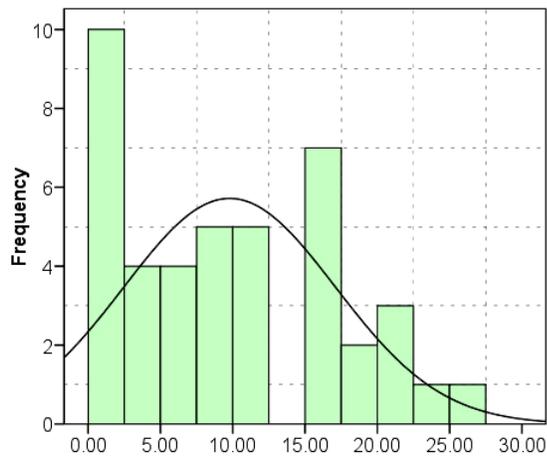
Campaña 04_05



Campaña 05_06



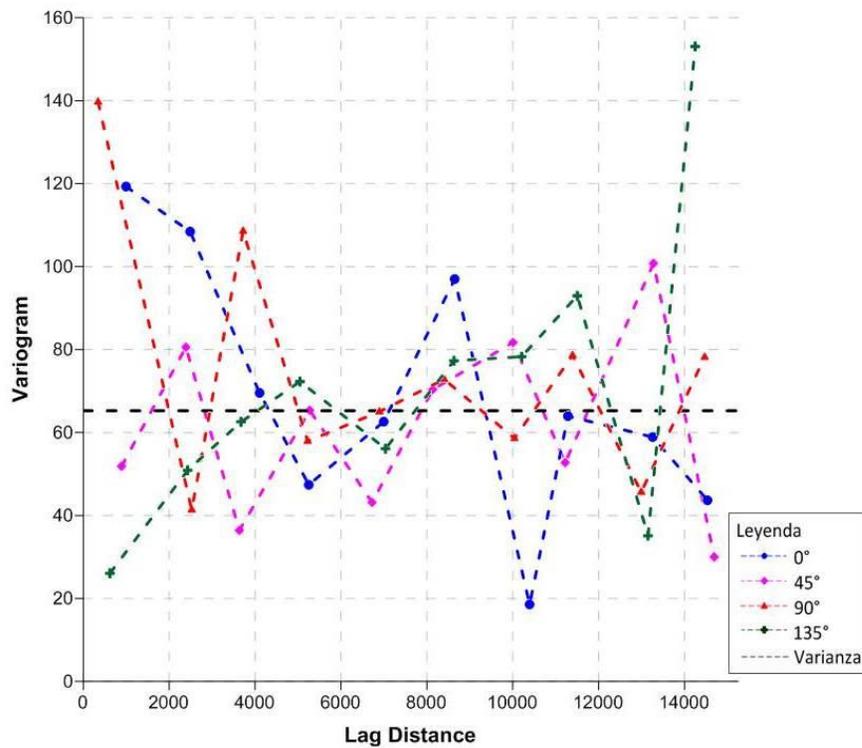
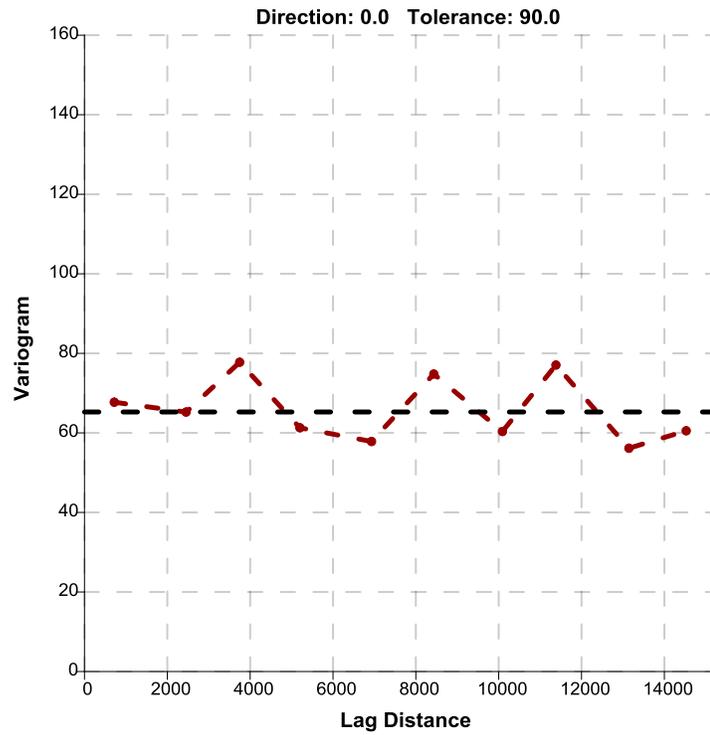
Campaña 06_07



Capaña 07_08

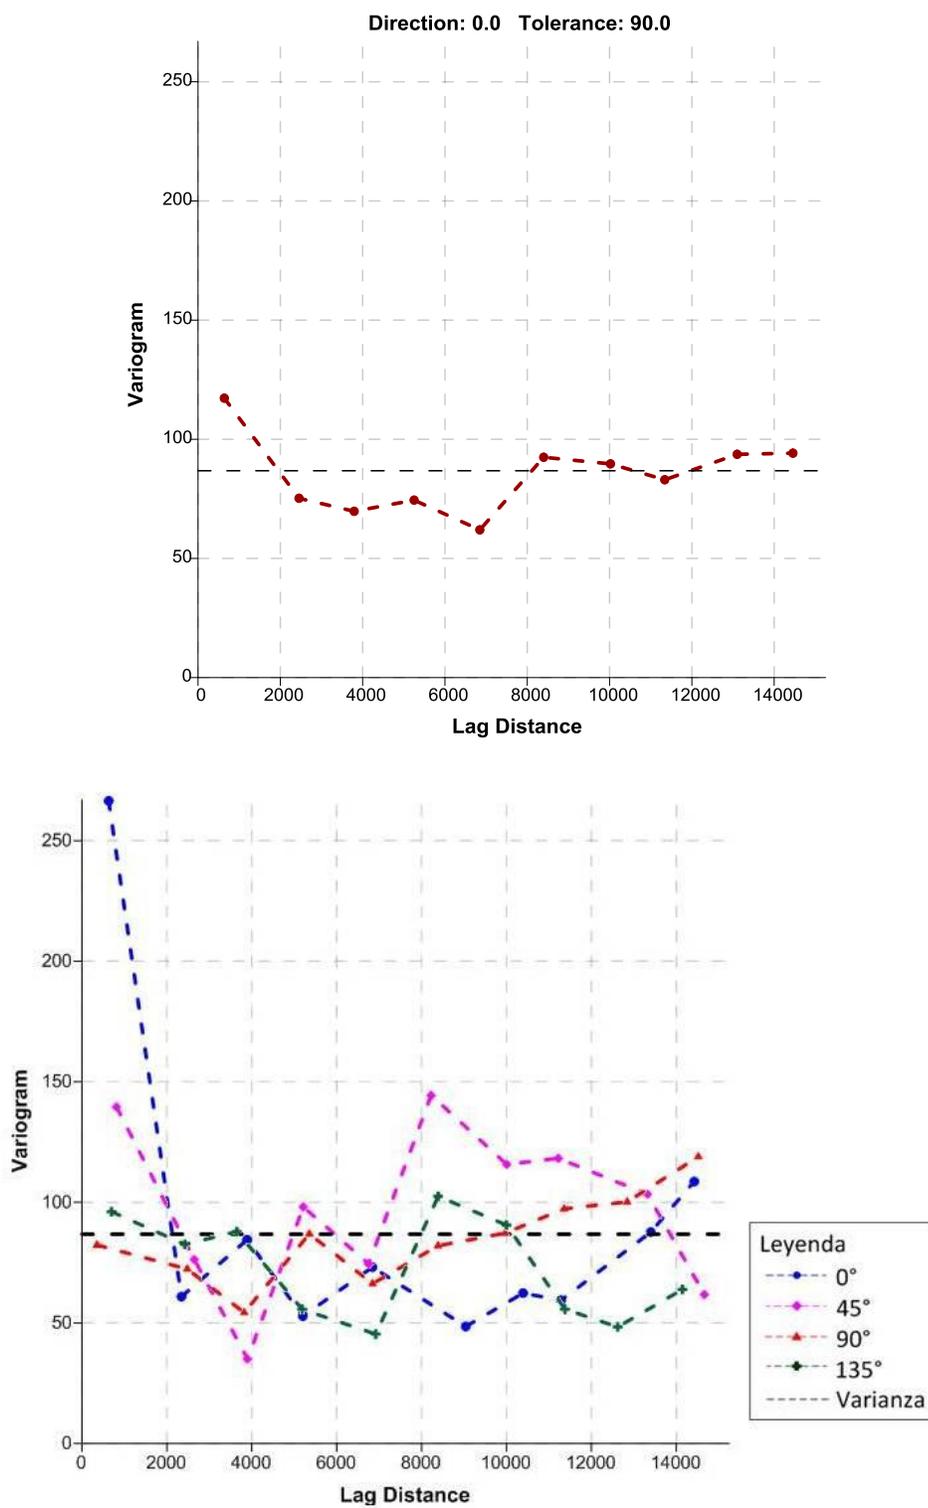
Anexo 5: Semivariogramas de la intensidad de *Alternaria solani* Sor.. en la campaña 03_04.

Fuente: Elaboración Propia.



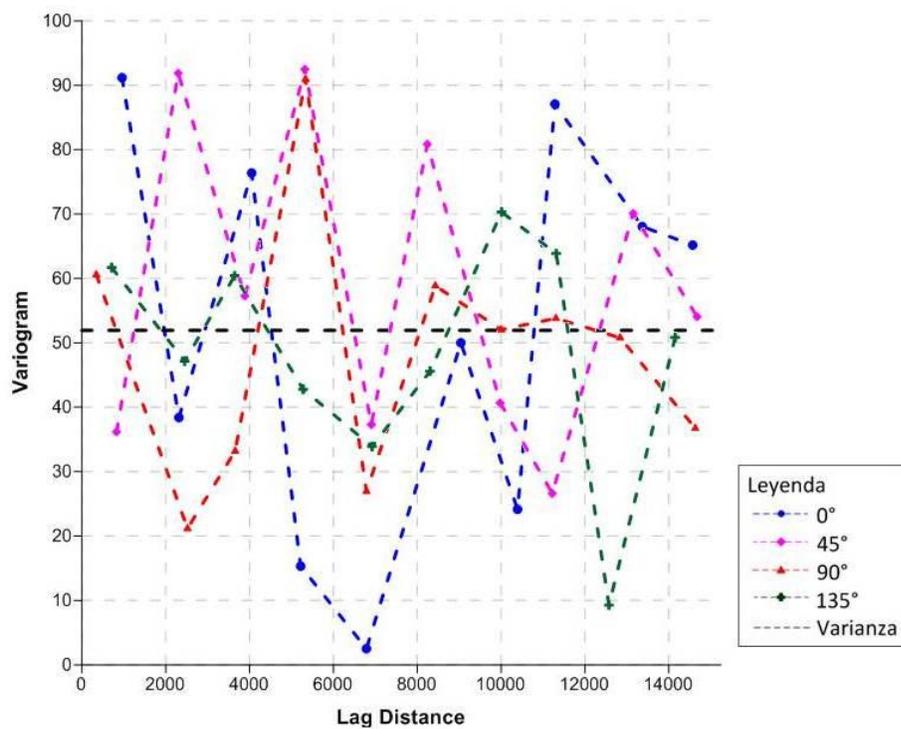
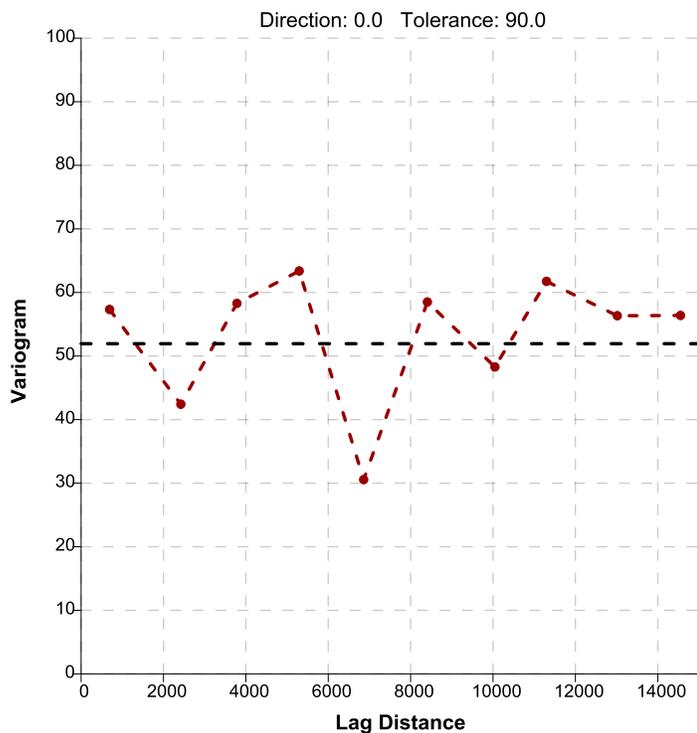
Anexo 6: Semivariogramas de la intensidad de *Alternaria solani* Sor., en la campaña 04_05.

Fuente: Elaboración Propia.



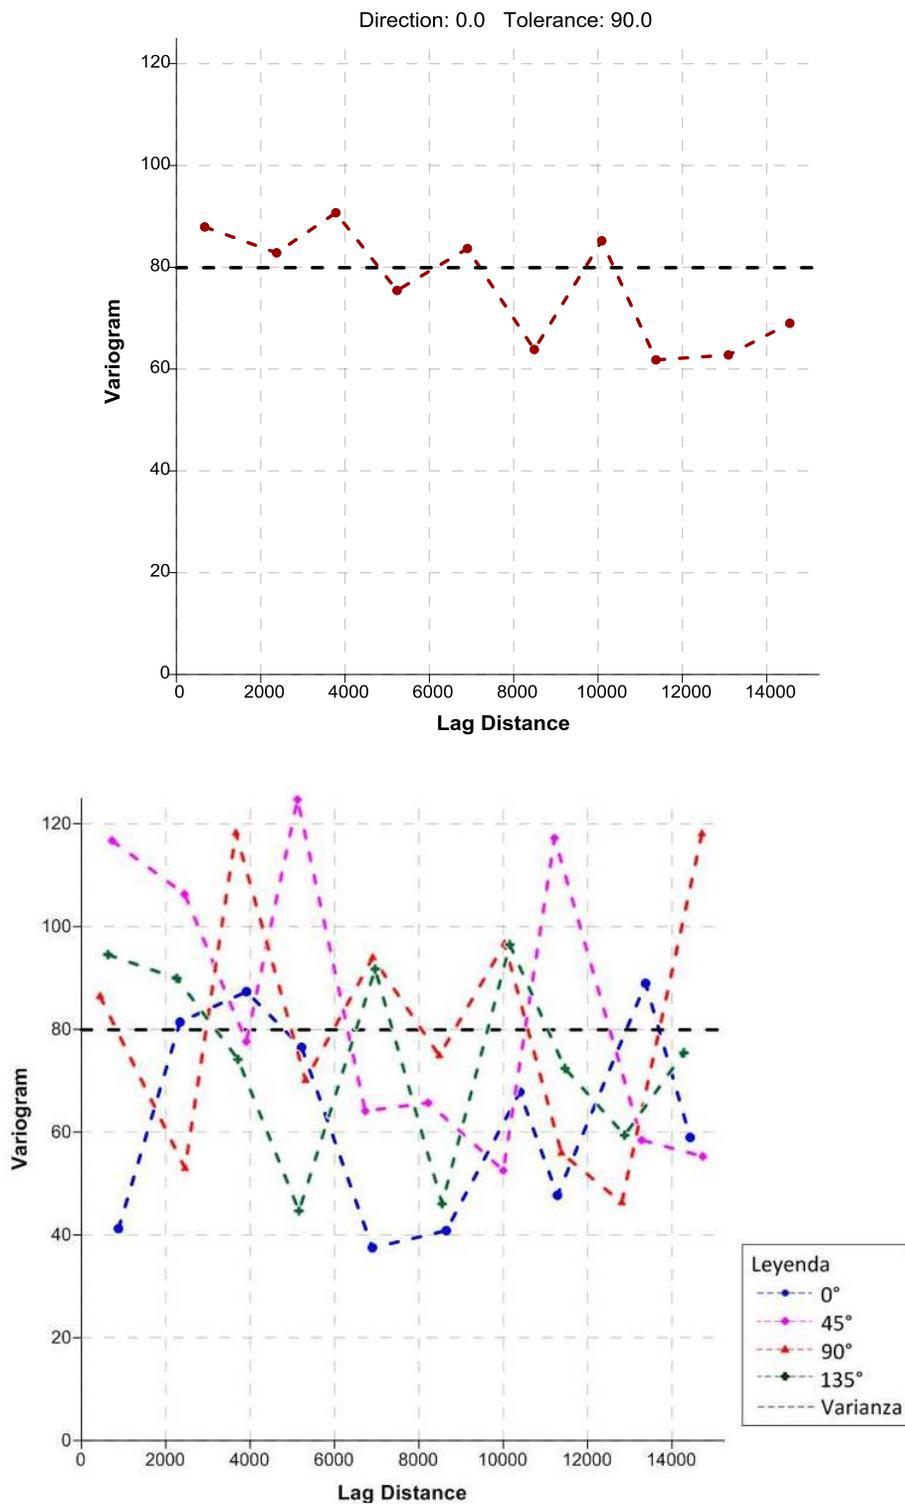
Anexo 7: Semivariogramas de la intensidad de *Alternaria solani* Sor., en la campaña 05_06.

Fuente: Elaboración Propia.



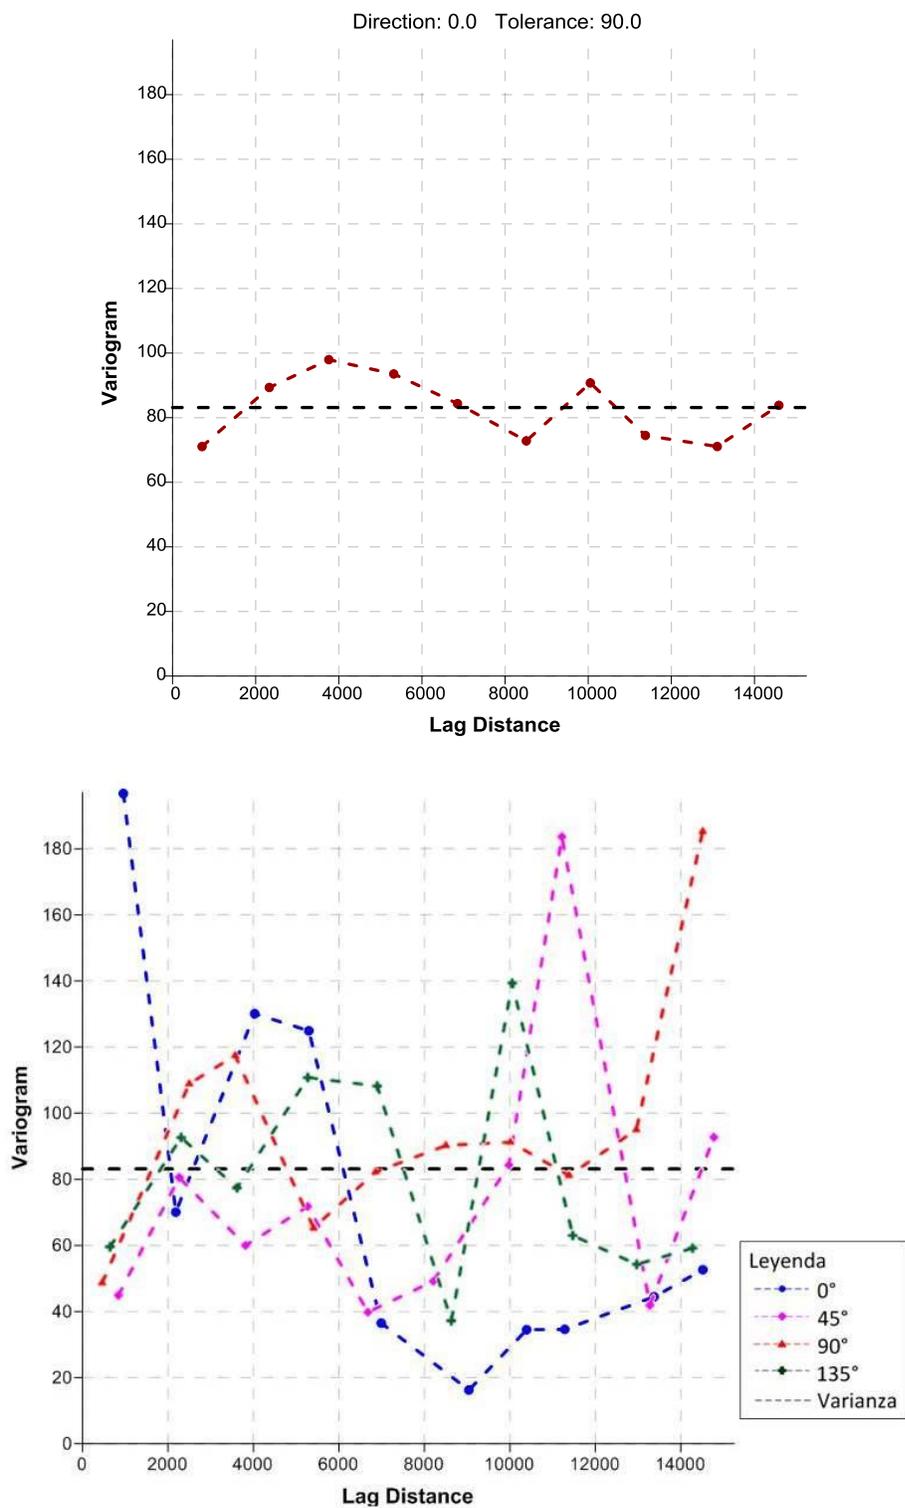
Anexo 8: Semivariogramas de la intensidad de *Alternaria solani* Sor., en la campaña 06_07.

Fuente: Elaboración Propia.



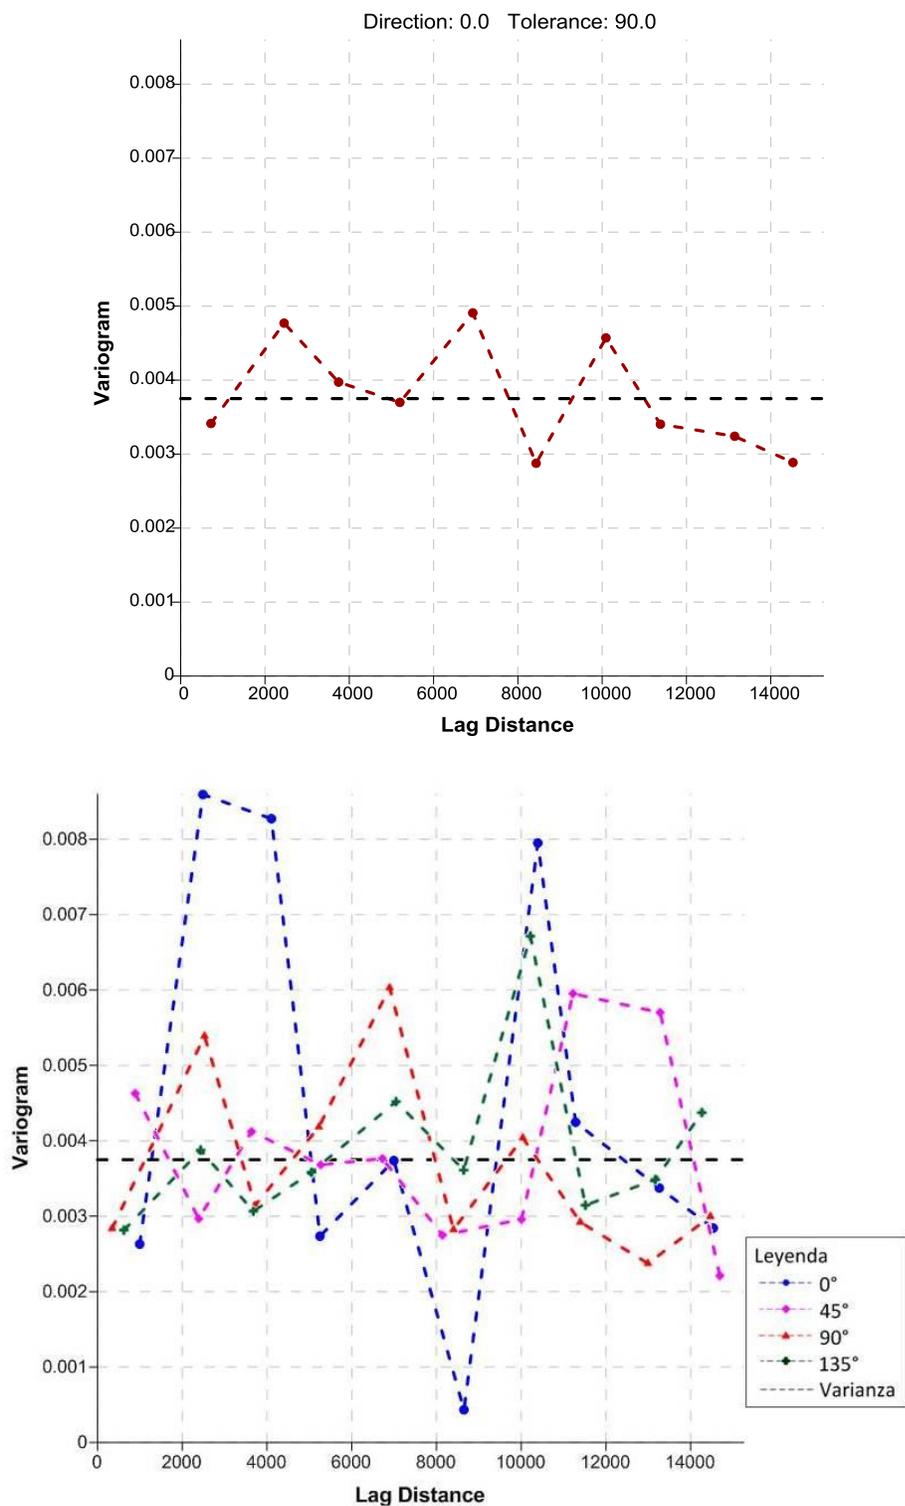
Anexo 9: Semivariogramas de la intensidad de *Alternaria solani* Sor., en la campaña 07_08.

Fuente: Elaboración Propia.



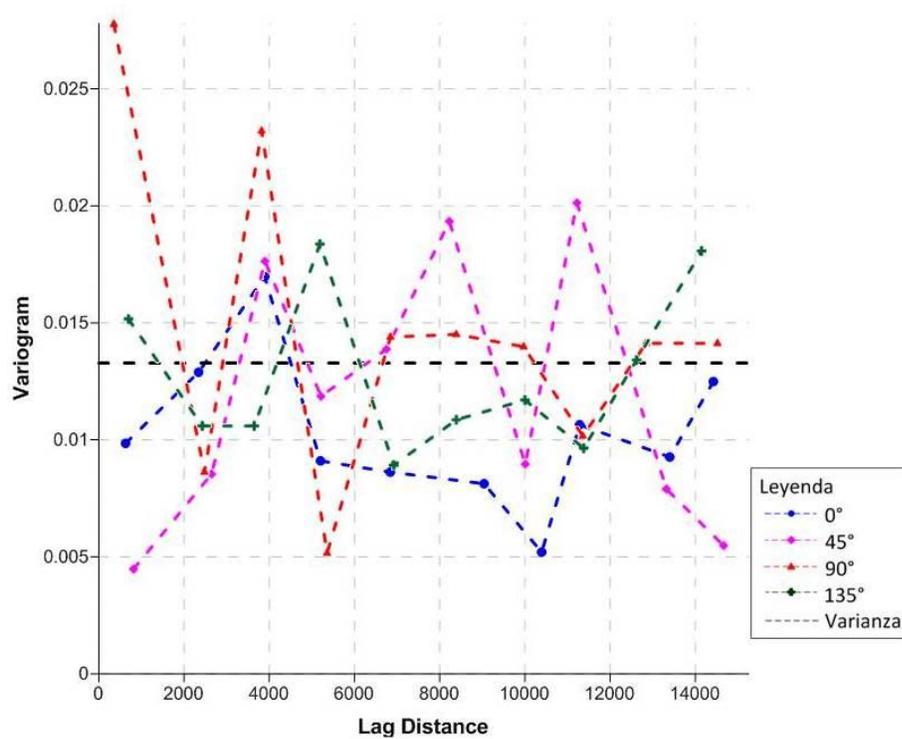
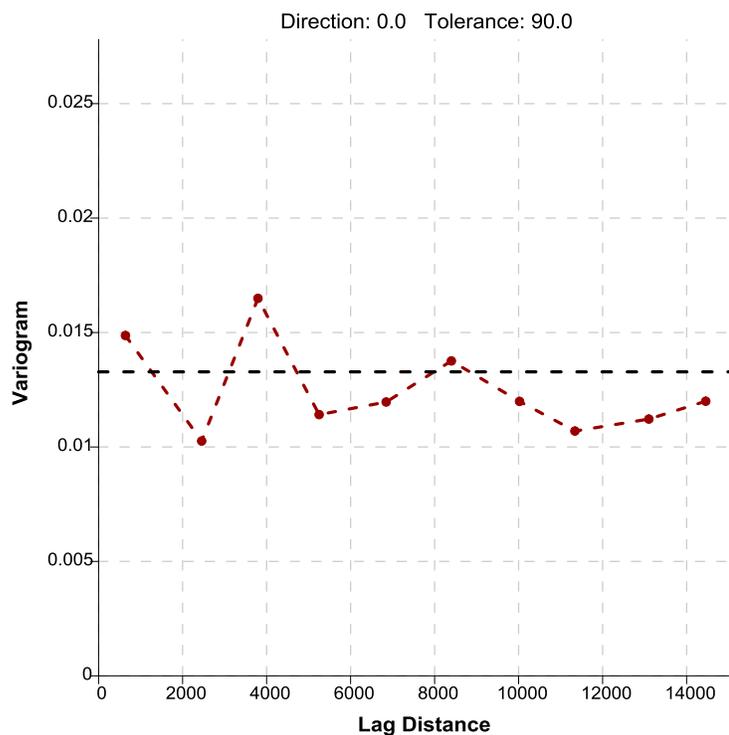
Anexo 10: Semivariogramas de la intensidad de *Bemisia tabaci* Guen. en la campaña 03_04.

Fuente: Elaboración Propia.



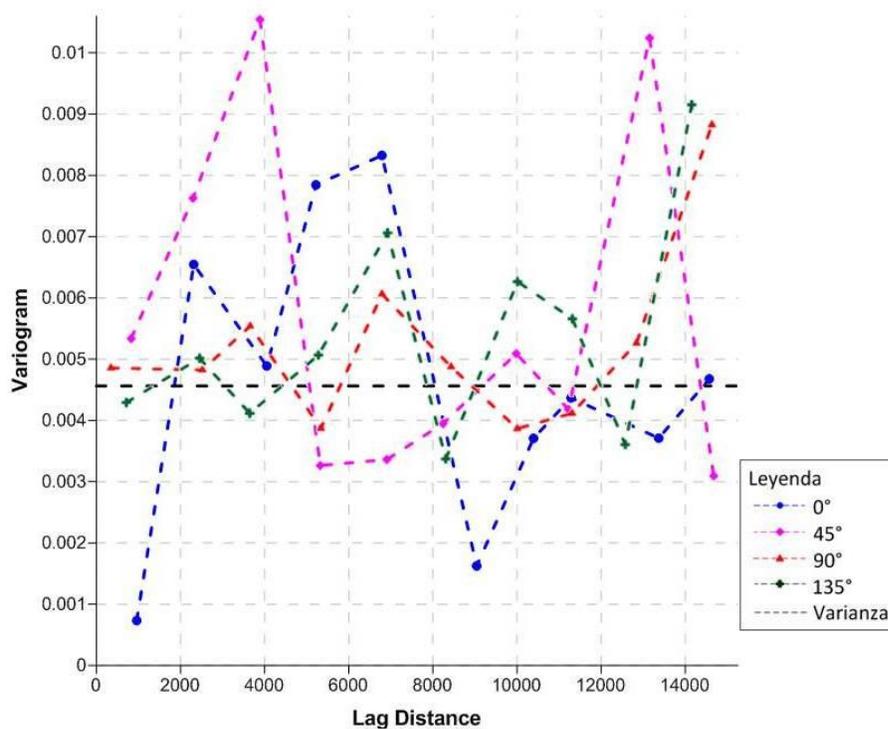
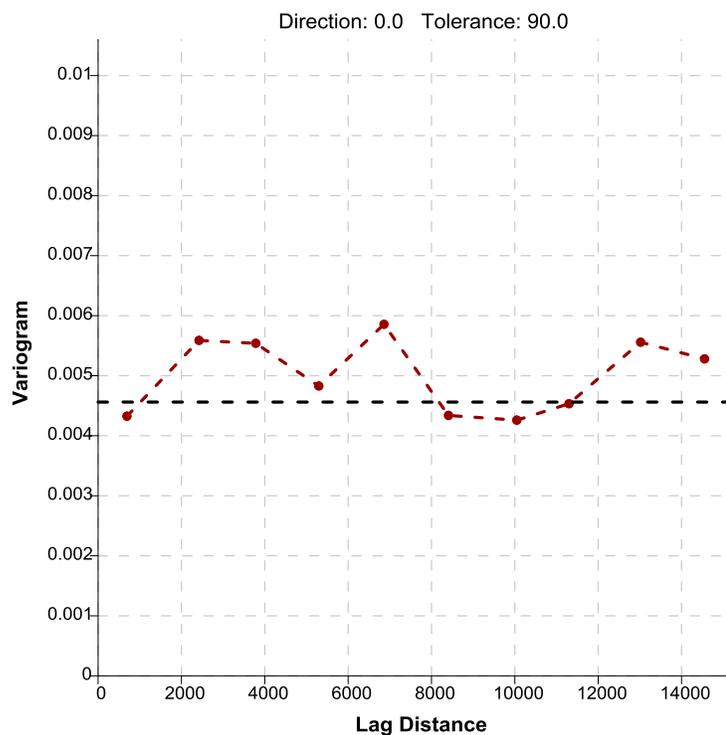
Anexo 11: Semivariogramas de la intensidad de *Bemisia tabaci* Guen. en la campaña 04_05.

Fuente: Elaboración Propia.



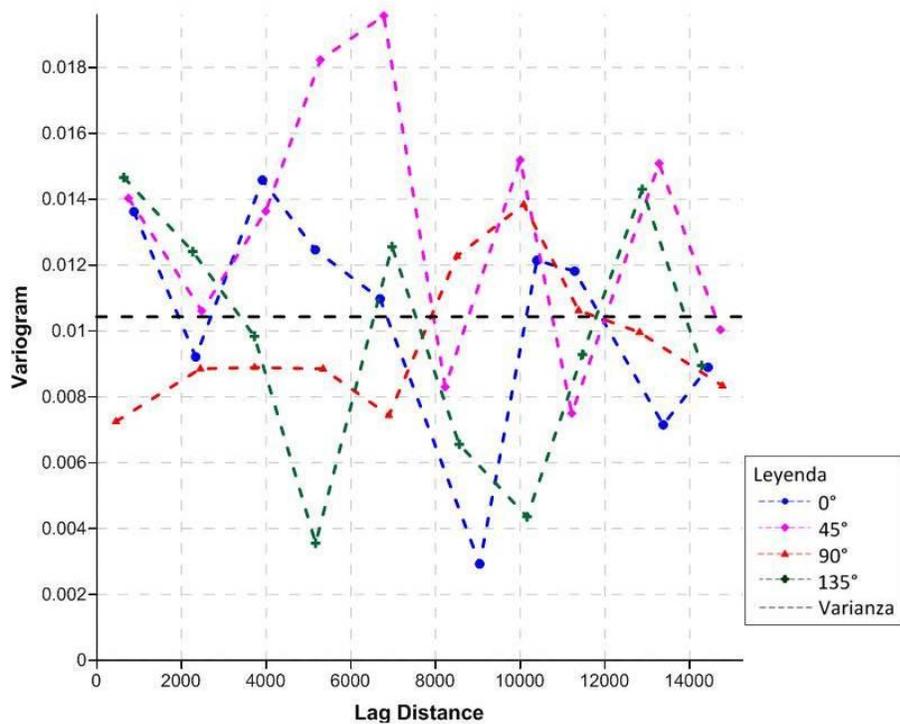
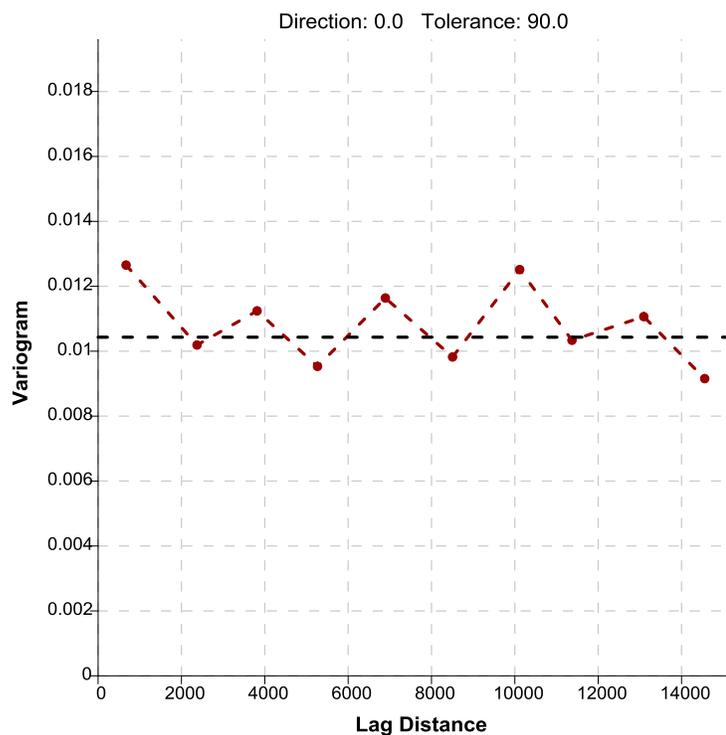
Anexo 12: Semivariogramas de la intensidad de *Bemisia tabaci* Guen. en la campaña 05_06.

Fuente: Elaboración Propia.



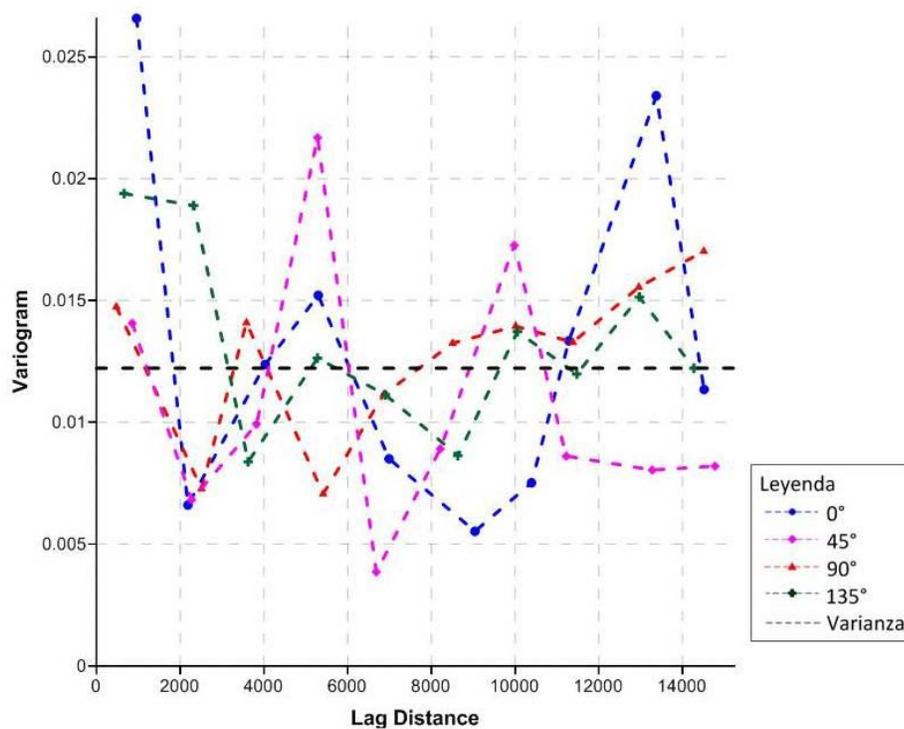
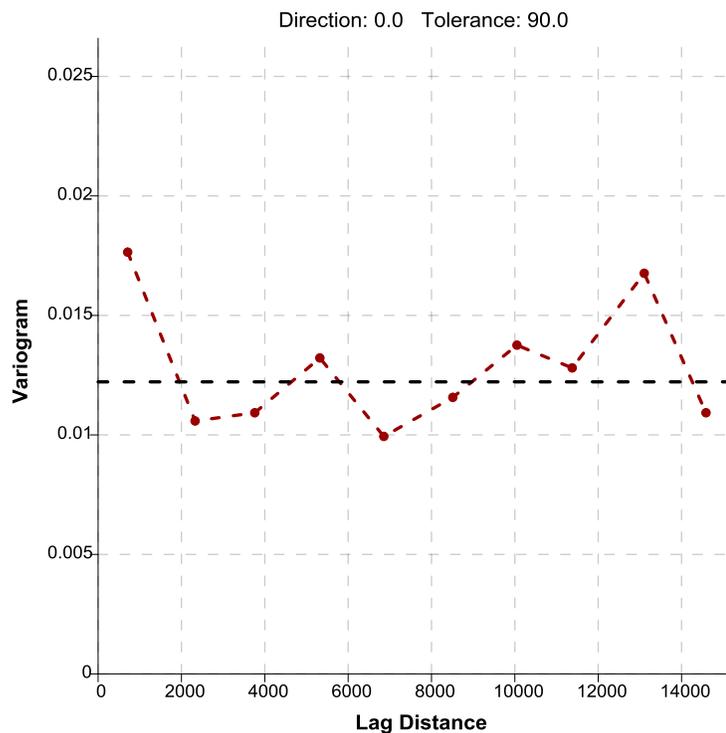
Anexo 13: Semivariogramas de la intensidad de *Bemisia tabaci* Guen. en la campaña 06_07.

Fuente: Elaboración Propia.



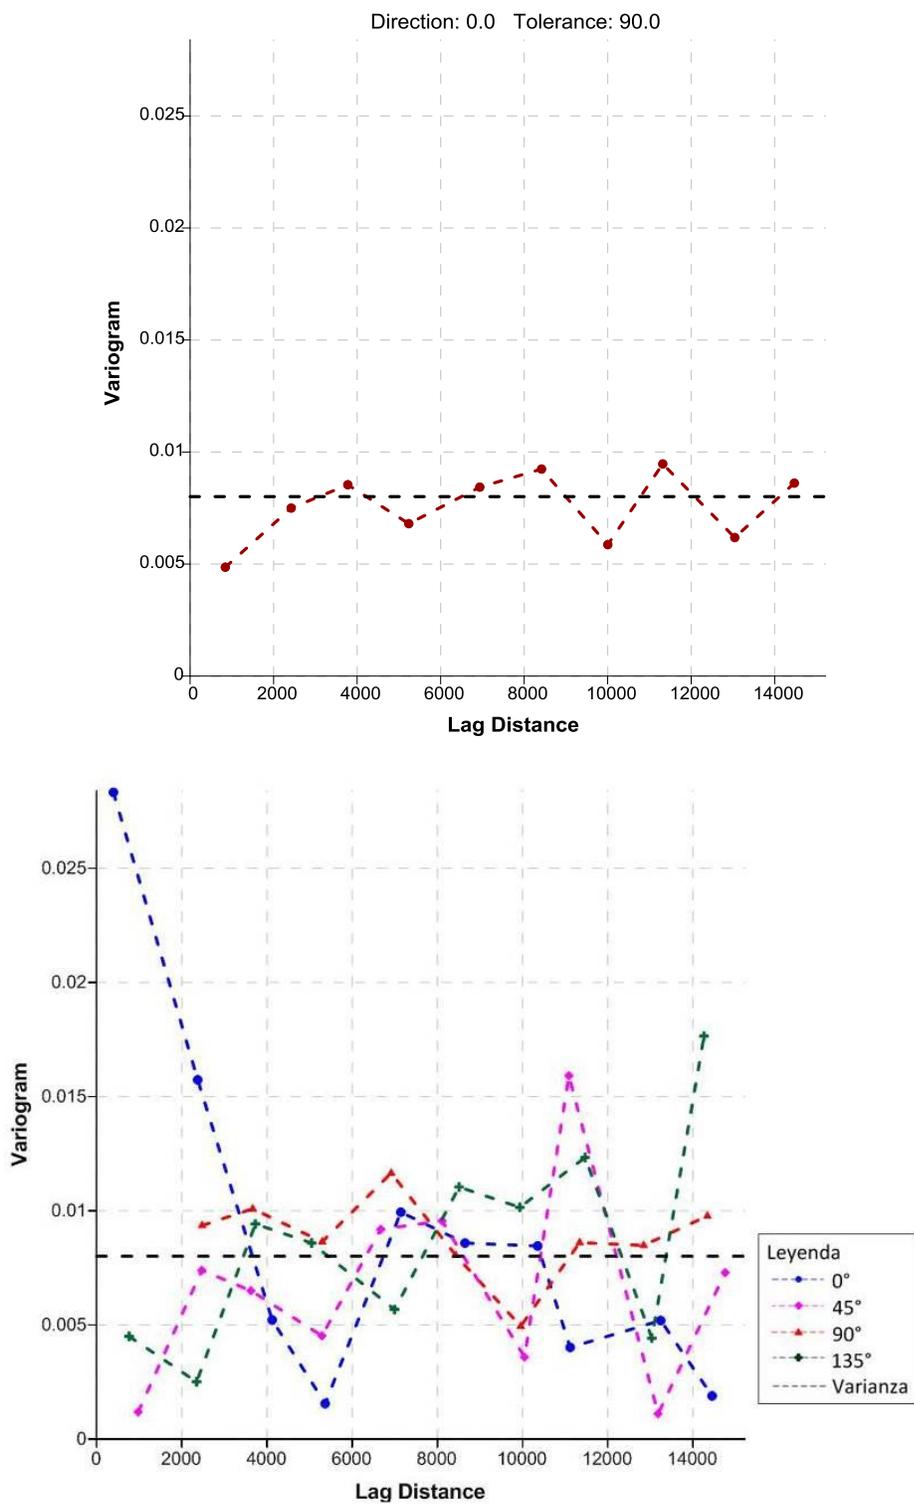
Anexo 14: Semivariogramas de la intensidad de *Bemisia tabaci* Guen. en la campaña 07_08.

Fuente: Elaboración Propia.



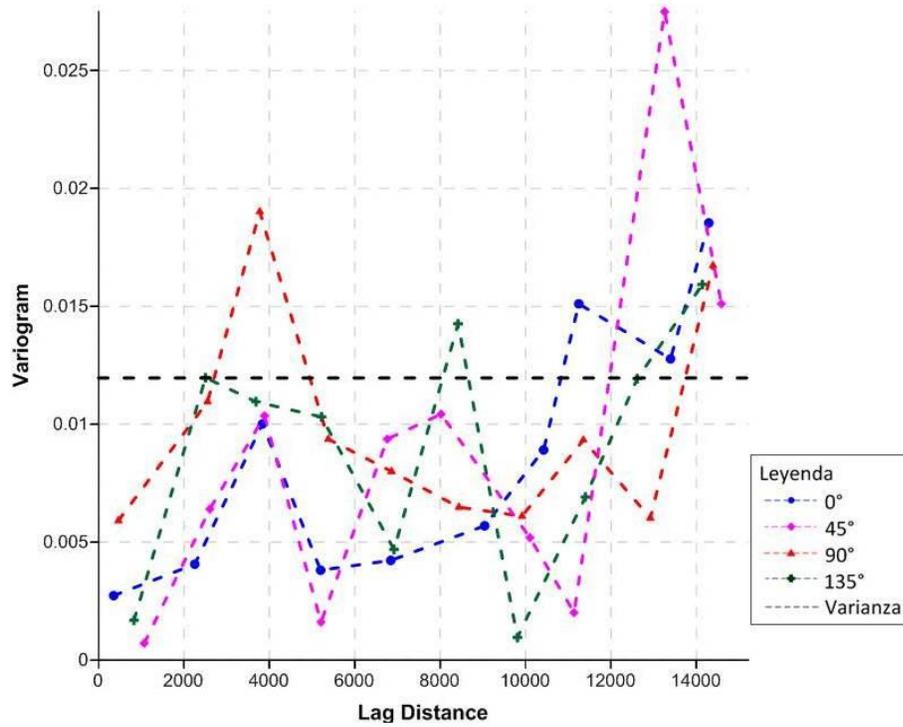
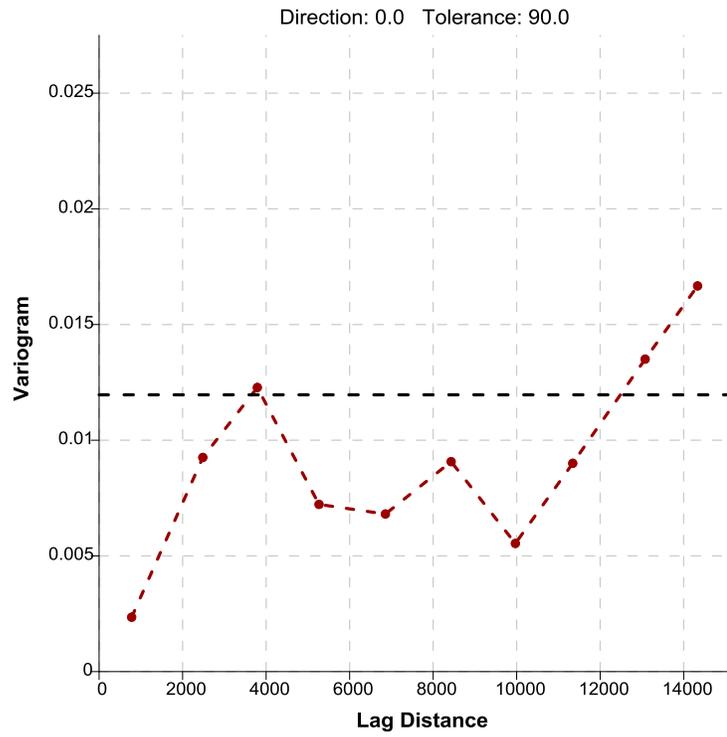
Anexo 15: Semivariogramas de la distribución de la enfermedad viral en la campaña 03_04.

Fuente: Elaboración Propia.



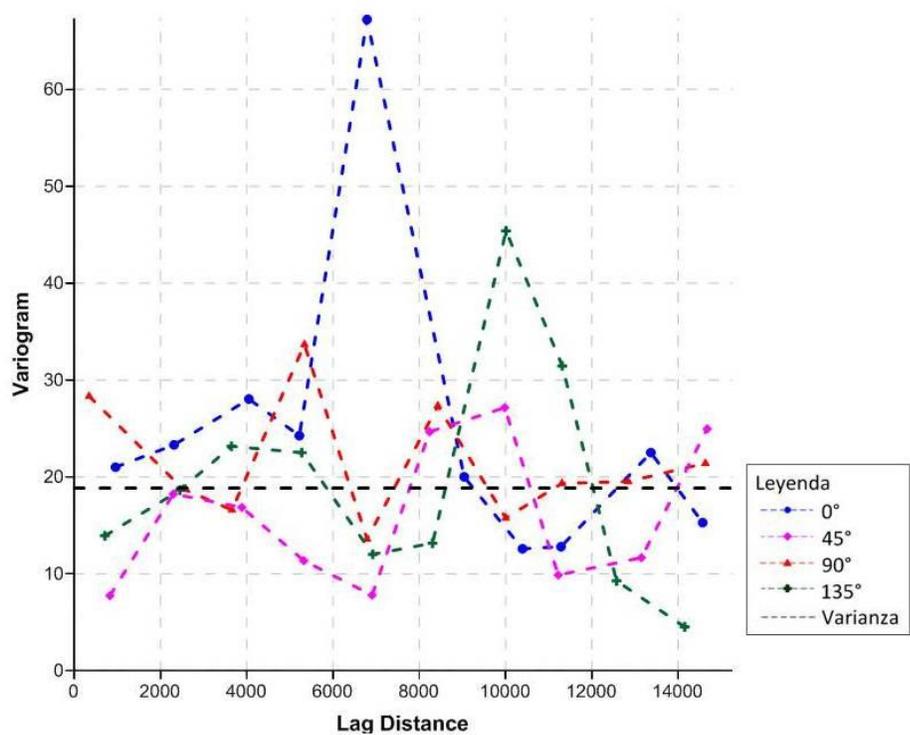
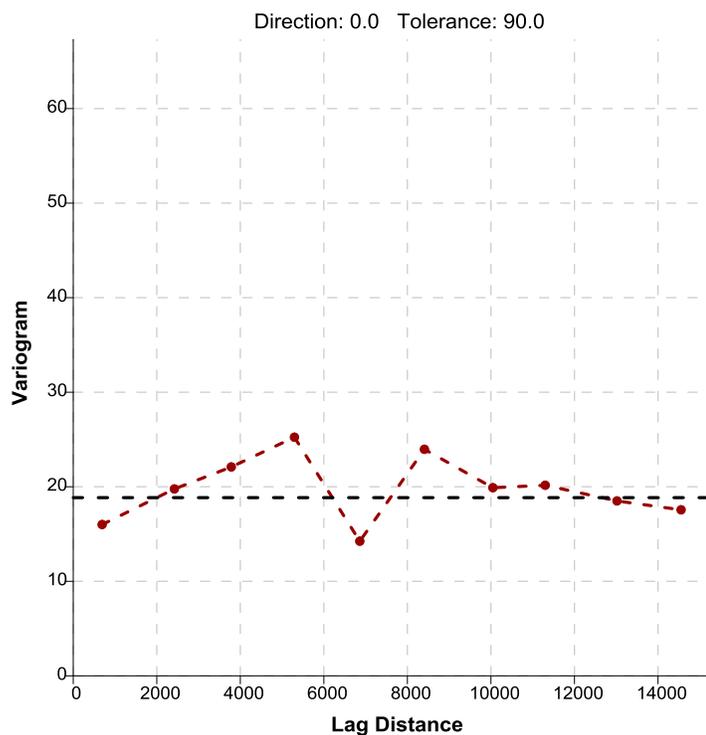
Anexo 16: Semivariogramas de la distribución de la enfermedad viral en la campaña 04_05.

Fuente: Elaboración Propia.



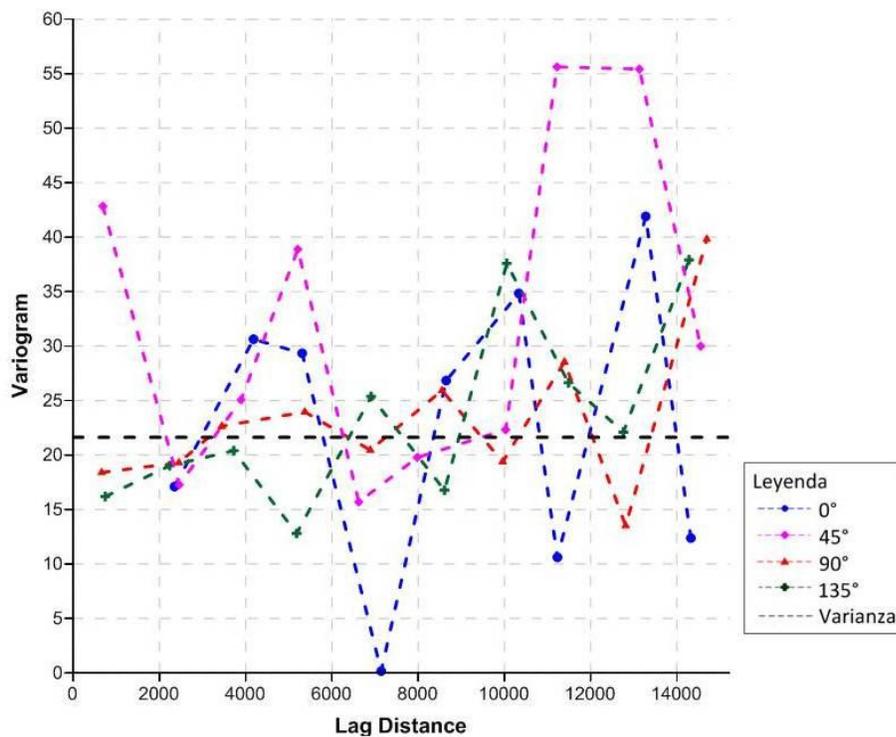
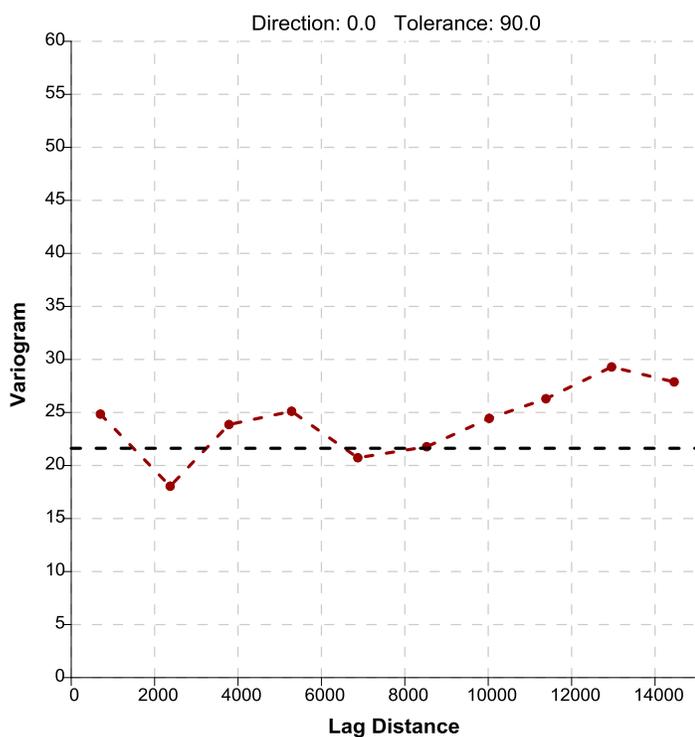
Anexo 17: Semivariogramas de la distribución de la enfermedad viral en la campaña 05_06.

Fuente: Elaboración Propia.



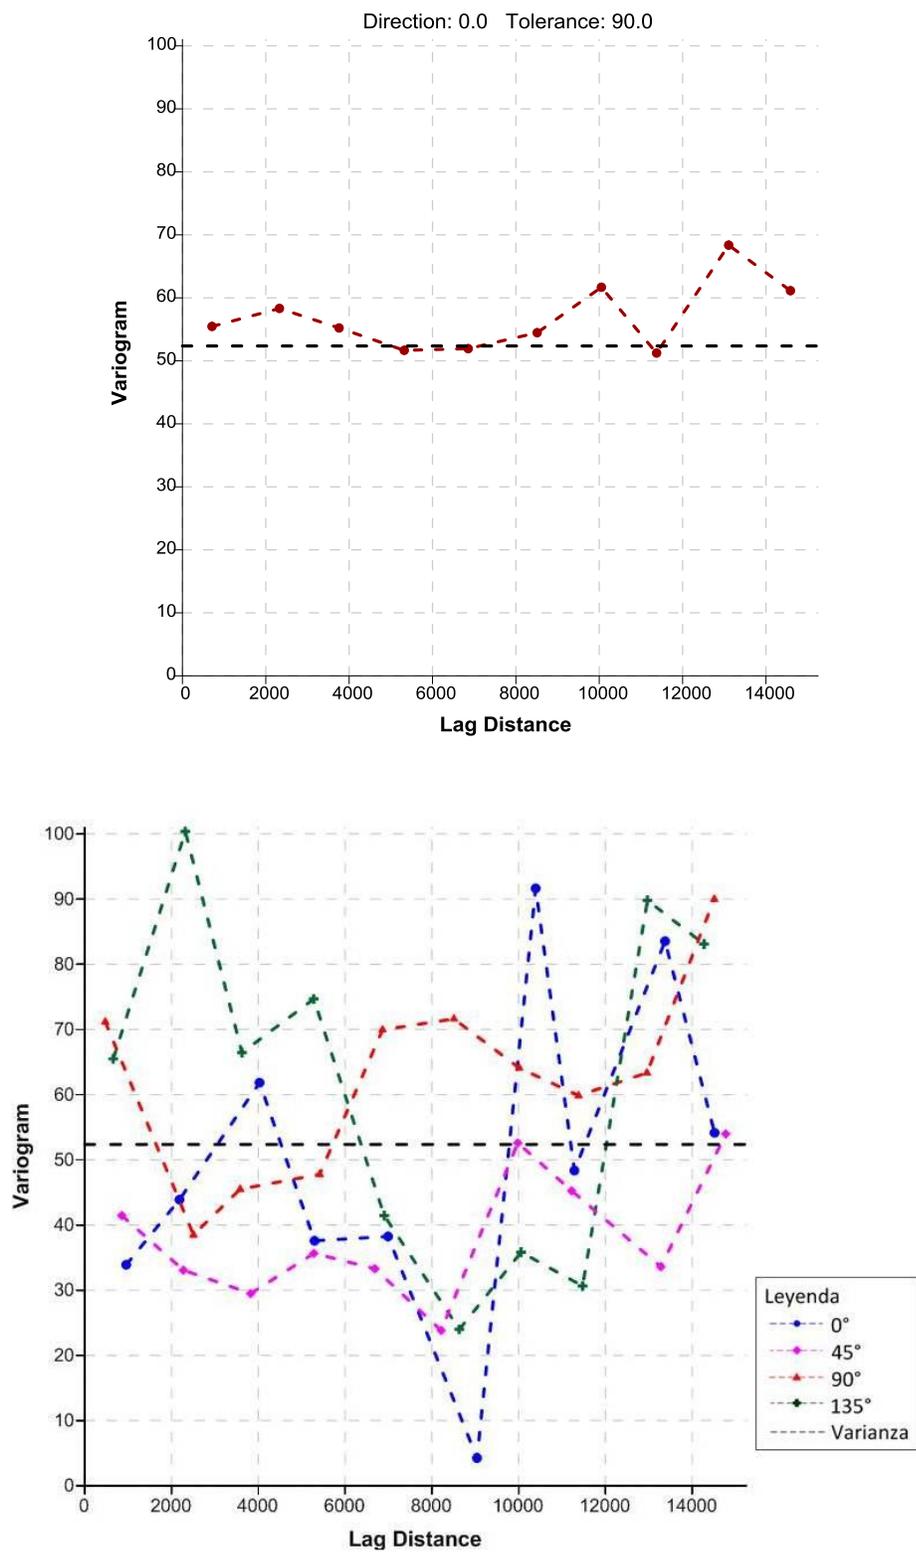
Anexo 18: Semivariogramas de la distribución de la enfermedad viral en la campaña 06_07.

Fuente: Elaboración Propia.

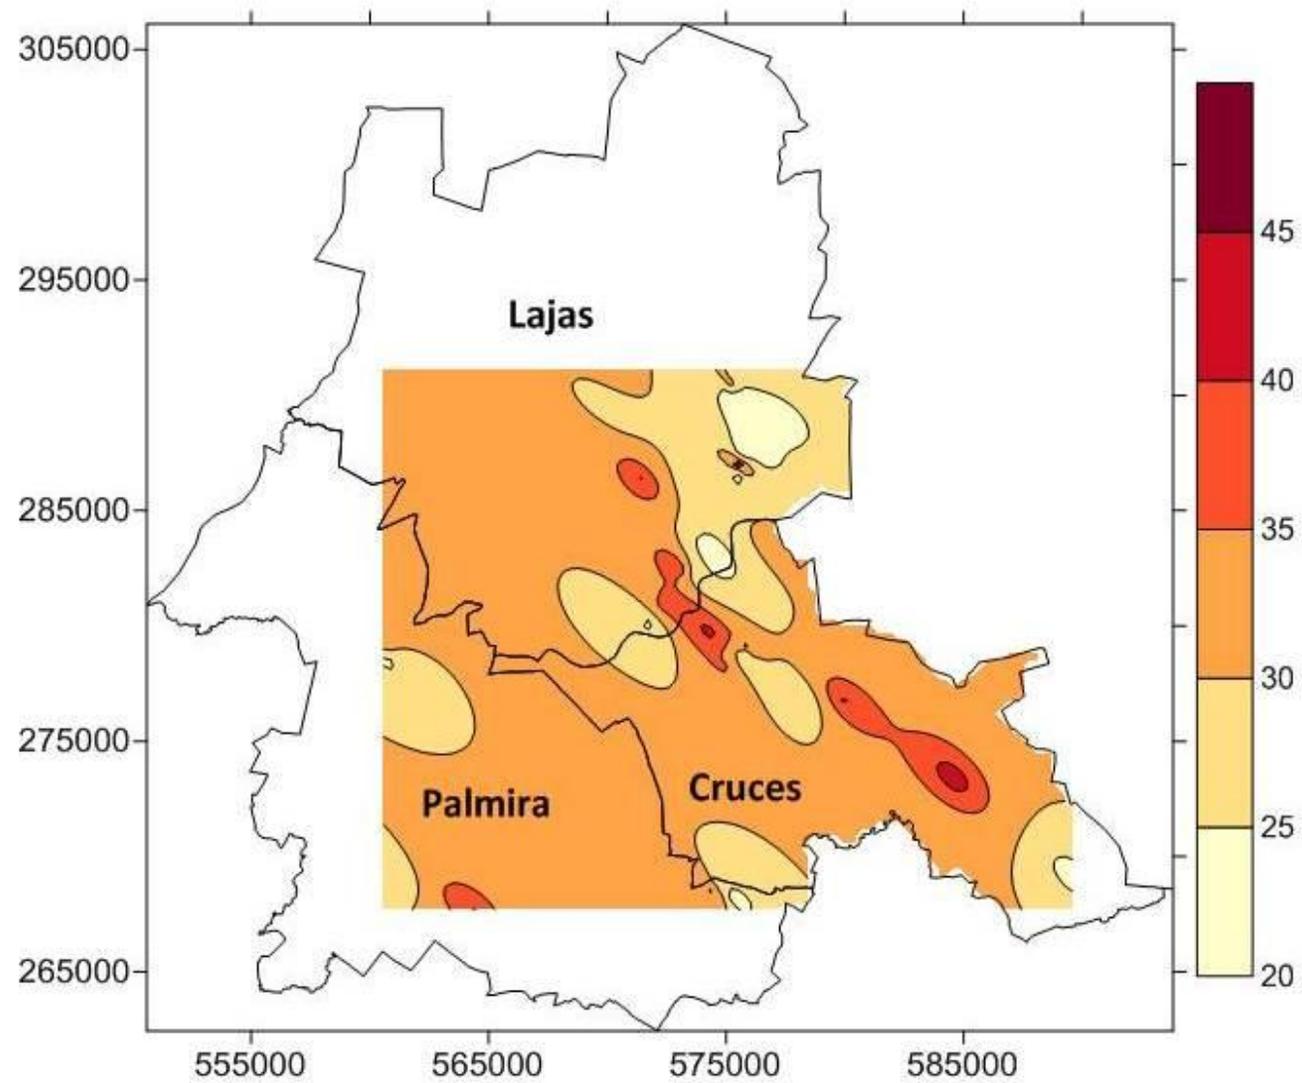


Anexo 19: Semivariogramas de la distribución de la enfermedad viral en la campaña 07_08.

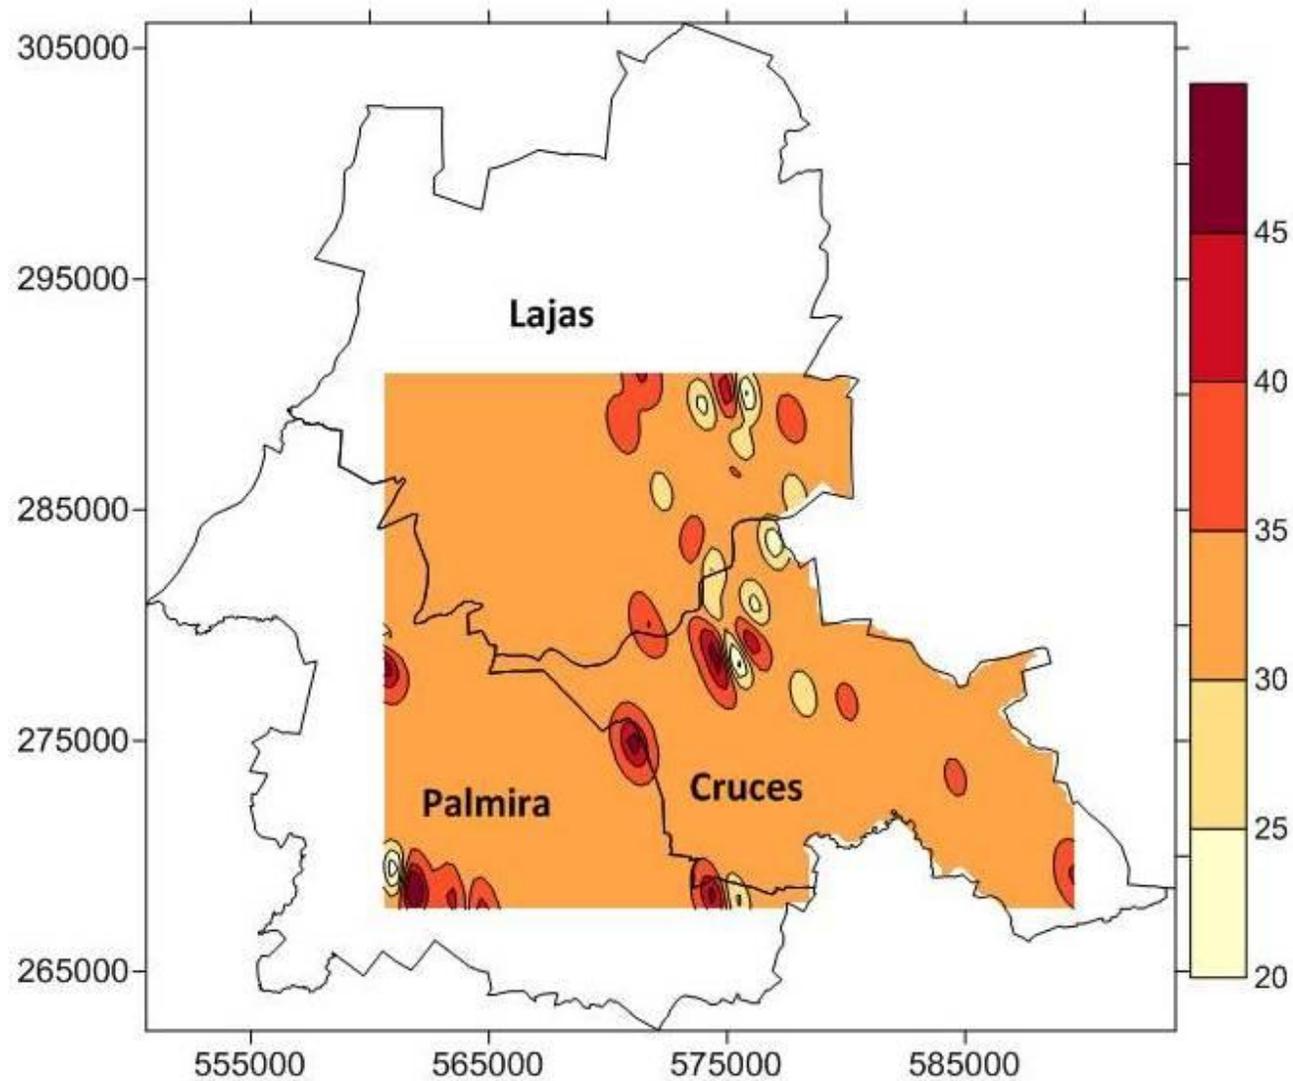
Fuente: Elaboración Propia.



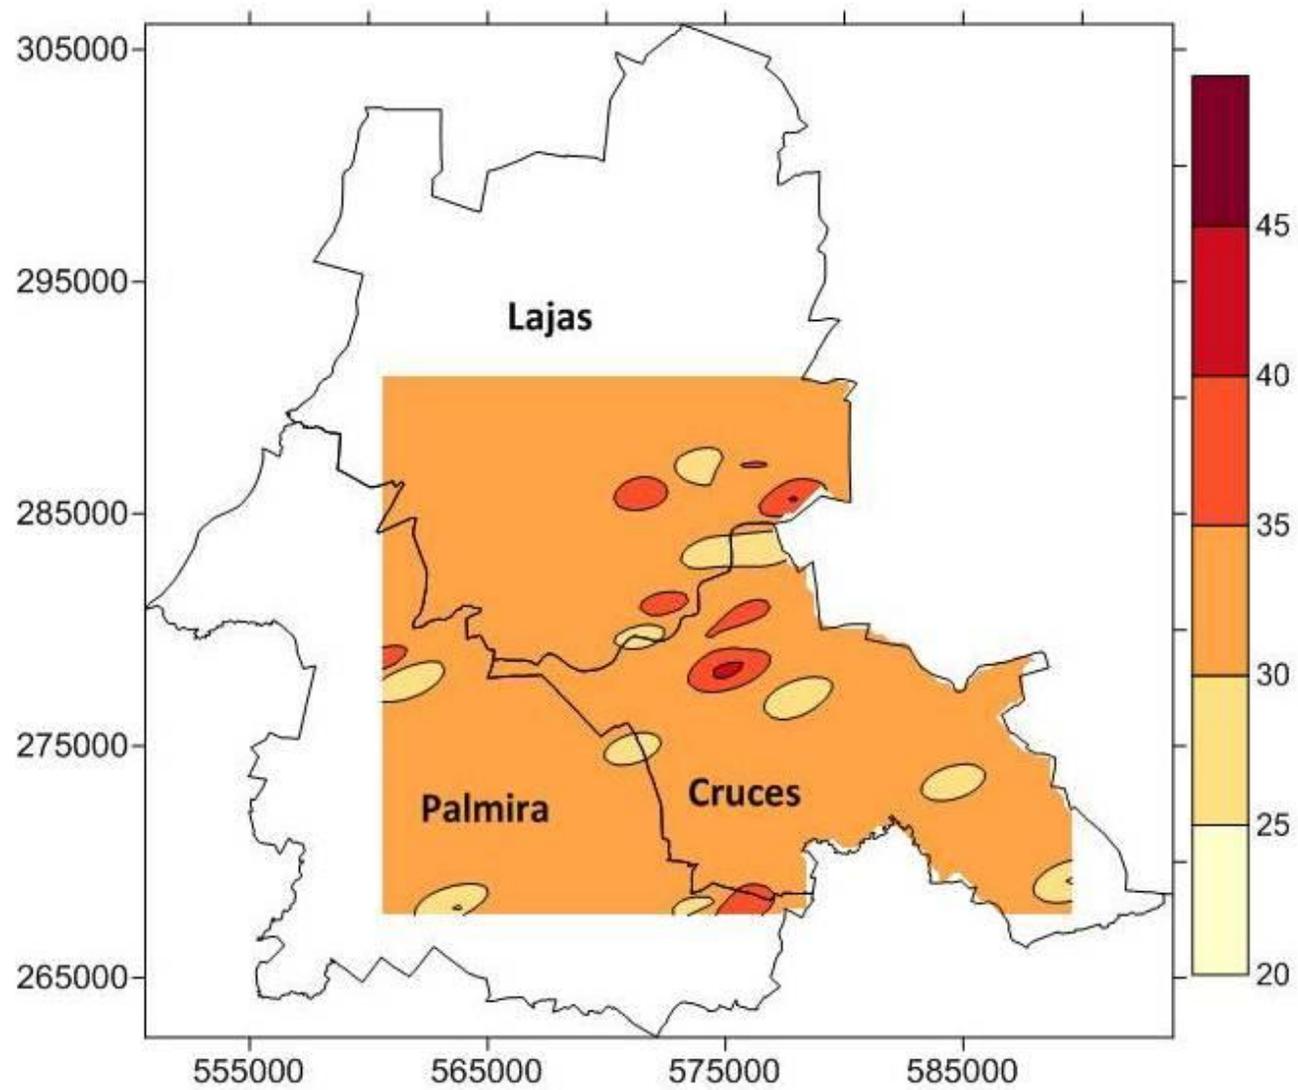
Anexo 20: Mapa de estimación de la intensidad de *Alternaria solani* Sor.. en la campaña 03_04. **Fuente:** Elaboración Propia.



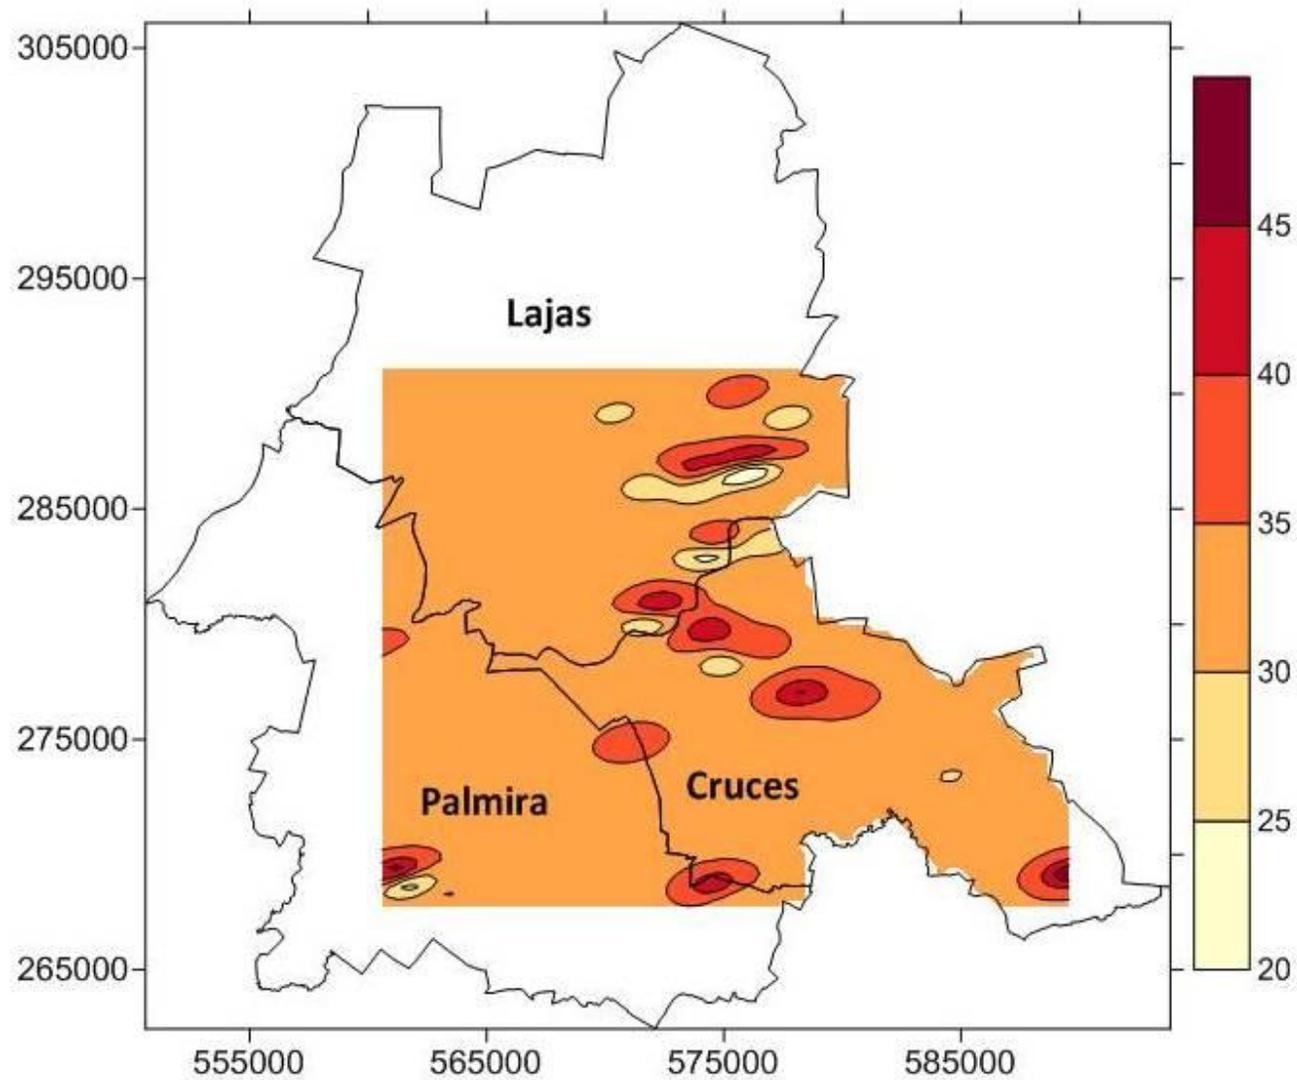
Anexo 21: Mapa de estimación de la intensidad de *Alternaria solani* Sor.. en la campaña 04_05. **Fuente:** Elaboración Propia.



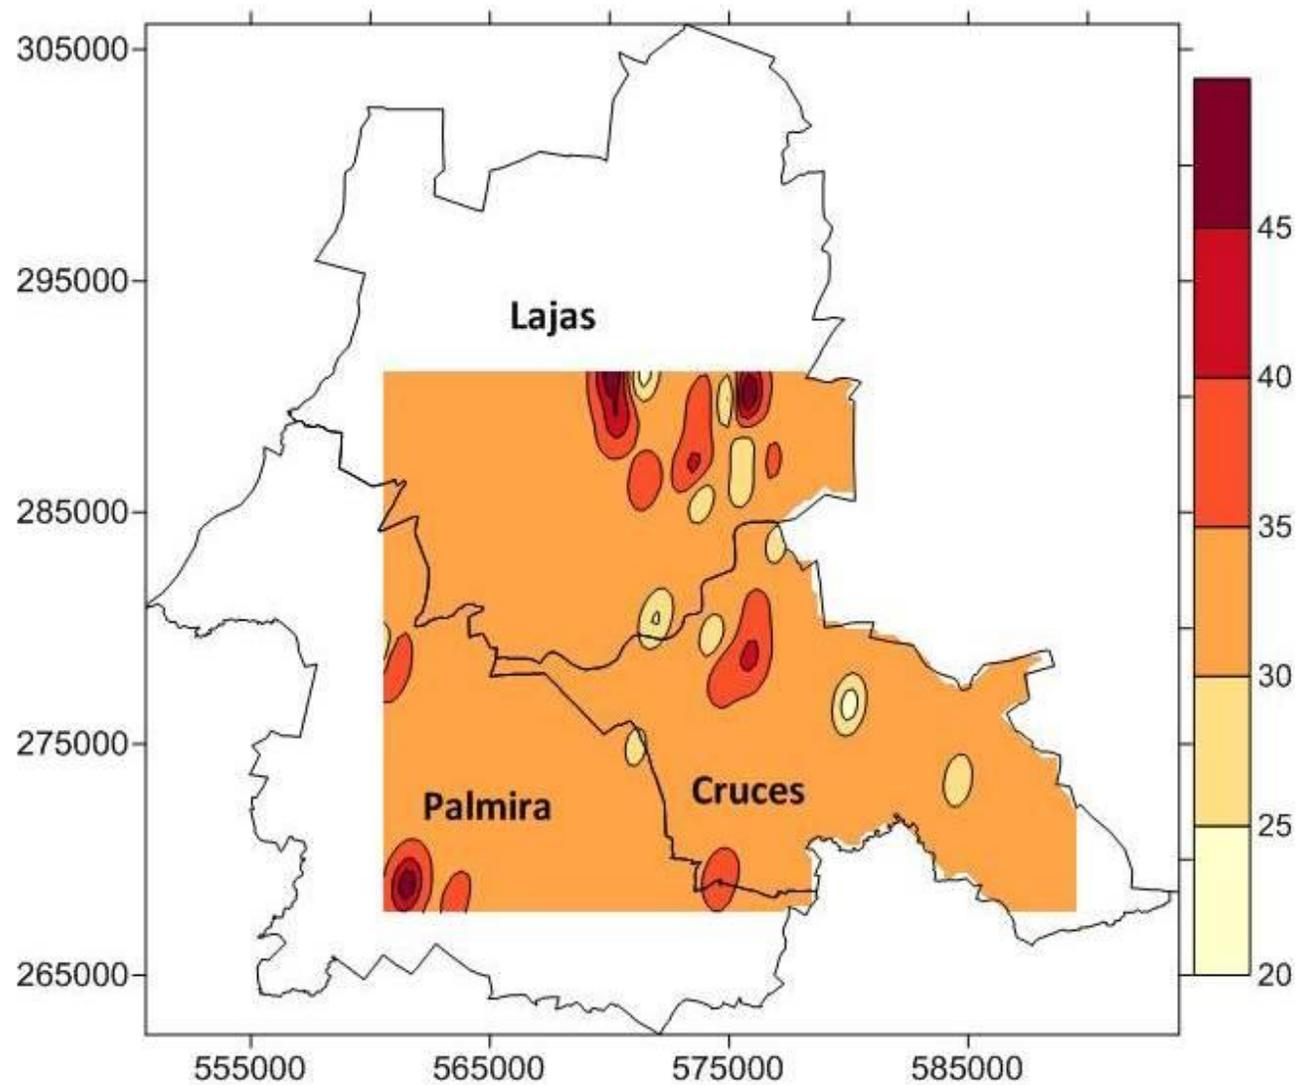
Anexo 22: Mapa de estimación de la intensidad de *Alternaria solani* Sor.. en la campaña 05_06. **Fuente:** Elaboración Propia.



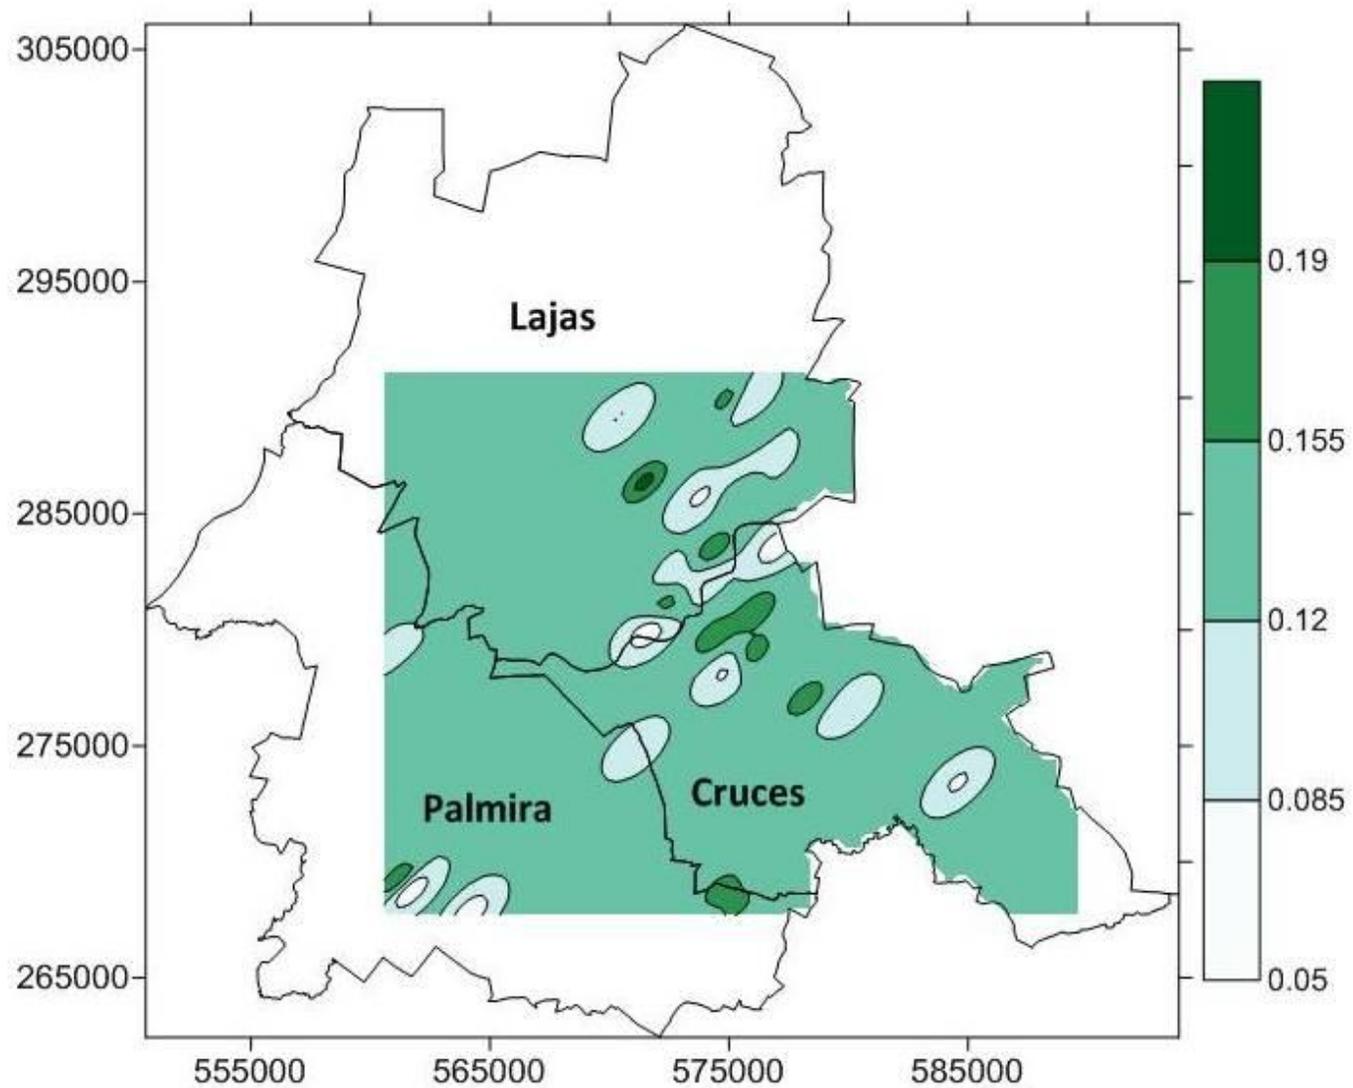
Anexo 23: Mapa de estimación de la intensidad de *Alternaria solani* Sor.. en la campaña 06_07. **Fuente:** Elaboración Propia.



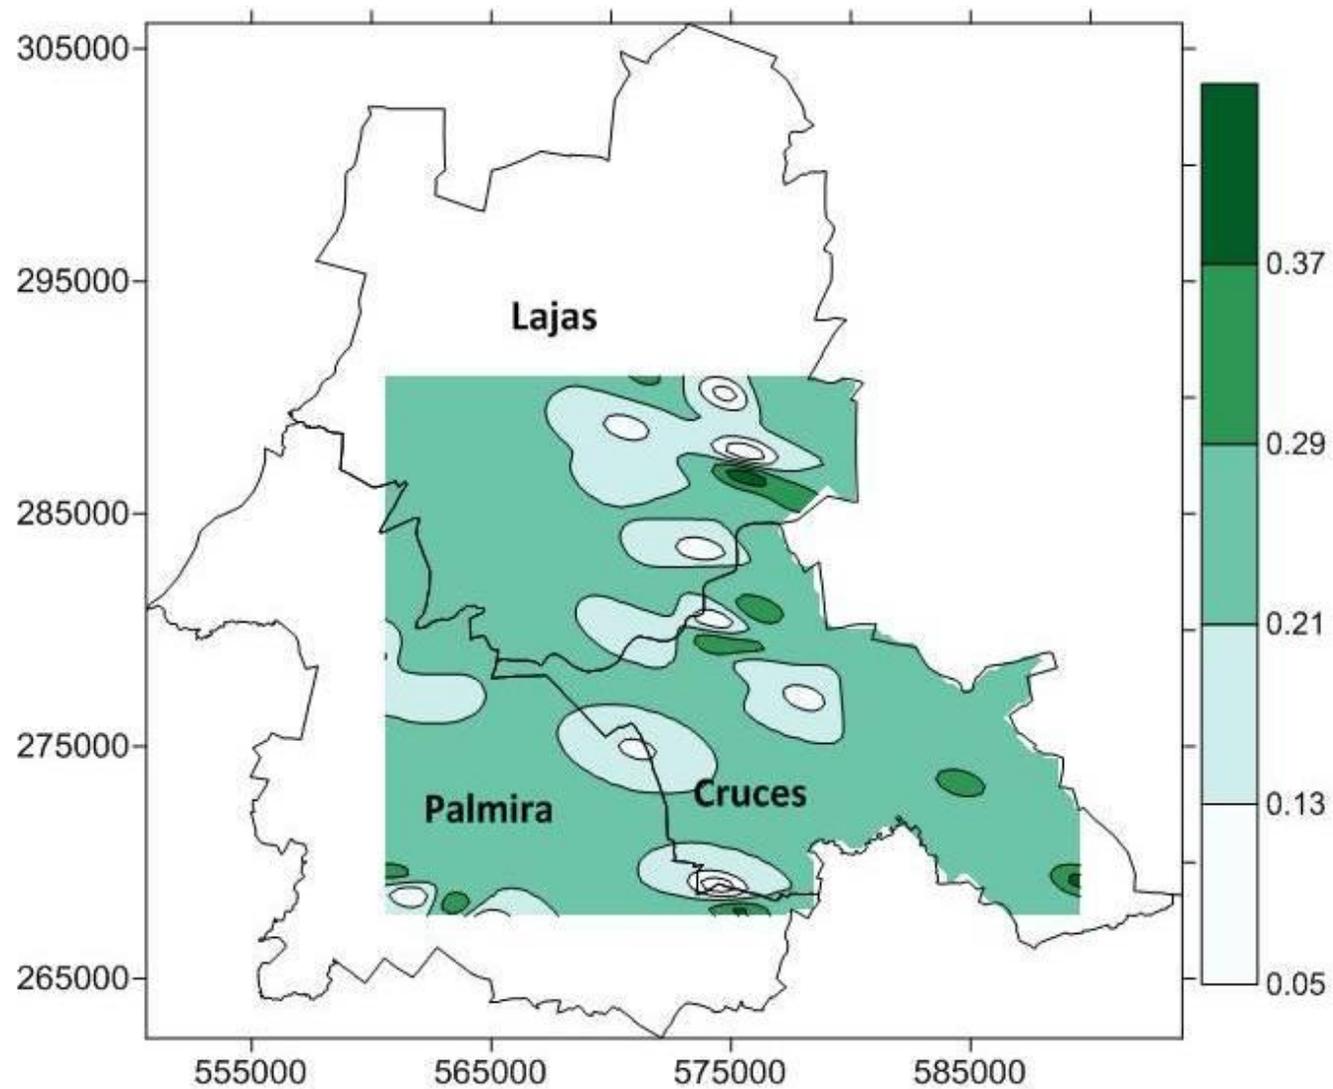
Anexo 24: Mapa de estimación de la intensidad de *Alternaria solani* Sor.. en la campaña 07_08. **Fuente:** Elaboración Propia.



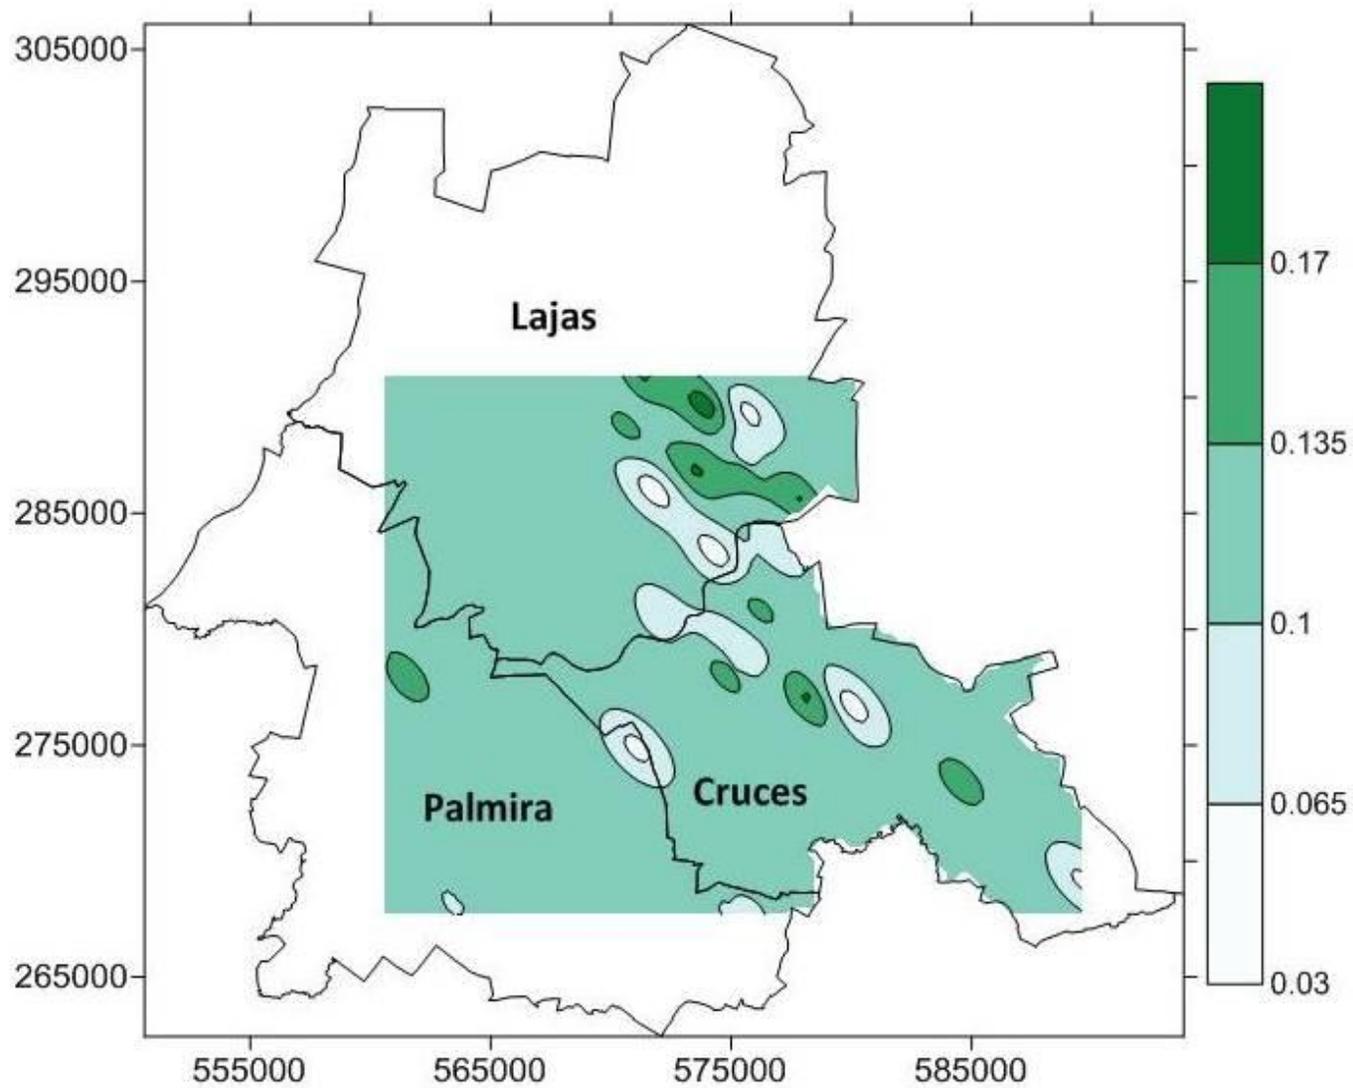
Anexo 25: Mapa de estimación de la intensidad de *Bemisia tabaci* Guen. en la campaña 03_04. **Fuente:** Elaboración Propia.



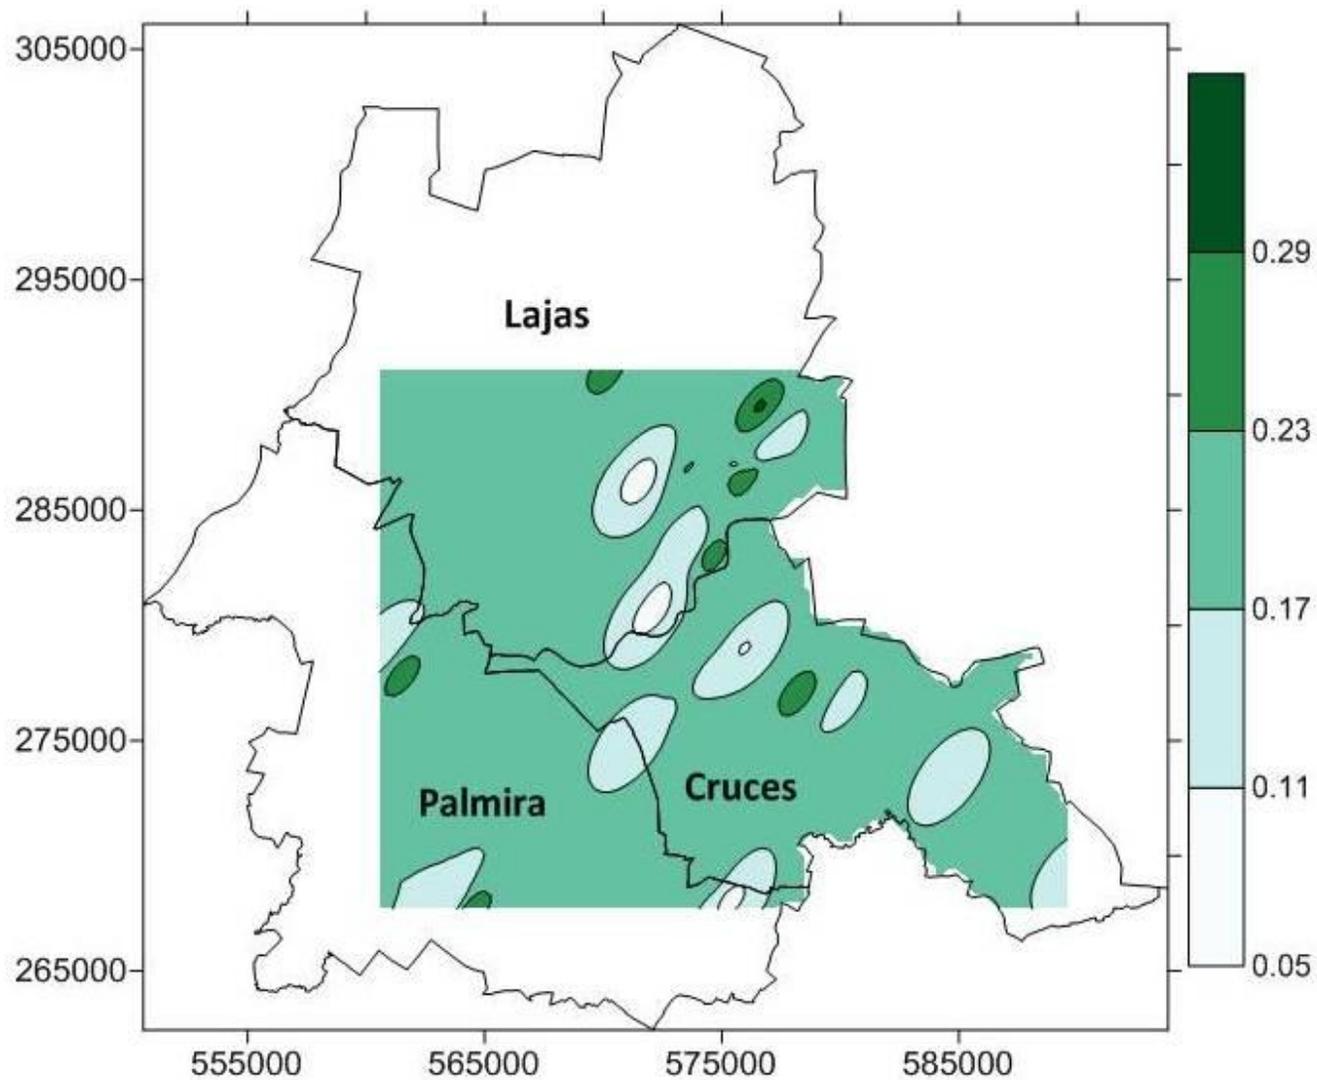
Anexo 26: Mapa de estimación de la intensidad de *Bemisia tabaci* Guen. en la campaña 04_05. **Fuente:** Elaboración Propia.



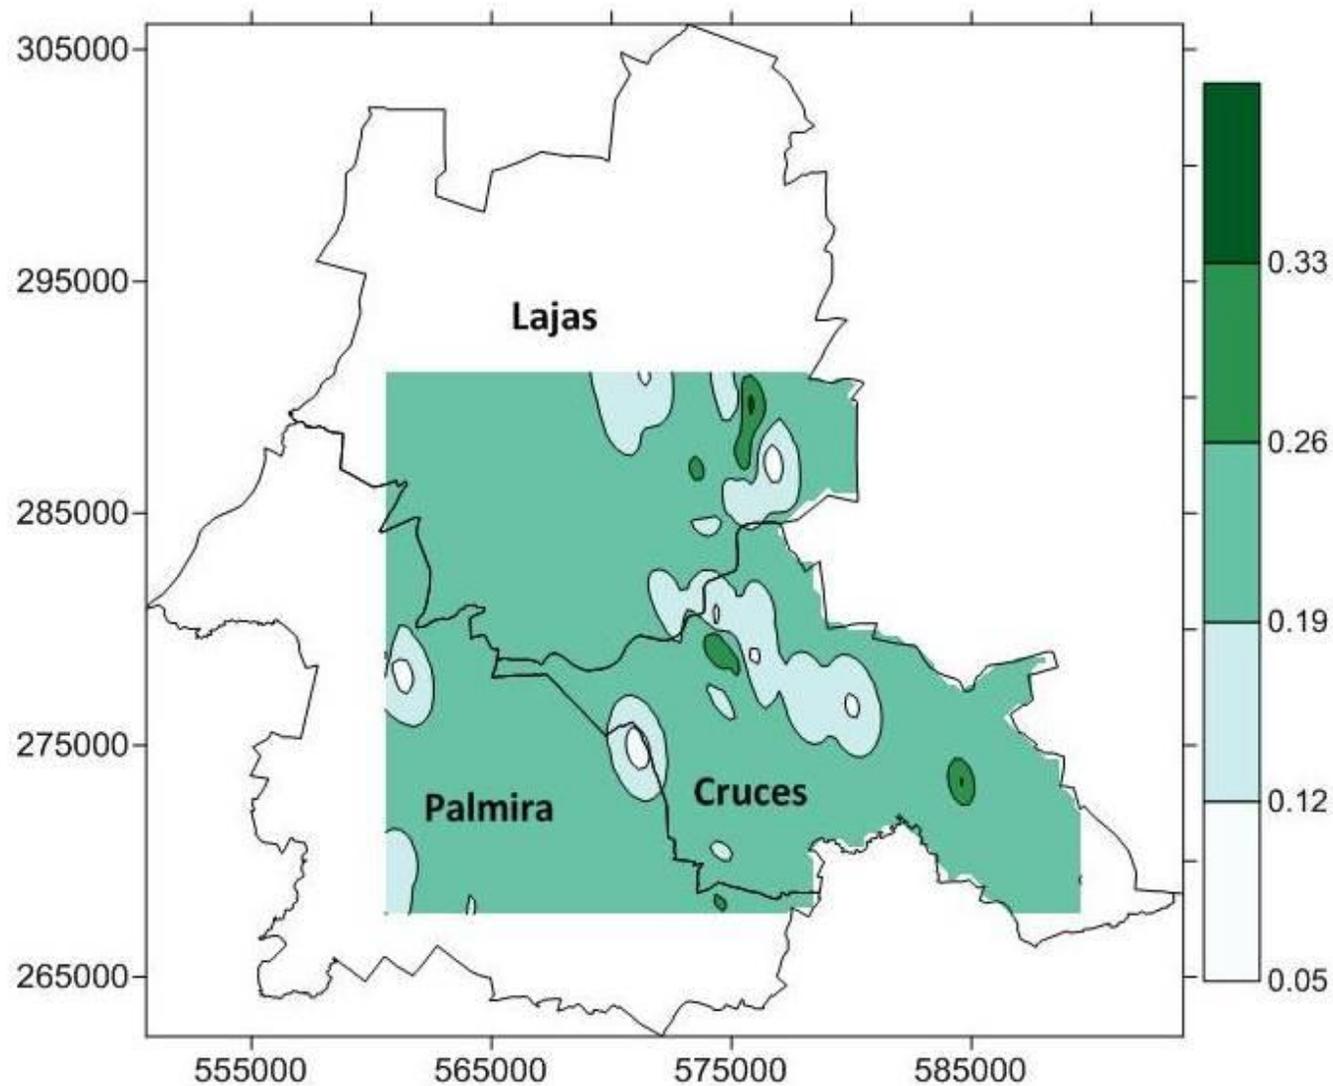
Anexo 27: Mapa de estimación de la intensidad de *Bemisia tabaci* Guen. en la campaña 05_06. **Fuente:** Elaboración Propia.



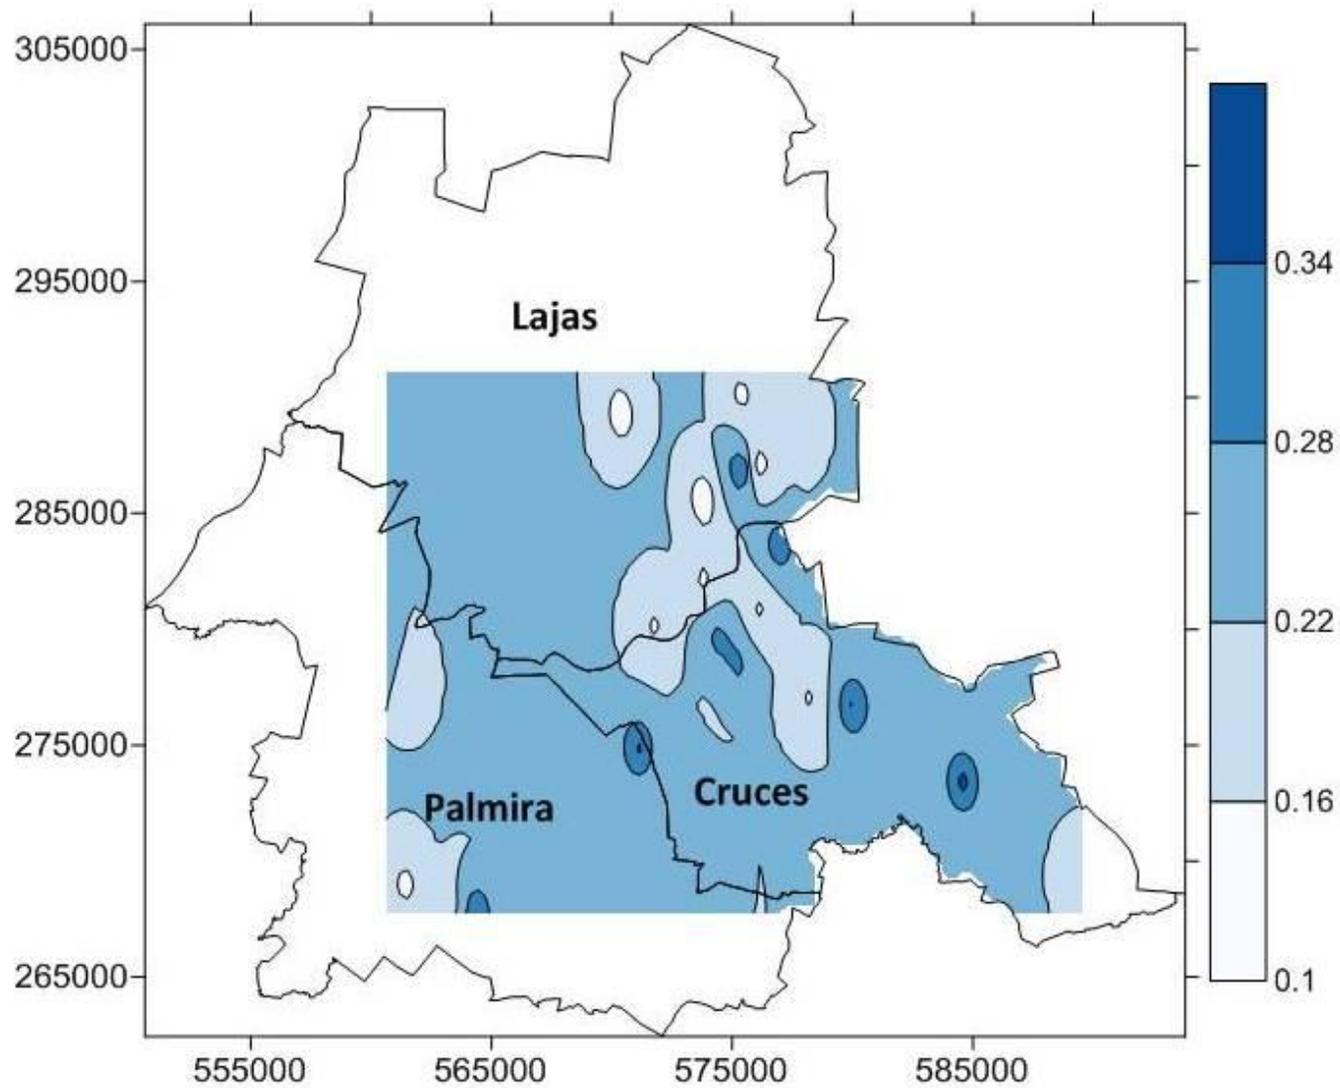
Anexo 28: Mapa de estimación de la intensidad de *Bemisia tabaci* Guen. en la campaña 06_07. **Fuente:** Elaboración Propia.



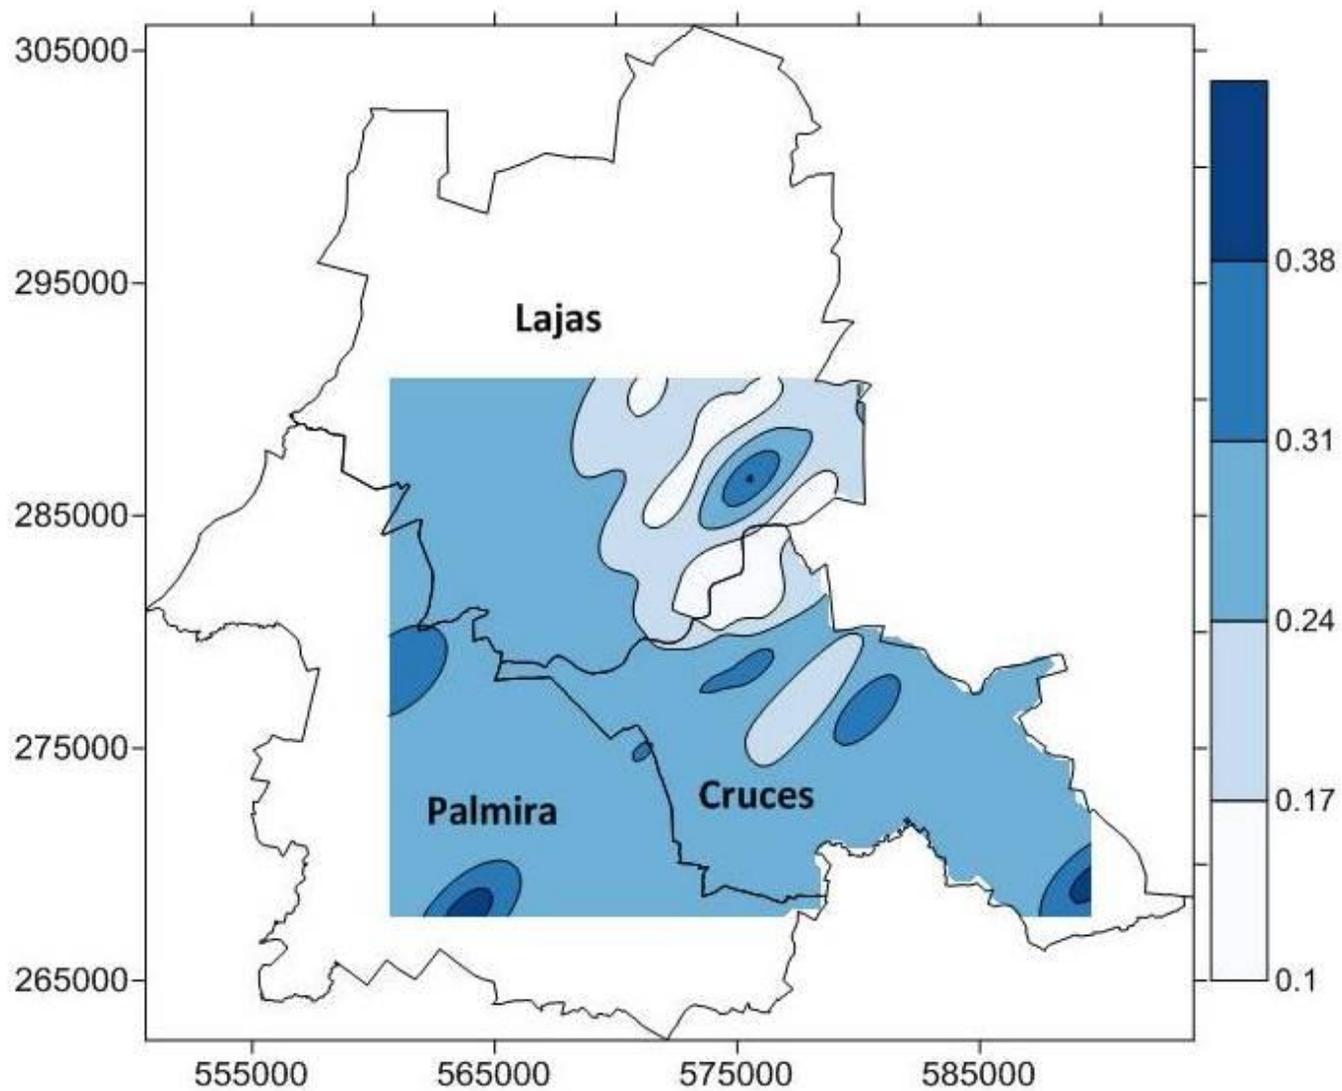
Anexo 29: Mapa de estimación de la intensidad de *Bemisia tabaci* Guen. en la campaña 07_08. **Fuente:** Elaboración Propia.



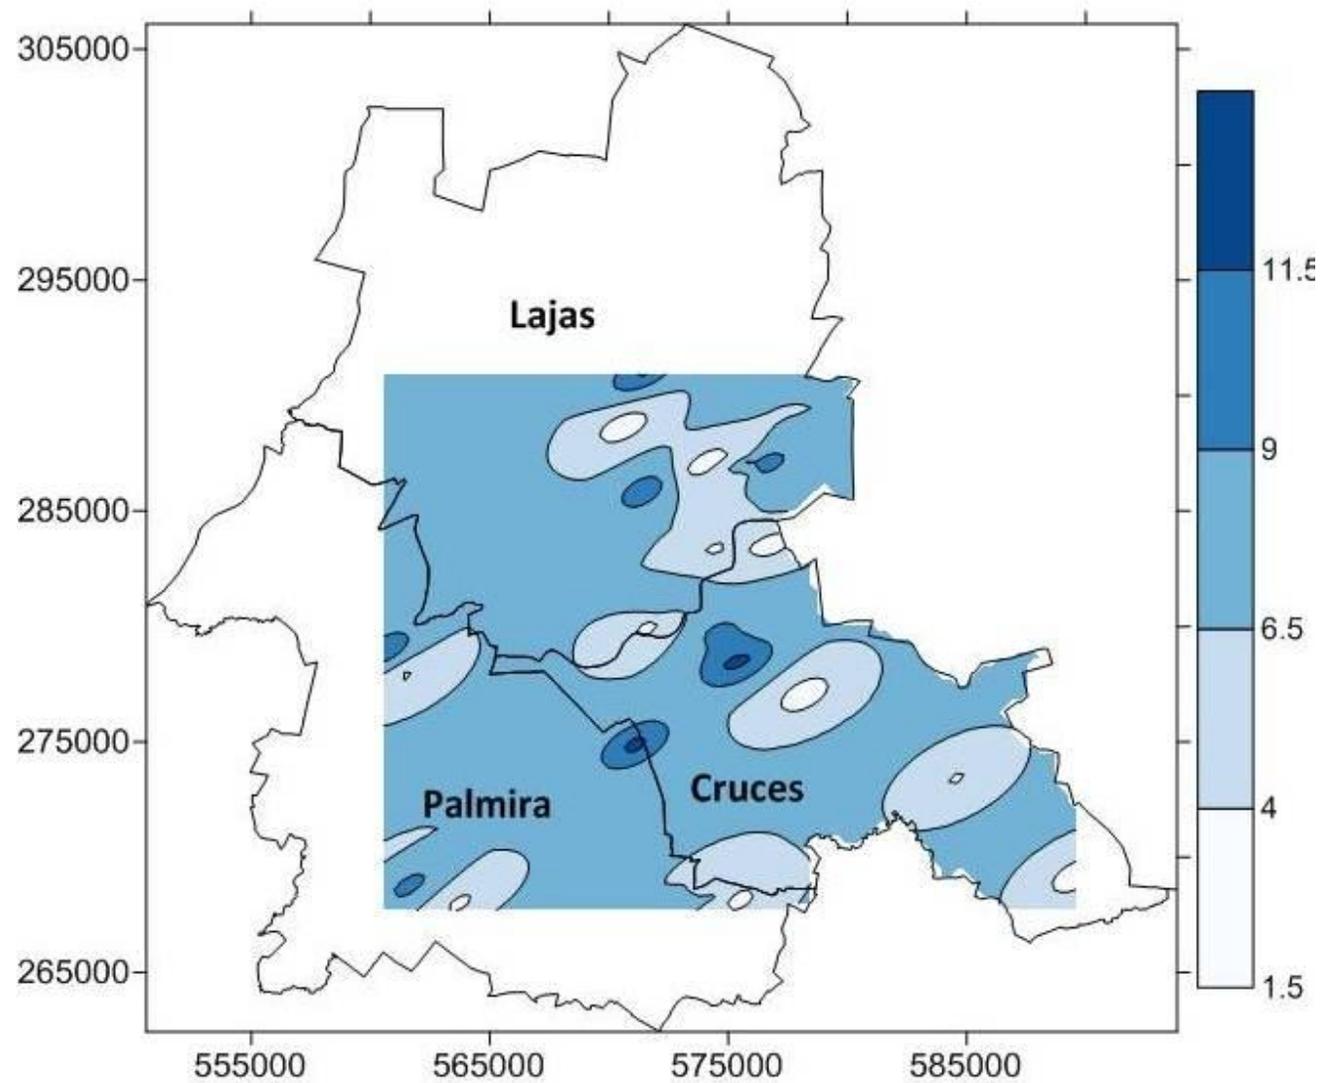
Anexo 30: Mapa de estimación de la distribución de la enfermedad viral en la campaña 03_04. **Fuente:** Elaboración Propia.



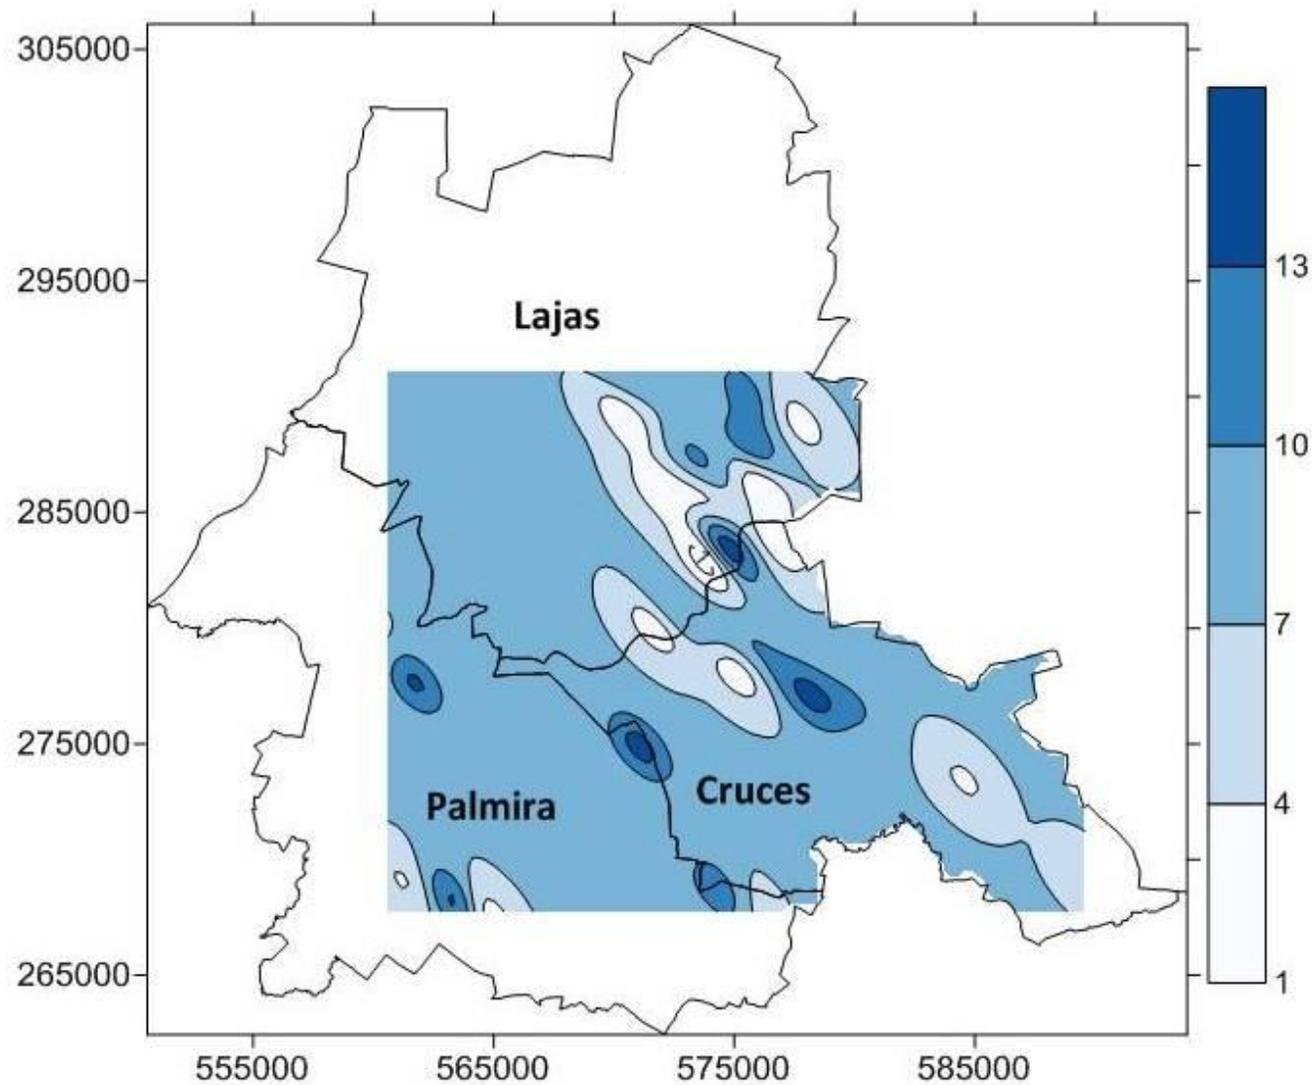
Anexo 31: Mapa de estimación de la distribución de la enfermedad viral en la campaña 04_05. **Fuente:** Elaboración Propia.



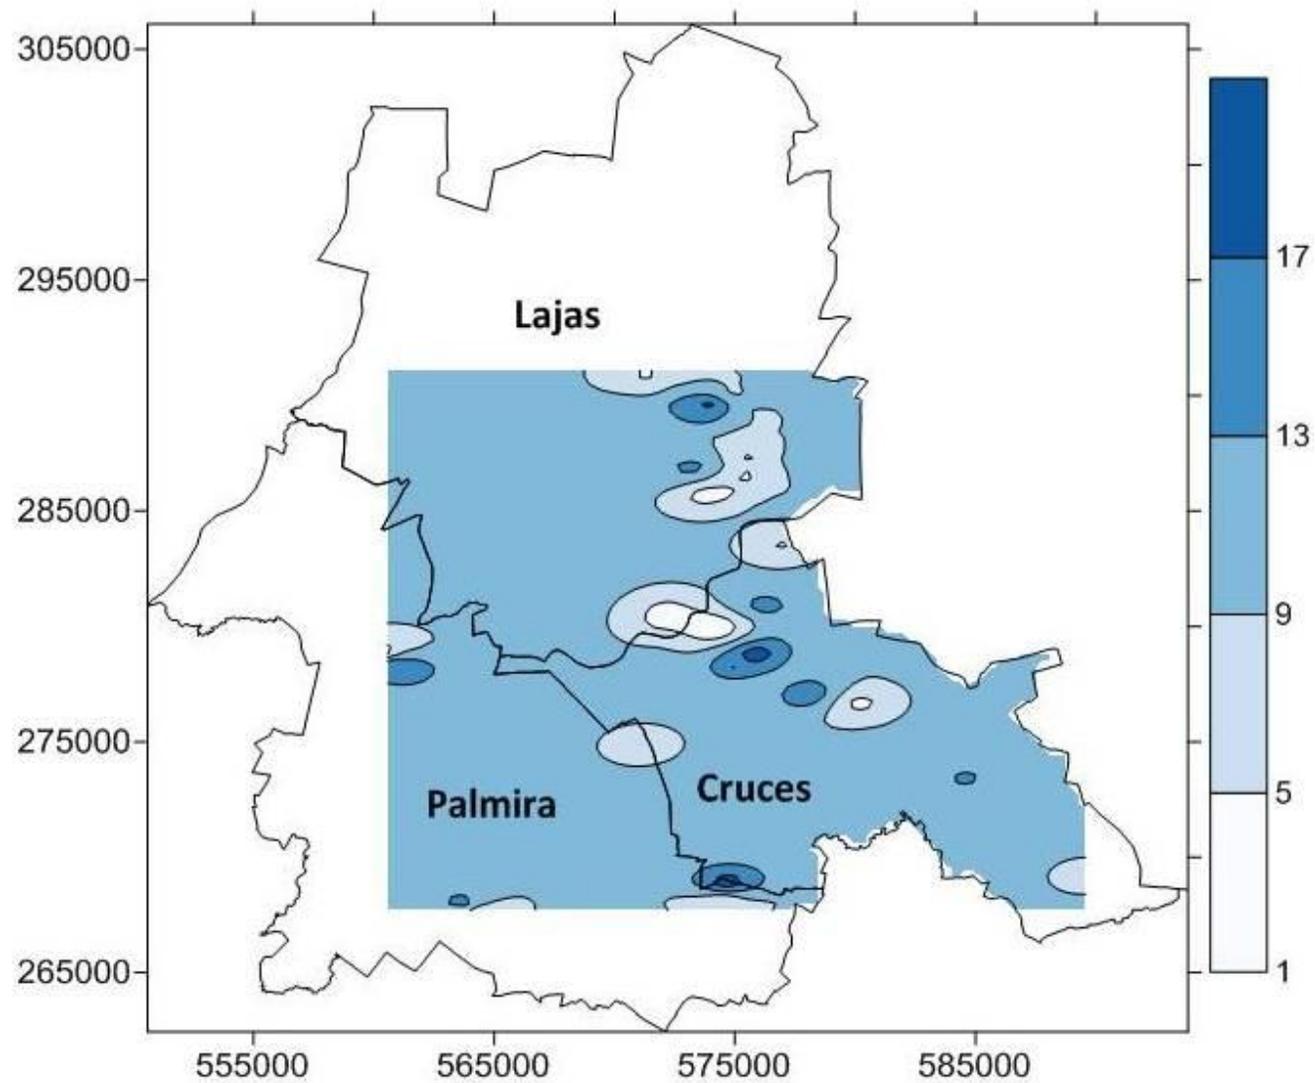
Anexo 32: Mapa de estimación de la distribución de la enfermedad viral en la campaña 05_06. **Fuente:** Elaboración Propia.



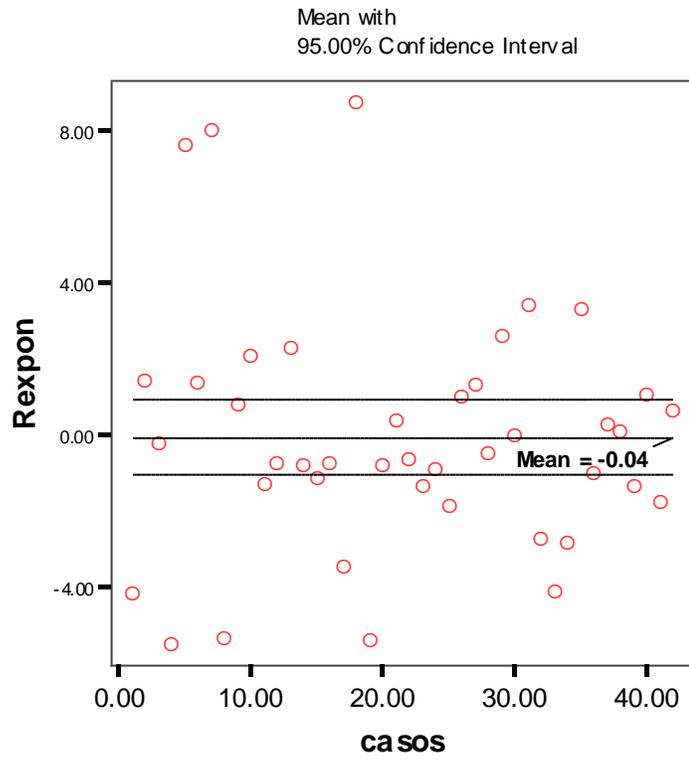
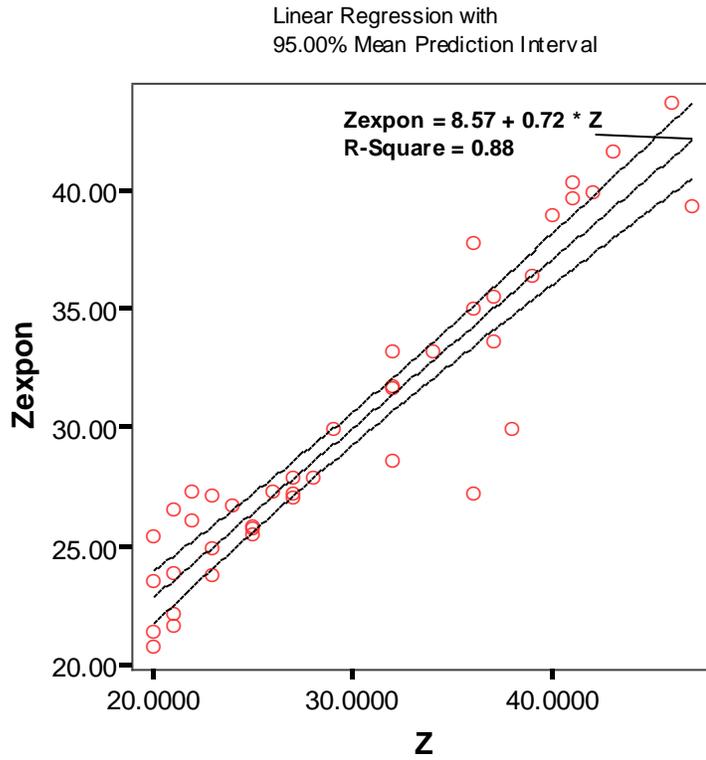
Anexo 33: Mapa de estimación de la distribución de la enfermedad viral en la campaña 06_07. **Fuente:** Elaboración Propia.



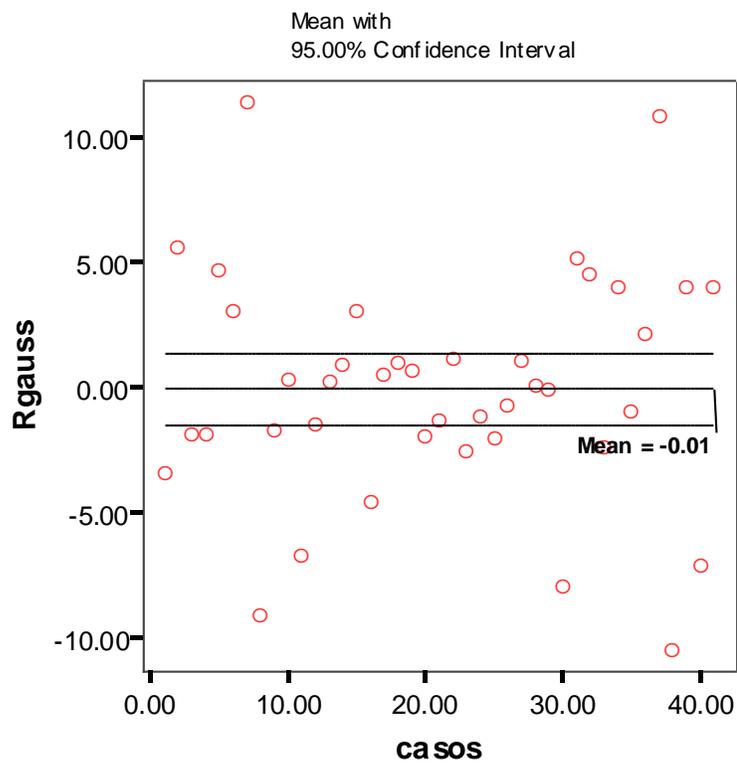
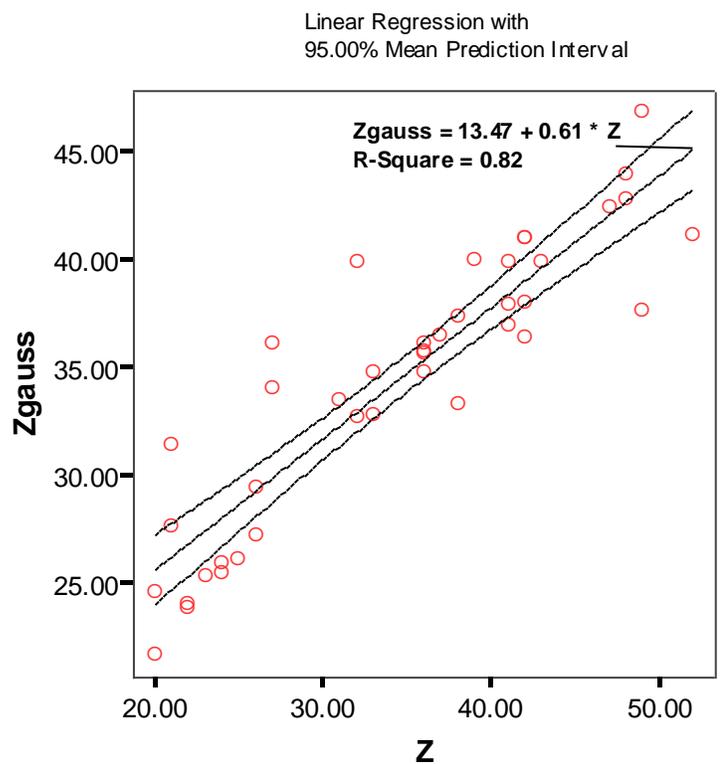
Anexo 34: Mapa de estimación de la distribución de la enfermedad viral en la campaña 07_08. **Fuente:** Elaboración Propia.



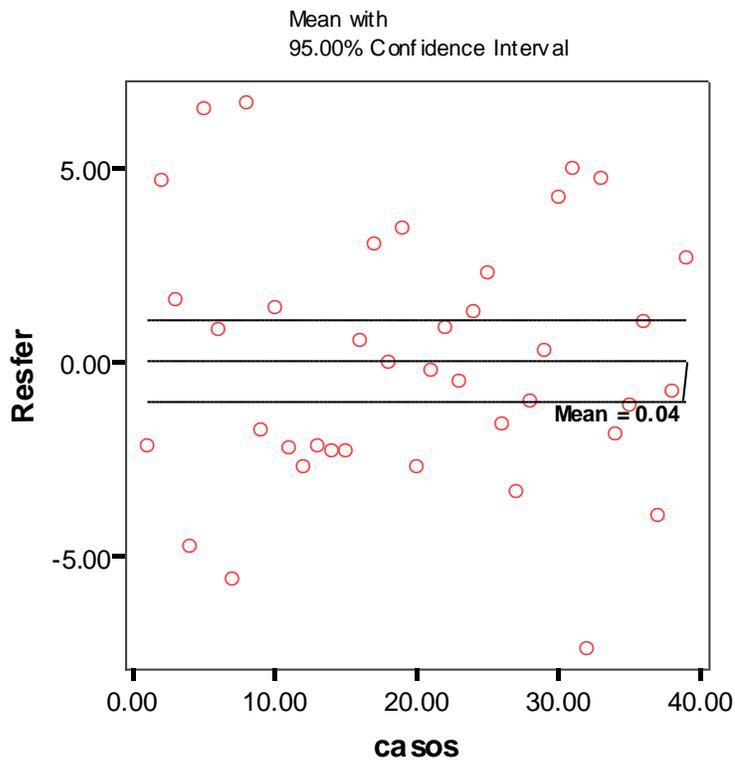
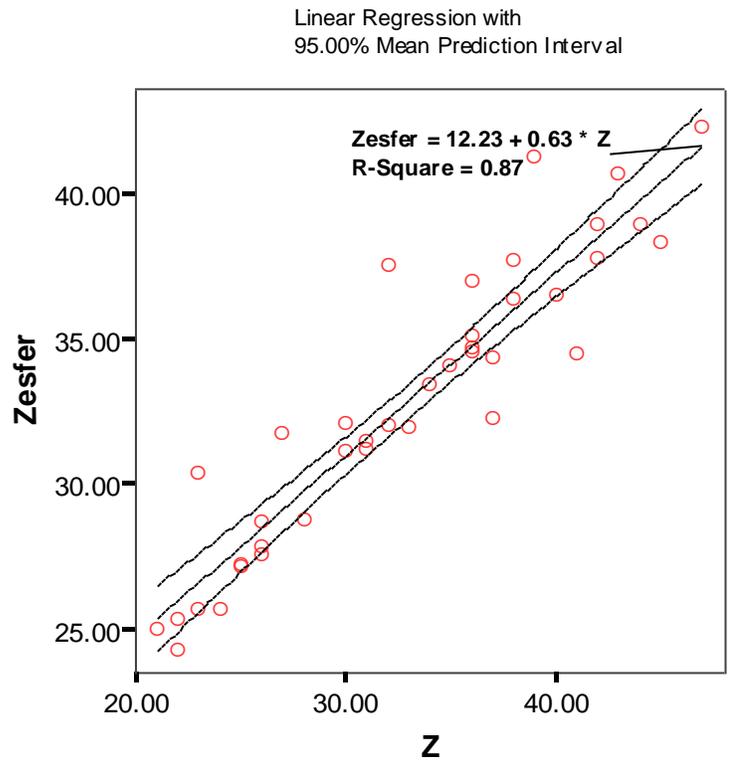
Anexo 35: Diagramas de dispersión de la intensidad de *Alternaria solani* Sor.. en la campaña 03_04. **Fuente:** Elaboración Propia.



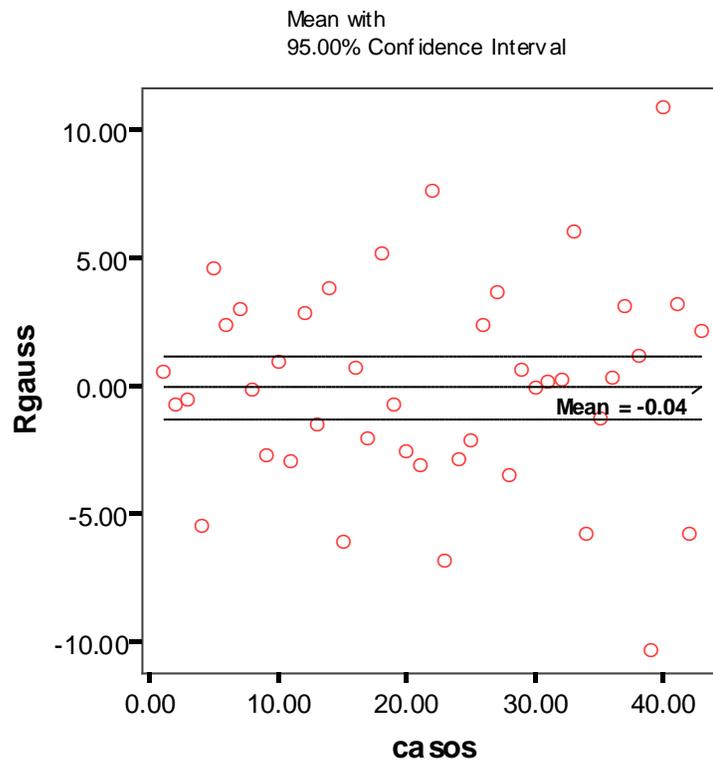
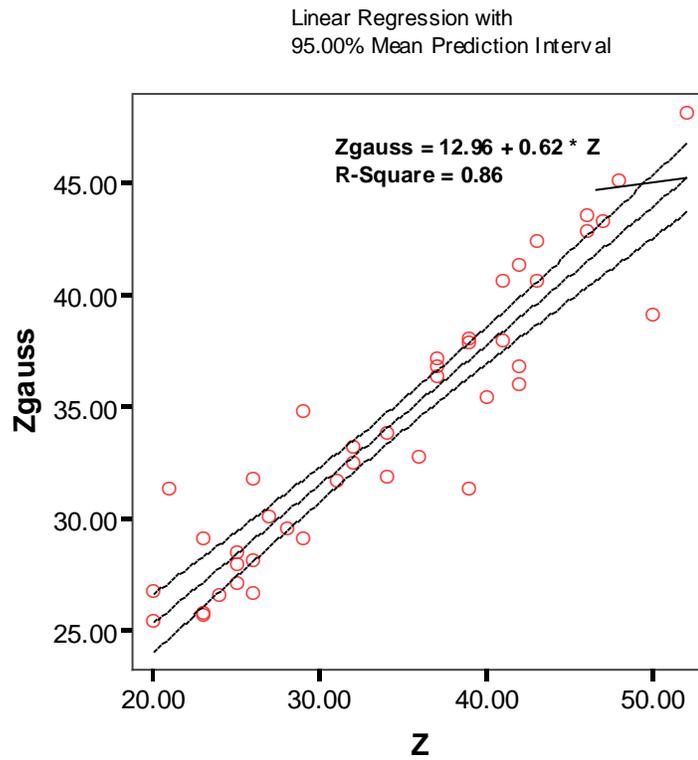
Anexo 36: Diagramas de dispersión de la intensidad de *Alternaria solani* Sor.. en la campaña 04_05. **Fuente:** Elaboración Propia.



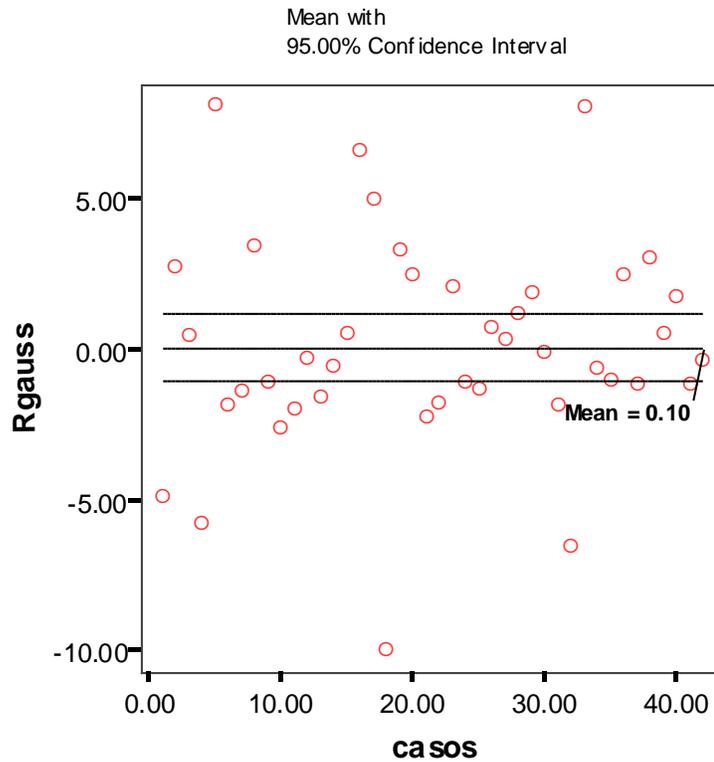
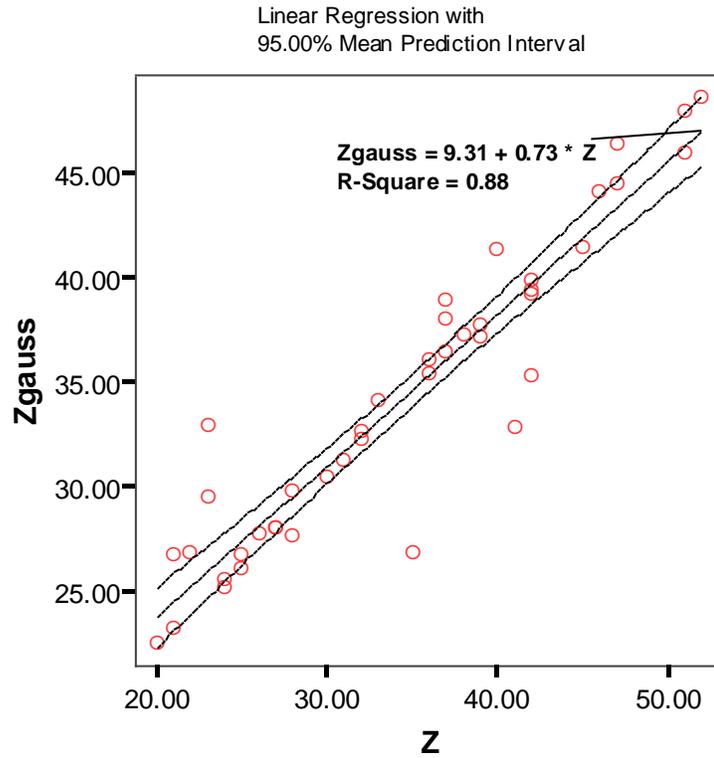
Anexo 37: Diagramas de dispersión de la intensidad de *Alternaria solani* Sor.. en la campaña 05_06. **Fuente:** Elaboración Propia.



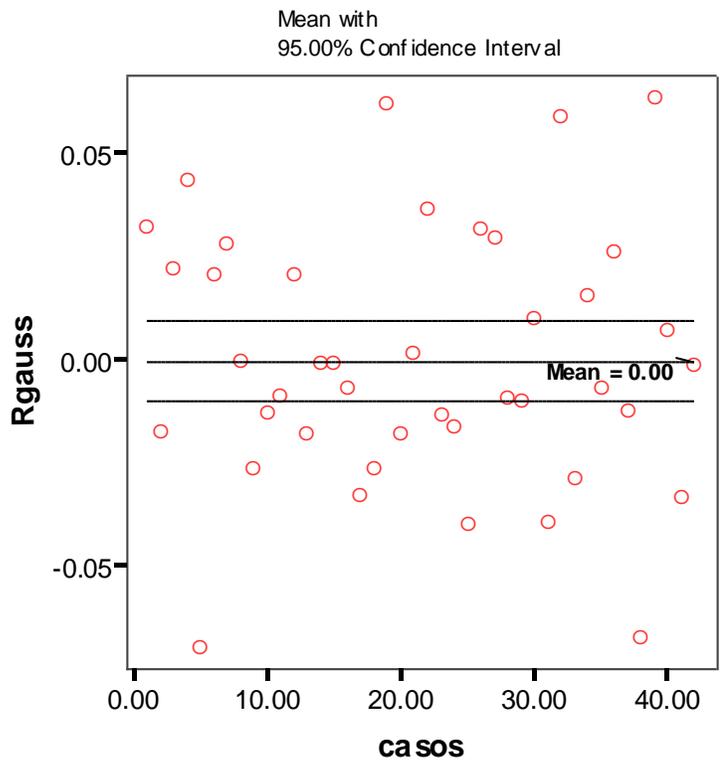
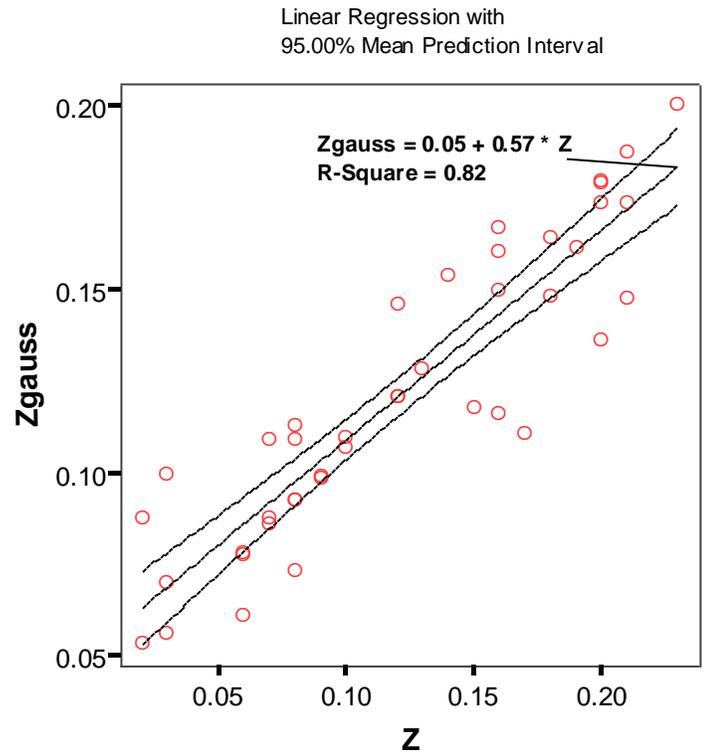
Anexo 38: Diagramas de dispersión de la intensidad de *Alternaria solani* Sor.. en la campaña 06_07. **Fuente:** Elaboración Propia.



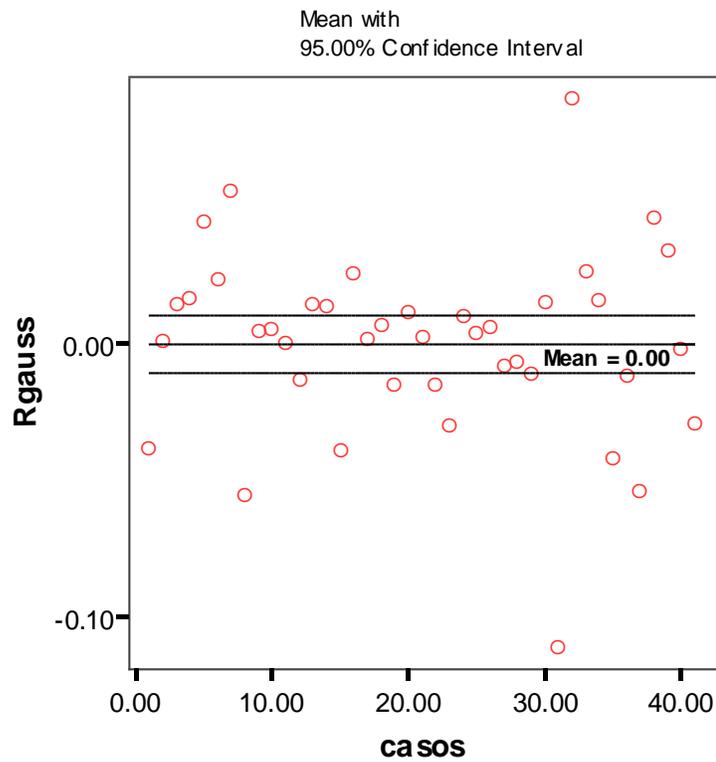
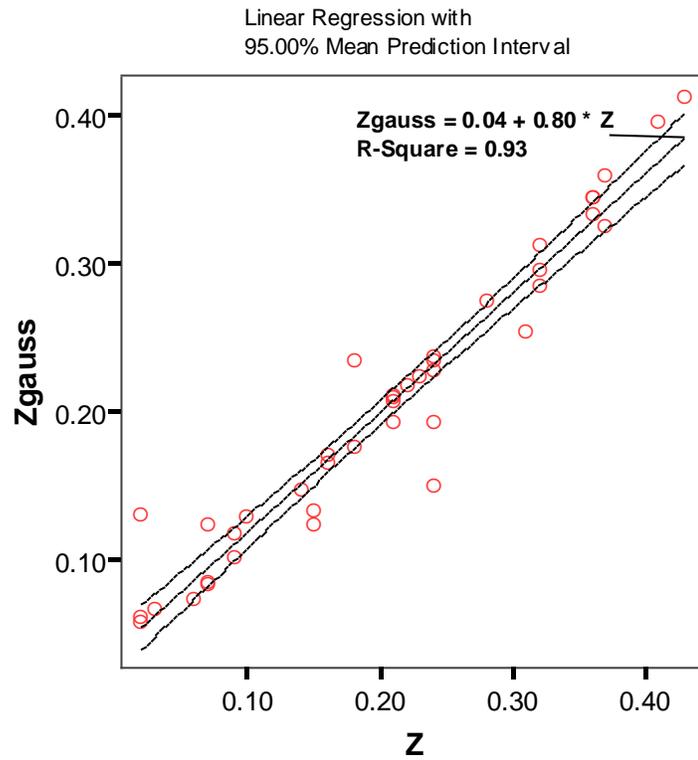
Anexo 39: Diagramas de dispersión de la intensidad de *Alternaria solani* Sor.. en la campaña 07_08. **Fuente:** Elaboración Propia.



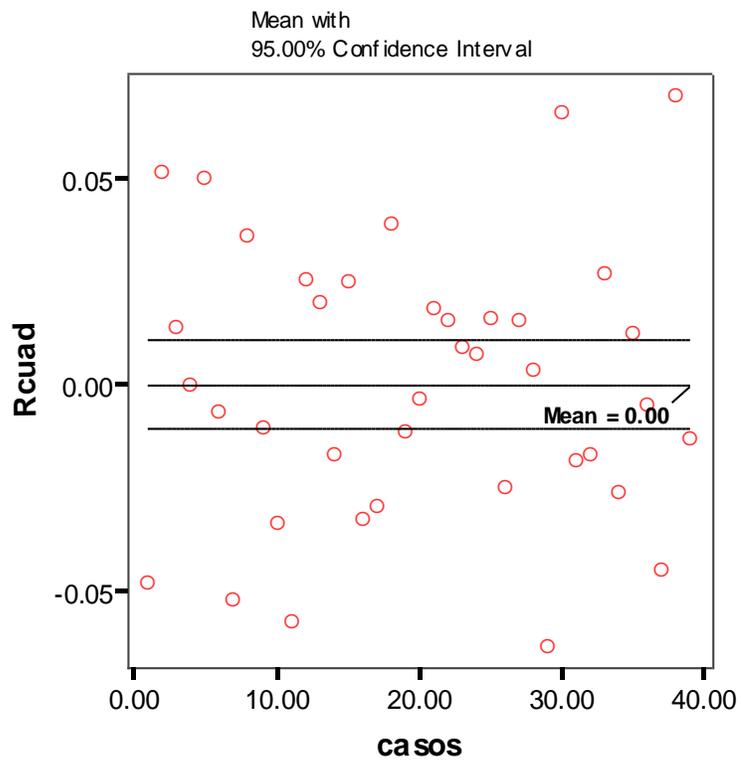
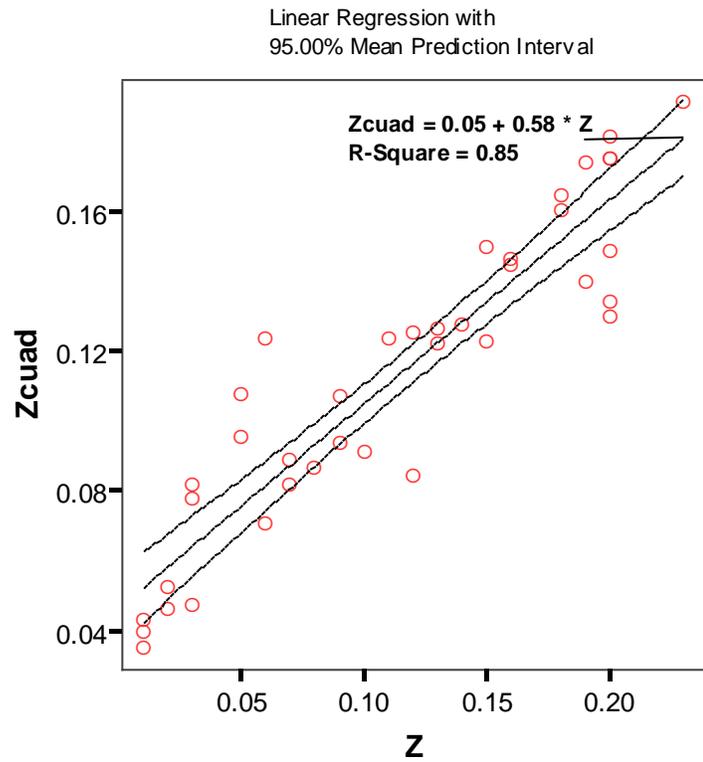
Anexo 40: Diagramas de dispersión de la intensidad de *Bemisia tabaci* Guen. en la campaña 03_04. **Fuente:** Elaboración Propia.



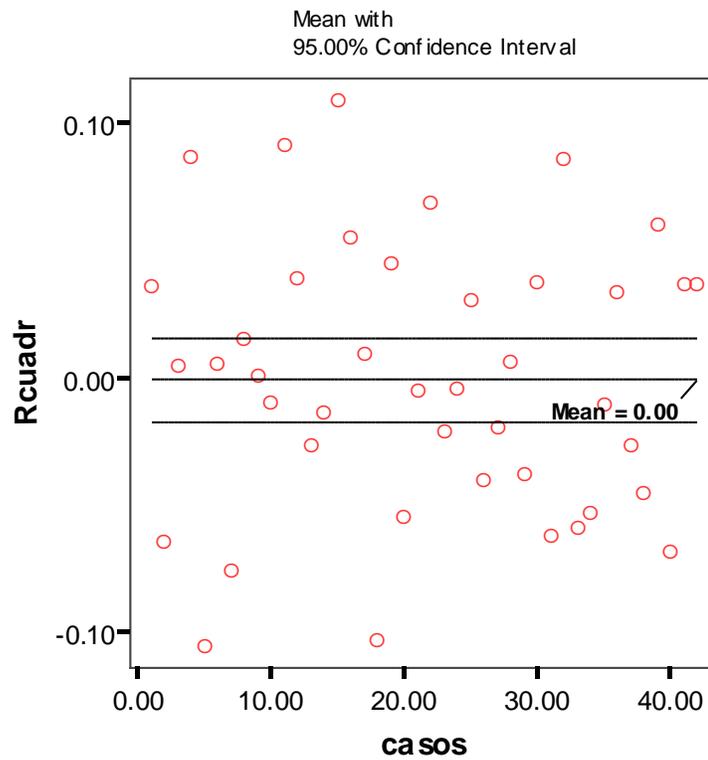
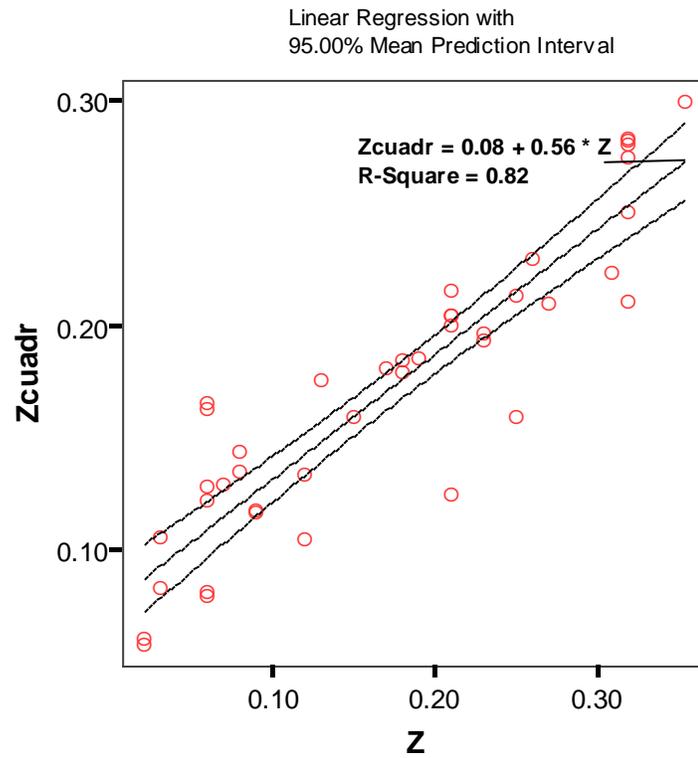
Anexo 41: Diagramas de dispersión de la intensidad de *Bemisia tabaci* Guen. en la campaña 04_05. **Fuente:** Elaboración Propia.



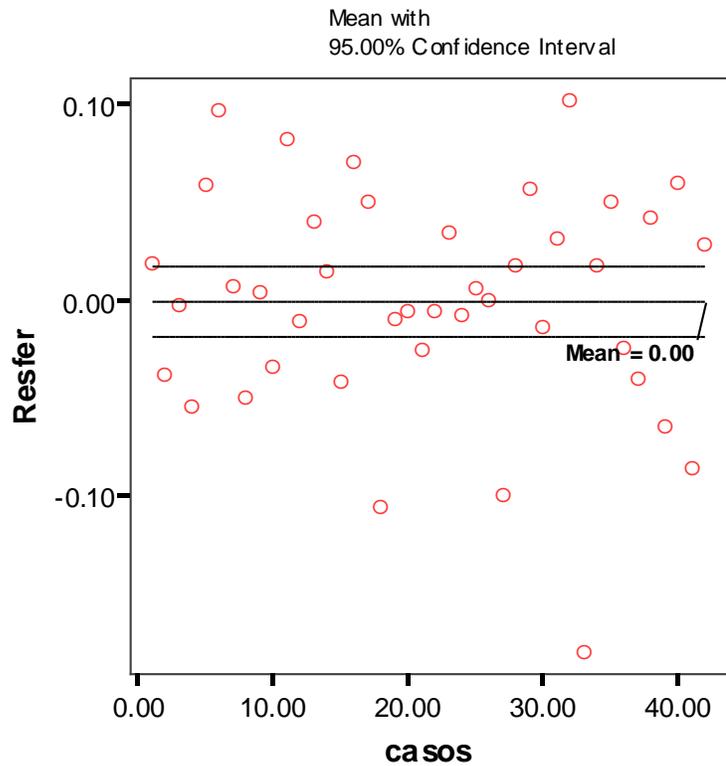
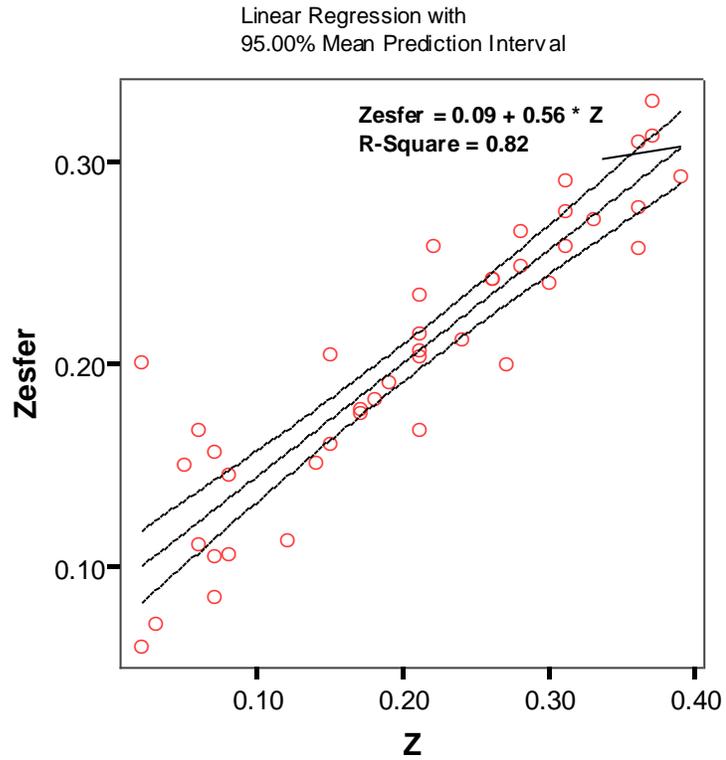
Anexo 42: Diagramas de dispersión de la intensidad de *Bemisia tabaci* Guen. en la campaña 05_06. **Fuente:** Elaboración Propia.



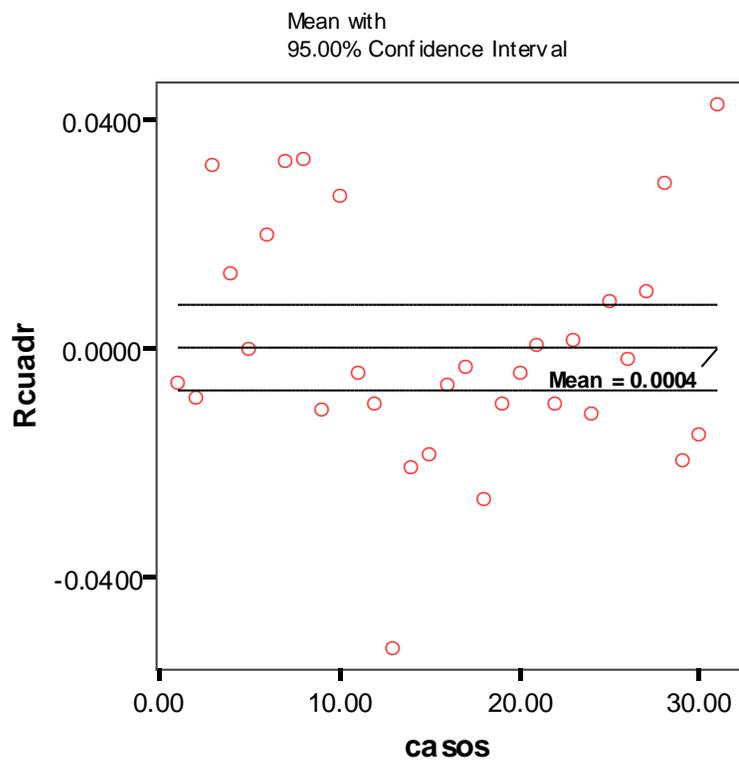
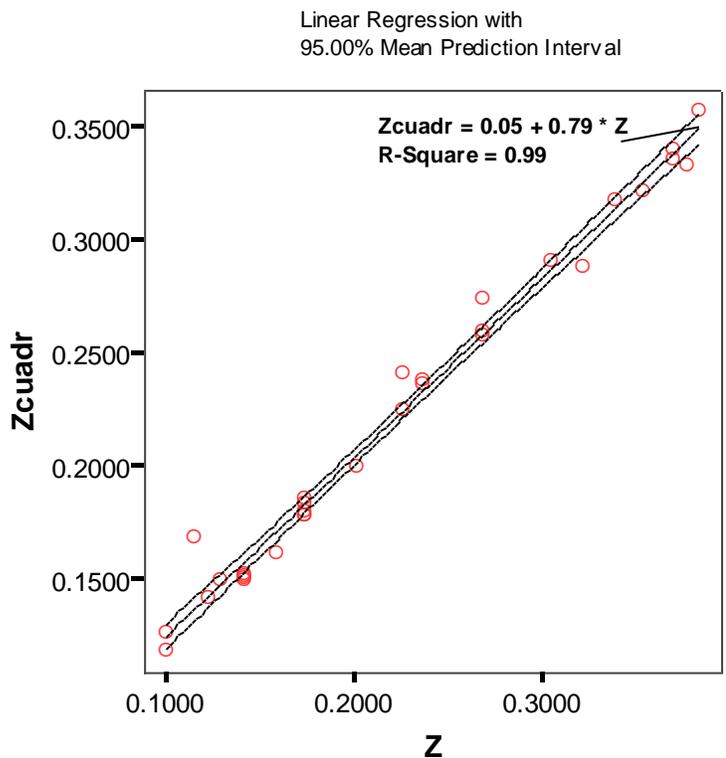
Anexo 43: Diagramas de dispersión de la intensidad de *Bemisia tabaci* Guen. en la campaña 06_07. **Fuente:** Elaboración Propia.



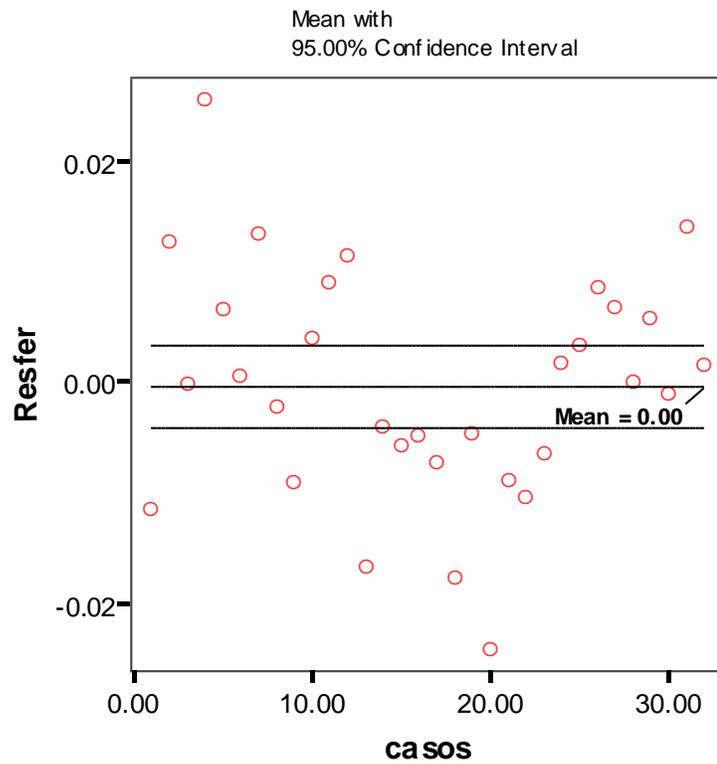
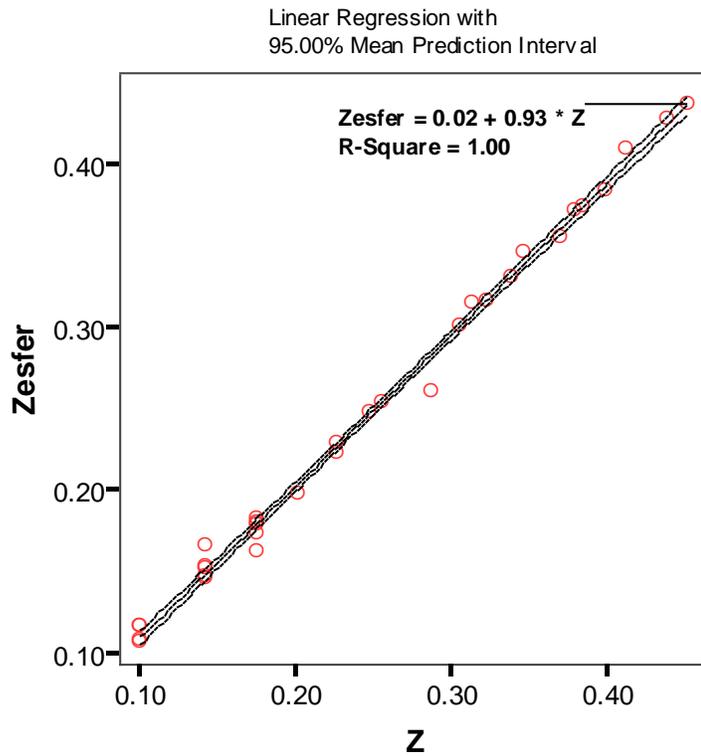
Anexo 44: Diagramas de dispersión de la intensidad de *Bemisia tabaci* Guen. en la campaña 07_08. **Fuente:** Elaboración Propia.



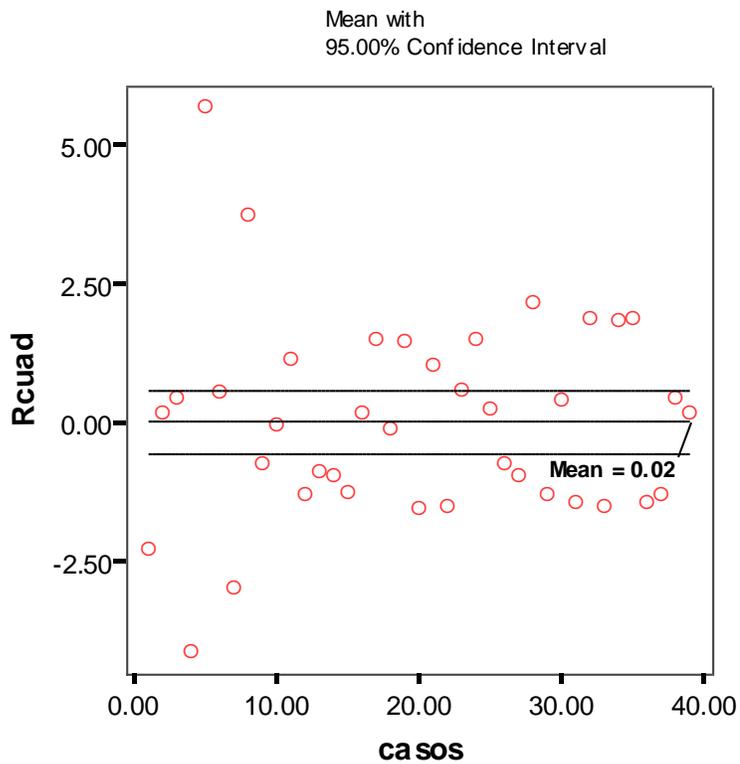
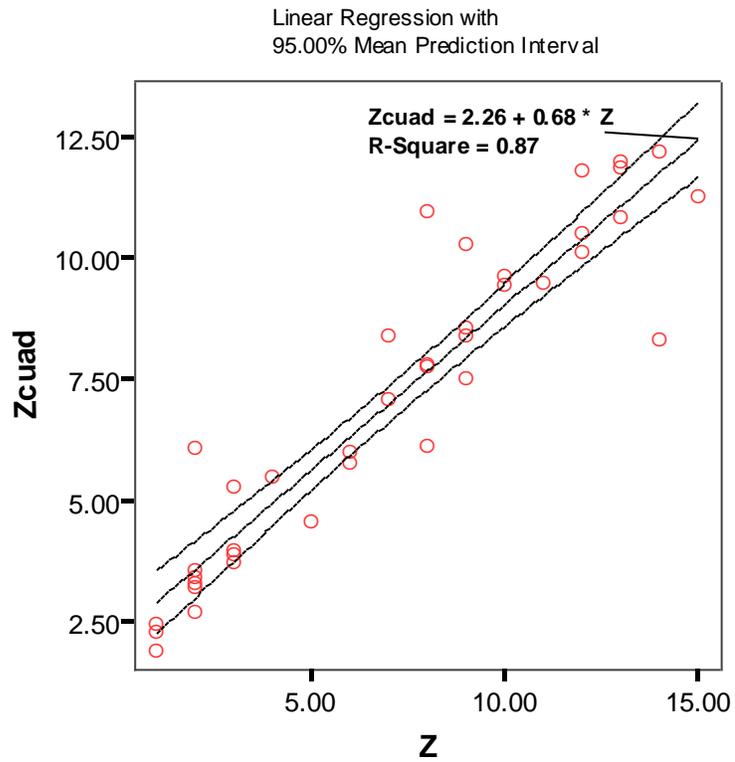
Anexo 45: Diagramas de dispersión de la distribución de la enfermedad viral en la campaña 03_04. **Fuente:** Elaboración Propia.



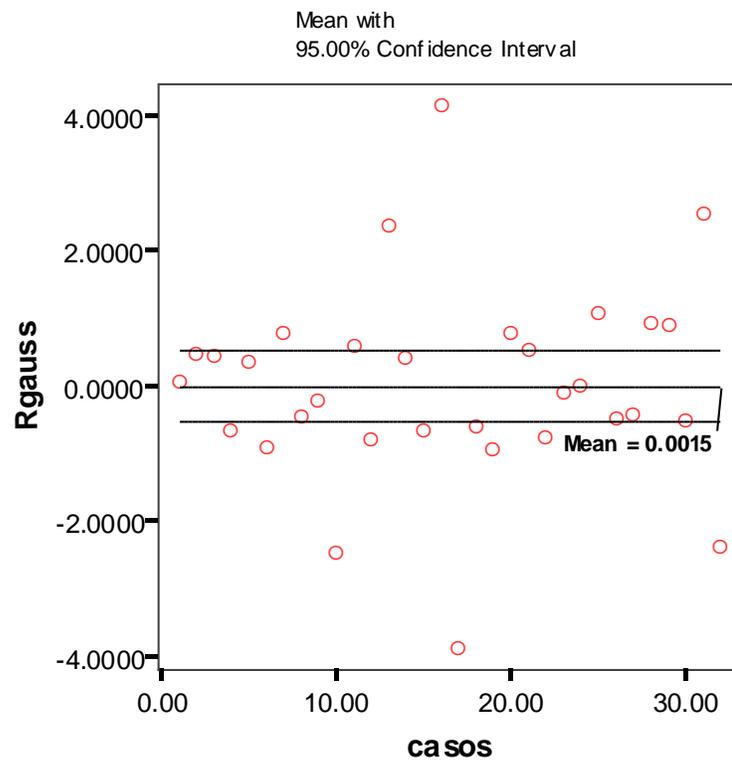
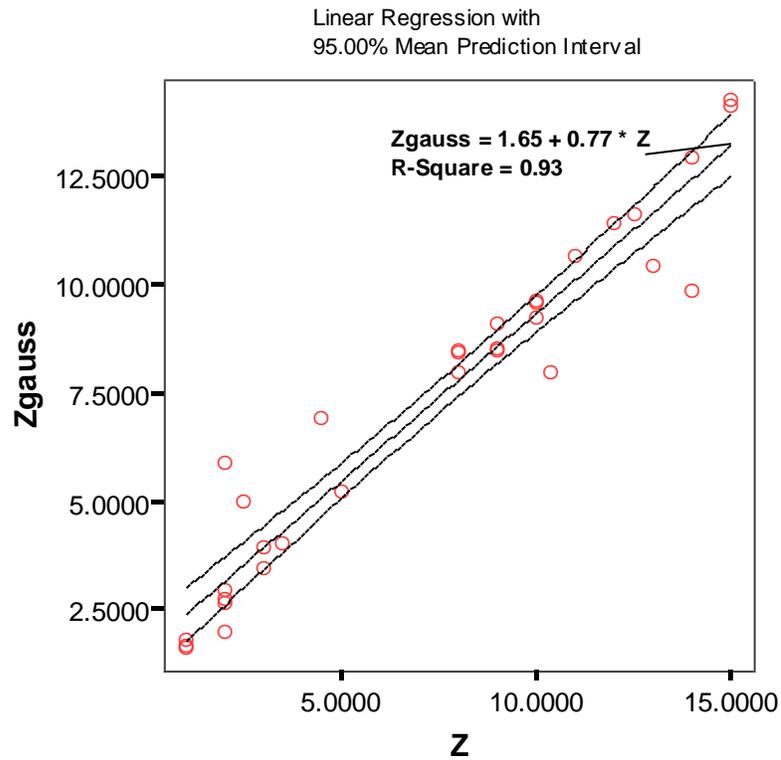
Anexo 46: Diagramas de dispersión de la distribución de la enfermedad viral en la campaña 04_05. **Fuente:** Elaboración Propia.



Anexo 47: Diagramas de dispersión de la distribución de la enfermedad viral en la campaña 05_06. **Fuente:** Elaboración Propia.



Anexo 48: Diagramas de dispersión de la distribución de la enfermedad viral en la campaña 06_07. **Fuente:** Elaboración Propia.



Anexo 49: Diagramas de dispersión de la distribución de la enfermedad viral en la campaña 07_08. **Fuente:** Elaboración Propia.

