

MODELADO COMPUTACIONAL DE DATOS EPIDEMIOLÓGICOS PARA PREDECIR ENFERMEDADES DE CULTIVOS CON BASE METEOROLÓGICA

Bombelli E.C.¹, Wright E.R.¹, Moschini R.C.², López M.V.¹, María del Carmen Fabrizio M.C.¹, Barberis J.G.¹, Rivera M.C.¹

1. Facultad de Agronomía. UBA. Av. San Martín 4453. C1417DSE. CABA. Argentina.
{bombelli, wright, mvlopez, fabrizio, barberis, mrivera}@agro.uba.ar

2. Instituto de Clima y Agua. INTA Castelar. Los Reseros y Las Cabañas s/n. B1712WAA. Castelar. Prov. de Buenos Aires. Argentina.
rmoschini@cni.inta.gov.ar

Resumen

Para predecir el comportamiento de enfermedades de las plantas, mediante la construcción de modelos predictivos, se evaluó la severidad de manchas foliares, ocasionada por el hongo *Alternaria tenuissima*, en plantaciones de arándano alto (cultivar *O'Neal*) en tres localidades: San Pedro (S 33° 43' - W 059° 41'), Concordia (S 31° 24' - W 058° 02') y Gualaguaychú (S 33° 01' - W 058° 31'), durante los ciclos epidémicos primavera-estivo-otoñales de 2008/09 y 2009/10. Los mejores modelos simples de regresión logística de respuesta binaria integraron a Snc y a DTxnP (días con temperaturas entre 16 y 36°C), con precisiones de predicción de 93,8% y 78,5% respectivamente. El mejor modelo de respuesta ordinal integró a la interacción FPr*DTxnP (días con precipitación*días con temperaturas entre 16 y 36°C) y a Snc, con una precisión de predicción de 86,2%. La explicación biológica que subyace a los resultados obtenidos, refiere a un lento progreso epidémico primaveral, observado y simulado, contrastando con las altas tasas de incremento epidémico estivales, concordantes con hojas de senescencia creciente y alta frecuencia de días con registros térmicos entre 16 y 36°C. Un adecuado ajuste y validación de los modelos predictivos obtenidos en esta investigación, permitirá el desarrollo de verdaderos sistemas de pronóstico, para la correcta gestión de la enfermedad, tanto desde el punto de vista técnico, como económico y ambiental.

Palabras clave: Modelos predictivos, epidemiología, manejo de enfermedades, arándano alto, *Alternaria tenuissima*.

Introducción

Modelado predictivo de enfermedades vegetales

Tanto el modelado mecanístico como el empírico, constituyen técnicas que se utilizan para desarrollar modelos predictivos. El mecanístico, suele utilizar una serie de submodelos para caracterizar múltiples subetapas del ciclo de la enfermedad, y a menudo se basan en los resultados de experimentos diseñados para investigar la biología de patógenos en condiciones controladas. Cuando el conocimiento sobre el sistema es incompleto, dichos submodelos permiten incorporar suposiciones acerca de las relaciones entre hospedante, patógeno y ambiente [1].

Los modelos mecanísticos generalmente se caracterizan por tener una mayor capacidad explicativa que los puramente empíricos. En comparación, los enfoques empíricos, utilizan métodos estadísticos para describir las relaciones entre las variables ambientales y el aumento de la intensidad de la enfermedad. Estos tipos de modelos, a menudo se basan en experimentos a campo que simulan condiciones de producción, y pueden utilizar resultados de experimentos controlados para dirigir la construcción del modelo [2].

Los modelos empíricos no caracterizan relaciones causa/efecto dentro de un sistema de enfermedad, sin embargo, pueden utilizarse para hacer inferencias acerca de la biología subyacente de dicho sistema. A su vez, ambos tipos de modelado, mecanístico y empírico, se utilizan para identificar las partes del ciclo de la enfermedad que necesitan una mayor exploración a base de experimentos. En la literatura reciente, existen casi igual número de modelos mecanísticos y empíricos exitosos, así como también muchas combinaciones pragmáticas de ambos enfoques [1].

Los modelos predictivos, pueden basarse en factores de riesgo que predispongan cultivos a epidemias de enfermedades. Estos modelos a menudo consideran dichos factores de riesgo asociados al ambiente predisponente al desarrollo general de la enfermedad, e incorporan a menudo información respecto a la influencia de prácticas productivas tales como: rotación de cultivos, prácticas de la labranza, fechas de siembra y grado de susceptibilidad de cultivares. Este acercamiento fue utilizado para modelar la mancha gris de la hoja de maíz (*Cercospora zeae-maydis*) [3]. El modelo predice un riesgo severo de que se produzca la enfermedad, basado en horas de temperatura favorable, y humedad relativa durante etapas críticas del crecimiento, considerando además la localización geográfica, la cantidad de residuos de cosecha dejados en la superficie del suelo, y el grado de resistencia de los cultivares disponibles a la enfermedad. Este acercamiento

también fue utilizado para predecir epidemias de la pudrición del tallo (*Sclerotinia sclerotiorum*) por ataque a semillas oleaginosas [4].

Modelos predictivos como sistemas de gestión de enfermedades

Los modelos predictivos poseen un gran potencial como soporte a la administración de estrategias, que permitan sobre todo mantener los suministros mundiales de alimentos. Sin embargo, el verdadero valor de dichos modelos radica en su utilización para la toma de decisiones relativas al manejo de enfermedades en campos de producción [1].

Para evaluar un modelo predictivo, de manera tal que forme parte de un sistema de gestión de enfermedades, es necesario replicar las investigaciones a nivel de parcela, para determinar el desempeño de las decisiones basadas en modelos y contrastarlas con las correspondientes a prácticas de gestión estándar. Este procedimiento de evaluación de modelos fue utilizado para comprobar la bondad de un sistema predictivo para el mildiú de la vid en Ohio. La investigación evaluó el desempeño del modelo predictivo sobre la base de repeticiones en bloques por más de 7 años, comparando el control de la enfermedad con tratamientos de fungicidas en base a un modelo de tiempo con un programa estándar de aplicaciones basado en el sistema calendario. Los resultados de este estudio, indicaron que tanto el modelo de tiempo como el estándar basado en el sistema calendario, para realizar las aplicaciones con fungicidas, redujeron significativamente ($P < 0,05$) la incidencia de mildiú de la vid en comparación a la ausencia de tratamientos. Más aún, este estudio demostró que era posible alcanzar similares niveles de control de la enfermedad con menor cantidad de aplicaciones de fungicidas utilizando el modelo predictivo en comparación con tratamientos estándar [5]. El mismo enfoque fue utilizado para evaluar un modelo de tiempo para realizar tratamientos orgánicos contra la sarna del manzano en Alemania, pudiendo demostrar que los modelos predictivos pueden ser utilizados con eficacia en sistemas de producción orgánica [6].

En algunos estudios, la investigación a nivel de parcela se utilizó para comparar el desempeño de predicción de múltiples modelos para la misma enfermedad [7]; [8]; [9]; [10]; [11]. En este sentido, [9] evaluaron el rendimiento relativo de los cinco modelos predictivos para tizón tardío de la papa (*Phytophthora infestans*) en un período de 6 años en 5 localidades. Los resultados del mismo indican que el modelo denominado NEGFRY proporciona la mejor combinación exactitud/oportunidad de aplicación.

La evaluación de modelos predictivos en base a parcelas de investigación, se amplió hacia la evaluación del valor económico de la información proporcionada por un modelo. Este valor económico puede provenir de los gastos evitados por eludir una gran epidemia, o bien evitar aplicaciones innecesarias de pesticidas. [12] describieron los beneficios económicos resultantes de un pronóstico temprano a los productores de Virginia, en relación a la mancha foliar del maní (*Cercospora arachidicola*). Estas evaluaciones indican que entre 1987 y 1990 dichos productores ahorraron en promedio de 2,25 aplicaciones de fungicidas por temporada en comparación a la norma de 14 días sobre la base del sistema calendario. Según las estimaciones de costos, para aplicaciones de clorotalonil a razón de 1,12 kg/ a durante ese período, el programa de asesoramiento redujo los costos de los insumos en un 33% o 57 U\$S/ha. Durante el período 1990 a 1995, el asesoramiento promedio generó un ahorro de 3 aplicaciones de fungicidas por temporada y la reducción de los costos de entrada en un 43% o 66 U\$S/ha. Los ahorros estimados sólo en insumos, para un productor que maneja 40 hectáreas de maní en Virginia fue de U\$S 2.640 [12]. En definitiva, las estimaciones del potencial económico de los modelos predictivos son muy valiosos, y puede llegar a ser algo esencial para los fitopatólogos con el fin de intentar justificar el continuo gasto de recursos necesarios para desarrollar y mantener estos sistemas [1].

Aplicaciones prácticas de modelos predictivos

Los modelos predictivos se desarrollan sobre escalas espaciales continuas. En un extremo del espectro, dichos modelos se ejecutan a nivel de campo o lote. En general, estos sistemas utilizan computadoras para combinar mediciones del ambiente con observaciones locales, acerca de la gestión y el estado del cultivo. Las predicciones resultantes del modelo son específicas del sitio y sólo disponibles para usuarios individuales. La fortaleza de este tipo de sistemas es que representan las variaciones biológicas y ambientales, las cuales son importantes para la generación de recomendaciones referidas a la gestión de la enfermedad a escala de campo o lote [1]. En este sentido, el sistema de alarma llamado ADEM, provee de predicciones a productores y técnicos, para múltiples enfermedades de manzana. En este programa, los modelos de enfermedades fueron desarrollados sobre la base de variables meteorológicas provenientes de estaciones locales del mismo nombre. Dicha información meteorológica se combinó con información local como ser nivel de inóculo y susceptibilidad del cultivar, para proporcionar predicciones de riesgo de ataque por sarna, oídio, fuego bacteriano, cancro Europeo y podredumbre [13]; [14].

En el otro extremo, los modelos predictivos pueden desarrollarse a escala regional. En los mismos, se utilizan equipos de alta potencia para combinar información meteorológica proveniente de una amplia red de estaciones, con otras fuentes de datos meteorológicos como ser estimaciones de precipitación por radar, mediciones de la temperatura, humedad y vientos por satélite, etc. Estos sistemas proporcionan una estimación general del riesgo de enfermedad para toda una región y comunidad de usuarios, pero consideran poco o nada en lo referente a variaciones de la biología, prácticas de cultivo o condiciones microclimáticas a nivel local. Los productos de modelos predictivos bajo la forma de mapas o recomendaciones están disponibles para toda la comunidad y se pueden utilizar para planificar el manejo de la enfermedad a distintos niveles. Los puntos fuertes del modelado de sistemas de enfermedades a escala regional, permiten el uso eficiente de los recursos de información meteorológica, utilizar la velocidad y alcance de Internet como medio de comunicación y hacer mejoras debido a cambios en la estructura del modelo, inmediata y automáticamente a disposición de toda la comunidad de usuarios. Existen varios ejemplos de este tipo de sistemas en la literatura actual. Uno de ellos corresponde al implementado por [15] para cultivos frutales y hortícolas, en el oeste de Estados Unidos. Este sistema genera predicciones para múltiples enfermedades e insectos, basado en observaciones meteorológicas de más de 2000 estaciones. El sistema fue automatizado para que los datos de la red de estaciones meteorológicas, recogidos cada 15 minutos, se utilicen a diario para generar mapas a color del riesgo de enfermedad para la región correspondiente en un sitio web.

[16] han implementado modelos predictivos para la fusariosis de la espiga de trigo para 23 estados al este de las Montañas Rocosas. Estos modelos fueron desarrollados utilizando el modelado empírico por los fitopatólogos de la Universidad Estatal de Pennsylvania y la de Ohio, con la participación de epidemiólogos de varios estados, combinando datos de estaciones convencionales y teledetección del medio ambiente. Un sistema automatizado (Fusarium Head Blight Risk Assessment Tool) se implementó al utilizar estos datos para ejecutar los modelos y así producir mapas de riesgo de la enfermedad con una resolución para la región del orden de los 20 km, mostrados al público por medio de Internet (Figura 1).

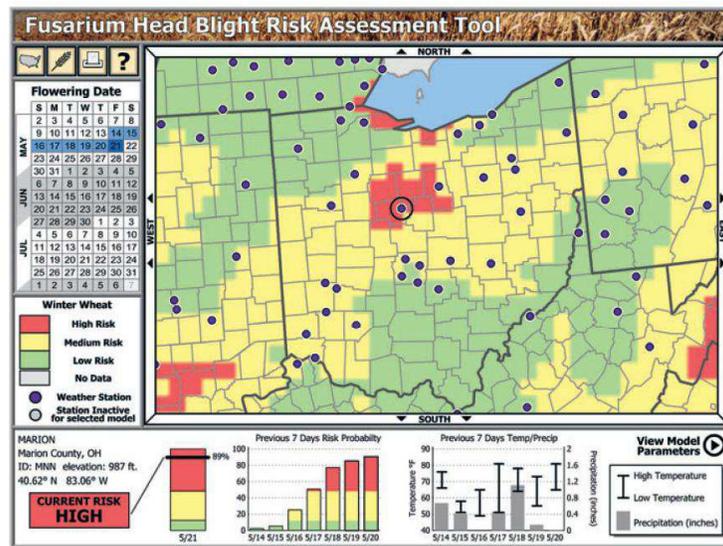


Figura 1: Herramienta de uso público a través de Internet, para la predicción de la fusariosis de la espiga de trigo (*Fusarium graminearum*). La interfaz gráfica muestra los mapas de riesgo diario de la enfermedad para 23 estados al este de las Montañas Rocosas. En este caso, se muestra una ampliación de Ohio y parte de Pennsylvania, Michigan e Indiana (la interfaz gráfica fue diseñada por el Centro de Informática Ambiental del Estado de Pennsylvania) [De Wolf *et al.*, 2005].

En un futuro próximo, el desarrollo de los modelos predictivos se dirigirá hacia el centro de este continuo conceptual. Los avances en tecnologías de la información y comunicación están haciendo posible el diseño de sistemas de predicción de enfermedades vegetales que integren datos ambientales proporcionados en tiempo real por las redes de vigilancia mundial, proporcionando al usuario local información sobre el estado de los cultivos y las enfermedades dentro de los distintos campos. Si los fitopatólogos son capaces de mantener el ritmo de estos avances tecnológicos, mediante el establecimiento de equipos multidisciplinarios que incluyan meteorólogos y expertos en tecnología, el futuro de la predicción de enfermedades vegetales seguirá siendo brillante [1].

Contexto

De las muchas enfermedades que amenazan al cultivo de arándano en Argentina, *Alternaria tenuissima* es el patógeno de mayor incidencia y prevalencia [17]; [18]; [19], responsable de pérdidas de hasta un 20% en poscosecha [20]; [21]; [22].

Se trata de un hongo común y abundante en el aire, así como en el suelo, las semillas y productos agrícolas. Incluye especies tanto fitopatógenas como saprófitas, conocidas por producir metabolitos, sobre todo fitotoxinas, que desempeñan un papel importante en la patogénesis de las plantas. Las que producen metabolitos tóxicos en las plantas infectadas y/o en los productos agrícolas, pueden contaminar los alimentos y provocar efectos adversos en animales. La sintomatología en arándano es muy variable, aunque la más común consiste en manchas foliares, ocasionando también pudrición de frutos en pre y poscosecha.

Tratándose de un patógeno necrotrófico¹, su control preventivo consiste en eliminar órganos afectados, disminuir la humedad foliar y evitar condiciones de estrés, manteniendo el cultivo bien fertilizado y regado. Cuando aparecen los primeros síntomas en hojas y/o tallos, se recomienda aplicar fungicidas [24]. Para el caso que nos ocupa, los fungicidas foliares constituyen la principal herramienta a utilizar para minimizar los daños causados. Pero si se busca una estrategia de control químico basada en la ocurrencia de condiciones meteorológicas favorables al progreso epidémico, es necesario contar con modelos matemáticos que cuantifiquen la relación ambiente/enfermedad.

En Argentina, no se dispone hasta el presente de observaciones de severidad final de la enfermedad, que permitan encarar el desarrollo de modelos empíricos con base meteorológica para predecir niveles de ocurrencia de la enfermedad.

Objetivos

General

- Elaborar modelos matemáticos que permitan predecir adecuadamente el comportamiento de enfermedades en cultivos de arándano.

Específicos

- Desarrollar métodos de medición junto con el equipamiento correspondiente para la colecta de datos de enfermedad que condicionan el desarrollo de las plantas e identificar los elementos meteorológicos que favorecen el desarrollo de las mismas.
- Organizar los datos de enfermedad y las variables meteorológicas, sobre la base de ciertas reglas, que permitan realizar distintas simulaciones para así poder arribar a modelos de conocimiento, que a través de la cuantificación de la relación ambiente/enfermedad, permitan predecir niveles de ocurrencia futuros.

Metodología

El desarrollo de modelos predictivos, requiere la construcción de una base de datos. El protocolo para la elaboración de la misma refiere a datos que responden a dos orígenes. Por un lado, los registros de enfermedad, que en este caso provienen de lotes de arándano, y por otro los meteorológicos, los cuales resultan de estaciones meteorológicas convencionales o automáticas ubicadas en las cercanías de las plantaciones de arándano.

Colecta de datos

Registros de enfermedad

Los registros de enfermedad se realizaron aproximadamente cada 30 días, utilizando una escala con 8 grados de severidad, la cual fue elaborada luego de varias pruebas a campo y sucesivas modificaciones, las cuales fueron descriptas en el apartado anterior (Cuadro 1) y (Figura 2).

Cuadro 1: Escala diagramática de severidad usada para los registros de enfermedad.

Grado	1	2	3	4	5	6	7	8
Porcentaje de severidad máximo	0	5	10	20	40	60	80	100

¹ Parásito que mata a las células y obtiene su energía de las células muertas [23].

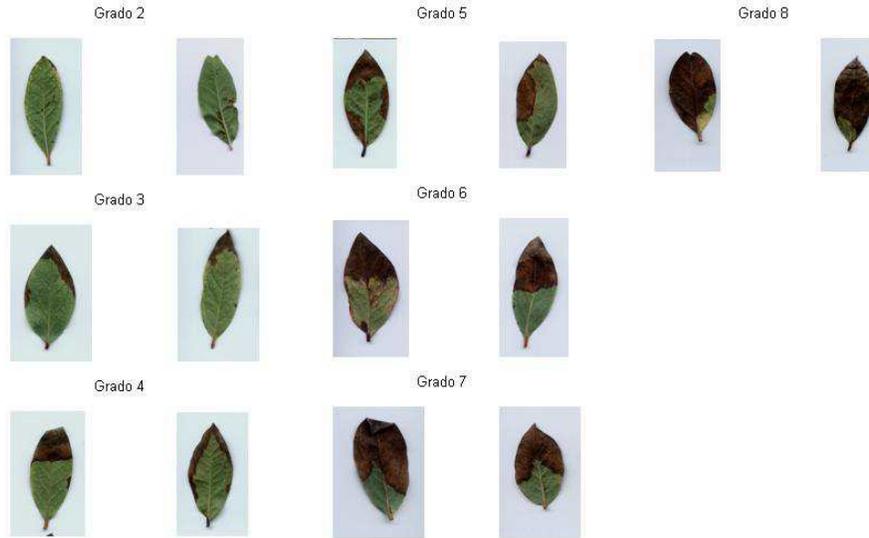


Figura 2: Diagramas correspondientes a cada grado de la escala de severidad.

Los datos recabados provinieron de lotes de arándanos ubicados en tres sitios analizados: San Pedro (S 33° 43' - W 059° 41'), Concordia (S 31° 24' - W 058° 02') y Gualaguaychú (S 33° 01' - W 058° 31'). Las mediciones se realizaron sobre parcelas de la variedad "O'Neal", con por lo menos 6 meses previos sin aplicación de fungicidas.

Para realizar las mediciones se eligieron 4 hileras de plantas y la severidad se midió en las 2 centrales, marcando un total de 20 plantas. En cada una de ellas se seleccionaron dos ramas, una interna y otra externa contándose en los 15 cm superiores el número de hojas. Sobre todas las hojas del sector seleccionado, se midió la severidad utilizando la mencionada escala. También se contó el número total de ramas por planta. Los evaluadores fueron entrenados previamente a la evaluación. Paralelamente se tomaron muestras de hojas con presencia de síntomas idénticos a los evaluados, de plantas cercanas a las mismas, a efectos de determinar en laboratorio la presencia de microorganismos asociados a los síntomas evaluados. Las mismas fueron procesadas a través de técnicas fitopatológicas de rutina.

Registros meteorológicos

En el estudio de la relación ambiente/enfermedad, se deben identificar las variables meteorológicas claves asociadas a la epidemia y el lapso en el cual aquellas son procesadas. En esta investigación, las variables ambientales fueron calculadas a partir de elementos meteorológicos de paso diario, registrados en estaciones meteorológicas convencionales del Servicio Meteorológico Nacional (SMN) y del Instituto Nacional de Tecnología Agropecuaria (INTA). Dichos registros meteorológicos diarios, están disponibles en el Instituto de Clima y Agua (CIRN/INTA Castelar), en soporte magnético, desde el año 1971 a la fecha (Figura 3).

```
/*Datos meteorológicos de Concordia (concordia.dat): (por fila) año
(anio), día juliano (dj), temperatura máxima (tmax), mínima (Tmin),
precipitación (Prec) y humedad relativa (hrd)
2008 273 22.2 16.2 53 93
2008 274 23.1 15.8 0 80
2008 275 24.2 13.3 8 81
2008 276 23.2 10.5 0 60
2008 277 23.3 8.5 0.2 66
2008 278 21.6 13.2 0.3 64
2008 279 20.8 5.6 0 48
2008 280 26 7.5 0 45
2008 281 22.5 12.7 0 43
2008 282 19 4.9 0 50
2008 283 25.8 6.2 0 61
2008 284 27.8 13 0 54
2008 285 30.3 14.8 0 64
```

2008	286	24.2	19.1	24	86
2008	287	21.9	18.8	6	90
2008	288	25.8	18.5	0	80
2008	289	21	18.2	1	83
2008	290	23	13.8	0	61
2008	291	22.1	11.1	0	65
2008	292	23.3	10.6	0	61

Figura 3: Extracto de la base de datos meteorológicos correspondiente a Concordia.

En la Figura 4, se detallan las sentencias de programación (lenguaje *Statistical Analysis System*) que permitieron la lectura de registros diarios de dichos elementos meteorológicos.

```
/*Lectura de datos meteorológicos de los ciclos 2008/09 y 2009/10 */
DATA C1;
INFILE 'E:\concordia.dat';
INPUT ANIO dj tmax tmin prec hrd;
if anio>=2008 then output;
DATA C2;
INFILE 'E:\gualaguaychu.dat';
INPUT ANIO dj tmax tmin prec hrd;
if anio>=2008 then output;
DATA C3;
INFILE 'E:\sanpedro.dat';
INPUT ANIO dj tmax tmin prec hrd;
if anio>=2008 then output;
run;
```

Figura 4: Lectura de registros diarios (año y día juliano) de temperatura máxima (Tmax) y mínima (Tmin), precipitación (Prec) y humedad relativa (Hrd), para los ciclos de crecimiento 2008/09 y 2009/10 en Concordia, Gualaguaychú y San Pedro.

Modelado de datos epidemiológicos con base meteorológica

La ocurrencia, desarrollo y dispersión de enfermedades de cultivos, depende de los efectos integrados del patógeno, hospedante y condiciones ambientales (Figura 5).

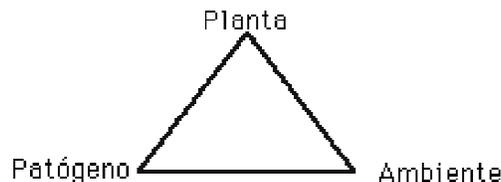


Figura 5: Triángulo epidémico [1].

El productor puede implementar una serie de prácticas de manejo que modifican este sistema interactivo, con el objeto de reducir las pérdidas atribuidas a enfermedades y de esta forma incrementar los rendimientos de los cultivos, bajo el marco de sustentabilidad exigible a los sistemas productivos.

Para apoyar al manejo táctico y estratégico de enfermedades de cultivos, muchos esfuerzos de investigación se concentran en el desarrollo de modelos que simulan el progreso epidémico y/o el nivel final de enfermedad, basados en algunos o todos los factores que expresan la enfermedad (patógeno, hospedante, ambiente). Dichos modelos se desarrollan analizando información observada de las enfermedades y meteorológica del pasado reciente. Se trata de explicar la variación de la enfermedad a través de variables meteorológicas que captan la variabilidad del clima regional, en un intervalo temporal de corta duración.

Esta metodología responde a los sistemas de pronóstico empíricos o deductivos, muchos de los cuales son de gran utilidad y funcionales (datos actuales e históricos de registros de enfermedad y condiciones ambientales de un sitio dado). Esto resulta en la formulación de reglas que deben cumplirse antes que se produzca el desarrollo de la enfermedad, como las establecidas para el tizón tardío de la papa (*Phytophthora infestans*) [25]. [26] sugiere un mínimo de 8 a 12 años de observaciones de enfermedad para identificar con certeza los factores climáticos asociados. Si esto no fuera posible, se podría utilizar información meteorológica y de la enfermedad de varios sitios pertenecientes a una región geográfica, de manera de obtener variabilidad. En este sentido, [27] mediante técnicas de regresión lineal múltiple, ajustaron modelos basados en variables hídricas

para predecir la severidad final de la roya asiática de la soja (*Phakopsora pachyrhizi*). Para ello, utilizaron datos de severidad (%) de sólo 3 campañas, pero de 34 experimentos de campo, en 21 sitios de Brasil. [28] utilizaron observaciones de incidencia de escudete negro (*Alternaria alternata* y *Bipolaris sorokiniana*) en trigo fideo, de 5 sitios y 3 campañas, para ajustar modelos predictivos de regresión lineal múltiple y logística basados en 2 variables meteorológicas.

Para el desarrollo de los mencionados modelos, se dispuso de observaciones de severidad de *Alternaria tenuissima* en arándano, las cuales trataron de representar su progreso epidémico durante los ciclos de crecimiento 2008/09 y 2009/10, en tres sitios geográficos (San Pedro, Concordia y Gualaguaychú). Si se hubiesen usado los valores máximos de severidad de cada ciclo de crecimiento, sólo se hubiese dispuesto de seis observaciones (3 sitios x 2 ciclos). Dicho número de observaciones es considerado insuficiente para establecer, a través de técnicas de regresión, la relación cuantitativa ambiente/enfermedad. Por ello se pensó entonces, en otra técnica de análisis que incluyera todas las observaciones disponibles de severidad de *Alternaria tenuissima* (n=29) a lo largo de los ciclos de crecimiento de arándano. En este marco, debido al excesivo e irregular espaciado temporal entre observaciones de la enfermedad, se consideró impreciso el proceso de identificación de variables ambientales relacionadas a las tasas diarias de incremento epidémico, calculadas entre observaciones sucesivas de severidad. Con las restricciones descriptas, los objetivos fueron los siguientes:

1. Ajustar modelos linealizados (Logístico y Gompertz) a los datos de severidad observados por ciclo y sitio.
2. Estimar la severidad y la tasa de incremento epidémico diario a intervalos de tiempo fijos, a partir de las curvas epidémicas seleccionadas
3. Desarrollar modelos empíricos mediante técnicas de regresión logística, para estimar probabilidades de ocurrencia de distintos niveles de tasas de incremento epidémico (severidad) de *Alternaria tenuissima* en hojas de arándano, basados en el grado de senescencia foliar y en variables meteorológicas (simples e interactivas).
4. Procesar dichas variables regresoras a intervalos de tiempo fijos, previos a cada valor de severidad, en la curva de progreso epidémico seleccionada por ciclo y sitio.

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 System* (SAS), el cual se viene utilizando con regularidad desde el año 1988 por Ricardo Moschini [29]; [30]; [31]; [32]; [33]; [34]; [35]; [28]; [36], para la obtención de modelos predictivos de enfermedades de cultivos basados en variables meteorológicas.

Modelos linealizados de ajuste a curvas de progreso epidémico

Mediante análisis de regresión lineal (procedimiento GLM del SAS) fue evaluada la bondad de ajuste de las formas linealizadas de los modelos Logístico (L) y Gompertz (G) [2] a cada una de las 6 epidemias observadas (3 sitios y 2 campañas) (Cuadro 2).

Se analizaron para cada modelo el coeficiente de determinación (R^2) y la raíz cuadrada del error cuadrático (RECM). La variable dependiente en la regresión lineal fue para $L = \ln(\text{sev}/(1-\text{sev}))$ y para $G = -\ln(-\ln(\text{sev}))$, siendo "ln" el logaritmo natural y "sev" la severidad observada de la enfermedad en proporción, para cada fecha. La variable independiente es el tiempo (d) expresado en días que van transcurriendo desde una fecha inicial. El inicio de cada ciclo epidémico en los años 2008 y 2009, para los 3 sitios, coincidió con la fecha en la cual se acumulan 170 grados día desde el 1 de julio ($T_m \text{ base} = 12,5^\circ\text{C}$). La temperatura media base es la utilizada para simular el desarrollo de las especies cítricas [37]. Estas fechas supuestas de inicio epidémico fueron previas a la primera observación de cada ciclo epidémico por sitio (San Pedro: 27/9/08 y 2/10/09, Concordia: 1/9/08 y 31/8/09, Gualaguaychú: 17/9/08 y 20/9/09).

Cuadro 2: Valores de severidad (en proporción y acumulado %) de *Alternaria tenuissima* observados en 6 ciclos epidémicos (3 sitios: Concordia, Gualaguaychú y San Pedro y 2 campañas).

Sitio San Pedro: Ciclo 2008/09				
Fecha Observada	Día Juliano	Severidad	Severidad Acumulada (%)	Día Epidemia
27/09/08	271	0,001	0,1	1
27/11/08	332	0,0184	1,84	62
08/01/09	8	0,0238	2,38	104

09/03/09	68	0,1208	12,08	133
Sitio San Pedro: Ciclo 2009/10				
Fecha Observada	Día Juliano	Severidad	Severidad Acumulada (%)	Día Epidemia
02/10/09	275	0,001	0,1	1
22/10/09	295	0,0066	0,66	21
03/12/09	337	0,0262	2,62	63
29/12/09	363	0,0590	5,90	89
03/02/10	34	0,0883	8,83	125
13/02/10	44	0,1056	10,56	135
17/04/10	107	0,1211	12,11	198
Sitio Concordia: Ciclo 2008/09				
Fecha Observada	Día Juliano	Severidad	Severidad Acumulada (%)	Día Epidemia
1/09/08	245	0,001	0,1	1
23/11/08	297	0,0097	0,97	53
04/12/08	339	0,0144	1,44	95
06/01/09	6	0,1265	12,65	122
25/03/09	84	0,0957	9,57	200
Sitio Concordia: Ciclo 2009/10				
Fecha Observada	Día Juliano	Severidad	Severidad Acumulada (%)	Día Epidemia
31/08/09	243	0,001	0,1	1
09/10/09	282	0,0088	0,88	40
16/11/09	320	0,0259	2,59	78
21/12/09	355	0,0461	4,61	113
28/01/10	28	0,0490	4,90	151
27/02/10	58	0,2814	28,14	181
27/03/10	86	0,2868	28,68	209
Sitio Gualeguaychú: Ciclo 2008/09				
Fecha Observada	Día Juliano	Severidad	Severidad Acumulada (%)	Día Epidemia
17/09/08	261	0,001	0,1	1
25/11/08	330	0,1045	10,45	70
13/12/08	348	0,0894	8,94	88
02/01/09	2	0,1220	12,20	108
06/03/09	65	0,1141	11,41	171
Sitio Gualeguaychú: Ciclo 2009/10				
Fecha Observada	Día Juliano	Severidad	Severidad Acumulada (%)	Día Epidemia
20/09/09	263	0,001	0,1	1
07/10/09	280	0,0726	7,26	18
03/12/09	337	0,0840	8,40	75
28/12/09	362	0,0731	7,31	100
18/02/10	49	0,096	9,60	152
20/03/10	79	0,1063	10,63	182
24/04/10	114	0,1442	14,42	217

Resolviendo las siguientes ecuaciones se obtuvieron los valores de severidad (Sev) de cualquier día (d) en las curvas de progreso epidémico ajustadas:

Modelo L: $Sev = 1 / (1 + \exp(-(\text{intercepto} + \text{pendiente} * d)))$

Modelo G: $Sev = \exp(-\exp(-(\text{intercepto}) * \exp(-\text{pendiente} * d)))$

A partir de los modelos de progreso epidémico seleccionados, se obtuvieron valores estimados de severidad a intervalos de 14 días (el día 1 es la fecha de inicio epidémico definido por sitio y año). La tasa de incremento epidémico diario (TId%) resultó de: $(Sev\%_d - Sev\%_{d-1})/14$, siendo “d” el día que completa cada intervalo de 14 días, consecutivamente desde la fecha de inicio (el primer valor de TId% que se considera es el del día 15, desde el día inicial). En la Figura 43 del Anexo 3 se describen las sentencias de programación (lenguaje SAS) para obtener valores estimados de severidad cada 14 días y las TId%, usando el modelo Logístico ajustado en el ciclo de crecimiento 2009/10 en Concordia.

Para el siguiente paso de desarrollo de modelos de regresión logística (variables meteorológicas y senescencia) sólo se utilizaron las curvas simuladas de progreso epidémico que observaron valores de $R^2 > 0,65$ y $RECM < 1,1$.

Desarrollo de modelos de regresión logística

Variable respuesta

Dicha variable se categorizó en Binaria (los valores de TId% de las curvas de progreso epidémico seleccionadas se categorizaron en función de un valor umbral en “severo” y “moderado a nulo”) y Ordinal (ídem al caso anterior, aunque basado en tres categorías epidémicas: “severa”, “moderada” y “ligera a nula”). Dichos umbrales correspondieron a percentiles de los valores simulados cada 14 días.

Variables regresoras:

- **Variables meteorológicas:**

Las estaciones meteorológicas de San Pedro (INTA), Concordia (SMN) y Gualaguaychú (SMN), registraron diariamente la temperatura máxima (Tx: °C), temperatura mínima (Tn: °C), precipitación (Pr: mm) y humedad relativa (HR: promedio tridiurno). La temperatura media diaria (Tm) fue calculada como la semisuma de las temperaturas máxima y mínima. Basados en estos elementos se construyeron las siguientes variables meteorológicas: Simples e Interacciones (producto de 2 variables simples).

- **Simples**

DTxnP: número de días con $Tn > 16^\circ\text{C}$ y $Tx < 36^\circ\text{C}$.

DTnN: número de días con $Tn \leq \text{umbral}$ (rango: 12 a 18°C).

DTxN: número de días con $Tn \leq \text{umbral}$ (rango: 12 a 18°C) o $Tx \geq \text{umbral}$ (rango: 32 a 36°C).

TxM: temperatura máxima media.

TnM: 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 $HR > \text{umbral}$ (rango: 65 a 85%).

DPrHRT: número de días con registros de $Pr > 0,2$ mm y $HR > \text{umbral}$ (rango: 65 a 85%), en el rango térmico: $Tx < 36^\circ\text{C}$ y $Tn > 16^\circ\text{C}$.

DHR: número de días con $HR > \text{umbral}$ (rango: 65 a 85%).

- **Interacciones (producto de 2 variables simples)**

It1 = FPr * DTxnP

It2 = FPr * TnM

It3 = DPrHRT * FPr

It4 = DPrHRT * TnM

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

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 (198 días en San Pedro, 209 días en

Concordia y 171 días en Gualeguaychú). Por ejemplo, si en Concordia se está a 141 días del inicio de la epidemia simulada: $141/209=0,67$ o sea tercer cuartil: $Snc=3$.

Lapso de procesamiento de las variables

Las variables fueron procesadas en el lapso de 14 días previos a cada valor de $Tid\%$, a lo largo de cada curva de progreso epidémico. La Figura 44 del Anexo 3 detalla las sentencias de programación (lenguaje SAS) para calcular variables meteorológicas regresoras y factor senescencia a intervalos de 14 días en el ciclo de crecimiento 2009/10 en Concordia.

Análisis estadístico

1. Se calcularon los coeficientes de correlación de Kendall (rk) Tau-b (Proc Freq del SAS) [38] entre los niveles epidémicos (categorías de acuerdo a $Tid\%$) y las variables meteorológicas descriptas (simples e interacciones) y el factor de senescencia (Snc). En la Figura 45 del Anexo 3 se describe la categorización ordinal, el cálculo de interacciones y la obtención de la correlación de Kendall (FPr).
2. Mediante la técnica de regresión logística se estimó la probabilidad de ocurrencia de cada categoría epidémica en base a una o varias de las variables regresoras analizadas (simples o como componente interactivo) [39]; [40]; [38]; [41]; [42]; [36]; [43]. Regla de decisión: se pronostica la categoría epidémica con una probabilidad asociada $\geq 0,5$ (binaria) o con la máxima probabilidad asociada de ocurrencia (ordinal). 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. El procedimiento Logistic del SAS, fija modelos de regresión paralelos para datos de respuesta ordinaria por medio del método de máxima verosimilitud, basado en la distribución de probabilidad acumulada de los niveles de respuesta. Una función logit (logaritmo natural de $(Pr/1-Pr)$, siendo "Pr" la probabilidad acumulada de las categorías epidémicas) establece la unión entre el componente estocástico y las variables regresoras meteorológicas analizadas. Los supuestos requeridos por el análisis de regresión lineal paramétrico, no se exigen en la regresión logística. El método de selección de variables Stepwise del procedimiento Logistic, fue usado para obtener el modelo más apropiado, haciendo jugar las variables (simples e interactivas) descriptas y fijando distintos niveles de significancia para entrar y permanecer en el modelo (NSE y NSP respectivamente). En la Figura 46 del Anexo 3 se describen las sentencias de programación correspondientes (lenguaje SAS).
3. La precisión de la predicción se basó en el porcentaje de casos correctamente clasificados. Si en cada uno de los casos analizados se compara la categoría epidémica observada versus la predicha, con máxima probabilidad de ocurrencia por las ecuaciones logísticas desarrolladas, se puede calcular el porcentaje de casos correctamente clasificados.

Resultados y discusión

Sólo para San Pedro y Concordia, en ambos ciclos (2008/09 y 2009/10) y para Gualeguaychú en el ciclo 2008/09, se pudieron ajustar modelos linealizados Logístico y Gompertz con altos coeficientes de determinación y bajo error (Figuras 6, 7, 8, 9, 10 y Cuadro 3). Se desechó para el desarrollo de modelos predictivos, la información epidémica de Gualeguaychú correspondiente al ciclo 2009/10. Para este sitio, en la epidemia correspondiente a dicho ciclo (2009/10), el mejor modelo fue Gompertz, aunque obtuvo valores de R^2 de sólo 0,54, los cuales se encuentran por debajo de los supuestos iniciales ($R^2 > 0,65$).

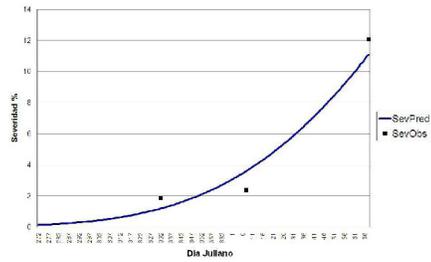


Figura 6: Severidad observada versus predicha para el ciclo epidémico San Pedro 2008/09.

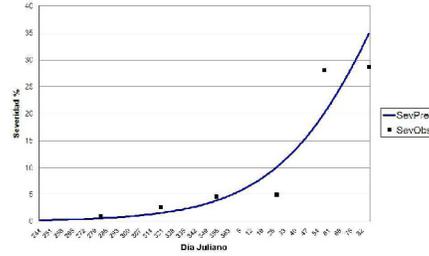


Figura 9: Severidad observada versus predicha para el ciclo epidémico Concordia 2009/10.

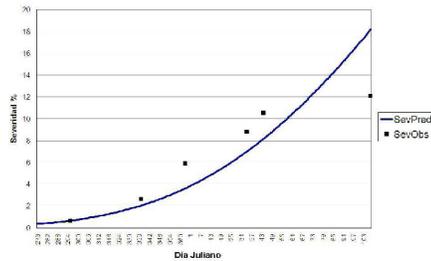


Figura 7: Severidad observada versus predicha para el ciclo epidémico San Pedro 2009/10.

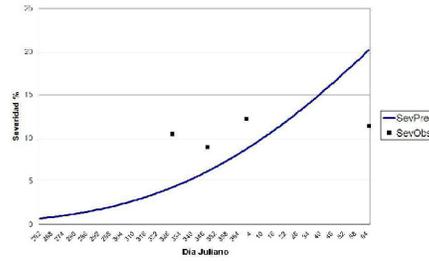


Figura 10: Severidad observada versus predicha para el ciclo epidémico Gualeguaychú 2008/09.

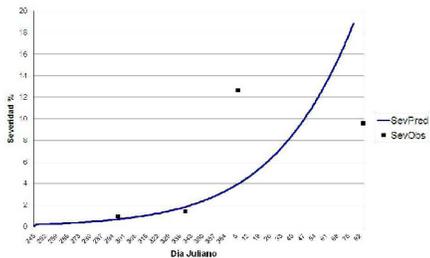


Figura 8: Severidad observada versus predicha para el ciclo epidémico Concordia 2008/09.

Los valores de TId% en función de umbrales, se categorizaron binariamente en severo ($TId\% \geq 0,077$) y moderado a nulo ($TId\% < 0,077$) y ordinalmente en severo ($TId\% \geq 0,077$), moderado ($TId\% < 0,077$ y $\geq 0,038$) y ligero a nulo ($TId\% < 0,038$), siendo 0,077 y 0,038 los percentiles 50 y 30% de los 65 valores de TId%.

Cuadro 3: Resumen estadístico del análisis de regresión lineal usado en la evaluación de modelos Logísticos (L) y Gompertz (G) de mejor ajuste, para describir las epidemias observadas en Concordia, San Pedro y Gualeguaychú (ciclo 2008/09). Resolviendo las siguientes ecuaciones se obtienen los valores de Severidad en proporción: $SevL = 1/(1 + \exp(-(-6,262 + 0,024 * t)))$; $SevL = 1/(1 + \exp(-(-6,265 + 0,027 * t)))$; $SevG = \exp(-\exp(1,9184 * \exp(-0,0069 * t)))$; $SevG = \exp(-\exp(1,7415 * \exp(-0,0061 * t)))$; $SevG = \exp(-\exp(1,6156 * \exp(-0,0067 * t)))$. Dichas ecuaciones corresponden a Concordia y San Pedro (2008/09 y 2009/10) respectivamente y Gualeguaychú (2008/09).

Sitio	Año	Modelo	N	R ²	RECM	intercepto	Pendiente
Concordia	2008/09	L	5	0,80	1,04	-6,2619	0,0241
Concordia	2009/10	L	7	0,93	0,61	-6,265	0,0268
San Pedro	2008/09	G	5	0,96	0,12	-1,9184	0,0069
San Pedro	2009/10	G	7	0,89	0,16	-1,7415	0,0061
Gualeguaychú	2008/09	G	5	0,66	0,34	-1,6156	0,0067

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 4.

Cuadro 4: Coeficientes de correlación de Kendall (r_k) Tau-b de variables meteorológicas (simples e interacciones) y del factor ligado a la senescencia foliar (Snc) en relación a los niveles de tasa de incremento epidémico diario (TId%) binarios (severo y ligero a nulo) y ordinales (severo, moderado y ligero a nulo). DTxnP: número de días con $T_n > 16^\circ\text{C}$ y $T_x < 36^\circ\text{C}$, DTnN: número de días con $T_n \leq 16^\circ\text{C}$; DTxnN: número de días con $T_n \leq 16^\circ\text{C}$ o $T_x \geq 36^\circ\text{C}$; TxM: temperatura máxima media; TnM: temperatura mínima media; FPr: días con registros de $Pr > 0,2$ mm; PrAc: se acumulan las precipitaciones $> 0,2$ mm; DPrHR: número de días con registros de $Pr > 0,2$ mm y $HR > 65\%$; DPrHRT: número de días con registros de $Pr > 0,2$ mm y $HR > 65\%$, en el rango térmico: $T_x < 36^\circ\text{C}$ y $T_n > 16^\circ\text{C}$; DHR: número de días con $HR > 65\%$; Interacciones: It1=FPr*DTxnP; It2=FPr*TnM; It3=DPrHRT*FPr; It4=DPrHRT*TnM; Snc: factor de senescencia: valores de 1 a 4 (primer a cuarto cuartil del ciclo epidémico).

Respuesta binaria		Respuesta ordinal	
Variabes	r_k	Variabes	r_k
<i>Simples</i>		<i>Simples</i>	
DTxnP	0,52	DTxnP	0,60
DTnN	-0,49	DTnN	-0,59
DTxnN	-0,52	DTxnN	-0,60
TxM	0,39	TxM	0,46
TnM	0,49	TnM	0,57
FPr	0,14	FPr	0,17
PrAc	0,18	PrAc	0,18
DPrHR	0,17	DPrHR	0,19
DPrHRT	0,36	DPrHRT	0,40
DHR	0,25	DHR	0,24
<i>Interactivas</i>		<i>Interactivas</i>	
It1	0,40	It1	0,49
It2	0,29	It2	0,34
It3	0,33	It3	0,37
It4	0,36	It4	0,41
<i>Senescencia foliar</i>		<i>Senescencia foliar</i>	
Snc	0,76	Snc	0,81

Las variables meteorológicas simples como DTnN (días con temperatura mínima $\leq 16^\circ\text{C}$), DTxnP (días con temperatura máxima $< 36^\circ\text{C}$ y temperatura mínima $> 16^\circ\text{C}$), TnM (temperatura mínima media) y el factor de senescencia (Snc), alcanzaron los más altos coeficientes de correlación de Kendall ($r_k > 0,49$). Las variables simples asociadas a elementos meteorológicos de naturaleza continua, como las térmicas, presentaron las más elevadas correlaciones con los niveles de enfermedad. Variables ligadas a elementos discretos, como las relacionadas a la precipitación, tuvieron menor grado de asociación con las tasas de incremento epidémico. Ello puede explicarse dado que el primer lapso primaveral de las curvas de progreso simuladas por los modelos Logísticos y Gompertz, se caracterizó por observar un lento y uniforme ritmo de incremento. Esta situación se acopla perfectamente a la normal ocurrencia de días con temperaturas bajas (alto valor de DTnN: temperaturas $\leq 16^\circ\text{C}$) y hojas jóvenes (bajo factor de Snc). En cambio, en el verano, las pendientes de las curvas simuladas son muy elevadas, concordando con hojas de senescencia creciente (alto valor de Snc) y alta frecuencia de días con temperaturas entre 16 y 36°C (alto valor de DTxnP). Las variables ligadas a elementos de ocurrencia esporádica y errática, como la precipitación, no realizaron aportes significativos como para explicar el comportamiento uniforme, característico de los dos subperíodos de la curva epidémica (bajos valores de r_k).

La alta correlación de las variables térmicas con la enfermedad, coincide con lo expresado por [44], quien afirma 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 . Dicha afirmación, compete a cultivos de arándano alto en el estado de Carolina del Norte. [24] señalaron que la mancha foliar es una enfermedad prevalente en tejidos senescentes viejos, justificando la correlación positiva encontrada en el presente estudio entre Snc y los niveles de incremento epidémico diario.

Mediante el procedimiento Logistic del SAS, se ajustaron diferentes modelos de respuesta binaria y ordinal (Cuadro 5). Las mayores precisiones de predicción se lograron con modelos de respuesta binaria. El modelo I fue el que logró la mayor precisión de predicción, cuando sólo se analizaron variables estrictamente meteorológicas como DTxnP. El modelo II, que sólo incluyó al factor de senescencia (Snc), clasificó correctamente 61 de las 65 observaciones de tasas de incremento epidémico diario (93,8%). Esta precisión de

predicción sólo fue superada por el modelo III, que integró, además del factor de senescencia (Snc), a las variables meteorológicas simples “DTnN” y “DPrHR” y al componente interactivo surgido del producto entre “DPrHRT*TnM” (95,4%).

Respecto a los modelos de respuesta ordinal, gradualmente los univariados a bivariados (modelos IV a VI), fueron mejorando la precisión de predicción desde 70,8% a 86,2%. Analizando sólo variables meteorológicas (simples e interacciones), el mejor modelo fue aquel que incluyó a DTxnP (modelo IV, P=0,47), logrando clasificar correctamente 46 de las 65 tasas de incremento epidémico. Se destacó el modelo univariado V, que sólo integró al factor de senescencia “Snc”, clasificando correctamente 54 casos de 65. El modelo VI que integra a “Snc” y a la interacción entre “FPr*DTxnP”, predijo erróneamente sólo 9 casos de los 65 analizados (P=0,45). Los modelos II y V fueron seleccionados por el método Stepwise (0,05 para NSE y NSP) cuando se hicieron intervenir todas las variables meteorológicas (simples e interactivas) y el factor Snc.

Cuadro 5: Modelos logísticos para estimar la probabilidad de ocurrencia de cada categoría de nivel de tasa de incremento epidémico diario (Tid%): Binaria: severa (S) y moderada a nula (M); Ordinal: severa (S), moderada (M) y ligera a nula (L), en base a variables meteorológicas simples e interacciones y a un factor de senescencia foliar (Snc). *LogitPrS= $\ln(\text{PrS}/1-\text{PrS})$; 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. PrM=PrMac-PrS. PrL=1-(PrS+PrM) siendo “PrL” la probabilidad de observar un nivel de incremento epidémico ligero a nulo (L). DTxnP: número de días con Tn>16°C y Tx<36°C; DTnN: número de días con Tn<=16°C; DPrHR: número de días con registros de Pr>0,2 mm y HR>65%; DPrHRT: número de días con registros de Pr>0,2 mm y HR> 65%, en el rango térmico: Tx<36°C y Tn>16°C; FPr: días con registros de Pr>0,2 mm; Interacciones: It1=FPr*DTxnP; It4=DPrHRT*TnM Snc: factor de senescencia: valores de 1 a 4 (primer a cuarto cuartil del ciclo epidémico).

Modelo	Ecuaciones del Modelo*	Precisión (%)
<i>Respuesta Binaria</i>		
I	LogitPrS= - 3,4412 + 0,4172*DTxnP	78,5
II	LogitPrS= - 10,8126 + 4,2892*Snc	93,8
III	LogitPrS= -14,2559+4,7867*Snc+0,2043*It4+0,3672*DTnN-3,1527*DPrHR	95,4
<i>Respuesta Ordinal</i>		
IV	LogitPrS= - 4,1985 + 0,4955*DTxnP LogitPrMac= - 2,5761 + 0,4955*DTxnP	70,8
V	LogitPrS= - 11,6675 + 4,6174*Snc LogitPrMac= - 8,6741 + 4,6174*Snc	83,1
VI	LogitPrS= -12,8144 + 4,5697*Snc + 0,0338*It1 LogitPrMac= - 9,4060 + 4,5697*Snc + 0,0338*It1	86,2

Conclusiones

A través de los resultados obtenidos a partir de los modelos desarrollados, fue posible explicar y cuantificar el lento progreso epidémico (observado y simulado) 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 epidémico leves a nulas. Concordando con las elevadas pendientes de la curva de progreso epidémico estival (hojas de senescencia creciente y tiempo templado a cálido), las salidas de los modelos estimaron predominantemente, para este lapso, valores altos de probabilidad de ocurrencia de tasas de incremento epidémico severas.

La continuidad de la investigación, sobre la base de una mayor cantidad de datos, que permitan el ajuste y validación de los modelos predictivos desarrollados, como parte de un sistema de pronóstico, que admita la representación de los resultados (mapas), así como también su difusión (Internet), constituye, sin lugar a dudas, un aporte más al manejo integrado de enfermedades de las plantas, siendo también el primero de los antecedentes en materia de desarrollo de modelos predictivos de enfermedades en cultivos intensivos en la Argentina.

Formación de recursos humanos

Esta investigación se caracterizó por una fuerte demanda de recursos humanos. En este sentido, fueron capacitados testistas de grado en reconocimiento y evaluación visual de daños provocados por la enfermedad respectiva, en cultivos de arándano. Asimismo, la metodología y resultados obtenidos en la misma se ponen en conocimiento de los alumnos que participan del curso de intensificación denominado Fitopatología General², como parte del Ciclo de Intensificación requerido para acceder al título de Ingeniero Agrónomo. Este último, constituye a su vez un estímulo para que nuevos estudiantes se sumen al equipo que continúa trabajando en esta línea de investigación.

Referencias

1. De Wolf, E.D. e Isard, S.A. (2007). Disease cycle approach to plant disease prediction. Annual Review of Phytopathology. 45(9):1-18.
2. Campbell, C.L. y Madden, L.V. (1990). Introduction to plant disease epidemiology. Wiley, New York. 532p.
3. Paul, P.A. y Munkvold, G.P. (2004). A model-based approach to preplanting risk assessment for gray leaf spot of maize. Phytopathology. 94:1350-1357.
4. Twengström, E.; Sigvald, R.; Svensson, C. y Yuen, J. (1998). Forecasting Sclerotinia stem rot in spring sown oilseed rape. Crop Prot. 17:405-411.
5. Madden, L.V.; Ellis, M.A.; Lalancette, N.; Hughes, G. y Wilson, L.L. (2000). Evaluation of a disease warning system for downy mildew of grapes. Plant Disease. 84:549-554.
6. Triloff, P. (1997). Apple scab control with the simulation programme "RIMpro" at Lake Constance, Germany: results and experience in the past three years. Int. Org. Biol. Integr. Control Noxious Anim. Plants, West Palearctic Reg. Sect. 20:229-240.
7. Xu, X.M.; Butt, D.J. y Van Santen, G. (1995). A dynamic model simulating infection of apple leaves by *Venturia inaequalis*. Plant Pathology. 44:865-876.
8. Shtienberg, D.; Shwartz, H.; Oppenheim, D.; Zilberstaine, M. y Herzog, Z. (2003). Evaluation of local and imported fire blight warning systems in Israel. Phytopathology. 93:356-363.
9. Taylor, M.C.; Hardwick, N.V.; Bradshaw, N.J. y Hall, A.M. (2003). Relative performance of five forecasting schemes for potato late blight (*Phytophthora infestans*) I. Accuracy of infection warnings and reduction of unnecessary, theoretical, fungicide applications. Crop Protection. 22:275-283.
10. Gilles, T.; Phelps, K.; Clarkson, J.P. y Kennedy, R. (2004). Development of MILLIONCAST, an improved model for predicting downy mildew sporulation on onions. Plant Disease. 88:695-702.
11. Batista, D.C.; Lima, M.A.; Haddad, F.; Maffia, L.A. y Mizubuti, E.S.G. (2006). Validation of decision support systems for tomato early blight and potato late blight, under Brazilian conditions. Crop Protection. 25:664-670.
12. Phipps, P.M.; Deck, S.H. y Walker, D.R. (1997). Weather-based crop and disease advisories for peanuts in Virginia. Plant Disease. 81:236-44.
13. Xu, X.M. y Butt, D.J. (1996). A description of AdemTM-a PC-based disease warning system for apple. Presented at Proc. Works. Integr. Control Pome Fruit Disease, 4th, Croydon, U.K.
14. Berrie, A.M. y Xu, X.M. (2003). Managing apple scab (*Venturia inaequalis*) and powdery mildew (*Podosphaera leucotricha*) using Adem. Int. J. Pest Management. 49:243-249.
15. Thomas, C.S.; Skinner, P.W.; Fox, A.D. Greer, C.A. y Gubler, W.D. (2002). Utilization of GIS/GPS-based information technology in commercial crop decision making in California, Washington, Oregon, Idaho, and Arizona. J. Nematol. 34:200-206.

² Otorga 4 créditos (1 crédito = 16 hs).

16. De Wolf, E.D.; Molineros, J.E.; Madden, L.V.; Lipps, P.E.; Knight, P. y Miller, D. (2005). Future directions in the development and application of risk assessment models for *Fusarium* head blight. Presented at Proc. Natl. *Fusarium* Head Blight Forum, Milwaukee, WI.
17. Wright, E.R.; Pérez, B.A.; Fernández, R.L.; Ascitutto, K.; Rivera, M.C.; Murillo, F.; Vasquez, P.; Divo de Sesar, M.; Pérez, A.; Aguilar Heredia, L.; Rosato, M.F.; Crelier, A. y Baldomá, J. (2005). Conocimiento actual sobre enfermedades de arándano. Libro de Resúmenes. 113-117. I Congreso Latinoamericano de Arándanos y otros berries. Buenos Aires.
18. Wright, E.R.; Vasquez, P.; Ascitutto, K.; Pérez, A.; Diano, M.; Ciorca, 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. 11° Congreso Nacional de Horticultura. Montevideo. Uruguay.
19. Wright, E.R. y Pérez, J.A. (2007). Enfermedades del arándano. Publicado en CD. XXX Congreso Argentino de Horticultura. La Plata. Buenos Aires.
20. 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.
21. Wright, E.R.; Rivera, M.C.; Esperón, J.; Cheheid, A. y Rodríguez Codazzi, A. (2004). *Alternaria* leaf spot, twig blight and fruit rot of highbush blueberry in Argentina. *Plant Disease*. 88:1383.
22. Wright, E.R.; Fernández, R.L.; Benveniste, M.; Pérez, J.A.; Rivera, M.C.; Roncoroni, S.; Nicolini, F.; Vasquez, P.E.; Ciorca, P. y Pérez, B.A. (2010). Deterioro poscosecha de arándano en Entre Ríos y Buenos Aires, Argentina. p. 63-68. En: Divo de Sesar, M.; Rocca, M.; Vilella, F. (eds.) Avances en cultivos frutales no tradicionales. Arándanos-Cerezas-Frutillas-Granadas.
23. Dárcy, C.J.; Eastburn, D.M. y Schuman, G.L. (2001). Illustrated glossary of plant pathology. The American Phytopathological Society. Education Center. www.apsnet.org.
24. Rivera, M.C.; Wright, E.R.; Pérez, B.A.; González Rabellino, P. y Pérez, J.A. (2009). Enfermedades del arándano. p. 1-68. En: Wright, E.R. (ed.). Guía de enfermedades, plagas y malezas del arándano. Orientación. Buenos Aires.
25. Hyre, R.A. (1954). Progress in forecasting late blight of potato and tomato. *Plant Disease Reporter*. 38:245-253.
26. Coakley S.M. (1988). Variation in climate and prediction of disease in plants. *Annual Review of Phytopathology*. 26:163-181.
27. Del Ponte, E.M.; Godoy, C.V.; Li, X. y Yang, X.B. (2006). Predicting severity of Asian soybean epidemics with empirical rainfall models. *Phytopathology*. 96:797-803.
28. Moschini, R.C.; Sisterna, M.N. y Carmona, M. (2006). Modelling of wheat black point incidence based on meteorological variables in the southern Argentinean Pampas Region. *Australian Journal of Agricultural Research*. 57(11):1151-1156.
29. Moschini, R.C. y Fortugno, C. (1996). Predicting wheat head blight incidence using models based on meteorological factors in Pergamino, Argentina. *European Journal of Plant Pathology*. 102:211-218.
30. Moschini, R.C.; Carmona, M.; Barreto, D. y Conti, H.A. (1996). Modelos de predicción de la incidencia de la mancha en red de la cebada cervecera basados en variable meteorológicas: evaluación del potencial climático de la región pampeana respecto a la enfermedad. *Fitopatología. Brasil*. 21(3).
31. Moschini, R.C.; Carmona, M. y Grondona, M. (1999). Wheat head blight incidence variations in the Argentinian Pampas region associated with the El Niño/Southern Oscillation. *Actas Simposio Israel*.
32. Moschini, R.C. y Perez, B.A. (1999). Predicting wheat leaf rust severity using planting date, genetic resistance, and weather variables. *Plant Disease*. 83:381-384.

33. Moschini, R.C.; Pioli, R.; Carmona, M. y Sacchi, O. (2001). Empirical predictions of wheat head blight in the northern Argentinian Pampas region. *Crop Science*. 41:1541-1545.
34. Moschini, R.C.; Escande, A.R.; Pereyra, V.R.; Pedraza, V.; Quiroz, F.; Troglia, C. e Iriarte, I. (2002). Predicción de la incidencia de la podredumbre blanda del capítulo de girasol en base a factores ambientales y genéticos. *Revista Argentina de Agrometeorología*. 2(1):51-57.
35. Moschini, R.C.; Carranza, M.R. y Carmona, M.A. (2004). Meteorological-based predictions of wheat head blight epidemic in the southern Argentinean pampas region. *Cereal Research Communication* 32:45-52.
36. Moschini, R.C. (2007). Los cultivos de Soja y Trigo: Herramientas para la predicción y manejo de enfermedades en la Argentina. p. 39-48. 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.
37. Davies, F.S. y Albrigo, L.G. (1994). *Citrus*. *Crop Production Science in Horticulture*. Vol 2, CAB International, Wallingford, UK. 254p.
38. De Wolf, E.D.; Madden, L.V. y Lipps, P.E. (2003). Risk assessment models for wheat Fusarium head blight epidemics based on within-season weather data. *Phytopathology*. 93:428-435.
39. Johnson, D.A.; Alldredge, J.R. y Vakoch, D.L. (1996). Potato late blight forecasting models for the semiarid environment of south-central Washington. *Phytopathology*. 86:480-484.
40. Turechek, W.W. y Stevenson, K.L. (1998). Effects of host resistance, temperature, leaf wetness duration and leaf age on infection and lesion development of pecan scab. *Phytopathology*. 88:1294-1301.
41. Troglia, C.; Escande, A.R.; Moschini, R.C.; Damiano, F. y Quiroz, F. (2004). Modelos logísticos basados en variables térmicas e hídricas para simular la dinámica de la producción de inóculo de *Sclerotinia sclerotiorum* en suelos con rastrojo de girasol. *Actas X Reunión Nacional de Agrometeorología*. Mar del Plata.
42. Henderson, D.; Williams, C.J. y Miller, J.S. (2007). Forecasting late blight in potato crops of southern Idaho using logistic regression analysis. *Plant Disease*. 91: 951-956.
43. Carmona, M.; Moschini, R.; Cazenave, G. y Sautua, F. (2010). Relación entre la precipitación registrada en estados reproductivos de la soja y la severidad de *Septoria glycines* y *Cercospora kikuchii*. *Tropical Plant Pathology*. 35(2): 71-78.
44. Milholland, R.D. (1973). A leaf spot disease of highbush blueberry caused by *Alternaria enuissima*. *Phytopathology*. 63: 1395-1397.