



Severidade de *Phakopsora pachyrhizi* em soja estimada por modelos de crescimento não lineares

Otávio dos Santo Escobar¹, Alessandro Dal'Col Lúcio¹, Danie Martini Sanchotene², Fernando Machado Haesbaert³, Sidnei Jose Lopes¹, Jaqueline Sgarbossa^{1(*)} e Sylvio Henrique Bidel Dornelles¹

¹Universidade Federal de Santa Maria (UFSM). Avenida Roraima nº 1000, Cidade Universitária, Bairro Camobi, CEP 97105-900 Santa Maria, RS.

E-mails: otescobar@gmail.com, adlucio@ufsm.br, sgarbossajs@yahoo.com e sjlopes2008@gmail.com

²Universidade Regional do Alto Uruguai e das Missões (URI). Avenida Batista Bonoto Sobrinho nº 733, Bairro São Vicente, CEP 97700-000 Santiago, RS.

E-mail: danie.sanchotene@hotmail.com

³Universidade Federal de Tocantins (UFT). Rua Badejós, Lote 7, Chácara 69/72, Bairro Jardim Sevilha, CEP 77402-970 Gurupi, TO.

E-mail: fhaesbaert@gmail.com

(*)Autor para correspondência.

INFORMAÇÕES

História do artigo:

Recebido em 19 de dezembro de 2022

Aceito em 16 de maio de 2023

Termos para indexação:

ferrugem asiática da soja

modelo logístico

modelo Gompertz

pontos críticos

RESUMO

O estudo teve por objetivo estimar o crescimento da severidade da Ferrugem Asiática da Soja (FAS) a partir de modelos de regressão não lineares em diferentes anos agrícolas, interpretar as estimativas dos parâmetros e calcular os pontos críticos no crescimento da doença. As curvas de crescimento da severidade nas safras 2015/2016, 2016/2017, 2017/2018, 2018/2019 e 2019/2020 foram ajustadas, selecionando o modelo que melhor representava este crescimento. Foram calculados os pontos críticos de crescimento dentro da evolução da doença, que são os pontos de máxima aceleração, inflexão e máxima desaceleração da severidade da doença. O modelo com melhor ajuste foi o modelo logístico parametrizado. Os valores máximos da severidade da doença (parâmetro β_1), foram observados nas safras 2015/2016 e 2016/2017, atingindo até 80,5% e 79,5% de severidade da doença, respectivamente. O parâmetro β_2 , que está relacionado à precocidade do crescimento da doença, mostrou nas safras 2015/2016 e 2016/2017, devido às condições meteorológicas mais favoráveis, maior a precocidade da doença. O parâmetro β_3 remete à taxa de crescimento da severidade da doença, com maior valor na safra 2019/2020. Nas safras 2015/2016 e 2016/2017, devido às condições climáticas favoráveis, os pontos de máxima aceleração ocorreram mais precocemente no ciclo da cultura. Os pontos de inflexão e de máxima desaceleração foram idênticos para as safras.

© 2023 SBAgro. Todos os direitos reservados.

Introdução

A produtividade da soja é afetada por diversos fatores e, dentre eles, destacam-se as doenças, que podem ser de origem fúngica, bacteriana, viral ou por nematoides (Ogoshi

et al., 2019). No Brasil já foram identificadas quarenta doenças em lavouras de soja, sendo que a importância econômica de cada doença específica varia em virtude da região de cultivo e as condições meteorológicas intrínsecas de cada região (Amorim et al., 2018). Estudos demonstram

que a ocorrência de doenças resulta em perdas de 15 a 20% na produtividade, entretanto para a Ferrugem Asiática da Soja (FAS), principal doença da cultura no Brasil (Akamatsu et al., 2013; Langenbach et al., 2016), os danos podem acarretar perdas de até 90% de produtividade (Godoy et al., 2016).

A principal estratégia de controle da FAS utilizada pelos produtores é a aplicação de fungicidas químicos (Langenbach et al., 2016). Devido a redução da sensibilidade do fungo *Phakopsora pachyrhizi*, agente causal da FAS, aos principais grupos químicos disponíveis, faz-se necessário o desenvolvimento de novas alternativas que visem mitigar os impactos negativos gerados pela ocorrência da doença em relação ao patamar produtivo da cultura, bem como possibilitar a sustentabilidade dos sistemas de produção (Godoy et al., 2016).

O conhecimento da dinâmica da doença na soja é de extrema importância para subsidiar à tomada de decisão, frente a necessidade de controle. Neste contexto, o uso de modelos não lineares para caracterizar o progresso temporal de epidemias botânicas se destaca como consolidado (Amelia et al., 2019). O desenvolvimento da FAS responde não linearmente à temperatura e à umidade relativa do ar, portanto, o uso de modelos não lineares pode ser empregado para a representação de progresso da doença (Laurindo et al., 2015). Com a aplicação de modelos não lineares tem-se a possibilidade de realização de interpretações biológicas com base nas estimativas dos parâmetros do modelo, bem como de seus pontos críticos.

Nos modelos de crescimento a assíntota da curva pode ser utilizada para determinar o platô da variável resposta total, e o parâmetro de crescimento pode ser utilizado para realizar inferências quanto a velocidade (taxa) de progresso da doença. Além disso, outros pontos da curva de crescimento, como o ponto de inflexão e os pontos de aceleração e de desaceleração podem contribuir para inferências quanto à resposta da variável ao longo do tempo (Mischan et al., 2014; Pinho et al., 2014). Considerando a importância da doença FAS para a cultura e, a escassez de informações sobre o uso de modelos não lineares no progresso da doença e da interpretação dos respectivos pontos críticos, como estratégia mitigadora das implicações negativas à cultura,

o estudo teve por objetivo estimar a evolução da severidade da FAS a partir de modelos de crescimento não lineares.

Material e Métodos

O Estudo foi realizado com dados de experimentos conduzidos durante as safras agrícolas 2015/2016, 2016/2017, 2017/2018, 2018/2019 e 2019/2020, provenientes da empresa BIEMONTE Pesquisa e Desenvolvimento, localizada na cidade de Santa Maria, estado do Rio Grande do Sul, sob coordenadas geográficas a 29°39'5,38"S, 53°57'24,07"W e a 160 m de altitude. O clima da região, conforme a classificação de Köppen, é do tipo *Cfa*, subtropical úmido, caracterizado por apresentar precipitação pluviométrica acumulada anual de 1.800 mm, uniformemente distribuída e, temperaturas subtropicais (Alvares et al., 2013).

Durante o período de condução dos experimentos, a variável avaliada foi a severidade da doença Ferrugem Asiática da Soja, agente causal *Phakopsora pachyrhizi*. Para tanto, foram atribuídas notas de severidade, em cada safra agrícola, sendo que as safras representam os tratamentos. As unidades experimentais (UE) apresentaram dimensões de 3 metros de largura por 5 metros de comprimento, onde, a área útil considerada para as avaliações foram os 10 m² centrais, com quatro repetições em cada ensaio. Na Tabela 1, são apresentadas as informações referentes ao número de ensaios, número de avaliações, número de observações, data de início das mensurações e a data final das mensurações, em cada safra.

As notas referentes a severidade da doença, foram atribuídas com base na escala diagramática que contabiliza a área foliar afetada pela doença (Martins et al., 2004). Em cada período de avaliação, foram selecionadas aleatoriamente dez plantas, em cada UE e posteriormente, estimada a média, contabilizando assim o valor médio de severidade da doença, para cada tratamento.

Para avaliação da severidade da FAS considerou-se a área foliar atacada em vinte folhas coletadas aleatoriamente em cada UE, conforme a escala proposta por Godoy et al. (2006). Os dados meteorológicos foram obtidos de uma estação meteorológica automática, instalada na área experimental, na qual foram coletados os valores de tem-

Tabela 1. Descrição dos ensaios conduzidos em cada safra agrícola, com seus respectivos números (n°) de ensaios, unidades experimentais, avaliações, observações e datas de primeira e última avaliação.

Safra	Unidades Experimentais (n°)	Avaliações (n°)	Observações (n°)	Primeira Avaliação	Última Avaliação
2015/16	20	23	92	18/03/2016	13/05/2016
2016/17	40	51	204	22/02/2017	20/04/2017
2017/18	36	41	164	15/02/2018	12/04/2018
2018/19	16	31	124	20/02/2019	18/04/2019
2019/20	28	47	188	07/01/2020	16/03/2020

peratura média diária do ar (C°), precipitação pluviométrica acumulada diária (mm) e umidade relativa média diária (%).

Para ajuste da curva de crescimento da severidade da FAS foram testados os modelos de regressão não lineares: logístico (LOGI1) (Equação 1), logístico parametrizado (LOGI2) (Equação 2), Gompertz (GOMP1) (Equação 3) e Gompertz parametrizado (GOMP2) (Equação 4).

$$Y_j = \frac{\beta_1}{(1+\exp(\beta_2 - \beta_3 t_j))} \quad \text{(Equação 1)}$$

$$Y_j = \frac{\beta_1}{(1+\exp(\beta_3(\beta_2 - t_j)))} \quad \text{(Equação 2)}$$

$$Y_j = \beta_1 * \exp(-\exp(\beta_2 - \beta_3 t_j)) \quad \text{(Equação 3)}$$

$$Y_j = \beta_1 * \exp(-\exp(\beta_3(\beta_2 - t_j))) \quad \text{(Equação 4)}$$

Em que Y : é a variável dependente no tempo (severidade da doença, %); t é a variável independente (dias após a emergência da cultura); o valor de β_1 representa a assíntota ou valor máximo da severidade da doença (%); β_2 é o valor da abscissa no ponto de inflexão (exceto no modelo Gompertz em o valor que é dado por β_2/\exp e, Gompertz parametrizado, em que este valor será encontrado pelo quociente β_2/β_3) e β_3 está relacionado com a taxa de crescimento do progresso da doença, ou seja, quanto maior for este valor, mais rápido a doença irá atingir a assíntota (Mischan & Pinho, 2014).

Em modelos não lineares é necessário o uso de métodos iterativos para obtenção da aproximação de estimativas dos parâmetros. Para o obter tais estimativas, foi utilizado o método dos mínimos quadrados ordinários através do algoritmo de Gauss-Newton. Esta etapa foi realizada através da função *nls()* e os valores iniciais obtidos por meio da função *manipulate* (Allaire, 2014), utilizando o software R (R Core Team, 2020).

A seleção dos modelos logísticos e de Gompertz com duas parametrizações, foi realizada pelos critérios de qualidade do ajuste e qualidade das estimativas, por meio do Critério de informação Akaike (AIC) (Akaike, 1974), Critério de informação Bayesiano (BIC) (Schwarz, 1978), Coeficiente de determinação ajustado (R^2_{aj}), Não-linearidade intrínseca (C') e paramétrica (C°), calculados a partir do critério Bates & Watts (1988) e interpretados de acordo com De Souza et al. (2010).

A normalidade, heterocedasticidade e independência dos resíduos foram testadas pelos testes de Shapiro-Wilk (Shapiro & Wilk, 1965), Breusch-Pagan (Breusch & Pagan, 1979) e Durbin-Watson (Durbin & Watson, 1950), respectivamente, sendo verificado que os pressupostos estatísticos não foram atendidos. Devido a violação pressupostos

do modelo, os intervalos de confiança dos parâmetros foram estimados por meio de reamostragem *bootstrap*, com 10.000 reamostragens. Para tal, foi utilizado a função *nlstools()* do pacote *nlstool* no software R (Baty et al., 2015), para os parâmetros dos modelos de cada uma das safras. Esta técnica permite estudar as propriedades distributivas dos estimadores (Souza et al., 2010), sendo a mais recomendada para contornar os problemas de não atendimento dos pressupostos (Ratkowski, 1983). Os intervalos de confiança de 95% (IC) foram obtidos pela diferença entre o 97,5º e 2,5º percentis, das estimativas dos 10.000 parâmetros.

Identificado o modelo de melhor ajuste, foram calculadas as coordenadas dos pontos críticos, ponto de aceleração máxima (MAP), ponto de inflexão (IP) e o ponto de desaceleração máxima (MDP). As coordenadas dos pontos críticos foram obtidas a partir das derivadas parciais do modelo logístico (Equação 5), selecionado em relação a variável independente, dias após emergência (DAE).

O ponto de inflexão (IP) foi obtido igualando a derivada de segunda (Equação 6) ordem a zero (Equação 7), o ponto de máxima aceleração (MAP) e o ponto de máxima desaceleração (MDP) tiveram sua derivada de terceira ordem (Equação 8) igualadas a zero (Equação 9) (Mischan & Pinho, 2014). As derivadas de primeira e segunda ordem foram representadas graficamente, junto com a curva do modelo selecionado, para apresentarem os pontos críticos.

As equações utilizadas para proceder as respectivas estimativas, são apresentadas a seguir:

$$Y_j = \frac{\beta_1}{(1+\exp(\beta_3(\beta_2 - t_j)))} \quad \text{(Equação 5)}$$

em que:

$$X = \exp(\beta_3(\beta_2 - t_j))$$

e,

$$Y_j = \frac{\beta_1}{(1+X)}$$

$$Y''_j = \frac{\beta_1 \cdot (\beta_3^2) \cdot \exp(\beta_3(\beta_2 - t_j)) \cdot (\exp(\beta_3(\beta_2 - t_j)) - 1)}{(1+\exp(\beta_3(\beta_2 - t_j)))^3} \quad \text{(Equação 6)}$$

$$Y''_j = \frac{\beta_1 \cdot (\beta_3^2) \cdot X \cdot (X - 1)}{(1+X)^3}$$

$$Y''_j = 0 \rightarrow X = \exp(\beta_3(\beta_2 - t_j)) = 1 \quad \text{(Equação 7)}$$

em que:

$$IP \rightarrow x = \beta_3$$

$$Y'''_j = \frac{\beta_1 \cdot (\beta_3^3) \cdot \exp(\beta_3(\beta_2 - t_j)) \cdot (\exp(\beta_3(\beta_2 - t_j)) - 4 \cdot \exp(\beta_3(\beta_2 - t_j)) + 1)}{(1 + \exp(\beta_3(\beta_2 - t_j)))^4} \quad (\text{Equação 8})$$

$$Y'''_j = \frac{\beta_1 \cdot (\beta_3^3) \cdot X \cdot (X^2 - 4X + 1)}{(1 + X)^4}$$

$$Y'''_j = 0 \rightarrow X^2 - 4X + 1 = 0, \quad X_1 = 2 + \sqrt{3}, \quad X_2 = 2 - \sqrt{3} \quad (\text{Equação 9})$$

em que:

$$MAP \rightarrow X_1 = \frac{1}{\beta_3} (\beta_2 \beta_3 - \ln(2 + \sqrt{3})) \cdot \frac{\beta_2 \beta_3 - 1,3171}{\beta_3}$$

$$MDP \rightarrow X_2 = \frac{1}{\beta_3} (\beta_2 \beta_3 - \ln(2 - \sqrt{3})) \cdot \frac{\beta_2 \beta_3 + 1,3171}{\beta_3}$$

onde Y , t , β_2 , e β_3 tem a mesma definição anteriormente descrita (Mischan & Pinho, 2014).

Resultados e Discussão

Na Tabela 2 são apresentados os coeficientes que indicam a qualidade do ajuste dos modelos. Os menores valores de C^i foram obtidos nos modelos LOGI1 e LOGI2, exceto para a safra 2019/2020, e os valores de C^o do modelo LOGI2 foram inferiores ao modelo LOGI1. Logo, o modelo LOGI2 é o modelo com comportamento mais próximo do linear neste estudo. Dentre os modelos avaliados, os que apresentaram melhor ajuste à estimação da severidade da FAS, segundo os critérios AIC e BIC, foram os modelos GOMP1 e GOMP2. Embora os valores de AIC e BIC sendo menores ao GOMP1 e GOMP2, observa-se que os modelos LOGI1 e LOGI2 apresentaram valores próximos aos de GOMP1 e GOMP2, além das estimativas dos coeficientes de determinação ajustados R^2_{aj} dos modelos LOGI1 e LOGI2 sendo inferiores aos dos modelos GOMP1 e GOMP2.

A escolha de um modelo com as melhores medidas de bondade (R^2 ou R^2_{aj}) ou menores estimativas dos critérios de seleção (AIC e BIC) nem sempre serão uma garantia que aquele é o melhor modelo. Sendo assim, um modelo pode ser escolhido erroneamente quando selecionado somente com base nos critérios de qualidade ou de seleção do modelo (Sari et al., 2018).

A partir da interpretação das estimativas dos coeficientes e critérios, o modelo LOGI2 apresentou um melhor ajuste da estimação de severidade da FAS, com menores estimativas de C^i e C^o , menores valores de R^2_{aj} e os valores dos critérios de AIC e BIC ligeiramente superiores aos demais modelos testados. Todos esses critérios devem ser usados em conjunto para a seleção de um modelo não linear (Sari et al., 2018).

Na safra 2017/2018, não foi verificado ajuste do modelo e, conseqüentemente, das medidas C^i e C^o . Nessa safra os níveis de severidade da FAS foram muito baixos, atingindo o valor máximo de 7,5% de severidade da doença, aos 88 dias após a emergência das plantas, pois as condições para a instalação e desenvolvimento da doença não foram ideais. Desta forma, com base nos dados coletados no experimento dessa safra, não foi possível realizar uma estimação da curva de crescimento da doença. Além dos estimadores evidenciarem essa resposta, a estimação dos parâmetros também foi comprometida (Tabela 2). Assim, para a safra 2017/2018 não foi ajustado o modelo LOGI2.

Após a seleção do modelo LOGI2, foram ajustados os dados de severidade da doença, nas diferentes safras. Como os pressupostos do modelo, normalidade, homogeneidade e independência dos resíduos não foram atendidos, foi

Tabela 2. Valores das estimativas de não linearidade paramétrica (C^o) e intrínseca (C^i), critério de informação Bayesiano (BIC), coeficiente de determinação ajustado (R^2_{aj}) e critério de informação de Akaike (AIC).

Safra	Modelos			
	LOGI1	LOGI2	GOMP1	GOMP2
C^o				
2015/16	1,24	1,004	1,874	2,495
2016/17	1,05	0,798	1,805	2,672
2017/18	16,39	8,412	39,78	198,808
2018/19	3,02	1,789	7,892	22,072
2019/20	1,03	0,905	1,619	1,991
BIC				
2015/16	728,818	728,818	725,403	725,403
2016/17	1571,833	1571,833	1569,876	1569,876
2017/18	757,923	757,923	757,165	757,165
2018/19	656,706	656,706	654,78	654,78
2019/20	1196,587	1196,587	1195,202	1195,202
AIC				
2015/16	718,731	718,731	715,316	715,316
2016/17	1558,561	1558,561	1556,603	1556,603
2017/18	745,524	745,524	744,766	744,766
2018/19	645,425	645,425	643,499	643,499
2019/20	1183,642	1183,642	1182,256	1182,256
C^i				
2015/16	0,181	0,181	0,206	0,206
2016/17	0,127	0,127	0,177	0,177
2017/18	0,122	0,122	0,152	0,152
2018/19	0,15	0,15	0,242	0,242
2019/20	0,234	0,234	0,22	0,22
R^2_{aj}				
2015/16	0,739	0,739	0,749	0,749
2016/17	0,786	0,786	0,788	0,788
2017/18	0,77	0,77	0,771	0,771
2018/19	0,915	0,915	0,916	0,916
2019/20	0,718	0,609	0,72	0,720

utilizado da técnica de reamostragem *bootstrap* (10.000 reamostragens) para as estimativas dos parâmetros e dos pontos críticos do modelo LOGI2, para cada uma das safras (Tabela 3 e Figura 1). A interpretação das diferenças entre as safras foi realizada por meio do intervalo de confiança dos parâmetros e dos pontos críticos do modelo LOGI2, gerados a partir da reamostragem *bootstrap* (Figura 1).

As safras 2015/2016 e 2016/2017, apresentaram os maiores níveis de severidade da FAS (maior assíntota, β_1) atingindo níveis de 65,48% e 65,97%, respectivamente, de área foliar atacada pela doença. Na safra 2019/2020, foi registrado o menor valor de severidade da doença (24,37%), aspecto que pode ser condicionado à ocorrência de estiagem, impedindo o desenvolvimento do inóculo do fungo, acarretando em níveis baixos de dano à cultura.

Sari et al. (2019) relatam que quanto menor a estimativa de β_2 , os pontos de inflexão (IP), de máxima aceleração (MAP) e de máxima desaceleração (MDP) são atingidos em menor tempo, ou seja, os picos da severidade de FAS ocorrem de forma antecipada (Figura 2C). A safra 2015/2016 teve o menor valor de β_2 e, conseqüentemente, atingiu os pontos de MAP, IP e MDP antes das demais safras.

As maiores estimativas de β_3 indicam um aumento da inclinação da curva (Figura 2B). As safras 2015/2016 e 2016/2017 apresentaram estimativas do parâmetro β_3 próximos entre si. Observa-se que na safra 2015/2016 houve uma inclinação mais acentuada que na safra 2016/2017, proporcionando uma maior taxa de crescimento da severidade FAS em menor intervalo de tempo. Segundo Sari et al. (2019), esse parâmetro é responsável pelo aparecimento do IP em menor tempo, o que se verifica na figura 2B, além de estar vinculado ao encurtamento entre o MAP e MDP, chamado de concentração, resultado evidenciado na safra 2019/2020 que apresentou o maior valor de β_3 (Figura 2C).

Observando os pontos críticos, o crescimento da severidade da FAS tem uma característica de taxa crescente até atingir o IP. Após atingir este ponto, a taxa se torna decrescente (Figura 2B). Este ponto permite uma interpretação relacionada com a precocidade no crescimento da severidade da FAS, uma vez que, quanto antes este ponto

for alcançado, significa que a FAS atingiu sua máxima taxa de crescimento de severidade na lavoura. Logo, na safra 2015/2016, a taxa de crescimento da severidade da FAS ocorreu antes das demais safras estudadas pois, aos 80 dias após a emergência a severidade da FAS já havia atingido seu IP, alterando a sua taxa de crescimento de uma condição crescente para decrescente.

Nas Figuras 3, 4, 5 e 6 estão representados os pontos críticos do modelo junto das variáveis meteorológicas temperatura média do ar (TDM), umidade relativa do ar média (URM) e precipitação pluviométrica (PP), em escala diária. Analisando os MAP, observa-se que nas safras 2015/2016 (Figura 3A), 2016/2017 (Figura 4A) e 2019/2020 (Figura 6A), as TDM encontravam-se em condições favoráveis para o desenvolvimento da doença, entre 18 e 26,5 °C, nos dias que antecediam estes pontos. As TDM anteriores ao IP evidenciam que nas safras 2016/2017 (Figura 4A), 2018/2019 (Figura 5A) e 2019/2020 (Figura 6A), as condições estavam desfavoráveis para o desenvolvimento da severidade da FAS, sendo uma explicação potencial para a alteração de uma taxa crescente do crescimento da severidade da FAS para decrescente.

No MDP, as TDM nas safras 2015/2016 (Figura 3A), 2016/2017 (Figura 4A) e 2019/2020 (Figura 6A), estavam fora das condições ideais para o desenvolvimento da doença nos dias anteriores ao ponto crítico. Assim, a TDM não favoreceu o desenvolvimento da doença e pode ter auxiliado para essa desaceleração.

Nas safras 2015/2016 (Figura 3C), 2016/2017 (Figura 4C) e 2019/2020 (Figura 6C) pode-se observar que o MAP ocorreu após registros de maiores volumes de PP, chegando em alguns casos até a 60 mm registrados. Nas safras 2016/2017 (Figura 4C), 2018/2019 (Figura 5C) e 2019/2020 (Figura 6C) ocorreram dias com PP inferior a 1 mm, condição desfavorável ao desenvolvimento da doença, e que justificam a taxa decrescente do crescimento da severidade da FAS indicado pelo IP. No MDP para as safras 2018/2019 (Figura 5C) e 2019/2020 (Figura 6C), foi verificado a ausência de PP ou a ocorrência de volumes baixos anteriormente a este ponto.

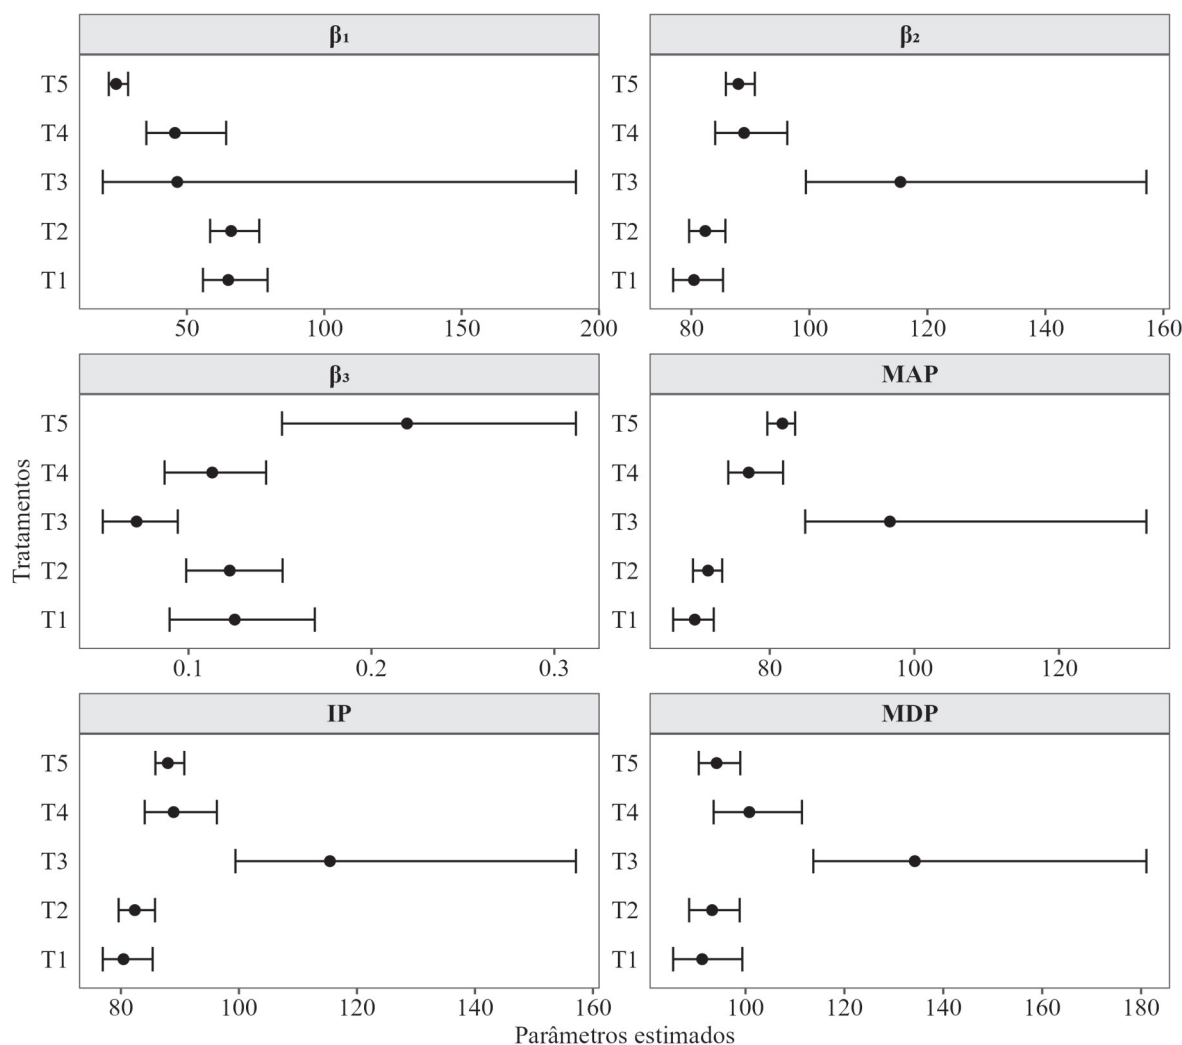
Tabela 3. Estimativas bootstrap dos parâmetros β_1 , β_2 e β_3 do modelo logístico (LOGI2) ajustados para a severidade da FAS.

Safras	β_1			β_2			β_3		
	LI*	Média	LS**	LI	Média	LS	LI	Média	LS
2015/16	55,92	65,48	80,67	76,97	80,59	85,58	0,09	0,12	0,17
2016/17	58,45	65,97	76,96	79,58	82,3	86	0,1	0,12	0,15
2017/18	18,97	43,02	131,02	99,11	114,9	146,08	0,05	0,07	0,09
2018/19	35,86	45,49	64,62	84,34	88,83	95,97	0,09	0,11	0,14
2019/20	21,54	24,37	29,05	85,72	88,07	91,06	0,15	0,21	0,3

*LI: Limite inferior;

**LS: Limite superior.

Figura 1. Estimativas dos parâmetros β_1 , β_2 e β_3 e dos pontos de aceleração máxima (MAP), pontos de inflexão (IP) e pontos de desaceleração máxima (MDP) do modelo logístico (LOGI2) e seus respectivos intervalos de confiança *bootstrap* ajustados para a severidade da FAS, onde T1 representa a safra 2015/2016, T2 safra 2016/2017, T3 safra 2017/2018, T4 safra 2018/2019 e o T5 a safra 2019/2020.



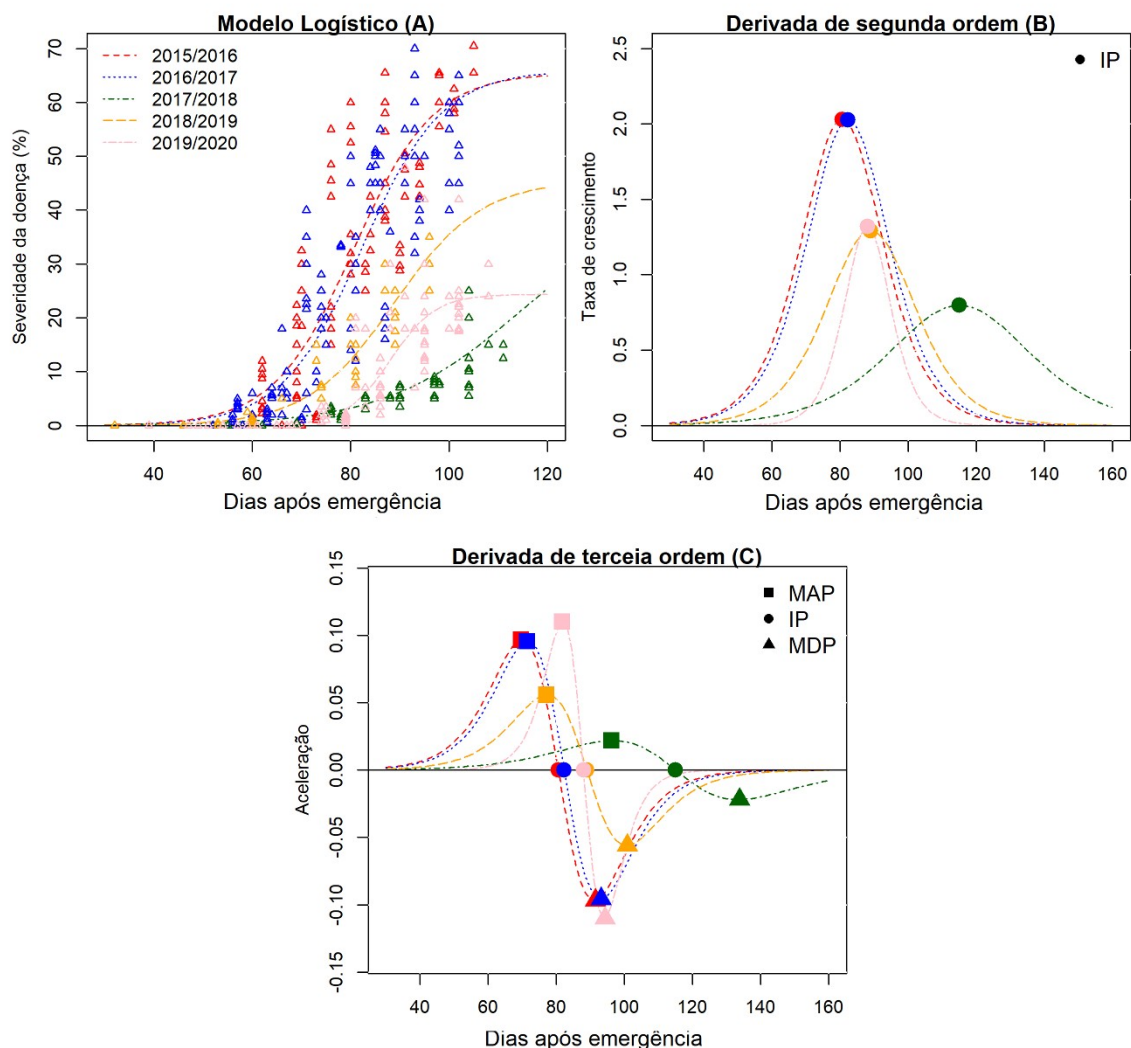
O MAP representa a aceleração máxima do desenvolvimento da severidade da FAS, ou seja, neste ponto a evolução da severidade da FAS atingiu sua máxima velocidade. Um estudo das condições que levaram a FAS alcançar sua máxima aceleração é de interesse para o planejamento do controle da doença e amenizar perdas na lavoura. Este ponto pode estar vinculado com condições meteorológicas favoráveis para o desenvolvimento da doença. As condições meteorológicas favoráveis são um indicativo para o desenvolvimento da doença atingir essa aceleração, uma vez que, quanto mais favoráveis forem as condições, mais rápida será a proliferação da doença. Assim, quanto mais tardio se dá o aparecimento deste ponto MAP, maior a dificuldade da FAS se desenvolver no ambiente de cultivo, causado pela falta de condições ambientais favoráveis ao seu desenvolvimento e também à condição de hospedeiro para sua proliferação, uma vez que a soja se encaminha para a senescência de suas folhas, tanto natural de fechamento de ciclo quanto de abortamento

devido a severidade da doença.

Além das condições meteorológicas favoráveis a ocorrência da FAS, a obtenção de seu ponto MAP em menor intervalo de tempo, pode estar associada a alta pressão de esporos presentes no ar. Assim, mesmo que as condições meteorológicas não sejam as mais favoráveis ao desenvolvimento da FAS, a doença pode se estabelecer, pois embora a temperatura ideal ao desenvolvimento seja 18 à 26,5 °C, os esporos podem germinar em uma ampla faixa de 5 a 34 °C (Alves et al., 2006).

Se o MAP é o ponto de máxima velocidade do desenvolvimento da FAS, o MDP é o ponto de máxima desaceleração. Para a compreensão deste ponto considera-se que as condições meteorológicas tornaram-se desfavoráveis ao estabelecimento da doença. Assim como o MAP, o MDP pode ser explicado por outras condições além das referentes ao ambiente, como as características morfológicas das plantas, onde o desenvolvimento da planta é composto por diferentes estádios, cada um sendo caracterizado por condi-

Figura 2. Modelo Logístico (LOG12) para severidade de FAS (A); Taxa de crescimento da severidade da FAS (B); Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e pontos de desaceleração máxima (MDP) para a aceleração da severidade da FAS (C).



ções morfológicas e fisiológicas da planta, os quais podem interferir no desenvolvimento da FAS, como por exemplo folhas mais velhas serem menos suscetíveis à ferrugem da soja (Xavier et al., 2017).

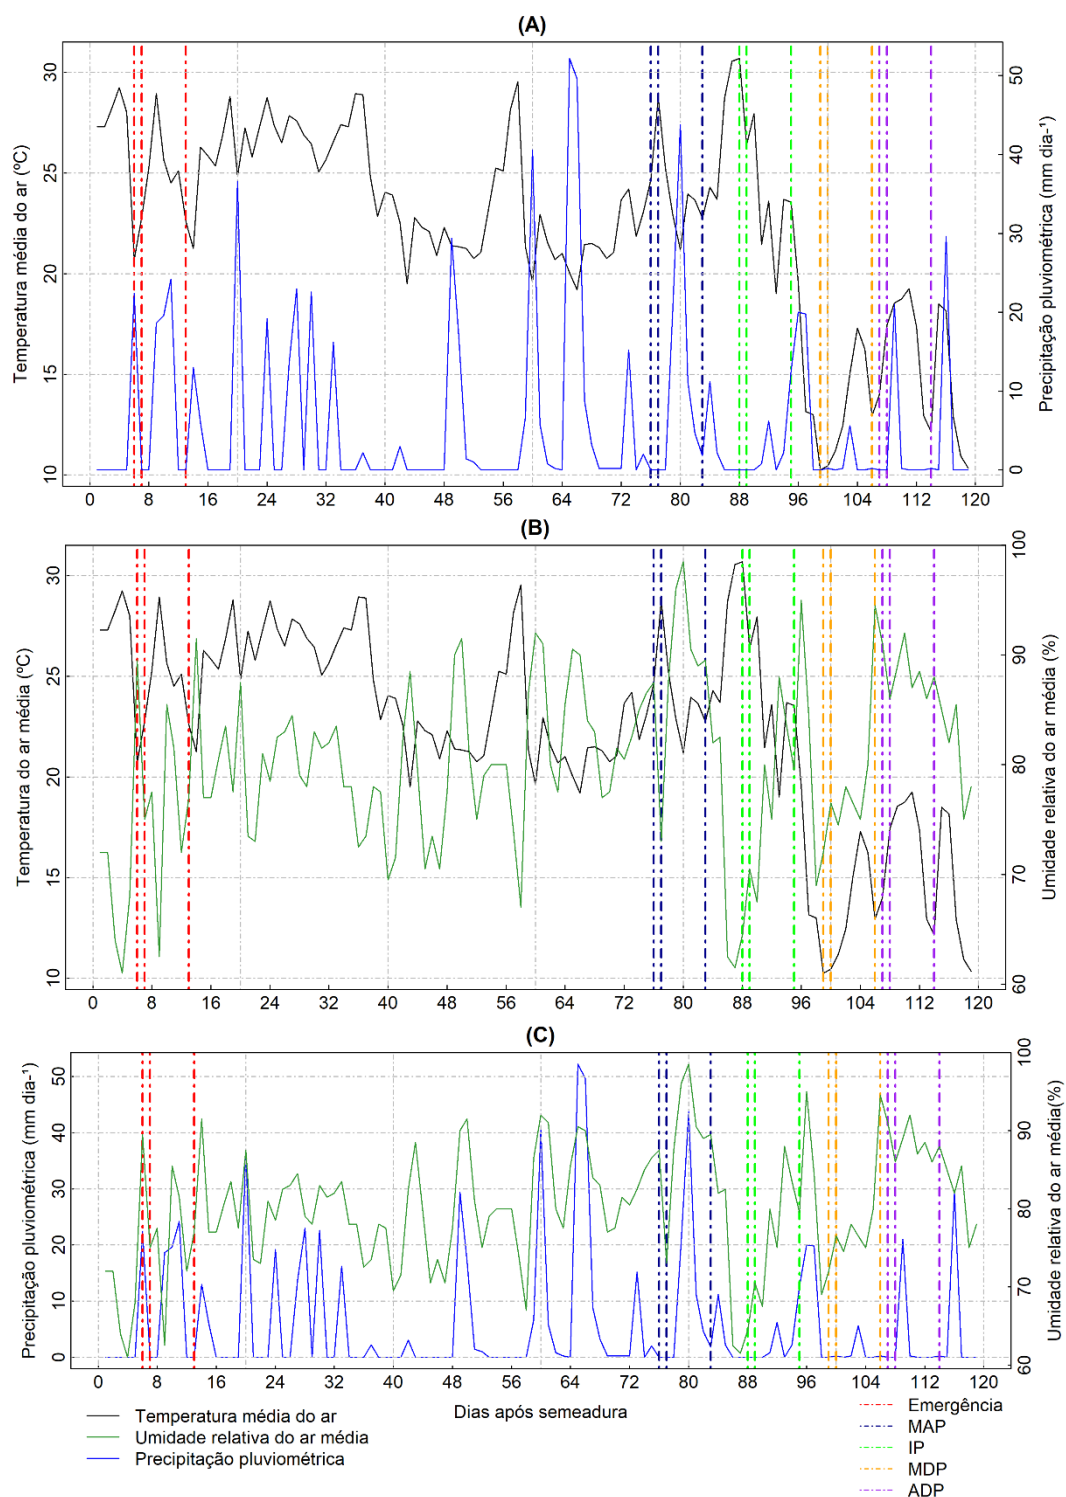
A URM é uma variável meteorológica influenciada diretamente pelas condições de PP e temperatura do ar, pois, é dependente da concentração de vapor de água no ar e da capacidade máxima de retenção deste vapor de água do ar, a uma dada temperatura. Assim a URM, não pode ser totalmente predita pela PP, como pode se observar nas Figuras 3C, 4C, 5C, 6C e 7C. A URM nos dias que antecedem o MAP nas safras 2015/2016 (Figura 3C), 2016/2017 (Figura 4C) e 2019/2020 (Figura 6C), apresentaram valores médios de 80% até 95% nos dias que antecedem o MAP.

Os valores de URM que antecedem o IP na safra 2015/2016 (Figura 3C), 2016/2017 (Figura 4C), 2018/2019 (Figura 5C) e 2019/2020 (Figura 6C) corroboram para uma alteração da taxa de crescimento da severidade da FAS, uma vez que nestas safras a URM não foi favorável para a FAS se desenvolver. Já no MDP observa-se que a URM nas

safras 2015/2016 (Figura 3C) e 2016/2017 (Figura 4C) não apresentavam níveis adequados para o desenvolvimento da FAS, onde observaram-se valores de até 70% nos dias anteriores a este ponto.

Com a interpretação das estimativas dos parâmetros dos modelos e de seus pontos críticos aliados a análise da ocorrência de condições meteorológicas, favoráveis ou desfavoráveis ao desenvolvimento da doença, é possível planejar as datas de semeadura, identificar os períodos críticos para monitoramento mais rigoroso das lavouras, bem como planejar ou otimizar manejos passíveis de serem utilizados pelos produtores de soja. Sendo assim, o uso dos modelos não lineares e suas possíveis interpretações se apresentam como estratégias mitigadoras ao desenvolvimento da doença e podem auxiliar na tomada de decisão de técnicos e consultores a campo, em relação ao melhor momento para se proceder o controle da FAS.

Figura 3. Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e pontos de desaceleração máxima (MDP) da safra 2015/2016. (A) Temperaturas do ar média e Precipitação pluviométrica; (B) Temperaturas do ar média e Umidade relativa do ar média; (C) Umidade relativa do ar média e Precipitação pluviométrica.



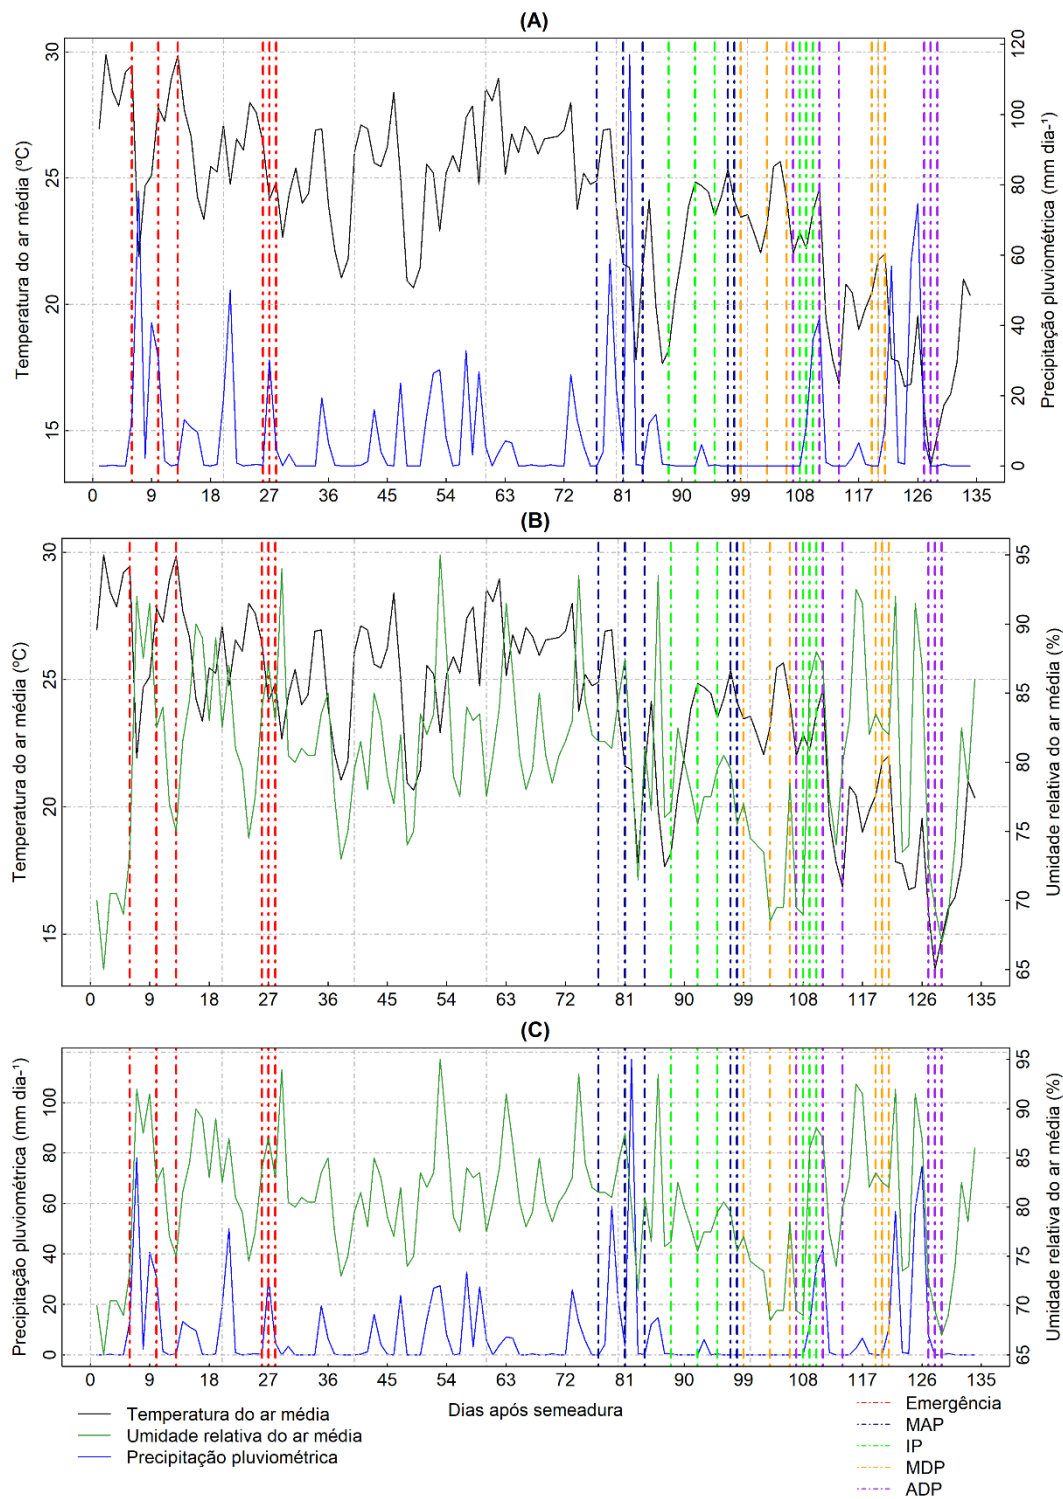
Conclusões

O modelo não-linear de base biológica do tipo logístico pode ser usado para descrever a severidade da Ferrugem Asiática da Soja (FAS).

Os pontos críticos na curva de crescimento da severidade da FAS sugerem a ocorrência de relação direta com

as variáveis meteorológicas temperatura média do ar, precipitação pluviométrica acumulada e umidade relativa do ar média e, com base nestas informações pode-se realizar inferências sobre os períodos de maior potencial de crescimento da doença.

Figura 4. Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e pontos de desaceleração máxima (MDP) da safra 2016/2017. (A) Temperaturas do ar média e Precipitação pluviométrica; (B) Temperaturas do ar média e Umidade relativa do ar média; (C) Umidade relativa do ar média e Precipitação pluviométrica.



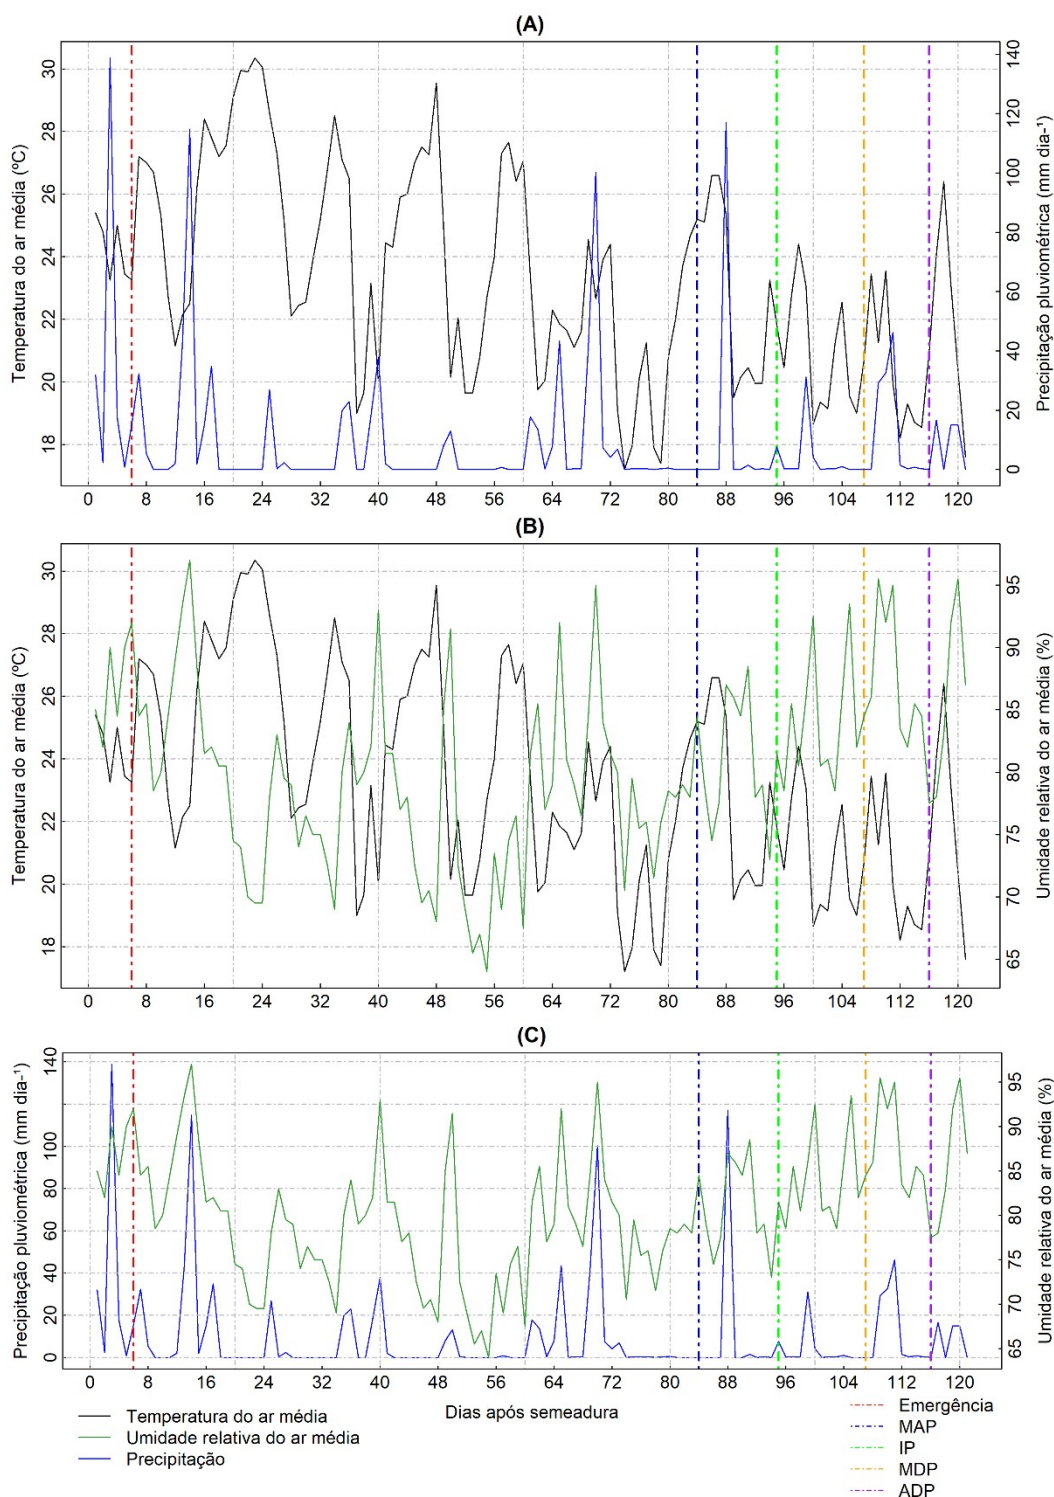
Contribuição dos autores

A.D. LÚCIO e S.H.B DORNELLES concepção e orientação do projeto. O.S. ESCOBAR e D.M. SANCHOTENE condução do experimento e coleta dos dados. O.S. ESCOBAR, S.J. LOPES, F.M.HAESBAERT realização das análises de dados, análises estatísticas, redação original do manuscrito. J. SGARBOSSA análises estatísticas e revisão do manuscrito.

Referências

- AKAIKE, H. A new look at the statistical model identification. *IEEE transactions on automatic control*, v.19, p.1974-723-716. DOI: 10.1109/TAC.1974.1100705.
- AKAMATSU, H.; YAMANAKA, N.; YAMAOKA, Y.; SOARES, R.M.; MOREL, W.; IVANCOVICH, A.J.G.; BOGADO, A.N.; KATO, M.; YORINORI, J.T.; SUENAGA, K. Pathogenic diversity of soybean rust in Argentina, Brazil, and Paraguay. *Journal of General Plant Pathology*, v.79, p.28-40, 2013. DOI: 10.1007/s10327-012-0421-7.

Figura 5. Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e pontos de desaceleração máxima (MDP) da safra 2018/2019. (A) Temperaturas do ar média e Precipitação pluviométrica; (B) Temperaturas do ar média e Umidade relativa do ar média; (C) Umidade relativa do ar média e Precipitação pluviométrica.



ALLAIRE, J.J. **Manipulate: Interactive plots for RStudio.** 2014. Available from: < <https://CRAN.R-project.org/package=manipulate> >. Accessed on: Mar. 17 2019.

ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.L.M.; SPAROVEK, G. Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, v.22, p.711-728, 2013. DOI: 10.1127/0941-2948/2013/0507.


ALVES, S.A.M.; FURTADO, G.Q.; BERGAMIN FILHO, A. Influência das condições climáticas sobre a ferrugem da soja. In: ZAMBOLIM, L. (Ed.). **Ferrugem asiática da soja.** Viçosa: Suprema Gráfica e Editora, 2006. p.37-59.

AMELIA, R.; MARDIYAH, M.; NAHAR, J.; ANGGRIANI, N.; SUPRIATNA, A.K. Optimal control for the use of botanical fungicides in the spread of plant diseases. *Journal of physics: conference series*, v.1315, p.012054, 2019. DOI:10.1088/1742-6596/1315/1/012054.

AMORIM, L.; BERGAMIM FILHO, A.; REZENDE, J.A.M. **Manual de fitopatologia.** 5.ed. Piracicaba: Agrônômica Ceres. Piracicaba, 2018. 573p.

BATES, D.M.; WATTS, D.G. **Nonlinear regression analysis and its applications.** United states: John Wiley & Sons, 1988. DOI:10.1002/9780470316757.

Figura 6. Pontos de aceleração máxima (MAP), pontos de inflexão (IP) e pontos de desaceleração máxima (MDP) da safra 2019/2020. (A) Temperaturas do ar média e Precipitação pluviométrica; (B) Temperaturas do ar média e Umidade relativa do ar média; (C) Umidade relativa do ar média e Precipitação pluviométrica.



BATY, F.; RITZ, C.; CHARLES, S.; BRUTSCHE, M.; FLANDROIS, J.P.; DELIGNETTE-MULLER, M.L. Uma caixa de ferramentas para regressão não linear em R: o pacote nlstools. *Journal of Statistical Software*, v.66, p.1-21, 2015. DOI: 10.18637/jss.v066.i05.

BREUSCH, T.S.; PAGAN, A.R. A simple test for heteroscedasticity and random coefficient variation. *Econometrica*, v.47, p.1287-1294, 1979. DOI: 10.2307/1911963.

DE SOUZA, E.M.; MUNIZ, J.A.; MARCHI, G.; GUILHERME, L.R.G. Modelagem não linear da extração de zinco de um solo tratado com lodo de esgoto. *Acta Scientiarum. Technology*, v.32, p.193-199, 2010. DOI: 10.4025/actascitechnol.v32i2.5505.

DURBIN, J.; WATSON, G.S. Testing for serial correlation in least squares regression: I. *Biometrika*, v.37, p.409-428, 1950. DOI: 10.2307/2332391.

GODOY, C.V.; KOGA, L.J.; CANTERI, M.G. Diagrammatic scale for assessment of soybean rust severity. *Fitopatologia Brasileira*, v.31, p.63-68, 2006. DOI: 10.1590/S0100-41582006000100011.

GODOY, C.V.; SEIXAS, C.D.S.; SOARES, R.M.; MARCELINO-GUIMARÃES, F.C.; MEYER, M.C.; COSTAMILAN, L.M. Asian soybean rust in Brazil: past, present, and future. *Pesquisa Agropecuária Brasileira*, v.51, p.407-421, 2016. DOI: 10.1590/S0100-204X2016000500002.

- LANGENBACH, C.; CAMPE, R.; BEYER, S.F.; MUELLER, A.N.; CONRATH, U. Fighting Asian Soybean Rust. **Frontiers in Plant Science**, v.7, p.797, 2016. DOI: 10.3389/fpls.2016.00797.
- LAURINDO, B.S.; LAURINDO, R.D.F.; AZEVEDO, A.M.; NICK, C.; DA SILVA, D.J.H.; MIZUBUTI, E.S.G. Seleção de acessos de tomateiro resistentes à pinta-preta pela análise de agrupamento das curvas de progresso da doença. **Pesquisa Agropecuária Brasileira**, v.50, p.106-114, 2015. DOI: 10.1590/S0100-204X2015000200002.
- MARTINS, M. C.; GUERZONI, R. A.; CÂMARA, G. M. D. S.; MATTIAZZI, P.; LOURENÇO, S. A.; AMORIM, L. Escala diagramática para a quantificação do complexo de doenças foliares de final de ciclo em soja. **Fitopatologia Brasileira**, v. 29, p. 179-184, 2004.
- MISCHAN, M.M.; PINHO, S.Z. **Modelos não lineares: funções assintóticas de crescimento**. 1.ed. São Paulo: Cultura Acadêmica, 2014. 184p.
- OGOSHI, C.; ZANON, A.J.; JUNIOR, D.F.U.; BITTECOURT, C.R.C.; ULGUIM, A.R.; CARLOS, F.S. Progresso temporal da ferrugem asiática em função de épocas de semeadura e de cultivares de soja em terras baixas. **Brazilian Journal of Development**, v.5, p.17102-17114, 2019. DOI: 10.34117/bjdv5n9-231.
- PINHO, S.Z., CARVALHO L.R., MISCHAN, M.M., PASSOS, J.R.S.. Critical points on growth curves in autoregressive and mixed models. **Sci. Agric.**, v. 71, p. 30-37, 2014.
- R DEVELOPMENT CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2020.
- RATKOWSKY, D.A. Principles of nonlinear regression modeling. **Journal of Industrial Microbiology**, v.12, p.195-199, 1993. DOI: 10.1007/BF01584190.
- SARI, B.G.; OLIVOTO, T.; DIEI, M.I.; KRYSCZUN, D.K.; LÚCIO, A.D.C.; SAVIAN, T.V. Nonlinear modeling for analyzing data from multiple harvest crops. **Agronomy Journal**, v.110, p.2331-2342, 2018. DOI: 10.2134/agronj2018.05.0307.
- SARI, B.G.; LÚCIO, A.D.C.; SANTANA, C.S.; OLIVOTO, T.; DIEI, M.I.; KRYSCZUN, D.K. Nonlinear growth models: An alternative to ANOVA in tomato trials evaluation. **European Journal of Agronomy**, v.104, p.21-36, 2019. DOI: 10.1016/j.eja.2018.12.012.
- SCHWARZ, G. Estimating the dimension of a model. **The annals of statistics**, v.6, p.461-464, 1978. Available at: < <http://www.jstor.org/stable/2958889>>. Accessed on: Out. 10 2022.
- SHAPIRO, S.S.; WILK, M.B. An analysis of variance test for normality (complete samples). **Biometrika**, v.52, p.591-611, 1965. DOI: 10.2307/2333709.
- XAVIER, S.A.; MARTINS, D.C.; FANTIN, L.H.; CANTERI, M.G. Older leaf tissues in younger plants are more susceptible to soybean rust. **Acta Scientiarum. Agronomy**, v.39, p.17-24, 2017. DOI: 10.4025/actasciagron.v39i1.30638.

REFERENCIAÇÃO

- ESCOBAR, O. S.; LÚCIO, A. D.; SANCHOTENE, D. M.; HAESBAERT, F.M.; LOPES, S. J.; SGARBOSSA, J.; DORNELLES, S. H. B. Severidade de *Phakopsora pachyrhizi* em soja estimada por modelos de crescimento não lineares. **Agrometeoros**, Passo Fundo, v.31, e027185, 2023.



Severity of *Phakosora pachyrhizi* in soybean estimated in nonlinear regress models

Otávio dos Santo Escobar¹, Alessandro Dal'Col Lúcio¹, Danie Martini Sanchotene², Fernando Machado Haesbaert³, Sidnei Jose Lopes¹, Jaqueline Sgarbossa^{1(*)} and Sylvio Henrique Bidel Dornelles¹

¹Universidade Federal de Santa Maria (UFSM). Avenida Roraima nº 1000, Cidade Universitária, Bairro Camobi, CEP 97105-900 Santa Maria, RS, Brazil. E-mails: otescobar@gmail.com, adlucio@ufsm.br, sgarbossajs@yahoo.com and sjlopes2008@gmail.com

²Universidade Regional do Alto Uruguai e das Missões (URI). Avenida Batista Bonoto Sobrinho nº 733, Bairro São Vicente, CEP 97700-000 Santiago, RS, Brazil. E-mail: danie.sanchotene@hotmail.com

³Universidade Federal de Tocantins (UFT). Rua Badejós, Lote 7, Chácaras 69/72, Bairro Jardim Sevilha, CEP 77402-970 Gurupi, TO, Brazil. E-mail: fhaesbaert@gmail.com

(*)Corresponding author.

ARTICLE INFO

Article history:

Received 19 December 2022

Accepted 16 May 2023

Index terms:

asian soybean rust
logistic model
Gompertz model
critical points

ABSTRACT

The use of models to elaborate the Asian rust growth curve is an important tool for the interpretation of its dynamics. The aim of the study was to estimate the progress in the severity of FAS from non-linear regression models in different agricultural years, interpret the parameter estimates and calculate the critical points in the disease's growth. The severity growth curves in the 2015/2016, 2016/2017, 2017/2018, 2018/2019 and 2019/2020 seasons were adjusted to different models, selecting the model that best represented this growth. The critical growth points within the disease growth were calculated, which are the points of maximum acceleration, inflection and maximum deceleration of disease severity. The model with the best fit was the parameterized logistic model. The parameter β_1 , the 2015/2016 and 2016/2017 seasons showed higher levels of disease severity, reaching up to 80.5% and 79.5% of disease severity, respectively. The parameter β_2 is related to the precocity of disease growth, where, in the 2015/2016 and 2016/2017 seasons, due to more favorable weather conditions, we had this precocity of the disease onset. The parameter β_3 refers to the growth rate of disease severity, in the 2019/2020 seasons this growth rate was higher. In the 2015/2016 and 2016/2017 seasons, due to favorable weather conditions, the points of maximum acceleration occurred earlier in the crop cycle. For the inflection and maximum deceleration points, they were identical for harvests.

© 2023 SBAgro. All rights reserved.

CITATION

ESCOBAR, O. S.; LÚCIO, A. D.; SANCHOTENE, D. M.; HAESBAERT, F.M.; LOPES, S. J.; SGARBOSSA, J.; DORNELLES, S. H. B. Severidade de *Phakosora pachyrhizi* em soja estimada por modelos de crescimento não lineares. *Agrometeoros*, Passo Fundo, v.31, e027185, 2023.