

ALEXANDRE HENRIQUE ALVES DOS SANTOS BATISTA E CAMPOS

**USO DE REDES NEURAS NA PREVISÃO DE ATAQUE DE *Chrysodeixis
includens* EM LAVOURAS DE SOJA**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Mestrado Profissional em Defesa Sanitária Vegetal, para obtenção do título de *Magister Scientiae*.

Orientador: Marcelo Coutinho Picanço

Coorientadores: Ricardo Siqueira da Silva
Natália de Souza Ribas

**VIÇOSA - MINAS GERAIS
2023**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

C198u
2023

Campos, Alexandre Henrique Alves dos Santos Batista e, 1993-
Uso de redes neurais na previsão de ataque de *Chrysodeixes
includens* em lavouras de soja / Alexandre Henrique Alves dos
Santos Batista e Campos. – Viçosa, MG, 2023.

1 dissertação eletrônica (30 f.): il. (algumas color.).

Orientador: Marcelo Coutinho Picanço.

Dissertação (mestrado) - Universidade Federal de Viçosa,
Departamento de Entomologia, 2023.

Referências bibliográficas: f. 27-30.

DOI: <https://doi.org/10.47328/ufvbbt.2023.479>

Modo de acesso: World Wide Web.

1. Lagarta-falsa-medideira. 2. Soja - Doenças e pragas -
Controle integrado. 3. Meteorologia agrícola. 4. Inteligência
artificial. 5. Manejo de pragas. I. Picanço, Marcelo Coutinho,
1958-. II. Universidade Federal de Viçosa. Departamento de
Entomologia. Programa de Pós-Graduação em Defesa Sanitária
Vegetal. III. Título.

CDD 22. ed. 595.78


ALEXANDRE HENRIQUE ALVES DOS SANTOS BATISTA E CAMPOS

**USO DE REDES NEURAIIS NA PREVISÃO DE ATAQUE DE *Chrysodeixis*
includens EM LAVOURAS DE SOJA**


Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Mestrado Profissional em Defesa Sanitária Vegetal, para obtenção do título de *Magister Scientiae*.

APROVADA: 17 de julho de 2023

Assentimento:

Documento assinado digitalmente
 ALEXANDRE HENRIQUE ALVES DOS SANTO
Data: 08/08/2023 15:27:20-0300
Verifique em <https://validar.iti.gov.br>

Alexandre Henrique Alves dos Santos Batista e Campos
Autor

Documento assinado digitalmente
 MARCELO COUTINHO PICANÇO
Data: 08/08/2023 15:51:35-0300
Verifique em <https://validar.iti.gov.br>

Marcelo Coutinho Picanço
Orientador

À Maria Pessoa, minha namorada, que sempre me apoiou, e me deu todo o suporte para a conquista desse projeto.

AGRADECIMENTOS

Agradeço a Deus por minha vida e por renovar diariamente minhas forças para que eu tenha perseverança em seguir e persistir nas minhas metas.

À minha mãe pelo olhar de sabedoria e entendimento em todos os momentos. E aos meus irmãos pelo laço de fraternidade e partilha da minha história.

Ao professor Marcelo Picanço, Dra. Natália Ribas e professor Ricardo Siqueira pela parceria e ensinamentos que contribuíram para a concretização deste trabalho e realização de um sonho.

À Universidade Federal de Viçosa, pela missão educativa e social que viabiliza a aprendizagem digna e a oportunidade do desenvolvimento humano e profissional.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO

CAMPOS, Alexandre Henrique Alves dos Santos Batista, M.Sc., Universidade Federal de Viçosa, julho de 2023. **Uso de redes neurais na previsão de ataque de *Chrysodeixis includens* em lavouras de soja.** Orientador: Marcelo Coutinho Picanço. Coorientadores: Natália de Souza Ribas e Ricardo Siqueira da Silva.

A determinação de modelos de dinâmica espaço-temporal das pragas nos cultivos possibilita identificação dos períodos e locais com maiores riscos desses organismos causarem danos econômicos. As populações de pragas nos cultivos são reguladas por fatores bióticos e abióticos como as variáveis meteorológicas, planta hospedeira e inimigos naturais. Com isso a utilização de redes neurais artificiais (RNAs) são ferramentas de inteligência artificial que possibilitam a determinação de modelos com alto poder de previsão da dinâmica espaço-temporal das pragas. A soja (*Glycine max*) é a leguminosa mais cultivada no mundo, e o continente americano é a principal região do mundo onde ela é cultivada. A lagarta falsa medideira *Chrysodeixis includens* (Lepidoptera: Noctuidae) é uma das pragas mais importantes nos cultivos de soja nas Américas. Assim, o objetivo desse trabalho foi determinar modelo de previsão da intensidade de ataque de *C. includens* a lavouras de soja usando RNAs. Os dados do trabalho foram coletados durante dois anos em quatro lavouras comerciais de soja no bioma Cerrado em Formoso do Araguaia e Gurupi, TO. Nos cultivos foram monitoradas a cada duas semanas as densidades *C. includens* e de predadores e variáveis meteorológicas. Foram selecionadas como preditores do modelo variáveis meteorológicas com baixa autocorrelação ($< 0,50$). Foram construídas 1080 RNAs. O modelo selecionado foi aquele que apresentou maior correlação entre os valores observados e previstos (r_v), menor quadrado médio do resíduo (RMSEv) e menor número de neurônios na camada oculta. A RNA selecionada teve quatro preditores significativos (temperatura média do ar, umidade relativa do ar, velocidade dos ventos e idade das plantas), dois neurônios na camada oculta, $r_v = 0,7167$ e $RMSEv = 0,2041$. A temperatura média do ar e idade das plantas tiveram efeito positivo sobre a intensidade de ataque da praga. Já a umidade relativa do ar e a velocidade dos ventos tiveram efeito negativo sobre o ataque da praga. O modelo foi capaz de prever de forma precisa o ataque de *C. includens* em diferentes anos e épocas e em períodos com baixas e altas densidades dessa praga. Portanto, o modelo de RNA determinado no trabalho pode ser usado para prever as épocas e locais como maiores riscos de ataque

de *C. includens* aos cultivos de soja como uma possível ferramenta de consulta do produtor.

Palavras-chave: Lagarta falsa medideira. Variáveis meteorológicas. Dinâmica de pragas. *Glycine max*. Inteligência artificial. Manejo integrado de pragas.

ABSTRACT

CAMPOS, Alexandre Henrique Alves dos Santos Batista, M.Sc., Universidade Federal de Viçosa, July 2023. **Use of neural networks in predicting *Chrysodeixis includens* attack in soybean crops.** Adviser: Marcelo Coutinho Picanço. Co-advisers: Natália de Souza Ribas and Ricardo Siqueira da Silva.

The determination of space-time dynamic models of pests in crops makes it possible to identify the periods and places with the greatest risk of these organisms causing economic damage. Pest populations in crops are regulated by biotic and abiotic factors such as meteorological variables, host plant and natural enemies. Thus, the use of artificial neural networks (ANNs) are artificial intelligence tools that enable the determination of models with high predictive power of the space-time dynamics of pests. Soybean (*Glycine max*) is the most cultivated legume in the world, and the American continent is the main region in the world where it is cultivated. The bollworm *Chrysodeixis includens* (Lepidoptera: Noctuidae) is one of the most important pests of soybean crops in the Americas. Thus, the objective of this work was to determine a model for predicting the attack intensity of *C. includens* on soybean crops using ANNs. The work data were collected during two years in four commercial soybean plantations in the Cerrado biome in Formoso do Araguaia and Gurupi, TO. In the crops, densities of *C. includens* and predators and meteorological variables were monitored every two weeks. Meteorological variables with low autocorrelation (< 0.50) were selected as model predictors. 1080 ANNs were built. The model selected was the one that presented the highest correlation between the observed and predicted values (r_v), the lowest residual mean square (RMSE_v) and the lowest number of neurons in the hidden layer. The selected ANN had four significant predictors (mean air temperature, relative air humidity, wind speed and plant age), two neurons in the hidden layer, $r_v = 0.7167$ and RMSE_v = 0.2041. Mean air temperature and plant age had a positive effect on pest attack intensity. On the other hand, relative humidity and wind speed had a negative effect on pest attack. The model was able to accurately predict the attack of *C. includens* in different years and times and in periods with low and high densities of this pest. Therefore, the RNA model determined in the work can be used to predict the times and places with the greatest risk of attack by *C. includens* to soybean crops as a possible tool for consultation with the producer.

Keywords: False measuring caterpillar. Meteorological variables. Pest dynamics. *Glycine max*. Artificial intelligence. Integrated pest management.

SUMÁRIO

1. INTRODUÇÃO	10
2. MATERIAL E MÉTODOS	12
2.1 Coleta de dados	12
2.2 Pré-processamento dos dados	12
2.3 Análise dos dados	13
3. RESULTADOS	15
4. DISCUSSÃO	20
5. CONCLUSÕES	26
6. REFERÊNCIAS BIBIOGRÁFICAS	27

1. INTRODUÇÃO

A soja (*Glycine max* (L.) Merrill) é a leguminosa mais cultivada no mundo (FAO 2023; USDA 2023). Seus grãos são usados na alimentação humana e animal e na indústria para a produção de tinta, cosméticos, remédios e espumas. Os grãos de soja são ricos em proteínas, lipídios com alta concentração de ácidos graxos poli-insaturados, sais minerais (como ferro, fósforo, magnésio e potássio), vitaminas (E e do complexo B) e compostos fenólicos (Kassem 2021). Em 2021 a produção mundial de soja foi de 371,69 milhões de toneladas ocupando uma área de cultivo de 129,52 milhões de hectares. O continente americano é o principal local (87,23%) de produção de soja do mundo, sendo que o Brasil (36,30%), Estados Unidos (32,47%) e Argentina (12,43%) são os três países maiores produtores dessa cultura (FAO 2023; USDA 2023).

A lagarta falsa medideira *Chrysodeixis includens* (Walker) (Lepidoptera: Noctuidae: Plusiinae) é uma das principais pragas nos cultivos de soja podendo causar perdas de até 40% no rendimento dessas lavouras (Owen et al. 2013). *C. includens* está presente nas Américas do Canadá até o sul da América do Sul (Huseth et al. 2021; Soares et al. 2021). O complexo de lagartas *C. includens* é uma espécie polífaga que já foi observada atacando 174 espécies de plantas pertencentes a 39 famílias (Specht et al. 2015). O ciclo de vida *C. includens* tem duração de 15 a 26 dias nas condições de cultivo de soja e durante ele esse inseto passa pelos estágios de ovo, larva, pupa e adulto (Dami et al. 2021; Mitchel 1967). As lagartas de *C. includens* alimentam do limbo foliar deixando apenas as nervuras das folhas (Carpane et al. 2022).

A determinação dos fatores que regulam as populações das pragas possibilita a identificação dos locais e épocas com maiores riscos desses organismos causarem danos. Essas informações são essenciais no planejamento da realização das amostragens e controle das pragas nos cultivos (Foresti et al. 2022; Galdino et al. 2017; Milonas et al. 2016). As variáveis climáticas, as plantas hospedeiras e as populações de inimigos naturais são os principais fatores que afetam distribuição espaço-temporal das pragas nos cultivos. As variáveis climáticas podem afetar diretamente e indiretamente as populações de pragas nos cultivos. De forma direta elas afetam a sobrevivência, reprodução, desenvolvimento, crescimento e comportamento de insetos (Farias et al. 2021; Peacock et al. 2006; Pereira et al.

2007). Já de forma indireta as variáveis climáticas podem afetar a qualidade do nutricional, defesas e distribuição das plantas hospedeiras e populações de inimigos naturais (Pereira et al. 2007; Fidelis et al. 2019).

As plantas hospedeiras afetam as populações de pragas nos cultivos devido seu conteúdo nutricional e defesas químicas e físicas a esses organismos pois a mesma apresenta em seu ciclo de vida diferentes estados vegetais, desde a planta jovem com grande capacidade de produção de folhas, até a sua senescência perdendo as folhas para gerar indivíduos em sementes. Essas características variam ao longo do desenvolvimento das plantas. Além disso, ao longo do desenvolvimento das plantas ocorre migração e novas gerações das pragas nos cultivos (Fei et al., 2014; Rosado et al., 2015; Thierry et al., 2021). Já os inimigos naturais exercem controle biológico natural das populações de pragas nos cultivos (Bacci et al. 2019; Fidelis et al. 2019; Pereira et al. 2018).

Com isso é necessário utilizar ferramentas que associem o processo de avaliação de indivíduos pragas e da genética de plantas, ocasionando uma previsibilidade dos ataques destes indivíduos e que possa prever o controle, com substâncias químicas, biológicas ou manejo de pragas de fazendas, dadas ao conhecimento do produtor.

Os algoritmos de aprendizado de máquina são ferramentas de inteligência artificial que simulam o funcionamento do cérebro humano. Entre essas ferramentas estão as redes neurais artificiais, que simulam o funcionamento de neurônios dos organismos (Akkem et al. 2023; Durgabai et al. 2018; Liakos et al. 2018). As redes neurais artificiais podem ser usadas em pesquisas de dinâmica espaço-temporal das populações das pragas nos cultivos, conforme trabalhos de previsão em diversas culturas permanentes ou culturais. Nos modelos de redes neurais artificiais é possível determinar a contribuição de cada fator abiótico e biótico na dinâmica populacional dos organismos. Além disso, os modelos de redes neurais são capazes de prever a intensidade de pragas em diferentes locais e épocas de cultivo (Farias et al. 2022; Ibrahim et al. 2022; Kujawa & Niedbała 2021). Apesar da importância de *C. includens* como praga nos cultivos de soja não existem até o momento pesquisas sobre sua distribuição espaço-temporal usando ferramentas modernas de inteligência artificial. Assim, o objetivo desse foi determinar uma rede neural artificial para identificar os fatores de previsão que regulam as populações de *C. includens* nas lavouras de soja e também prever a intensidade de ataque dessa praga nesses cultivos.

2. MATERIAL E MÉTODOS

2.1 Coleta de dados

As avaliações foram realizadas em quatro lavouras comerciais seguindo padrão da fazenda de soja durante dois anos (2017/2018 e 2018/2019) em Formoso do Araguaia (11°47'48"S, 49°31'44"O, 240 m de altitude) e Gurupi (11°43'48"S, 49°04'08"O, 287m de altitude), no estado de Tocantins. Essas áreas pertencem ao bioma Cerrado e nelas o clima é tropical com inverno seco e verão chuvoso sendo comum suas características . As duas lavouras localizadas em Gurupi foram conduzidas de maio a setembro. Já as duas lavouras localizadas em Formoso do Araguaia foram conduzidas de dezembro a abril. Cada lavoura possuía cerca de 20 ha, e nelas foi plantada a variedade de soja M8808 IPRO (transgênica Cry1Ac-RR) no espaçamento foi de 0,45 x 0,10 m. A adubação foi realizada de acordo com a análise dos solos (Sediyama et al. 2015). A área de cada lavoura foi dividida em quatro subáreas de cinco hectares e cada uma dessas subáreas constituiu uma repetição.

Em cada repetição, quinzenalmente, 50 plantas distribuídas num gride regular foram avaliadas aleatoriamente em cada processo, do plantio á colheita. Em cada planta foram avaliadas a densidade de lagartas de *C. includens* e de predadores. As lagartas e os predadores foram separados em morfoespécies. Essas morfoespécies foram identificadas usando chaves taxonômicas (Silva et al. 2013; Barrionuevo & San Blas 2016) e em comparação com espécimes existentes no Museu de Entomologia da Universidade Federal de Viçosa. Nas avaliações foi usada a técnica de batida do ápice das plantas em bandeja plástica branca (40 × 25 × 3 cm). Isso foi feito devido a Pereira (2021) ter verificado que essa é a melhor técnica para avaliação da intensidade de ataque de lagartas aos cultivos de soja. Dados meteorológicos diários de precipitação pluviométrica (mm/dia), umidade relativa do ar média (%), temperatura média do ar (°C), radiação solar (Kj/m²), pressão atmosférica média (hPa) e ponto de orvalho (°C) foram monitorados em estações automáticas do Instituto Nacional de Meteorologia nos dois municípios em que estavam localizadas as lavouras de soja (INMET 2023).

2.2 Pré-processamento dos dados

As análises dos dados foram feitas usando o software R (R Core Team 2021). Inicialmente foram selecionadas as variáveis meteorológicas a serem usadas no modelo.

Para isso, foi realizada análise de correlação de Pearson entre os dados diários das variáveis meteorológicas. Entre as variáveis que apresentaram altas correlações ($\geq 0,50$) apenas uma delas foi selecionada para ser usada no modelo. O ponto de orvalho ($r = 0,73$), pressão atmosférica ($r = -0,68$) foram altamente correlacionados com a temperatura média do ar e a radiação solar com a umidade relativa média do ar ($r = -0,77$). Assim, ponto de orvalho, pressão atmosférica média e irradiação solar não foram usados como preditores nos modelos.

Os preditores usados no modelo foram as variáveis meteorológicas temperatura média do ar, precipitação pluviométrica, umidade relativa do ar média e velocidade média dos ventos, densidade de predadores e idade das plantas de soja (dias). Já a variável resposta foi a densidade de lagartas de *C. includens*. Para as variáveis meteorológicas foram utilizados os dados médios de 1, 5, 10, 15, 20, 25, 30, 45 e 60 dias antes da avaliação da densidade de *C. includens*. Os dados foram divididos aleatoriamente em dois grupos usando a função `sample`, `split`, pacote `caTools`. O primeiro grupo (70% dos dados) foi utilizado para treinamento do modelo. Já o segundo grupo (30% dos dados) foi utilizado na validação do modelo (Tuszynski 2020). As variáveis de entrada foram centralizadas (subtraindo a média) e dimensionadas (convertendo em escores z). Esse procedimento foi realizado para se evitar sobre peso das variáveis utilizadas e acelerar a convergência modelos de redes neurais artificiais (Wickham & Seidel 2020).

2.3 Análise dos dados

As redes neurais artificiais foram desenvolvidas utilizando a função `mlp` do pacote `R5NN5` (Bergmeir & Benítez 2012) utilizando as funções do sistema. Foram testadas quatro funções de ativação (`Act_Sigmoid`, `Act_Identity`, `Act_Logistic` e `Act_TanH`) e três algoritmos de aprendizado (`Std_Backpropagation`, `Rprop` e `SCG`). O número máximo de iterações foi fixado em 100 e número de neurônios da camada oculta variou de 1 a 10. O peso inicial da rede neural artificial foi gerado aleatoriamente (`initFunc="Randomize Weights"`) e para os seus demais componentes foram usados valores padrões existentes no programa (Bergmeir & Benítez 2012).

Foram construídas 1080 redes neurais artificiais (quatro funções de ativação x três algoritmos de aprendizado x 10 neurônios da camada oculta x uma variável resposta x nove intervalos de cálculo das variáveis meteorológicas). Foram realizadas análises de correlação de Pearson (r_v) entre os valores observados da variável resposta (densidade de lagartas de *C. includens*) e as previsões de cada um dos 1080 modelos. Utilizando esses dados também foi calculado o quadrado médio do resíduo (RMSEv). Inicialmente foi selecionado um modelo para cada um dos nove intervalos de cálculo das variáveis meteorológicas e posteriormente foi selecionado o modelo utilizando o melhor intervalo de cálculo das variáveis meteorológicas. Esta seleção foi baseada em três critérios: maior correlação de Pearson entre os valores observados e previstos, menor quadrado médio do resíduo e menor número de neurônios na camada oculta (Lee et al. 2016; Farias et al. 2021).

A importância relativa dos preditores do modelo selecionado foi estimada usando o algoritmo de Olden (função Olden, pacote NeuralNet Tools). Esse método calcula a importância relativa dos preditores com base no produto dos pesos da conexão entrada-oculta e saída-oculta e a soma desses produtos em todos os neurônios ocultos (Olden et al. 2004; Costa et al. 2021). Nesses cálculos a rede neural artificial vencedora foi executada 250 vezes em cada uma delas os valores e as estimativas pelo algoritmo Olden usadas para estimar o intervalo de confiança a 95% de probabilidade (IC95) para cada um dos preditores do modelo (Beck 2018). Um preditor foi considerado significativo quando seu IC95 não incluiu o valor zero (Beck 2018). Posteriormente, foram realizadas análises de sensibilidade para traçar gráficos da variável resposta (densidade de lagartas de *C. includens*) em função da variação de cada preditor do modelo (função parcial, pacote pdp) (Greenwell 2017).

3. RESULTADOS

A rede neural artificial que apresentou maior correlação de Pearson entre os valores observados e previstos ($r_v = 0,7167$), menor quadrado médio do resíduo $RMSE_v = 0,2041$) e menor número de neurônios na camada oculta (quatro neurônios) foi aquela que usou as variáveis meteorológicas dos 20 dias antes da avaliação da densidade de *C. includens*. O algoritmo de aprendizado dessa rede neural artificial foi Rprop e sua função de ativação foi logistic (Tabela 1) sendo o melhor modelo de previsão avaliado conforme as variáveis e previsões, implicando em uma capacidade da previsão de controle de *C. includens*, antes de 28 dias este que é o ciclo de vida deste inseto, foi avaliado também o menor número de camadas de neurônios de preditores, pois quanto menor o número de neurônios melhor para variação conforme análise dos dados.

A topologia da rede neural artificial selecionada para descrever a dinâmica sazonal de *C. includens* é mostrada na Figura 1. Essa rede neural possui seis neurônios na camada de entrada (idade das plantas de soja, densidade de predadores, temperatura média do ar, precipitação pluviométrica, umidade relativa do ar média e velocidade média dos ventos), dois neurônios (H1 e H2) na camada oculta e um neurônio na camada de saída (densidade de *C. includens*).

No modelo selecionado os preditores idade das plantas, temperatura média do ar, umidade relativa do ar média e velocidade média dos ventos foram significativos já que seus intervalos de confiança a 95% de probabilidade não incluíram o valor zero. Já os preditores densidades de predadores e precipitação pluviométrica não foram significativos já que seus intervalos de confiança a 95% de probabilidade incluíram o valor zero. Os preditores idade das plantas e a temperatura média do ar apresentaram efeitos positivos sobre a densidade de lagartas de *C. includens*. Por outro lado, os preditores umidade relativa do ar média e velocidade média dos ventos apresentaram efeitos negativos sobre a densidade de lagartas de *C. includens* (Figura 2).

Tabela 1. Topologia (número de neurônios, função de ativação e algoritmo de aprendizado) e desempenho (rv = correlação de Pearson entre as estimativas dos modelos e os dados observados e $RMSEv$ = quadrado médio do resíduo do conjunto de dados usados na validação) de redes neurais artificiais (RNA) projetadas para prever a intensidade de ataque de *Chrysodeixis includens* em cultivos de soja com diferentes defasagens dos dados meteorológicos.

Defasagem dos dados meteorológicos (dias) §	Nº de neurônios	Função de ativação	Algoritmo de aprendizado	rv	$RMSEv$
1	10	SCG	Tang_Hiper	0,7112	0,2189
5	10	Rprop	Sigmoid	0,5298	0,2438
10	7	Rprop	Sigmoid	0,6477	0,2256
15	8	Rprop	Sigmoid	0,7003	0,2092
20*	4	Rprop	Logistic	0,7167	0,2041
25	6	Rprop	Logistic	0,6891	0,2081
30	7	Rprop	Logistic	0,7114	0,2242
45	8	Rprop	Sigmoid	0,7123	0,2140
60	5	Rprop	Sigmoid	0,7035	0,2070

§ Número de dias antes da avaliação da intensidade de ataque de *C. includens* em que foram calculados os dados médios para as variáveis meteorológicas.

* Modelo selecionado por apresentar menor número de neurônios na camada oculta, maior correlação de Pearson e menor quadrado médio do erro.




Figura 1. Diagrama da rede neural artificial que atendeu todos os requisitos para prever a intensidade de ataque de *Chrysodeixis includens* aos cultivos de soja. Essa rede neural artificial foi constituída por seis preditores (I1 a I6) na camada de entrada, dois neurônios (H1 e H2) na camada oculta e um neurônio (O1) na camada de saída. I1 = idade das plantas de soja (dias), I2 = densidade de predadores, I3 a I6 = dados médios de variáveis meteorológicas dos últimos 20 dias: I3 = temperatura média do ar (°C), I4 = precipitação pluviométrica (mm/dia), I5 = umidade relativa do ar média (%) e I6 = velocidade média dos ventos (m/s). As linhas pretas e cinzas representam pesos positivos e negativos entre as camadas, respectivamente. A espessura da linha corresponde à magnitude relativa de cada peso.

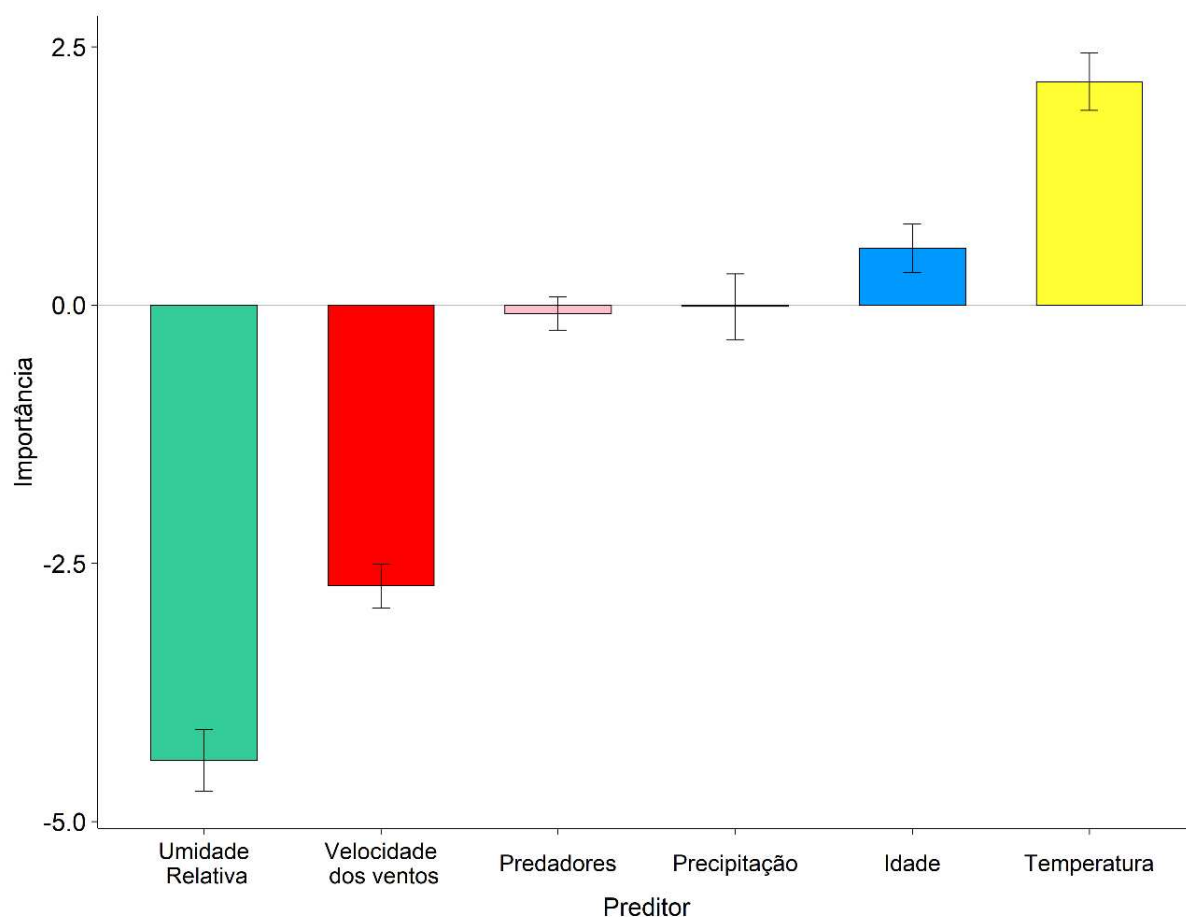


Figura 2. Importância relativa (média e intervalo de confiança a 95% de probabilidade) dos seis preditores (temperatura média do ar, precipitação pluviométrica, velocidade dos ventos e umidade relativa média do ar) para a variável de resposta (densidade de *Chrysodeixis includens*) estimada a partir dos pesos vencedores da rede neural artificial usando o método de Olden. Foram criadas 250 RNAs com diferentes pesos iniciais, e a importância dos preditores foi calculada e armazenada para permitir o cálculo de médias e intervalos de confiança.

As densidades de lagartas de *C. includens* foram maiores no segundo ano (até 2,25 lagartas/m) do que no primeiro ano (até 1,13 lagartas/m) sendo as máximas nas quatro lavouras de soja. A temperatura média do ar foi alta durante a condução das quatro lavouras de soja ($\bar{x} = 25,91$ °C) (Figura 3A). A umidade relativa do ar foi maior durante os períodos de condução das lavouras 1, 2 e 4 ($\bar{x} = 72,19\%$) do que no período de condução da lavoura 3 ($\bar{x} = 42,78\%$) (Figura 3B). A velocidade dos ventos foi maior nos períodos de condução das lavouras 1 e 3 ($\bar{x} = 1,90$ m/s) do que nos períodos de condução das lavouras 2 e 4 ($\bar{x} = 1,00$ m/s) (Figura 3C).

Verificaram-se maiores densidades de lagartas de *C. includens* com o aumento da idade das plantas de soja. A densidades de lagartas de *C. includens* foi maior com o aumento da temperatura do ar até que essa densidade atingiu um patamar a partir do qual ela não variou. A densidade de lagartas de *C. includens* diminuiu com o aumento da umidade relativa do ar e da velocidade dos ventos (Figura 4).

Verificou-se alta correlação ($r_v = 0,7167$) entre as densidades de lagartas de *C. includens* observadas nas lavouras de soja e as densidades previstas pelo modelo de redes neurais artificiais determinado neste trabalho. Esse modelo foi capaz de prever de forma adequada as populações de lagartas de *C. includens* tanto em períodos em que as densidades foram baixas (como aconteceu no final do mês de agosto na lavoura 1) como em períodos que a densidade dessa praga foi maior (como aconteceu no meio do mês de janeiro para a lavoura 4) (Figura 5).

4. DISCUSSÃO

O modelo determinado nesse trabalho para prever a dinâmica sazonal de *C. includens* é abrangente, simples e tem boa capacidade preditiva. A RNA vencedora apresentou um bom desempenho para dados em que há previsão e, também, para dados nos quais ela não foi treinada. O alto poder preditivo do modelo determinado nesse trabalho é comprovado pela alta correlação ($r_v = 0,7167$) entre as densidades observadas e as densidades previstas de *C. includens* nas lavouras de soja. Além disso, o modelo foi capaz de prever adequadamente a intensidade de ataque em épocas diferentes do ano.

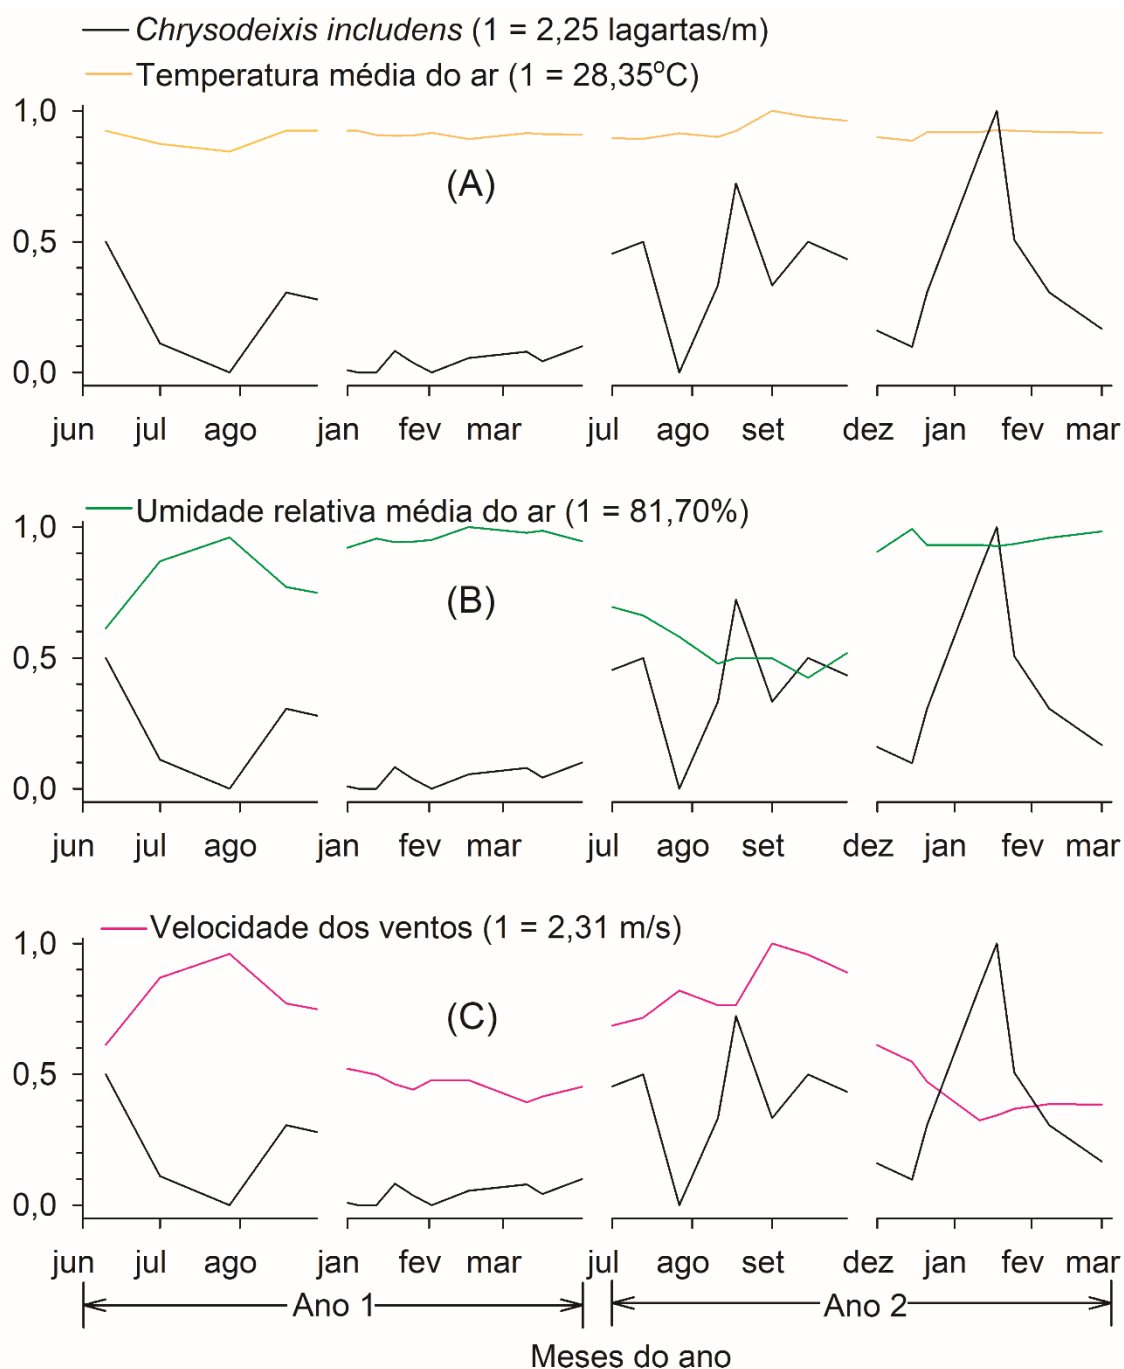


Figura 3. Variação sazonal da intensidade de ataque de *Chrysodeixis includens* e das variáveis significativas no modelo (temperatura média do ar, precipitação pluviométrica, velocidade dos ventos e umidade relativa média do ar) durante dois anos nos cultivos de soja. As variáveis foram redimensionadas de 0 para 1 e os valores máximos de cada uma delas são mostrados nas legendas.

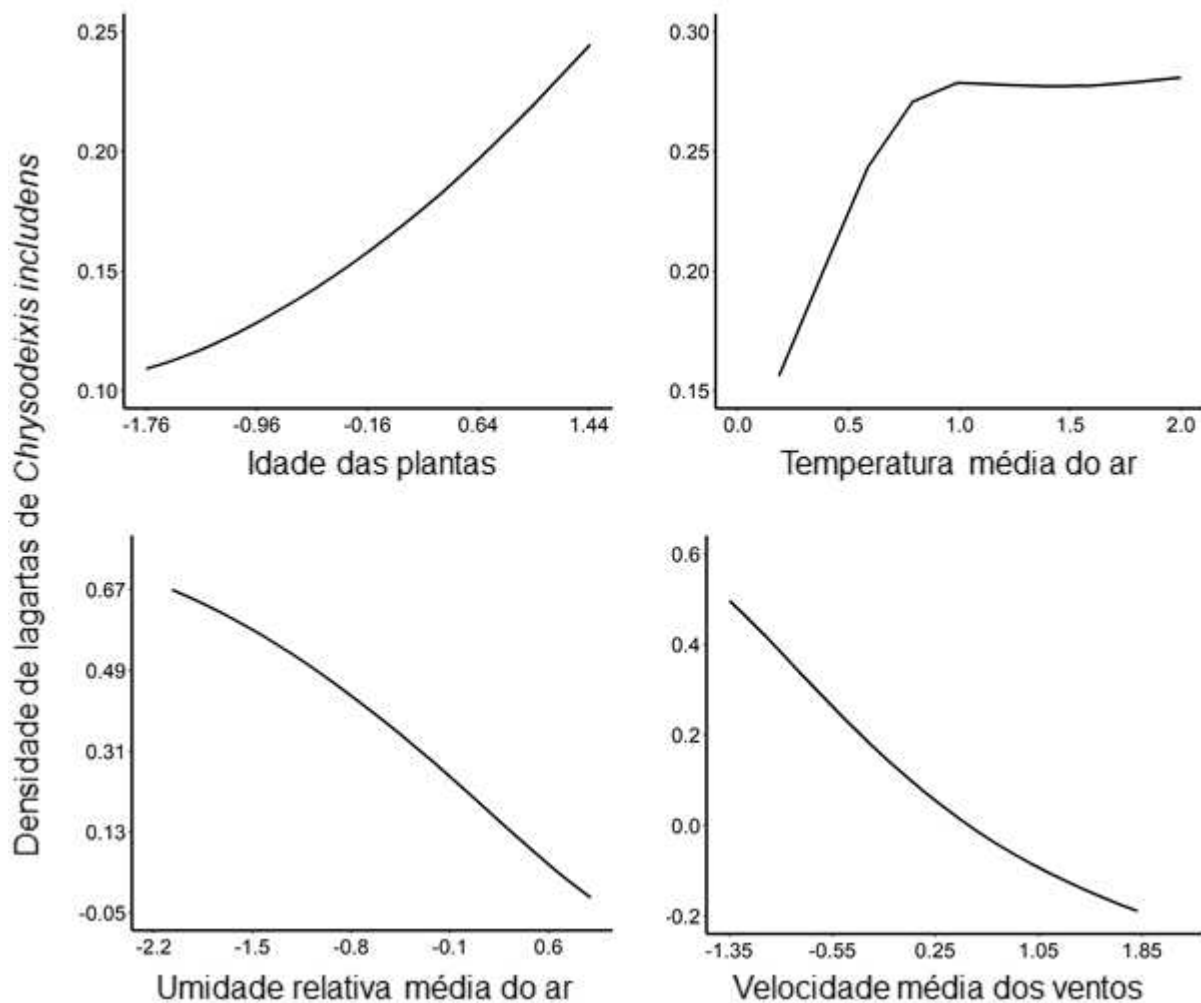


Figura 4. Variação da densidade de lagartas de *Chrysodeixis includens* em função dos níveis dos preditores do modelo selecionado com efeitos significativos: idade das plantas de soja, temperatura média do ar, umidade relativa do ar média e velocidade dos ventos.

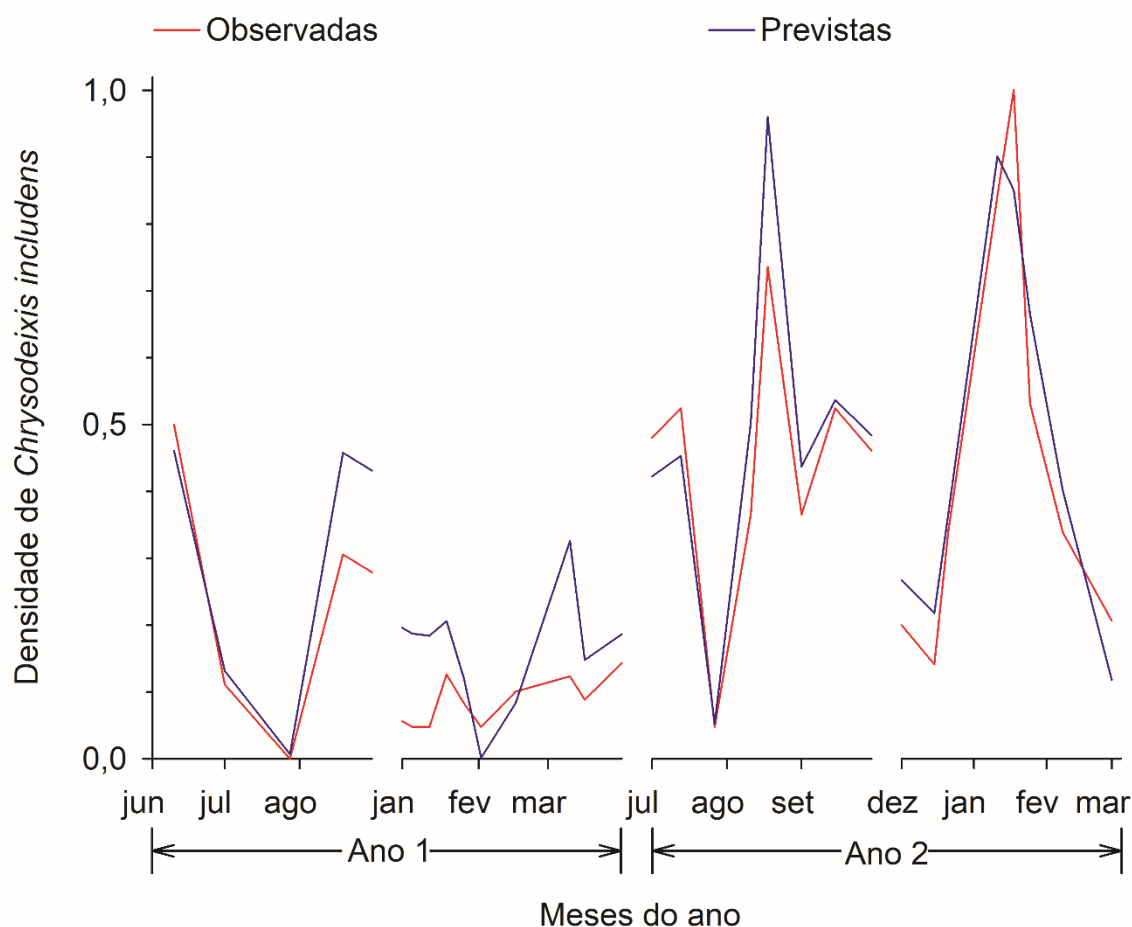


Figura 5. Densidades de lagartas de *Chrysodeixis includens* previstas pelo modelo e observadas em cultivos de soja durante dois anos.

Considerando a idade das plantas, a densidade de *C. includens* aumentou à medida que a planta foi crescendo e atingindo seus estágios mais avançados. Nos instares iniciais, as lagartas *C. includens* se alimentam de folhas novas por possuírem baixa quantidade de fibra. À medida que se desenvolvem, começam a se alimentar das folhas mais velhas e fibrosas, tais características comprovam a avaliação de campo, onde as lagartas raspavam até o terceiro ínstar e após o quarto instar é capaz de perfura-las e consumir grandes áreas foliares (Bueno et al., 2011; Baldin et al., 2014). Em média, o consumo total de folhas de soja por *C. includens* varia de 64 a 200 cm³ o que pode reduzir bastante a área foliar conforme (Baldin et al., 2014).

Em estudos da flutuação populacional de *C. includens* observa-se que as primeiras posturas e lagartas ocorrem entre os estádios fenológicos V2 e V3 de

plantas de soja, favorecendo a sua disseminação e reprodução (Zulin et al., 2018) onde a soja se encontra com seu maior período de produção de folhas. O mesmo ocorreu com os fatores observados no período de novembro e junho no presente trabalho, além disso as plantas começavam a ter seu dossel fechado devido a sua fase de expansão. Adicionalmente, houve preferência pela região inferior da planta, uma vez que o ambiente confere maior proteção, pois as deixam menos expostas as condições climáticas e predadores, porém apresentam comportamento de deslocarem no perfil da planta de soja ao longo do dia (Zulin et al., 2018).

A precipitação foi o fator que menos afetou a dinâmica de *C. includens* e isso pode ter ocorrido pelo histórico da área, onde as chuvas foram bem localizadas e distribuídas. Além disso a capacidade *C. includens* em se deslocarem no perfil da planta de soja, pode ser outro fator que faz com que a chuva não tenha tanto efeito, pois possibilita a esses insetos ficarem em locais com menor impacto da precipitação (Zulin et al., 2018).

A temperatura média do ar foi o preditor que apresentou maior variação positiva na dinâmica de *C. includens*, isso se dá pela associação dos períodos mais quentes e úmidos do ano, associada também com o aumento dos plantios de soja. A dinâmica de *C. includens* se desenvolvem em temperaturas médias de 25° a 30°C e umidade relativa de 70 a 90% (Barrionuevo & San Blas 2016), fatores esses observados no local de avaliação do presente trabalho. Além disso a temperatura após certo momento se estabilizou atingindo a faixa ótima de reprodução e desenvolvimento de *C. includens*. A temperatura do local do trabalho se manteve em 28° possibilitando a maior densidade populacional de *C. includens*.

Os preditores umidade média relativa do ar e velocidade média dos ventos apresentaram efeitos negativos sobre a densidade de lagartas de *C. includens*. Isso pode ter ocorrido devido ao hábito de oviposição desse inseto, uma vez que as fêmeas colocam seus ovos na parte abaxial das folhas de soja e isso faz com que eles fiquem protegidos contra intempéries naturais (Carvalho et al. 2012; Zulin et al. 2018). O fato desses ovos ficarem protegidos na parte de baixo da folha, pode fazer com que o vento não tenha efeito sobre a densidade de lagartas dessa praga (Santos et al. 2017).

A umidade relativa apresentou efeito negativo na densidade dessa praga, pois na cultura da soja, sob condições de maior umidade, o ciclo da *C. includens* é menor (Bueno et al. 2011; Carvalho et al., 2012) fator que no local de avaliação se mostrou

equilibrado. Isso porque pode ocorrer redução da capacidade de reprodução desses insetos e pode favorecer a ação de inimigos naturais (Régnière et al., 2012, Pereira et al., 2018).

5. CONCLUSÕES

O modelo de rede neural artificial determinado nesse trabalho pode ser usado para prever as épocas e locais como maiores riscos de ataque de *Chrysodeixis includens* aos cultivos de soja. Isso pode ser demonstrado pela simplicidade ao utilizar apenas quatro preditores (idade das plantas de soja, temperatura média do ar, umidade relativa do ar média e velocidade média dos ventos) de fácil obtenção.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- Akkem, Y., Biswas, S. K., Varanasi, A. (2023). Smart farming using artificial intelligence: A review. *Engineering Applications of Artificial Intelligence*, 120, 105899.
- Bacci, L., da Silva, E. M., Martins, J. C., Soares, M. A., Campos, M. R. D., Picanço, M. C. (2019). Seasonal variation in natural mortality factors of *Tuta absoluta* (Lepidoptera: Gelechiidae) in open-field tomato cultivation. *Journal of Applied Entomology*, 143(1-2), 21-33.
- Baldin, E. L. L., Lourenção, A. L., Schlick-Souza, E. C. (2014). Outbreaks of *Chrysodeixis includens* (Walker) (Lepidoptera: Noctuidae) in common bean and castor bean in São Paulo State, Brazil. *Bragantia*, 73, 458-465.
- Barrionuevo, M. J., San Blas, G. (2016). Redescription of immature stages of the soybean looper (Lepidoptera: Noctuidae: Plusiinae). *The Canadian Entomologist*, 148(3), 247-259.
- Bergmeir, C. N., Benítez Sánchez, J. M. (2012). Neural networks in R using the Stuttgart neural network simulator: RSNNS. American Statistical Association.
- Bueno, R. C. O. F., Bueno, A. F., Moscardi, F., Parra, J. R. P., Hoffmann-Campo, C. B. (2011). Lepidopteran larva consumption of soybean foliage: basis for developing multiple-species economic thresholds for pest management decisions. *Pest Management Science*, 67(2), 170-174.
- Carpane, P. D., Llebaria, M., Nascimento, A. F., Vivian, L. (2022). Feeding injury of major lepidopteran soybean pests in South America. *Plos One*, 17(12), e0271084.
- Carvalho, L., Ferreira, F., Bueno, N. (2012). Importância econômica e generalidades para o controle da lagarta falsa-medideira na cultura da soja. *Enciclopédia Biosfera*, 8(15), 1021-1034.
- Costa, N. L., Lima, M. D., Barbosa, R. (2021). Evaluation of feature selection methods based on artificial neural network weights. *Expert Systems with Applications*, 168, 114312.
- Dami, L. C., Herrero, M. I., Casmuz, A. S., Alzogaray, R. A., Gastaminza, G. A. (2021). Fitness and mating compatibility of *Chrysodeixis includens* (W.) (Lepidoptera: Noctuidae) populations collected in different provinces and crops in Argentina. *Anais da Academia Brasileira de Ciências*, 93(2), e20190523.
- Durgabai, R. P. L., & Bhargavi, P. (2018). Pest management using machine learning algorithms: a review. *International Journal of Computer Science Engineering and Information Technology Research (IJCSSEITR)*, 8(1), 13-22.
- FAO - Food and Agriculture Organization of the United Nations. (2023). FAOSTAT. Disponível em <https://www.fao.org/faostat/en/>. Acesso em 05/06/2023.
- Farias, E. S., Farias, A. A., Santos, R. C., Santos, A. A., Picanço, M. C. (2022). Forecasting the seasonal dynamics of *Trichoplusia ni* (Lep.: Noctuidae) on three

Brassica crops through neural networks. *International Journal of Biometeorology*, 66(5), 875-882.

Farias, E. S., Santos, R. C., Carmo, D. G., Soares, J. R., Costa, T. L., Santos, A. A., Picanço, M. C. (2021). Life tables for the diamondback moth (*Plutella xylostella*) in southeast Brazil indicate ants and spiders as leading mortality factors. *Annals of Applied Biology*, 178(3), 498-507.

Fei, M., Gols, R., Harvey, J. A. (2014). Seasonal phenology of interactions involving short-lived annual plants, a multivoltine herbivore and its endoparasitoid wasp. *Journal of Animal Ecology*, 83(1), 234-244.

Fidelis, E. G., Farias, E. S., Lopes, M. C., Sousa, F. F., Zanuncio, J. C., Picanço, M. C. (2019). Contributions of climate, plant phenology and natural enemies to the seasonal variation of aphids on cabbage. *Journal of Applied Entomology*, 143(4), 365-370.

Foresti, J., Pereira, R. R., Santana Jr, P. A., Neves, T. N., Silva, P. R., Rosseto, J., Istchuk, A. N., Ishizuka, T. K., Harter, W., Schwertner, M. H., Picanço, M. C. (2022). Spatial-temporal distribution of *Dalbulus maidis* (Hemiptera: Cicadellidae) and factors affecting its abundance in Brazil corn. *Pest Management Science*, 78(6), 2196-2203.

Galdino, T. V. S., Ferreira, D. O., Santana Jr, P. A., Arcanjo, L. P., Queiroz, E. A., Sarmiento, R. A., Picanço, M. C. (2017). The role of the beetle *Hypocryphalus mangiferae* (Coleoptera: Curculionidae) in the spatiotemporal dynamics of mango wilt. *Journal of Economic Entomology*, 110(3), 865-874.

Greenwell, B. M. (2017). PDP: An R package for constructing partial dependence plots. *The R Journal*, 9(1), 421-436.

Huseth, A. S., Koch, R. L., Reisig, D., Davis, J. A., Paula-Moraes, S. V., Hodgson, E. W. (2021). Current distribution and population persistence of five lepidopteran pests in US soybean. *Journal of Integrated Pest Management*, 12(1), 11; 1-10.

Ibrahim, E. A., Salifu, D., Mwalili, S., Dubois, T., Collins, R., Tonnang, H. E. (2022). An expert system for insect pest population dynamics prediction. *Computers and Electronics in Agriculture*, 198, 107124.

INMET - Instituto Nacional de Meteorologia. (2023). Tabelas de dados das estações. Disponível em <https://tempo.inmet.gov.br/TabelaEstacoes/A001>. Acesso em 01/02/2023.

Kassem, M. A. (2021). Soybean seed composition: protein, oil, fatty acids, amino acids, sugars, mineral nutrients, tocopherols, and isoflavones. Springer International Publishing.

Kujawa, S., Niedbała, G. (2021). Artificial neural networks in agriculture. *Agriculture*, 11(6), 497.

Lee, K. Y., Chung, N., Hwang, S. (2016). Application of an artificial neural network (ANN) model for predicting mosquito abundances in urban areas. *Ecological Informatics*, 36, 172-180.

Liakos, K. G., Busato, P., Moshou, D., Pearson, S., Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674.

Milonas, P., Gogou, C., Papadopoulou, A., Fountas, S., Liakos, V., Papadopoulos, N. T. (2016). Spatio-temporal distribution of *Helicoverpa armigera* (Hübner) (Lepidoptera: Noctuidae) and *Pectinophora gossypiella* (Saunders) (Lepidoptera: Gelechiidae) in a cotton production area. *Neotropical Entomology*, 45, 240-251.

Mitchell, E. R. (1967). Life history of *Pseudoplusia includens* (Walker) (Lepidoptera: Noctuidae). *Journal of the Georgia Entomological Society*, 2(2), 53-57.

Olden, J. D., Joy, M. K., Death, R. G. (2004). An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data. *Ecological Modelling*, 178(3-4), 389-397.

Owen, L. N., Catchot, A. L., Musser, F. R., Gore, J., Cook, D. C., Jackson, R., Allen, C. (2013). Impact of defoliation on yield of group IV soybeans in Mississippi. *Crop Protection*, 54, 206-212.

Peacock, L., Worner, S., Sedcole, R. (2006). Climate variables and their role in site discrimination of invasive insect species distributions. *Environmental Entomology*, 35(4), 958-963.

Pereira, E. J. G., Picanço, M. C., Bacci, L., Crespo, A. L. B., Guedes, R. N. C. (2007). Seasonal mortality factors of the coffee leafminer, *Leucoptera coffeella*. *Bulletin of Entomological Research*, 97(4), 421-432.

Pereira, P. S. (2021). Perdas de produtividade e sistemas de tomada de decisão para pragas em cultivos de soja. Gurupi: UFT. (Tese de doutorado).

Pereira, R. R., Neves, D. V. C., Campos, J. N., Santana Jr, P. A., Hunt, T. E., Picanço, M. C. (2018). Natural biological control of *Chrysodeixis includens*. *Bulletin of Entomological Research*, 108(6), 831-842.

Pereira, R. R., Neves, D. V. C., Campos, J. N., Santana Jr, P. A., Hunt, T. E., Picanço, M. C. (2018). Natural biological control of *Chrysodeixis includens*. *Bulletin of Entomological Research*, 108(6), 831-842.

R Core Team. (2021). R: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing.

Régnière, J., Powell, J., Bentz, B., Nealis, V. (2012). Effects of temperature on development, survival and reproduction of insects: experimental design, data analysis and modeling. *Journal of Insect Physiology*, 58(5), 634-647.

Rosado, J. F., Picanço, M. C., Sarmiento, R. A., Silva, R. S., Pedro-Neto, M., Carvalho, M. A., Erasmo, E. A. L., Silva, L. C. R. (2015). Seasonal variation in the populations of *Polyphagotarsonemus latus* and *Tetranychus bastosi* in physic nut (*Jatropha curcas*) plantations. *Experimental and Applied Acarology*, 66, 415-426.

Sediyama, T., Silva, F., Borém, A. (2015). Soja: do plantio à colheita. Viçosa: UFV.

Silva, A. C., Gomes, C. C., Sacramento, F. Z., Garcia, G. L., Schultz, H., Pian, L. B., Almeida, L. H. M., Aguiar, L. A. (2013). Guia para o reconhecimento de inimigos naturais de pragas agrícolas. Brasília: EMBRAPA, 47p.

Soares, J. R. S., Silva, R. S., Ramos, R. S., Picanço, M. C. (2021). Distribution and invasion risk assessments of *Chrysodeixis includens* (Walker,[1858])(Lepidoptera: Noctuidae) using CLIMEX. International Journal of Biometeorology, 65, 1137-1149.

Specht, A., Paula-Moraes, S. V., Sosa-Gómez, D. R. (2015). Host plants of *Chrysodeixis includens* (Walker) (Lepidoptera, Noctuidae, Plusiinae). Revista Brasileira de Entomologia, 59(4), 343-345.

Thierry, H., Monteil, C., Parry, H., Vialatte, A. (2021). Simulating seasonal drivers of aphid dynamics to explore agronomic scenarios. Ecosphere, 12(5), e03533.

Tuszynski, J. (2020). caTools: Tools: Moving Window Statistics, GIF, Base64, ROC AUC, etc (Version 1.18. 0).

USDA - United States Department of Agriculture. (2023). Foreign Agricultural Service. Disponível em <https://www.fas.usda.gov/data/commodities/soybeans>. Acesso em 05/06/2023.

Wickham, H., Seidel, D. (2020). Scales: Scale functions for visualization. R package version, 1(1), 1.

Zulin, D., Ávila, C. J., Schlick-Souza, E. C. (2018). Population fluctuation and vertical distribution of the soybean looper (*Chrysodeixis includes*) in soybean culture. American Journal of Plant Sciences, 9(7), 1544-1556.