

**Universidad Nacional de La Matanza
Licenciatura en Matemática Aplicada**



**MODELIZACIÓN MATEMÁTICA BASADA EN
VARIABLES METEOROLÓGICAS PARA
PREDECIR EPIDEMIAS VEGETALES**

Tesista: Magalí Robles Esteban

Director: Ing. Mg. Enrique Carlos Bombelli

Codirector: Ing. Mg. Dr. Ricardo Carlos Moschini

Profesores: Dr. Osvaldo Galardo

Lic. Jorge Barreto

Junio de 2015

Contenidos

1.	Introducción	4
1.1.	Definición	4
1.2.	Utilidad	4
1.3.	El problema	5
1.4.	La solución	6
1.5.	La construcción	6
1.6.	Principios de éxito	7
1.7.	Clasificación	8
1.7.1.	Según la información de entrada	8
1.7.2.	Según el tipo de representación	8
1.7.3.	Según la aleatoriedad	9
1.7.4.	Según su aplicación u objetivo	9
1.7.5.	Según su forma de programación	10
1.8.	Componentes	14
1.9.	Implementación y validación	16
2.	Fundamentación	16
3.	Contextualización	19
4.	Objetivos	21
5.	Metodología	21
6.	Resultados y Conclusiones	27
7.	Bibliografía	34

Figuras y Cuadros

Figura 1: Triángulo epidémico (adaptado de Zadoks y Schein, 1979). _____	17
Cuadro 1: Severidad acumulada y tasa epidémica diaria observada para <i>Alternaria tenuissima</i> , sobre arándano, en la localidad de San Pedro, durante cuatro ciclos epidémicos entre 2008 y 2012. _____	28
Cuadro 2: Severidad acumulada y tasa epidémica diaria observada para <i>Alternaria tenuissima</i> , sobre arándano, en la localidad de Concordia, durante cuatro ciclos epidémicos entre 2008 y 2012. _____	28
Cuadro 3: Coeficientes de correlación (Kendall Tau-b) de variables meteorológicas y del factor ligado a la senescencia foliar (Snc), en relación a los niveles de tasa de incremento epidémico diario (Tid%) ordinales (S, M, N) y binarios (S, M-N). _____	30
Cuadro 4: Estimadores de los parámetros de modelos de regresión logística ajustados para estimar la probabilidad de ocurrencia de cada categoría ordinal de Tid% epidémica (severo (S), moderado (M) y nulo (N), basado en variables meteorológicas y factor de senescencia foliar. _____	32
Cuadro 5: Estimadores de los parámetros de modelos de regresión logística ajustados para estimar la probabilidad de ocurrencia de cada categoría binaria de Tid% (severo (S), moderado a nulo (M-N), basado en variables meteorológicas y factor de senescencia foliar. _____	33

1. Introducción

1.1. Definición

Existen muchas definiciones de lo que significa un modelo, algunas de ellas son:

- Un modelo es una representación de la realidad (Lee, 1972).
- Un modelo es una representación explícita y externa de parte de la realidad como la ven las personas que desean usar el modelo para entender, cambiar, gestionar y controlar dicha parte de la realidad (Pidd, 1996).
- Básicamente todos los modelos son erróneos, aunque algunos son útiles (Box, 1987).

La primera de ellas resulta fácilmente comprensible por su simplicidad, la segunda es mucho más completa y la tercera provoca cierto desaliento.

Los modelos representan parte de la realidad, la cual resulta ser siempre más compleja que cualquier modelo, por más sofisticado que sea. Durante el proceso de modelado, se discriminan cuáles aspectos son relevantes y cuáles no, en función del objetivo que se pretende alcanzar. Al representar externa y explícitamente parte de la realidad, los modelos, permiten principalmente comprender un problema.

1.2. Utilidad

El primero de los aspectos que atiende un modelo es el relacionado con el entendimiento y comprensión de un problema, a través del comportamiento de la realidad. De hecho, en muchas oportunidades, el proceso de modelado puede tener

más valor que el modelo propiamente dicho. Es frecuente que para desarrollar un modelo se tenga que acceder a información a la que de otra manera quizás nunca se le habría prestado atención. Una vez construido el modelo, es posible ejecutarlo para conocer cómo reacciona el sistema. Asimismo, posibilita el reconocimiento de errores, factibles de corregir, en pos de un mejor funcionamiento del mismo.

Un segundo aspecto es el relacionado con su implementación en una computadora. Evidentemente, si se desea gestionar la información de manera eficiente, será necesario que el modelo tenga la capacidad de ser implementado y resuelto por algún tipo de sistema informático.

El tercer y último aspecto, se encuentra fuertemente relacionado al anterior, ya que el esfuerzo de los investigadores por desarrollar modelos de datos tiene como principal objetivo ayudar a la toma de decisiones.

1.3.El problema

Dado que el usuario no conoce suficientemente bien su problema, o bien no es capaz de explicitarlo como corresponde, recurre a los expertos en modelado de datos, quienes cumplen también una valiosa función como intérpretes de los mismos, en búsqueda de una solución. Asimismo, la mayoría de las veces, el número de actores implicados en un problema es en general alto y con perfiles muy diferentes entre sí. Es decir, que en la mayor parte de los casos el conocimiento sobre el problema real es pobre.

1.4. La solución

A partir del relato del problema, se genera información que podrá ser capturada y utilizada bajo la forma de datos, analizables de tal modo que generen nuevos datos conocidos como variables de salida. Esos datos por lo general son inútiles salvo que se transformen en información, capaz de resolver el problema.

En este sentido, es posible asignar tres significados a la solución del problema:

- Conjunto de variables que han adquirido determinado valor.
- La aplicación que generará información a partir de los datos disponibles.
- Desaparición del problema.

1.5. La construcción

En general, puede decirse que la construcción de un modelo abarca tres etapas:

- Definir el problema: Esta etapa implica el entendimiento del problema y acordar con el cliente los resultados a obtener.
- Modelar datos: En esta etapa, se debe definir el tipo de técnica a utilizar, generar el modelo y por último validarlo.
- Utilizar la solución: Ello implica la posibilidad de implementar el modelo de tal manera que el usuario lo utilice.

Es importante destacar, que cualquiera de las etapas citadas, puede exigir replantearse siempre la vuelta al principio del proceso.

1.6. Principios de éxito

Existen algunos principios generales que pueden considerarse útiles a la hora de modelar datos:

- **Simplicidad:** Si bien un modelo puede resultar complejo en su construcción, dicha complejidad debe traducirse en una interfaz de uso “amigable” para el usuario, de manera que no deba realizar un gran esfuerzo por comprender, cómo cargar datos, interpretar resultados, etc.
- **Modelar paso a paso:** Construir un modelo considerando todos los aspectos simultáneamente, puede implicar errores y la no optimización de los tiempos de concreción. Es importante aislar la complejidad del modelo en pequeñas partes o secciones que se unirán en el momento oportuno.
- **Utilizar analogías, metáforas y similitudes:** Se refiere básicamente a abordar la realidad desde varios puntos de vista, a fin de encontrar la mejor solución de modelado, y no como se percibe a primera vista.
- **No deben conformar el modelo los datos disponibles:** Uno de los errores que se comete bastante a menudo, es retrasar el modelado hasta que se dispone de los datos. El camino debe ser exactamente al revés, el modelo es el que debe requerir datos, y no los datos conformar el modelo, siendo necesario definir y desarrollar las líneas básicas del modelo y una vez hecho esto, definir la estructura de datos necesarios.
- **Modelar explorando:** Teniendo en cuenta que un modelo es el resultado de intentar representar parte de la realidad para principalmente tomar decisiones, se podría pensar que el proceso de modelado es de carácter lineal. Sin

embargo, la experiencia demuestra que en general no es así, sino que muchas veces se producen retrocesos, cambios de perspectiva e incluso de herramientas de modelado.

1.7. Clasificación

1.7.1. Según la información de entrada

El origen de la información utilizada, para construir modelos, puede clasificarse de otras formas. Así, es posible distinguir entre modelos heurísticos y empíricos:

- Heurísticos (hallar, inventar): Son los que están basados en la explicación de las causas o mecanismos naturales que dan lugar al fenómeno estudiado.
- Empíricos (relativo a la experiencia): Son los que utilizan la observación directa o los resultados de experimentos del fenómeno estudiado.

1.7.2. Según el tipo de representación

Los modelos matemáticos encuentran distintas denominaciones según el campo de aplicación. Una posible clasificación puede atender a si pretenden hacer predicciones de tipo cualitativo o cuantitativo:

- Cualitativos (conceptuales): Pueden usar figuras, gráficos o descripciones causales. Generalmente, se contentan con predecir si el estado del sistema irá en determinada dirección, si aumentará o disminuirá alguna magnitud, sin importar exactamente la dimensión concreta de la mayoría de los factores estudiados.

- **Cuantitativos (numéricos):** Utilizan números para representar factores del sistema, y generalmente incluyen fórmulas y algoritmos matemáticos más o menos complejos, que relacionan los valores numéricos entre sí. El cálculo con los mismos, permite representar el proceso físico o los cambios cuantitativos del sistema.

1.7.3. Según la aleatoriedad

Si para una situación inicial o entrada de datos concreta puede corresponder o no diversas salidas o resultados, el modelo se clasifica en:

- **Determinista:** Es decir, que se conoce de manera puntual la forma del resultado, ya que no existe incertidumbre. Además, los datos utilizados para alimentar el modelo son completamente conocidos y determinados.
- **Estocástico:** O sea, probabilístico. No se conoce el resultado esperado, sino su probabilidad, existiendo por tanto cierto grado de incertidumbre.

1.7.4. Según su aplicación u objetivo

Si bien se reconocen por lo general tres áreas básicas, pueden existir otras:

- **De simulación (descriptivo):** Corresponde a situaciones medibles de forma precisa (programación lineal) o aleatoria (probabilística o heurística). Este tipo de modelos pretende predecir qué sucede en una situación específica.
- **De optimización:** Sirve para determinar el punto exacto, a fin de resolver alguna problemática de carácter administrativa, productiva, o cualquier otro tipo. Cuando la optimización es entera o no lineal, combinada, dichos

modelos resultan poco prácticos para realizar predicciones, sin embargo, pueden acoplarse a alguna alternativa existente u aproximada en su cuantificación. Asimismo, son modelos que requieren la comparación de diversas condiciones, casos o posibles valores de un parámetro, a fin de determinar cuál de ellos resulta óptimo según un determinado criterio elegido.

- De control: Para saber con precisión en qué estado de situación, se encuentra algo en una organización, investigación, área de operación, u otro ámbito, es justamente este, el modelo que sustenta las decisiones acerca de qué nuevas medidas, variables o parámetros deben ajustarse, para lograr un resultado o estado concreto del sistema que se está modelando.

1.7.5. Según su forma de programación

- De programación lineal: Son los de uso más generalizado. En su forma más básica, consiste en un conjunto de variables reales, que mediante la combinación lineal de parámetros ciertos, permite establecer un objetivo y cierto conjunto de restricciones lineales. Los fundamentos matemáticos de los modelos lineales se encuentran en la Teoría de las Desigualdades Lineales, desarrollada en el siglo XIX (Poler, 2001). Aunque existen antecedentes en distintos campos disciplinarios, el proyecto SCOOP (lanzado en 1947 por la fuerza militar aeronáutica de Estados Unidos), constituye la formulación y resolución general de los problemas en base a la programación lineal, habiendo dado lugar al algoritmo denominado Simplex, desarrollado inicialmente por Dantzig en 1947. En menos de 10 años, la programación lineal experimentó un fuerte desarrollo con trabajos que abordaron, entre

otros temas, la degeneración, la dualidad y las formas compactas. Actualmente es posible encontrar en el mercado, tanto aplicaciones gratuitas como comerciales para la resolución eficiente de problemas en base a la programación lineal (GUROBI, CPLEX, XPRESS, LINDO, QSB, etc.), siendo un avance significativo de los últimos años el desarrollo de paquetes que facilitan la introducción del modelo y la integración del mismo en los sistemas de información disponibles. La mayor parte de estos paquetes utilizan (o han utilizado) el denominado método Simplex. Dicho método, aunque computacionalmente ineficiente, tiene la ventaja de ser metódico y permitir explicar, mediante el propio método, algunos conceptos complejos tales como precios sombra o costos reducidos. Hasta finales de la década del '80, no surgen como alternativa válida los denominados métodos del punto interior. El menor costo computacional de este tipo de algoritmos, hace que su implantación en los paquetes comerciales sea creciente. Por último, cabe destacar, que aunque para el observador no experimentado la exigencia de linealidad puede parecer excesivamente restrictiva, la realidad es que un gran número de problemas reales puedan ser modelados bajo esa consideración (Williams, 1999). La ventaja de estos modelos, frente a los de programación no lineal, es que para estos últimos no se conocen modelos generales de resolución eficientes.

- De programación lineal entera: Si a alguna de las variables de un problema lineal, se le impone la condición de integridad, el problema pasa a ser de programación lineal entera mixta. Si todas son variables enteras, el problema pasa a ser de programación lineal entera. La condición de integridad puede

venir impuesta, entre otros motivos, por el imposible fraccionamiento de determinados recursos. Uno de los procedimientos más efectivos para la resolución de este tipo de problemas se fundamenta en el concepto de ramificación y cota. Desgraciadamente, aunque la lógica de este procedimiento es eficaz, conduciendo necesariamente al óptimo, el costo computacional en algunos problemas es, aún hoy día, sumamente oneroso. Otro procedimiento para la resolución de estos problemas, se basa en los métodos de planos cortantes. Aunque este método generó grandes expectativas, por ahora no han brindado resultados lo suficientemente eficientes. Una variante especial de los problemas de programación lineal entera, lo constituyen aquellos donde algunas variables son bivalentes. El uso de este tipo de variables, tiene su origen en la representación de aquellas decisiones que sólo admiten dos valores, pero también aquellos que exigen restricciones de tipo lógico. La pretensión de resolver estos problemas de modo eficiente, ha dado lugar a métodos como el de enumeración implícita o técnicas más generales como las descritas en Kauffmann y Henry-Labordere, en el año 1976. Hay que destacar la existencia de algunos tipos especiales de problemas con variables bivalentes, que se abordan mediante métodos específicos de resolución, óptimos en algunos casos y más eficientes por haber sido desarrollados "ex profeso". Algunos de estos problemas son los de cubrimiento, asignación, partición, mochila y rutas (Williams, 1999).

- De programación estocástica: Cuando se incorpora la incertidumbre en los parámetros, esta puede abordarse mediante la denominada programación estocástica. Una variante de la misma, especialmente interesante, es la

programación lineal estocástica, que puede ser resuelta de modo óptimo, aunque con un costo computacional elevado. Uno de los mecanismos para abordar la incertidumbre de los datos, es el uso de los denominados escenarios. Estos constituyen un posible conjunto de valores para los parámetros. Cada uno de estos escenarios pueden tener una probabilidad asociada aunque no necesaria (Dembo, 1991). Existen diferentes modos de formular un problema de programación lineal por medio de la estocástica, aunque básicamente consiste en obtener una decisión para el instante actual teniendo en cuenta los escenarios futuros. De este modo, la decisión a tomar no será óptima, para ninguno de los escenarios. aunque sí para el conjunto de ellos, hablando en términos generales. Este modo de plantear y resolver un problema, tiene un elevado costo computacional, tal como fue mencionado anteriormente, pero se puede abordar mediante descomposiciones y computación en paralelo con índices de paralelización elevados. Otro modo de abordar la estocasticidad de los parámetros, es obtener el óptimo para cada escenario y comparar el valor de decisión que tendría para el resto de escenarios, eligiendo como decisión definitiva la más buena, la menos mala o cualquier otro mecanismo que se considere adecuado.

- De programación no lineal: Cuando se elimina la linealidad a la función objetivo o a las restricciones o supuestos, se obtienen modelos de programación no lineal. La eliminación del requerimiento de linealidad, se suele fundamentar en la estructura no lineal del objeto, o parte de él, a modelar. En realidad debiera ser planteado al revés, dado que la realidad es generalmente no lineal y al linealizar estamos forzando el modelo. Sin

embargo muchas de las circunstancias aparentemente no lineales, pueden ser linealizadas sin pérdida de significado. El motivo de la aparente obsesión por la linealidad, se basa fundamentalmente en la falta de eficacia para la obtención de óptimos, mediante el uso de procedimientos actualmente existentes para la resolución de problemas no lineales en general. De hecho, la no linealidad, impide garantizar siempre la detección de un óptimo, aún habiéndolo encontrado. El teorema de optimalidad de Karush Kuhn y Tucker (KKT) establece las condiciones necesarias aunque no suficientes para los problemas no lineales.

1.8. Componentes

En términos básicos, un modelo matemático, posee dos componentes:

- Datos: Valores constantes y conocidos.
- Variables: Valores calculados.

Mediante la combinación en forma lineal, de los mismos es posible general:

- Función objetivo: Puede maximizarse o minimizarse.
- Restricciones o supuestos: Límites al espacio de soluciones posibles.

Tanto la función objetivo como las restricciones, es posible expresarlas matemáticamente mediante el uso de variables regresoras, pretendiendo definir uno o varios valores para dichas variables, de modo tal que sea factible obtener la mejor valoración de la función objetivo, siempre y cuando se cumplen todas las restricciones o supuestos.

En su formulación básica los modelos matemáticos tienen una función objetivo y una o más restricciones. Sin embargo pueden existir excepciones como:

- **Objetivos múltiples:** Un modelo de Programación Matemática exige normalmente una única función objetivo que, como dijimos, debe ser maximizada o minimizada. Esto sin embargo, no implica que no se puedan abordar problemas con múltiples funciones objetivo. De hecho, existen diferentes métodos de modelado y posterior resolución que se pueden aplicar en estos tipos de problemas. Numerosos autores relacionan la Programación Multi-Objetivo con la Teoría de la Decisión.
- **Objetivos nulos o no existentes:** En ocasiones, al plantear el problema, puede resultar difícil establecer un único objetivo para resolverlo, más allá de encontrar una solución que satisfaga las restricciones. En ese caso, es conveniente fijar un objetivo sencillo ligado a una única variable. Aunque la experiencia muestra una y otra vez, que una vez obtenida una solución factible, el usuario acaba encontrando un modo de distinguir una solución de otra peor.
- **Restricciones nulas o no existentes:** Los problemas de optimización sin restricciones, pretenden minimizar (o maximizar) una función real $f(x)$, donde x es un vector de n variables reales. Es decir se busca un x^* tal que $f(x^*) \leq f(x)$ para todos los x cercanos a x^* . En el caso de un problema de optimización global, el x^* buscado es el que minimiza f para todo el espacio $x \in \mathbb{R}^n$.

1.9. Implementación y validación

Un modelo matemático, aún desarrollado bajo el formato papel, debe ser consistente. Su posterior transformación a un formato que permita resolverlo adecuadamente, nos informará acerca de los posibles errores que el mismo posee.

Antes de poner toda la atención en la solución obtenida, tras resolver el modelo que se haya construido, se debe comprobar que se ha modelado lo que se pretendía. Asumiendo que no existen errores de tipo sintáctico (generalmente existen aplicaciones informáticas para detectarlos fácilmente) existen tres salidas que en general se recorrerán sucesivamente. Estas refieren a que el modelo sea incompatible, que no esté acotado y que sea resoluble. Aún llegado a este punto, cabe esperar dos situaciones, que el modelo sea resoluble, pero que sus soluciones no sean coherentes con el problema. Por último que el modelo sea resoluble y sus soluciones sean coherentes. Si se alcanza este punto, el modelo está listo para ser utilizado.

2. Fundamentación

Desde el punto de vista de la alimentación a escala mundial, las enfermedades que afectan a los cultivos, causan pérdidas significativas (De Wolf e Isard, 2007). Al menos el 10% de las pérdidas de la cosecha global, es explicado por las enfermedades, en parte responsables, del sufrimiento de ochocientos millones de personas que carecen de una alimentación adecuada (Strange y Scott, 2005). Estadísticas como éstas, son las que motivan a muchos investigadores

(fitopatólogos) a buscar nuevas formas de reducir el impacto de las enfermedades en la cosecha (De Wolf e Isard, 2007).

Particularmente, la fitopatología se dedica al desarrollo y uso de prácticas que reduzcan el efecto nocivo de una enfermedad sobre lo que será nuestra comida (Maloy, 1993). Estas prácticas deben ser económicamente posibles de llevar a cabo y aceptables desde lo ambiental (Campbell y Madden, 1990). La comprensión de los factores que desencadenan el desarrollo de epidemias vegetales, son esenciales si deseamos desarrollar y ejecutar estrategias eficaces para el manejo de una enfermedad. La interacción sincrónica entre hospedante, patógeno, y ambiente, gobierna el desarrollo de una enfermedad (Figura 1).



Figura 1: Triángulo epidémico (adaptado de Zadoks y Schein, 1979).

Estas interacciones se pueden conceptualizar como una secuencia continua o ciclo de acontecimientos biológicos que incluyen inactividad, reproducción, dispersión, y patogénesis (De Wolf e Isard, 2007). Aunque los fitopatólogos saben y reconocen, desde hace tiempo, la importancia de estos acontecimientos, Gaumann (1950) fue el primero en evaluar críticamente la progresión de acontecimientos que llevan al desencadenamiento de la enfermedad (Campbell y Madden, 1990; Maloy, 1993). Gaumann (1950) denominó a esta secuencia continua de eventos “cadena de la infección”, sin embargo, más recientemente han entrado en boga los términos “ciclo

de la enfermedad” o “ciclo de la infección” (Maloy, 1993; Kranz, 2003). La descripción y cuantificación del ciclo de una enfermedad, es la base fundamental de la epidemiología vegetal y constituye la llave para desarrollar un manejo eficaz de la misma (De Wolf e Isard, 2007).

La cuantificación de la distribución espacial de una enfermedad, proporciona información importante sobre potenciales fuentes de inóculo, así como también la extensión de la misma en una región agrícola (De Wolf e Isard, 2007). Uno de los usos más importantes de la epidemiología vegetal, lo constituye el poder predecir cuándo una enfermedad aumentará a un umbral que cause pérdidas económicamente significativas (Campbell y Madden, 1990). La predicción de la enfermedad en días o semanas antes de que una epidemia ocurra, permite que los productores respondan de manera oportuna y eficiente ajustando las prácticas de manejo de cultivos (Maloy, 1993). Dado un plazo de ejecución suficientemente largo, las predicciones de una enfermedad podrían ayudar a los productores a decidir qué cultivares utilizar y cuándo sembrarlos. Podría ayudarles también a programar la fertilización, la irrigación, la rotación de cultivos, y otras prácticas culturales (De Wolf e Isard, 2007).

Por otra parte, una predicción de bajo riesgo de ocurrencia de una enfermedad, puede dar lugar a un uso reducido de pesticidas, con positivas consecuencias económicas y ambientales (De Wolf e Isard, 2007).

3. Contextualización

El mencionado triángulo epidémico (Figura 1), a través de sus componentes: Patógeno, Hospedante y Ambiente, constituye la base conceptual en la que se sustenta este trabajo, el cual se encuadra en el área de la Epidemiología Vegetal, una de las que posee mayor potencial de trabajo dentro de la Fitopatología, en relación a la construcción de modelos de predicción.

El hospedante lo constituye el cultivo de arándano (*Vaccinium corymbosum*) cv. O'Neal, representado por un grupo de especies nativas, principalmente del Hemisferio Norte. Su importancia radica en la superficie implantada (5000 hectáreas para la campaña 2009/2010) y su destino, casi totalmente a la exportación (más de 12000 toneladas para la campaña 2009/2010) hacia el Hemisferio Norte y Europa, con valores que en períodos de contraestación pueden alcanzar los 28 U\$/kg (Pazos, 2005).

El patógeno está representado por el hongo *Alternaria tenuissima*, microorganismo de mayor incidencia y prevalencia en todas las localidades y épocas del año (Wright *et al.*, 2005; Wright *et al.*, 2007; Wright y Pérez, 2007). En 2002 se informó de aproximadamente un 20% de descarte de poscosecha en cultivos de la Provincia de Buenos Aires, identificándose a *Alternaria tenuissima* como el principal agente causante del reblandecimiento en frutos (Wright *et al.*, 2003; Wright *et al.*, 2004).

Por último, el ambiente, refiere a dos condiciones meteorológicas que deben darse en forma conjunta para que se produzca la infección: Temperaturas del orden de los 20 a 28°C, y elevada humedad ambiental.

Por todo lo mencionado, se hace necesario encarar acciones planificadas para la protección de dicho cultivo, frente a enfermedades, como la que se menciona en apartados anteriores, que deterioran la calidad de los frutos y disminuyen los rendimientos.

En tal sentido, los modelos matemáticos y estadísticos, son los que permiten representar lo que sucede en los cultivos, frente a distintos patógenos y en diferentes condiciones ambientales (Campbell y Madden, 1990). Los mismos se desarrollan dependiendo de los objetivos del trabajo, los datos disponibles, el tipo de experimento y la experiencia del investigador. En general, se utilizan dos estrategias para el modelado de datos epidemiológicos: Los modelos empíricos¹ y los mecanísticos². El caso que nos ocupa, utiliza el primero de ellos, como forma de describir el progreso epidémico, a través de la relación observada entre dos o más variables, basándose en algunos o todos los factores capaces de expresar la enfermedad.

¹ Los modelos empíricos, también llamados descriptivos, son los que predicen cómo una variable afecta una respuesta. Se sustentan en la identificación de relaciones estadísticamente significativas entre ciertas variables que se asumen como esenciales y suficientes para modelar el comportamiento del sistema. Con tal motivo, debe disponerse previamente de una base de datos de tamaño adecuado (Duek, 1979).

² Los modelos mecanísticos, también llamados explicativos, intentan representar la causalidad e interacción entre las variables a fin de imitar matemáticamente la estructura y funcionamiento de un sistema (Duek, 1979).

4. Objetivos

Objetivo general

Desarrollar modelos matemáticos que permitan predecir adecuadamente el comportamiento de la mancha foliar provocada por el patógeno *Alternaria tenuissima* en el cultivo de arándano.

Objetivos específicos

Colectar registros de enfermedad en localidades representativas desde el punto de vista productivo, que se encuentren cercanas a estaciones meteorológicas.

Colectar registros meteorológicos que permitan elaborar las variables meteorológicas que serán tenidas en cuenta para el desarrollo de los modelos matemáticos de predicción.

Organizar los registros de enfermedad y las variables meteorológicas, sobre la base de ciertas reglas, tal que permitan realizar distintas simulaciones para así poder arribar a modelos matemáticos, que a través de la cuantificación de la relación ambiente/enfermedad, permitan predecir niveles de ocurrencia futuros.

5. Metodología

Colección de datos de severidad y elementos meteorológicos

Construcción de bases de datos

Durante las campañas 2008/09 a 2011/12 se recorrieron cultivos de arándano (cultivar O'Neal) en las localidades de San Pedro (59° 38' S; 33° 44' O) y

Concordia (31° 19' S; 58° 5' O). Sobre cada una de las parcelas predefinidas para cada sitio, se seleccionaron cuatro filas consecutivas, de las cuales se evaluaron las dos internas. Las plantas se seleccionaron a intervalos regulares de 12 ejemplares, de manera de tener distancias uniformes entre ellas. A su vez, dentro de cada planta, se identificaron una rama denominada *interna* y otra *externa*, según sus posiciones en la corona, con el fin de que las sucesivas mediciones a lo largo del ciclo productivo se realicen siempre sobre las mismas ramas. Las observaciones se llevaron a cabo durante primavera y verano, a intervalos variables. Sobre plantas de las dos filas externas, se tomaron muestras de tejidos afectados con síntomas similares a los observados en los ejemplares evaluados, para determinar en laboratorio el o los patógenos asociados a la sintomatología foliar evaluada.

Se construyó una base de datos a partir de los registros de severidad de cada planta evaluada, en cada sitio y momento del ciclo productivo, el tiempo transcurrido hasta su aparición, los valores de la misma a intervalos de tiempo definidos y los datos meteorológicos (precipitación, temperatura máxima y mínima y humedad relativa) en un período previo a cada medición (a partir de los registros de estaciones meteorológicas de cada localidad).

Desarrollo de modelos de regresión logística

- *Variable respuesta*

Los valores de Tasa de Incremento Epidémico Diario (TId%) de las curvas de progreso epidémico seleccionadas (Tabla 1) se categorizaron binariamente en función de un valor umbral en (Severo S: $TId\% \geq 0,045$ y Moderado a nulo M-N: $TId\% < 0,045$) y ordinalmente en (Severo S: $TId\% \geq 0,045$; Moderado M: $TId\% < 0,045$

y >0 ; Nulo $N_{Tid\%}=0$). El valor umbral 0,045 correspondió al percentil 70% de los 48 valores de $Tid\%$ observados.

- *Variables dependientes regresoras*
 - *Variables meteorológicas*

Las estaciones meteorológicas de San Pedro (INTA) y Concordia (SMN) registraron diariamente la temperatura máxima (T_x), temperatura mínima (T_n), precipitación (Pr) y humedad relativa (HR), esta última como promedio tridiurno. La temperatura media diaria (T_m) fue calculada como la semisuma de las temperaturas máxima y mínima. Basados en estos elementos se construyeron las siguientes variables meteorológicas simples:

- ♦ DT_{xnP} : Número de días con $T_n > \text{umbral}$ (intervalo analizado: 12 a 16°C) y $T_x < 36^\circ\text{C}$.
- ♦ DT_n : Número de días con $T_n \leq \text{umbral}$ (intervalo: 8 a 16°C).
- ♦ DT_{xnN} : Número de días con $T_n \leq \text{umbral}$ (intervalo: 8 a 16°C) o $T_x \geq \text{umbral}$ (intervalo: 36 y 37°C).
- ♦ T_xM : Temperatura máxima media.
- ♦ T_nM : Temperatura mínima media.
- ♦ FPr : Días con registros de $Pr > 0,2$ mm.
- ♦ $PrAc$: Acumulación de precipitaciones $> 0,2$ mm.
- ♦ $DPrHR$: Número de días con registros de $Pr > 0,2$ mm y $HR > 81\%$.
- ♦ $DPrT$: Número de días con registro de $Pr > 0,2$ mm, en el intervalo térmico: $T_x < \text{umbral}$ (30 a 37°C) y $T_n > \text{umbral}$ (10 a 16°C).
- ♦ DHR : Número de días con $HR > 81\%$.

- *Variable ligada al grado de senescencia foliar (Snc)*

Dicha variable, toma valores de 1 a 4 de acuerdo al cuartil en el que se encuentra la observación respecto a la duración máxima de las curvas de progreso epidémico analizadas por sitio (260 días en San Pedro, 237 días en Concordia). Por ejemplo, si en Concordia se está a 141 días del inicio de la epidemia simulada: $141/237=0,59$ o sea tercer cuartil: $Snc=3$.

Lapso de procesamiento de las variables

Las variables fueron calculadas en lapsos de 28 días previos a cada valor de TId%, a lo largo de cada curva de progreso epidémico.

Para evaluar la asociación entre las variables regresoras con la epidémica se desarrolló un programa basado en el lenguaje de programación del software Statistical Analysis Systems, version 8.0, SAS Institute, Inc., Cary, NC, USA (SAS) (Moschini, 2007).

Análisis estadístico

El procedimiento *Freq* de SAS, fue usado para calcular los coeficientes de correlación no-paramétrica de Kendall Tau-b (r_k) entre las categorías ordinales de TId% epidémicas (S, M y N) y binarias (S y M-N) y las variables regresoras.

Mediante técnicas de regresión logística (Hosmer and Lemeshow, 2000), se desarrollaron modelos para estimar las probabilidades de ocurrencia de las categorías binarias y ordinales de TId%. El procedimiento *Logistic* de SAS, se usó para ajustar modelos de regresión para datos de respuesta binaria y ordinal por el

método de máxima verosimilitud. Una función *Logit* (logaritmo natural de $(P/1-P)$, siendo “P” la probabilidad acumulada de las categorías epidémicas) establece la unión entre el componente estocástico y las variables regresoras analizadas. El procedimiento *Logistic* ajusta un modelo de regresión de líneas paralelas a observaciones de respuesta ordinal. Uno de los supuestos de la regresión logística ordinal es que la relación de cada par de categoría de salida es la misma (un estadístico Chi cuadrado fue calculado para verificar este supuesto). En este estudio, los niveles de TId% fueron tratados en orden descendente (severo a nulo). En respuesta ordinal, cada modelo logístico ajusta 2 ecuaciones, una estima $\ln[PS/(1-PS)]=\alpha_S+\beta'x$ y la otra $\ln[PMac/(1-PMac)]=\alpha_M+\beta'x$, siendo “PS” la probabilidad de observar una TId% severa (S), “PMac” la probabilidad acumulada de observar una TId%=> a moderada (M), “ α_S ” y “ α_M ” los parámetros del intercepto, “ β ” el vector común de parámetros de las pendientes y “x” el vector de variables regresoras. Resolviendo las siguientes expresiones: $\text{Exp}\{\ln[PS/(1-PS)]\}/\{1+\text{Exp}\{\ln[PS/(1-PS)]\}\}$ y $\text{Exp}\{\ln[PMac/(1-PMac)]\}/\{1+\text{Exp}\{\ln[PMac/(1-PMac)]\}\}$, es posible obtener “PS” y “PMac”. Las probabilidades de observar una TId% moderada (M) y nula (N) resulta de las siguientes dos diferencias: $PM=PMac-PS$ y $PN=1-(PS+PM)$.

Dentro de las reglas de decisión tenemos:

Para los modelos de respuesta Binaria, se pronostica la categoría epidémica con una probabilidad asociada $\geq 0,5$ (binaria). En la evaluación de los mejores modelos de respuesta binaria se toma en cuenta el valor crítico “P” (valor de probabilidad

para clasificar una categoría epidémica como severa que logra la mayor precisión de predicción), que no necesariamente es el valor 0,5.

Para los modelos de respuesta Ordinal, la función de probabilidad que dio el valor de probabilidad más alto fue considerado como el nivel pronosticado (S, M o N).

El método de selección de variables *Stepwise* del procedimiento *Logistic*, fue usado para obtener el modelo más apropiado, sometiendo a todas las variables (simples) descriptas y fijando niveles de significancia para entrar y permanecer en el modelo (NSE y NSP respectivamente) de 0,05.

La habilidad predictiva de los modelos fue calculada sobre la base del número de pares de observaciones (t) con diferente categoría de salida (ordinal: $15S*25M+25M*8N+15S*8N=695$ pares, binario: $15S*33M-N=495$ pares). Un par de observaciones de entrada con diferentes respuestas es concordante (o discordante) si el valor ordenado más grande de la respuesta tiene una más alta (o más baja) probabilidad predicha del evento que el más pequeño. Si el par no es ni concordante ni discordante, es un empate. Los índices de correlación Somers`D y Gama fueron calculados a partir del número de pares de observaciones concordantes (nc) y discordantes (nd). Los valores de ambos índices tienen un rango que va de -1 (todos los pares no concuerdan, no hay asociación) a 1 (todos concuerdan, asociación perfecta). La precisión de predicción de los modelos seleccionados fue calculada como el porcentaje de casos analizados (n=48) en los cuales hubo acuerdo entre la categoría de TId% observada y la predicha por el modelo logístico con la máxima probabilidad.

6. Resultados y Conclusiones

Los parámetros epidemiológicos principales utilizados, correspondientes a manchas foliares ocasionadas por el patógeno *Alternaria tenuissima* en arándano, para cuatro campañas (2008/09, 2009/10, 2010/11, 2011/12) y dos sitios (San Pedro, Concordia) fueron: Severidad acumulada y tasa epidémica diaria observada (Cuadro 1, Cuadro 2). Asimismo, la sintomatología observada estuvo relacionada con la presencia de *Alternaria tenuissima*, de acuerdo a las corroboraciones de laboratorio.

Cuadro 1: Severidad acumulada y tasa epidémica diaria observada para *Alternaria tenuissima*, sobre arándano, en la localidad de San Pedro, durante cuatro ciclos epidémicos entre 2008 y 2012.

Sitio San Pedro: Ciclo 2008/09				
Fecha	Día Juliano	Severidad (%)	Tiempo (días)	Tid (%)
2008	270	0	1	0
2008	332	1,835	63	0,03
2009	8	2,376	105	0,013
2009	68	12,085	165	0,162
Sitio San Pedro: Ciclo 2009/10				
Fecha	Día Juliano	Severidad (%)	Tiempo (días)	Tid (%)
2009	275	0	1	0
2009	295	0,663	21	0,033
2009	337	2,623	63	0,047
2009	363	5,899	89	0,126
2010	34	8,833	125	0,082
2010	44	10,565	135	0,173
2010	107	12,108	198	0,024
Sitio San Pedro: Ciclo 2010/11				
Fecha	Día Juliano	Severidad (%)	Tiempo (días)	Tid (%)
2010	270	0	1	0
2010	286	0,653	17	0,041
2010	320	1,316	51	0,02
2011	25	5,935	121	0,066
2011	60	11,058	156	0,146
Sitio San Pedro: Ciclo 2011/12				
Fecha	Día Juliano	Severidad (%)	Tiempo (días)	Tid (%)
2011	258	0	1	0
2011	274	0,169	17	0,011
2011	291	0,041	34	0,0024
2011	309	0,375	52	0,021
2011	344	1,148	87	0,033

2012	28	1,399	136	0,029
2012	111	0,307	219	0,0037
2012	152	0,407	260	0,01

Cuadro 2: Severidad acumulada y tasa epidémica diaria observada para *Alternaria tenuissima*, sobre arándano, en la localidad de Concordia, durante cuatro ciclos epidémicos entre 2008 y 2012.

Sitio Concordia: Ciclo 2008/09				
Fecha	Día Juliano	Severidad (%)	Tiempo (días)	Tid (%)
2008	245	0	1	0
2008	297	0,969	53	0,019
2008	339	0,472	95	0,011
2009	6	11,214	128	0,34
Sitio Concordia: Ciclo 2009/10				
Fecha	Día Juliano	Severidad (%)	Tiempo (días)	Tid (%)
2009	243	0	1	0
2009	282	0,882	40	0,023
2009	320	1,708	78	0,045
2009	355	2,02	113	0,058
2010	28	0,287	151	0,008
2010	58	23,24	181	0,775
2010	86	0,547	209	0,02
Sitio Concordia: Ciclo 2010/11				
Fecha	Día Juliano	Severidad (%)	Tiempo (días)	Tid (%)
2010	249	0	1	0
2010	265	1,896	17	0,119
2010	323	1,813	75	0,031
2011	60	0,714	177	0,007
2011	120	0,51	237	0,009
Sitio Concordia: Ciclo 2011/12				
Fecha	Día Juliano	Severidad (%)	Tiempo (días)	Tid (%)
2011	258	0	1	0
2011	274	0,848	17	0,053
2011	291	0,542	34	0,032
2011	309	0,847	87	0,047
2011	344	0,502	122	0,014
2012	3	0,275	146	0,011
2012	46	0,218	189	0,005
2012	88	7,955	231	0,189

El inicio de cada ciclo epidémico (2008/09 a 2011/12), para los 2 sitios, coincidió con la fecha en la cual se acumularon 170 grados día desde el 1 de julio (T_m base=12,5°C). La temperatura media base es la utilizada para simular el desarrollo de las especies cítricas (Davies y Albrigo, 1994). Estas fechas supuestas de inicio epidémico fueron previas a la primera observación de cada ciclo epidémico por sitio

(San Pedro: 27/09/08, 2/10/09 y Concordia: 02/09/08, 31/08/09, 15/09/11). En San Pedro, para la campaña 2010/11 y 2011/12, los 170 grados día se cumplieron el 18/10 y 12/10, pocos días después de la primera observación de enfermedad, por ello se decidió tomar como fecha de inicio epidémico ($\text{Severidad}\%=0$) el 27/09/10 y el 15/09/10 (16 días antes de la primera observación). En Concordia el valor de severidad 0, correspondiente a la curva epidémica de 2010/11 se fijó el 06/09, 16 días antes de la primera observación (22/09).

Los valores de $\text{Tid}\%$, se categorizaron binariamente en severo ($\text{Tid}\% \geq 0,045$) y moderado a nulo ($\text{Tid}\% < 0,045$), siendo el umbral 0,045 el percentil 70% de los 48 valores observados de $\text{Tid}\%$.

Las correlaciones (r_k : coeficiente de Kendall Tau-b) entre los niveles de tasas de incremento epidémico, las variables meteorológicas y el factor de senescencia (Snc) analizadas, se presentan en el Cuadro 3.

Cuadro 3: Coeficientes de correlación (Kendall Tau-b) de variables meteorológicas y del factor ligado a la senescencia foliar (Snc), en relación a los niveles de tasa de incremento epidémico diario ($\text{Tid}\%$) ordinales (S, M, N) y binarios (S, M-N). Las variables regresoras se calcularon en los lapsos de 28 días previos a cada valor de $\text{Tid}\%$. DTxnP : número de días con $\text{Tn} > 12^\circ\text{C}$ y $\text{Tx} < 36^\circ\text{C}$, DTn : número de días con $\text{Tn} \leq 8^\circ\text{C}$, DTxnN : número de días con $\text{Tn} \leq 8^\circ\text{C}$ o $\text{Tx} \geq 37^\circ\text{C}$, TxM : temperatura máxima media, TnM : temperatura mínima media, FPr : días con registros de $\text{Pr} > 0,2$ mm, PrAc : se acumulan las precipitaciones $> 0,2$ mm, DPrHR : número de días con registros de $\text{Pr} > 0,2$ mm y $\text{HR} > 81\%$, DPrT : número de días con registros de $\text{Pr} > 0,2$ mm en el intervalo térmico: $\text{Tx} < 36^\circ\text{C}$ y $\text{Tn} > 12^\circ\text{C}$, DHR : número de días con $\text{HR} > 81\%$, Snc : factor de senescencia.

Variable Meteorológica	Coeficientes de correlación (r_k : Kendall Tau-b)	
	Respuesta Ordinal	Respuesta Binaria
DTxnP	0,536	0,388
DTn	-0,608	-0,442
DTxnN	-0,632	-0,481
TxM	0,405	0,234

TnM	0,537	0,389
PrAc	0,423	0,397
FPr	0,35	0,382
DPrHR	0,33	0,378
DPrT	0,659	0,555
DHR	0,226	0,297
Snc	0,313	0,182

Las máximas correlaciones se obtuvieron calculando las variables regresoras en lapsos de 28 días previos a cada valor de Tid%.

Las variables simples asociadas a elementos meteorológicos de naturaleza continua, como las térmicas, presentaron las más elevadas correlaciones con los niveles de enfermedad. Variables asociadas al requerimiento de mojado del patógeno para la infección, como FPr, PrAc, DPrHr y DHR mostraron correlaciones con el nivel de tasa de incremento epidémico, que oscilaron entre 0,423 a 0,226 (ordinal) y entre 0,397 a 0,297 (binaria).

Mayor cantidad de días con registro de precipitación acotado por temperaturas mínimas y máximas diarias de 12°C y 36°C, potenciaron el proceso de infección y se asociaron fuertemente al nivel epidémico ($r_k=0,659$ ordinal, 0,555 binario).

Los umbrales térmicos para las temperaturas mínimas y máximas, que resultaron más desfavorables para la evolución epidémica fueron de 8°C y 37°C, cuando las variables térmicas (DTn, DTxnN) no interaccionaron con elementos hídricos. La alta correlación de las variables térmicas con la enfermedad, coincide con lo mencionado por Milholland en 1973, quien afirmó que la temperatura es el principal factor meteorológico, aunque no el único, responsable de la infección y desarrollo de la enfermedad, no sólo a campo sino también in vitro, siendo la temperatura óptima

para el desarrollo de la enfermedad 20°C y para el crecimiento del hongo 28°C, para cultivos de arándano alto en el estado de Carolina del Norte.

El factor de senescencia (Snc), alcanzó valores moderados y positivos del coeficiente de correlación de Kendall ($r_k = 0,313$ y $0,182$, ordinal y binaria), marcando una tendencia que hacia el verano, hojas de senescencia creciente (alto valor de Snc) incrementarían el proceso de infección.

El Modelo logístico I de respuesta ordinal, que integra a las variables DPRT y a DTxN resultó el más apropiado cuando se corrió el procedimiento de selección Stepwise, haciendo intervenir todas las variables descriptas y fijando niveles de significancia para entrar y permanecer en el modelo de 0,05. El test de chi-cuadrado para verificar el supuesto de líneas paralelas indicó que el modelo fue apropiado para los datos analizados (chi-cuadrado=2,2499 con dos grados de libertad, $P > \text{chi-cuadrado} = 0,3247$). Dicho Modelo I, logró una precisión de predicción de 79,2%, clasificando correctamente 38 de las 48 observaciones de tasa de incremento epidémico diario (Cuadro 4).

En el Modelo II, se integra, además de las variables meteorológicas, al factor de senescencia (Snc), mejorando algunos índices que caracterizan la habilidad predictiva del modelo (supuesto paralelismo: chi-cuadrado=2,1932 con 3 grados de libertad, $P > \text{chi-cuadrado} = 0,533$) (Cuadro 4).

Cuadro 4: Estimadores de los parámetros de modelos de regresión logística ajustados para estimar la probabilidad de ocurrencia de cada categoría ordinal de Tid% epidémica (severo (S), moderado (M) y nulo (N)), basado en variables meteorológicas y factor de senescencia foliar (variables regresoras se calcularon en los lapsos de 28 días previos a cada valor de tasa de incremento epidémico diario). ^a Modelo I: concordante(%)=89,5, discordante(%)=9,2, empate(%)=1,3 Somers'D=0,803;

Gamma=0,813. Modelo II: concordante(%)= 90,2, discordante (%)8,6, empate (%)= 1,2. Somers'D=0,816; Gamma=0,825. $\text{LogitPrS}=\ln(\text{PrS}/1-\text{PrS})$; $\text{LogitPrMac}=\ln(\text{PrMac}/1-\text{PrMac})$. Resolviendo las expresiones $\text{Exp}(\text{LogitPrS})/(1+\text{Exp}(\text{LogitPrS}))$ y $\text{Exp}(\text{LogitPrMac})/(1+\text{Exp}(\text{LogitPrMac}))$ se obtienen los valores de PrS (probabilidad de observar un nivel de TId% severo (S)) y PrMac (probabilidad acumulada de ocurrencia de un nivel de TId%=> a la categoría moderada (M)). "ln" es el logaritmo natural. $\text{PrM}=\text{PrMac}-\text{PrS}$. $\text{PrN}=1-(\text{PrS}+\text{PrM})$ siendo "PrN" la probabilidad de observar un nivel de incremento epidémico nulo (N). ^b DPrT: número de días con registros de Pr>0,2 mm en el rango térmico: $T_x<36^\circ\text{C}$ y $T_n>12^\circ\text{C}$. DTxnN: número de días con $T_n\leq 8^\circ\text{C}$ o $T_x\geq 37^\circ\text{C}$. Snc: factor de senescencia.

Modelo ^a	Ecuaciones del Modelo ^b	Precisión de predicción (%)
I	$\text{LogitPrS} = -2,6542 + 0,5461 \cdot \text{DPrT} - 0,345 \cdot \text{DTxnN}$ $\text{LogitPrMac} = 2,9718 + 0,5461 \cdot \text{DPrT} - 0,345 \cdot \text{DTxnN}$	79,20
II	$\text{LogitPrS} = -1,3817 + 0,5732 \cdot \text{DPrT} - 0,4117 \cdot \text{DTxnN} - 0,5228 \cdot \text{Snc}$ $\text{LogitPrMac} = 4,2904 + 0,5732 \cdot \text{DPrT} - 0,4117 \cdot \text{DTxnN} - 0,5228 \cdot \text{Snc}$	79,20

El modelo III de respuesta binaria seleccionado por stepwise, solo erró en 8 casos de los 48 observados (precisión de predicción: 83,3%). La ocurrencia de precipitación en días con temperaturas que oscilan entre 12°C y 36°C es decisiva para estimular la tasa de infección. Cuando este efecto se complementa con otra variable meteorológica como DTxnN y el factor de senescencia (modelo IV), se incrementa moderadamente la habilidad predictiva (Cuadro 5).

Cuadro 5: Estimadores de los parámetros de modelos de regresión logística ajustados para estimar la probabilidad de ocurrencia de cada categoría binaria de Tid% (severo (S), moderado a nulo (M-N), basado en variables meteorológicas y factor de senescencia foliar (variables regresoras se calcularon en los lapsos de 28 días previos a cada valor de tasa de incremento epidémico diario). ^a Modelo III: concordante(%)=85,5, discordante(%)=6,7, empate(%)=7,9. Somers'D=0,788; Gamma=0,855. Modelo IV: concordante(%)= 90,5, discordante (%)9,3, empate (%)= 0,2. Somers'D=0,812; Gamma=0,814. $\text{LogitPrS}=\ln(\text{PrS}/1-\text{PrS})$. Resolviendo la expresión $\text{Exp}(\text{LogitPrS})/(1+\text{Exp}(\text{LogitPrS}))$ se obtienen los valores de PS (probabilidad de observar un nivel de tasa de incremento epidémico diario (TId%) severo (S)). $\text{PM-N}=1-\text{PrS}$, siendo "PM-N" la probabilidad de observar un nivel de incremento epidémico moderado a nulo (M-N). ^b DPrT: número de días con registros de Pr>0,2 mm en el rango

térmico: $T_x < 36^\circ\text{C}$ y $T_n > 12^\circ\text{C}$. DT_{xnN} : número de días con $T_n \leq 8^\circ\text{C}$ o $T_x \geq 37^\circ\text{C}$. S_{nc} : factor de senescencia.

Modelo^a	Ecuaciones del Modelo^b	Precisión de predicción (%)
III	$\text{LogitPrS} = -4,1858 + 0,6914 * DPrT$	83,30
IV	$\text{LogitPrS} = -1,8469 + 0,6083 * DPrT - 0,2238 * DT_{xnN} - 0,5554 * S_{nc}$	85,40

A través de los modelos obtenidos fue posible explicar y cuantificar el lento progreso epidémico de las manchas foliares en la primavera (tiempo fresco y hojas jóvenes). Para este subperíodo, los modelos estimaron frecuentemente valores muy altos de probabilidad de tasas de incremento leves a nulas. En concordancia con las elevadas pendientes de la curva de progreso epidémico estival (hojas de senescencia creciente y tiempo templado a cálido, los modelos estimaron predominantemente para este lapso, valores altos de probabilidad de ocurrencia de tasas de incremento severas.

Este trabajo constituye una contribución más en el camino a la construcción de un sistema de pronóstico que contribuya a dar soporte a la toma de decisiones de profesionales, técnicos y productores.

7. Bibliografía

Agrios, G.N. (2005). *Plant Pathology*. 3ª Ed. Academic Press. 922p.

Box, G. E. P., and Draper, N. R., (1987), *Empirical Model Building and Response Surfaces*, John Wiley & Sons, New York, NY.

Box, G. E. P., and Draper, N. R., (1987). *Empirical Model Building and Response Surfaces*, John Wiley & Sons, New York, NY.

Campbell, C.L y Madden, L.V. (1990). *Introduction to plant disease epidemiology*. Wiley, New York. 532p.

De Wolf, E.D. e Isard, S.A. (2007). *Disease cycle approach to plant disease prediction*. *Annual Review of Phytopathology*. 45(9):1p-18p.

Dembo, R.S. (1991). *Scenario Optimization*. *Annals of Operations Research* 30, pp 63-80.

Duek, J.J. (1979). *Métodos para la evaluación de impactos ambientales incluyendo programas computacionales*. A-6, CIDIAT, Mérida (Venezuela), 86p.

Fernandez Valiela, M.V. (1978). *Introducción a la Fitopatología*. Vol. III. Hongos. Colección Científica del INTA. Buenos Aires. 613p.

Gaumann, E. (1950). *Principles of Plant Disease Infection*. Hafner, New York. 543p.

Kranz, J. (2003). *Comparative Epidemiology of Plant Diseases*. Springer, New York. 212p.

Lee, C. (1975). *Modelos de planificación*. Ediciones pirámide. Madrid

Maloy, O.C. (1993). *Plant Disease Control*. Wiley, New York. 351p-356p.

Moschini, R.C. (2007). *Los cultivos de Soja y Trigo: Herramientas para la predicción y manejo de enfermedades en la Argentina*. 39p-48p. *En Mundo Agro. Intensificación de los sistemas de producción y el manejo del riesgo en agricultura. Incorporando nuevas tecnologías al manejo de los cultivos*. Buenos Aires.

Pazos, J. (2005). *El país, en vías de ser el segundo exportador de arándanos*. *La Nación. Suplemento Campo*. Setiembre de 2005. 12p.

Pidd, M. (1996). *Tools for thinking: Modelling in management science*. Chichester: Wiley. 153p.

Strange, R.N. y Scott, P.R. (2005). *Plant disease: a threat to global food security*. *Annu. Rev. Phytopathology*. 43:83p-116p.

Williams, H. P. (1999). Model Building in Mathematical Programming. Wiley. 348p.

Wright, E.R. y Pérez, J.A. (2007). Enfermedades del arándano. Publicado en CD. XXX Congreso Argentino de Horticultura. La Plata. Buenos Aires.

Wright, E.R.; Pérez, B.A.; Fernández, R.L.; Asciutto, K.; Rivera, M.C.; Murillo, F.; Vasquez, P.; Divo de Sesar, M.; Pérez, A.; Aguilar Heredia, L.; Rosato, M.F.; Crelier, A. y Baldoma, J. (2005). Conocimiento actual sobre enfermedades de arándano. Libro de Resúmenes. 113p-117p. I Congreso Latinoamericano de Arándanos y otros berries. Buenos Aires.

Wright, E.R.; Rivera, M.C.; Esperón, J. (2003). Alternaria tenuissima y Colletotrichum gloeosporioides: agentes causales de ablandamiento poscosecha en frutos de arándano. Resumen en CD. Código Fr 028. XXVI Congreso Nacional de Horticultura. Paraná. Entre Ríos.

Wright, E.R.; Rivera, M.C.; Esperón, J.; Cheheid, A. y Rodriguez Codazzi, A. (2004). Alternaria leaf spot, twig blight and fruit rot of highbush blueberry in Argentina. Plant Disease. 88:1383.

Wright, E.R.; Vasquez, P.; Asciutto, K.; Pérez, A.; Diano, M.; Ciurca, P.; Damiens, J.; Crelier, A.; Panigo, L.; Barrientos, M.E.; Rivera, M.C. y Pérez, B.A. (2007). Hongos presentes en el estado vegetativo de plantaciones de arándano (Vaccinium corymbosum) en Argentina. Código 147. 11º Congreso Nacional de Horticultura. Montevideo. Uruguay.