

LUCIANO CARDOSO DE FRANÇA

**REDES NEURAIS ARTIFICIAIS COMO FERRAMENTA DE PREVISÃO SAZONAL
DE *Spodoptera* spp EM SOJA Bt**

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: Poliana Silvestre Pereira
Renato Almeida Sarmento

**VIÇOSA - MINAS GERAIS
2023**

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

T

F814r
2023
França, Luciano Cardoso de, 1981-
Redes neurais artificiais como ferramenta de previsão sazonal de *Spodoptera* spp. em soja Bt / Luciano Cardoso de França. – Viçosa, MG, 2023.
1 dissertação eletrônica (26 f.): il. (algumas color.).

Orientador: Marcelo Coutinho Picanço.
Dissertação (mestrado) - Universidade Federal de Viçosa, Departamento de Entomologia, 2023.
Referências bibliográficas: f. 23-26.
DOI: <https://doi.org/10.47328/ufvbbt.2023.438>
Modo de acesso: World Wide Web.

1. *Glycine max*. 2. Soja - Doenças e pragas. 3. Lagartas - Controle biológico. 4. Inteligência artificial. 5. Soja - Fatores climáticos. 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. 633.3497


LUCIANO CARDOSO DE FRANÇA

**REDES NEURAIS ARTIFICIAIS COMO FERRAMENTA DE PREVISÃO SAZONAL
DE *Spodoptera* spp EM SOJA Bt**


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: 26 de junho de 2023.

Assentimento:

Documento assinado digitalmente
 LUCIANO CARDOSO DE FRANÇA
Data: 19/07/2023 12:49:55-0300
Verifique em <https://validar.iti.gov.br>

Luciano Cardoso de França
Autor

Documento assinado digitalmente
 MARCELO COUTINHO PICANÇO
Data: 19/07/2023 13:07:01-0300
Verifique em <https://validar.iti.gov.br>

Marcelo Coutinho Picanço
Orientador

Dedico este trabalho à Tatiane França, minha esposa, que sempre esteve ao meu lado, me apoiou e deu todo o suporte para eu poder seguir e concluir mais este projeto.

AGRADECIMENTOS

Agradeço a Deus, pela minha vida e por me ajudar a ultrapassar todos os obstáculos encontrados ao longo do Mestrado.

Aos meus pais, Milton e Marly, e meus filhos, Miguel e Maria Clara, que me incentivaram nos momentos difíceis e compreenderam a minha ausência enquanto eu me dedicava à realização deste projeto.

Ao professor Marcelo Picanço, Poliana Silvestre e Jhersyka da Silva Paes, pelas orientações e ensinamentos, que me permitiram apresentar um melhor desempenho no meu processo profissional.

À Universidade Federal de Viçosa, em especial ao Programa de Pós-graduação do Mestrado Profissional em Defesa Sanitária Vegetal.

A todas as pessoas contribuíram direta e indiretamente na elaboração deste trabalho.

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

RESUMO

FRANÇA, Luciano Cardoso, M.Sc., Universidade Federal de Viçosa, junho de 2023. **Redes neurais artificiais como ferramenta de previsão sazonal de *Spodoptera* spp. em soja Bt.** Orientador: Marcelo Coutinho Picanço. Coorientadores: Poliana Silvestre Pereira e Renato de Almeida Sarmiento.

A soja (*Glycine max*) é a leguminosa mais cultivada no mundo e atualmente nesses cultivos a maioria das variedades possuem toxinas da bactéria *Bacillus thuringiensis* (soja Bt) que conferem resistência a algumas espécies de Lepidoptera. O complexo de lagartas *Spodoptera* spp. (Lepidoptera: Noctuidae) são pragas importantes nos cultivos de soja Bt. Suas larvas atacam folhas, vagens e grãos, reduzindo o rendimento da cultura. O entendimento e previsão das intensidades de ataque das pragas aos cultivos é importante para o planejamento das épocas de realização de amostragem e de aplicação dos métodos de controle. As redes neurais artificiais (RNAs) são ferramentas de inteligência artificial que podem ser utilizadas em pesquisas de classificação e de análises de regressão como os estudos de dinâmica espaço-temporal das populações de pragas nos cultivos. Assim, este trabalho teve como objetivo usar modelo de RNA para identificação dos fatores reguladores de populações de *Spodoptera* spp. em cultivos de soja Bt. Durante dois anos foram avaliadas as densidades de lagartas de *Spodoptera* spp. e inimigos naturais em cultivos comerciais de soja na região do Cerrado brasileiro. Também foram coletados dados de elementos climáticos e da idade das plantas de soja. Para construir as RNAs foram utilizadas, como variáveis de entrada, a idade das plantas de soja, densidades de predadores e parasitoides e variáveis meteorológicas. A variável resposta foi a densidade de *Spodoptera* spp. Dentre as RNAs projetadas para prever a sazonalidade de lagartas *Spodoptera* spp. a mais adequada foi aquela com a médias dos 25 dias anteriores a avaliação da densidade da praga. Essa RNA tem dois neurônios na camada oculta, função de ativação de logística e propagação resiliente da função de aprendizado. As previsões da RNA e as densidades da praga nas lavouras apresentaram correlação de Pearson de 0,779. A temperatura média do ar foi o principal preditor ambiental e afetou negativamente as populações de *Spodoptera* spp. As maiores densidades de *Spodoptera* spp. ocorreram com plantas em estágio reprodutivo e nos cultivos de verão chuvoso.

Portanto, o modelo de rede neural artificial determinado nesse trabalho é promissor para prever as intensidades de ataque de lagartas *Spodoptera* spp. em cultivos de soja.

Palavras-chave: *Glycine max.* Lagartas. Inteligência artificial. Elementos climáticos. Dinâmica espaço-temporal.

ABSTRACT

FRANÇA, Luciano Cardoso, M.Sc., Universidade Federal de Viçosa, June 2023. **Artificial neural networks as a seasonal forecasting tool for *Spodoptera* spp. in Bt soybeans.** Advisor: Marcelo Coutinho Picanço. Co-advisors: Poliana Silvestre Pereira and Renato de Almeida Sarmiento.

Soybean (*Glycine max*) is the most cultivated legume in the world and currently in these crops most varieties have *Bacillus thuringiensis* bacteria toxins (Bt soybean) that confer resistance to some Lepidoptera species. The caterpillar complex *Spodoptera* spp. (Lepidoptera: Noctuidae) are important pests in Bt soybean crops. Its larvae attack leaves, pods and grains, reducing crop yield. Understanding and predicting the intensities of attack by pests on crops is important for planning the times for sampling and application of control methods. Artificial neural networks (ANNs) are artificial intelligence tools that can be used in classification research and regression analysis such as studies of space-time dynamics of populations of pests in crops. Thus, this work aimed to use an RNA model to identify the regulatory factors of populations of *Spodoptera* spp. in Bt soybean crops. During two years, the densities of caterpillars of *Spodoptera* spp. and natural enemies in commercial soybean crops in the Brazilian Cerrado region. Data on climatic elements and the age of soybean plants were also collected. To build the ANNs, the age of soybean plants, predator and parasitoid densities and meteorological variables were used as input variables. The response variable was the density of *Spodoptera* spp. Among the ANNs designed to predict the seasonality of *Spodoptera* spp. the most adequate was the one with the average of the 25 days prior to the pest density assessment. This ANN has two neurons in the hidden layer, logistic activation function and resilient propagation of the learning function. ANN predictions and pest densities in crops showed a Pearson correlation of 0.779. Mean air temperature was the main environmental predictor and negatively affected populations of *Spodoptera* spp. The highest densities of *Spodoptera* spp. occurred with plants in the reproductive stage and in rainy summer crops. Therefore, the artificial neural network model determined in this work is promising to predict the attack intensities of *Spodoptera* spp caterpillars. in soybean crops.

Keywords: *Glycine max*. Caterpillars. Artificial intelligence. Climatic elements. Space-time dynamics.

SUMÁRIO

1. INTRODUÇÃO	9
2. MATERIAIS E MÉTODOS.....	11
2.1 COLETA DE DADOS	11
2.2 PRÉ-PROCESSAMENTO DE DADOS	11
2.3 ANÁLISE DE DADOS	12
3. RESULTADOS	13
4. DISCUSSÃO	20
5. CONCLUSÕES	22
6. REFERÊNCIAS.....	23

1. INTRODUÇÃO

Atualmente, o ranking mundial de produtores de soja (*Glycine max* (L.) Merr.) é destaque o Brasil, seguido dos Estados Unidos e da Argentina (FAO, 2023). Estima-se que até 2030 o comércio mundial de soja crescerá 26,7%, o que representa um dos maiores aumentos entre as principais *commodities* (IPEA, 2022).

Na safra 2022/2023 a produção de soja no Brasil foi superior a 153 milhões de toneladas com uma área de cultivo de 43,4 milhões de hectares (CONAB, 2023; FAO, 2023). O consumo dos grãos de soja tem expandido no mundo, devido ao seu uso na alimentação humana e animal e como biocombustível. Os lucros obtidos nos cultivos de soja dependem da produtividade e custos de produção (Sediyama et al., 2015).

Para alcançar altas produtividades, é importante que o produtor adote tecnologias, principalmente aquelas que orientem na tomada de decisões quanto ao controle de pragas (Picanço et al., 2014). O ataque de insetos está entre os principais fatores de perdas nos cultivos de soja (Picanço et al., 2014; Xiaoming & Qiong, 2018).

Dentre os principais insetos-praga que atacam as lavouras de soja no Brasil e em outras partes do mundo, estão as lagartas deas espécies pertencentes às famílias estão Crambidae, Erebidae, Geometridae, Hesperidae, Noctuidae, Pieridae, Pyralidae, Saturniidae e Tortricidae. Os danos destas pragas são causados por suas larvas ao atacar toda a parte aérea das plantas, sobretudo folhas e vagens (Picanço et al., 2014; Formentini et al., 2015).

Para implementar programas de manejo integrado de pragas é importante determinar os fatores favoráveis ao ataque destes insetos à cultura (Picanço et al., 2014; Bacci et al., 2021). Entre os principais fatores que afetam o ataque das pragas nas lavouras estão o clima, os inimigos naturais, características da praga e da planta hospedeira, o ambiente e o sistema de cultivo (Bacci et al., 2021).

Temperaturas mais elevadas, geralmente favorecem mais ataques de pragas, devido a sua maior reprodução e a aceleração do seu ciclo de vida. Nas épocas chuvosas o ataque é menor, em razão da mortalidade ocasionada pelas chuvas (Bacci et al., 2021). O vento também interfere no ataque de pragas às culturas, por ser um dos principais veículos de dispersão dos insetos (Bacci et al., 2021). A ocorrência de inimigos naturais tem grande efeito na redução de populações de

insetos-praga às culturas. Assim, a preservação e aumento das populações de inimigos naturais pode reduzir o ataque de pragas às culturas (Picanço et al., 2007).

As plantas podem ter efeitos substanciais sobre a sobrevivência, reprodução e comportamento de insetos-praga (Williams, 1999). Thorpe & Barbosa (1986) ressaltam que as plantas afetam indiretamente o comportamento e fisiologia do inseto. Por exemplo, os metabólitos secundários produzidos pelas plantas, quando ingeridos, podem ter significativos efeitos na sobrevivência e na fecundidade dos insetos. Deste modo, as plantas alteram a capacidade dos insetos em causar dano (Raymond et al., 2002). Além disto, o descaso pelas medidas de controle, plantio de variedades suscetíveis ao ataque das pragas, falta de rotação de culturas nos agroecossistemas, plantio em regiões ou estações são favoráveis ao ataque de pragas (Picanço et al., 2014).

Desta maneira é necessário identificar os fatores que afetam o aparecimento e estabelecimento destes insetos na cultura da soja, para promover o manejo adequado e garantir a produtividade na lavoura. Assim, nos estudos atuais de dinâmica sazonal das populações de insetos-praga nas lavouras tem sido usadas ferramentas de inteligência artificial (Farias et al., 2022). O uso da inteligência artificial para resolução de problemas tem ganhado força, principalmente nas áreas que antes não estavam conectadas com este tipo de tecnologia (Farias et al., 2022).

Entre estas ferramentas estão as redes neurais artificiais. Estas redes são sistemas computacionais que simulam o funcionamento dos neurônios existentes nos seres vivos (Russell & Norvig, 2010; Farias et al., 2022). As redes neurais podem ser utilizadas para prever a dinâmica de variação sazonal das populações dos organismos. Além disto, estas redes podem ser usadas para a determinação da importância relativa dos fatores reguladores das populações dos insetos-praga nas lavouras (Anwar et al., 2022; Farias et al., 2022; Narava et al., 2022). De acordo com Aparecido et al. (2020), as redes neurais artificiais podem render modelos preditivos, que respondem por relacionamentos não lineares entre variáveis de entrada e saída e modelos complexos, com múltiplos preditores.

Apesar da importância dos cultivos de soja no Brasil e no mundo e da relevância das lagartas *Spodoptera* spp. como pragas desta cultura, por isso, desenvolver estudos que retrate a dinâmica sazonal destas pragas usando redes neurais artificiais, é importante para prevenção no que se refere ao ataque de

pragas na cultura da soja. Assim, este trabalho teve como objetivo determinar a dinâmica sazonal das populações de *Spodoptera* spp. em cultivos de soja, através das redes neurais artificiais.

2. MATERIAIS E MÉTODOS

2.1 COLETA DE DADOS

O trabalho foi conduzido durante dois anos, 2017 a 2019, em quatro campos comerciais de soja de variedade M8808 IPRO (transgênica Cry1Ac- RR), localizados nos Municípios de Formoso do Araguaia (11°47'48"S, 49°31'44"W, 240 m de altitude) e Gurupi (11°43'48"S, 49°04'08"W, 287m de altitude), ambos no Estado do Tocantins, Brasil (região de clima tropical, com inverno seco e verão chuvoso). Dois campos foram conduzidos na época seca (maio a setembro) - entressafra, e dois na época chuvosa (dezembro a abril) - safra. Cada lavoura tinha cerca de 20 ha e o espaçamento utilizado foi de 0,45 m (entre linhas) x 0,10 m (entre plantas). As plantas foram manejadas de acordo com as técnicas culturais recomendadas para a cultura (Sediyama et al., 2015).

Foram avaliadas as densidades de lagartas do complexo *Spodoptera* e de inimigos naturais (predadores e parasitoides) em 200 plantas por lavoura, em plantas nos estágios vegetativo e reprodutivo, por meio da técnica de amostragem batida do terço superior da planta em bandeja plástica branca (Pereira, 2021).

Durante a condução do trabalho, dados diários de temperatura média do ar, pluviômetros na lavoura, umidade relativa do ar e velocidade média dos ventos foram obtidos das estações meteorológicas do Instituto Nacional de Meteorologia localizadas próximas das regiões dos campos de cultivo (INMET, 2023).

2.2 PRÉ-PROCESSAMENTO DE DADOS

O trabalho foi realizado no software R V. 3.5.3 e RStudio V. 1.2.5001 1 (R Core Team 2019). Inicialmente, realizamos análises de correlação de Pearson entre os recursos de entrada, visando reduzir a dimensionalidade dos dados por meio da identificação de relações entre as variáveis preditoras. Isso é feito com o objetivo de reduzir o número de preditores utilizados.

As variáveis de entrada foram a idade da soja, inimigos naturais (predadores e parasitoides), temperatura média do ar, precipitação pluviométrica, umidade

relativa do ar e velocidade média dos ventos. A variável resposta foi a densidade de lagartas *Spodoptera* spp.

Também foi estudado o efeito de intervalos de tempo de diversos preditores de clima no desempenho das redes neurais artificiais (RNA). Para tanto, utilizou-se médias móveis de três dias das variáveis meteorológicas com espaçamento de 1, 5, 10, 15, 20, 25, 30, 45 e 60 dias entre as avaliações de campo.

Para a modelagem da RNA, as informações foram filtradas por intervalo de tempo (gerando seis conjuntos). Na sequência, para cada conjunto de dados, estes foram misturados e divididos aleatoriamente, sendo utilizado 70% dos dados para treinamento e 30% para validação (função *sample.split*, pacote *caTools*) (Tuszynski, 2019; Farias et al., 2022). As variáveis de entrada foram centralizadas (subtraindo a média) e dimensionadas, convertendo em escores z (função de *escala*, pacote de *estatísticas*). Este procedimento é essencial para modelagem de RNA para evitar o sobrepeso de medidas mais amplas no processo de aprendizagem e para tornar mais rápida a convergência do modelo. A variável resposta (*Spodoptera* spp.) também foi redimensionada de zero para um (função de *redimensionamento*, pacote de *escalas*) (Wickham, 2018; Farias et al., 2022).

2.3 ANÁLISE DE DADOS

As redes neurais artificiais (RNAs) foram determinadas utilizando a função *mlp* do pacote *RSNNS*. Para explorar diferentes configurações, foram testadas quatro funções de ativação (exponencial, tangente hiperbólica, logística e sigmoide) e três algoritmos de aprendizado (propagação resiliente, gradiente conjugado em escala e retropropagação padrão). O máximo de iterações foi estabelecido em 100, enquanto o tamanho do número de neurônios da camada oculta da RNA variou de 1 a 11. O peso inicial da RNA foi realizado aleatoriamente (*initFunc* = "*Randomize_Weights*") e os demais argumentos seguiram as configurações padrão (Bergmeir & Benítez, 2012)

Foram construídas um total de 1188 RNAs (4 funções de ativação × 3 algoritmos de aprendizado × 11 tamanhos de RNA × 1 variável de resposta × 9 intervalos de variáveis climáticas defasadas das avaliações de campo). Para avaliar a eficácia dos modelos, foram comparados os valores observados da variável de resposta com os valores ajustados pelas redes neurais artificiais (RNAs). Utilizamos a correlação de Pearson (r_v) e a raiz quadrada média do erro ($RMSE_v$) como métricas para avaliar o desempenho dos modelos no conjunto de validação. Para obter a melhor configuração de RNA que proporcionasse o modelo mais acurado, foi

selecionado o modelo de RNA que apresentou o menor valor de $RMSE_v$ e o maior valor de r_v (Farias et al., 2022).

Após a seleção da RNA vencedora, utilizamos o algoritmo de Olden (função *olden*, pacote *NeuralNetTools*) para estimar a importância relativa dos preditores. Esse método calcula a importância dos preditores com base nos pesos das conexões entre as camadas de entrada e oculta, assim como entre as camadas oculta e de saída, somando esses produtos em todos os neurônios ocultos (Olden et al., 2004; Farias et al., 2022). A configuração vencedora da RNA foi repetida 250 vezes, utilizando conjuntos aleatórios de pesos iniciais, onde as estimativas de Olden foram registradas e combinadas para calcular um intervalo de confiança de 95% (CI_{95}). Um preditor foi considerado significativo quando os limites do CI_{95} não incluíam zero (Beck, 2018). Por fim, foram conduzidas análises de sensibilidade por meio da utilização de gráficos de dependência parcial (função *parcial*, pacote *pdp*). Esses gráficos ilustram a relação entre a variável resposta e um preditor específico, considerando o efeito médio dos demais fatores (Greenwell, 2017; Farias et al., 2022).

3. RESULTADOS

Dentre as redes neurais artificiais (RNAs) projetadas para prever a sazonalidade de lagartas *Spodoptera* spp. na cultura da soja, a conformação contendo 25 dias de defasagem dos dados meteorológicos, dois neurônios na camada oculta, função de ativação de logística e propagação resiliente da função de aprendizado apresentou o melhor desempenho com base nos valores de r_v (0,779) e $RMSE_v$ (0,187) (Tabela 1).

A representação gráfica da rede neural artificial destaque no experimento, para prever a flutuação sazonal de lagartas *Spodoptera* spp. em lavouras de soja, incluiu uma camada de entrada com sete preditores (I1 a I7), uma camada oculta com dois neurônios (H1 e H2) e uma camada de saída com um neurônio (variável resposta; O1) (Figura 1).

Observou-se variação sazonal na densidade de lagartas *Spodoptera* spp., nas variáveis climáticas e na densidade de inimigos naturais (predadores e parasitoides), ao longo das épocas de cultivos (Figura 2). No primeiro e terceiro cultivo, inverno seco (junho a setembro) as densidades de *Spodoptera* spp. foram baixas. As maiores densidades da praga foram encontradas no segundo e quarto cultivo, verão chuvoso (janeiro a março), em plantas no estágio reprodutivo. A temperatura do ar variou em todas as épocas de cultivo, alcançando altas

temperaturas. A precipitação também variou ao longo dos meses de cultivo, sendo maior nos cultivos de verão (segundo e quarto cultivo). A umidade relativa do ar foi maior nos cultivos de início de ano, dos meses de janeiro a março (época chuvosa). Enquanto as maiores velocidades dos ventos ocorreram nos cultivos do meio do ano, dos meses de junho a setembro (época seca). Em relação a população de predadores foi maior que a população de parasitoides (Figura 2).

Tabela 1. Topologia (número de neurônios, função de ativação e algoritmo de aprendizado) e desempenho (r_v = 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 sazonalidade da intensidade de ataque de lagartas de *Spodoptera* spp. a cultivos de soja.

Defasagem dos dados § meteorológicos (dias)	Nº de neurônios	Função de ativação	Função de aprendizado	r_v	RMSEv
1	10	Rprop	Tang_H	0,644	0,241
5	1	Rprop	Logistic	0,627	0,182
10	7	Rprop	Sigmoid	0,644	0,241
15	10	SCG	Sigmoid	0,558	0,190
20	5	SCG	Sigmoid	0,514	0,205
25*	2	Rprop	Logistic	0,779	0,187
30	4	Rprop	Sigmoid	0,695	0,179
45	2	Rprop	Logistic	0,699	0,202
60	4	Rprop	Tang_H	0,688	0,175

§ Número de dias antes da avaliação do ataque de lagartas de *Spodoptera* spp. 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 esquemático da rede neural artificial vencedora para prever a dinâmica sazonal da intensidade de ataque de lagartas de *Spodoptera* spp. a cultivos de soja. A RNA consistiu de uma camada de entrada com sete neurônios (I1 a I7), uma camada oculta com dois neurônios (H1 e H2) e uma camada de saída com um único neurônio (O1). I1 = idade das plantas de soja (dias), I2 = densidade de predadores, I3 = densidade de parasitoides, I4 a I7 = dados médios de variáveis meteorológicas dos últimos cinco dias: I4 = temperatura média do ar (°C), I5 = precipitação pluviométrica (mm/dia), I6 = umidade relativa do ar média (%) e I7 = 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.

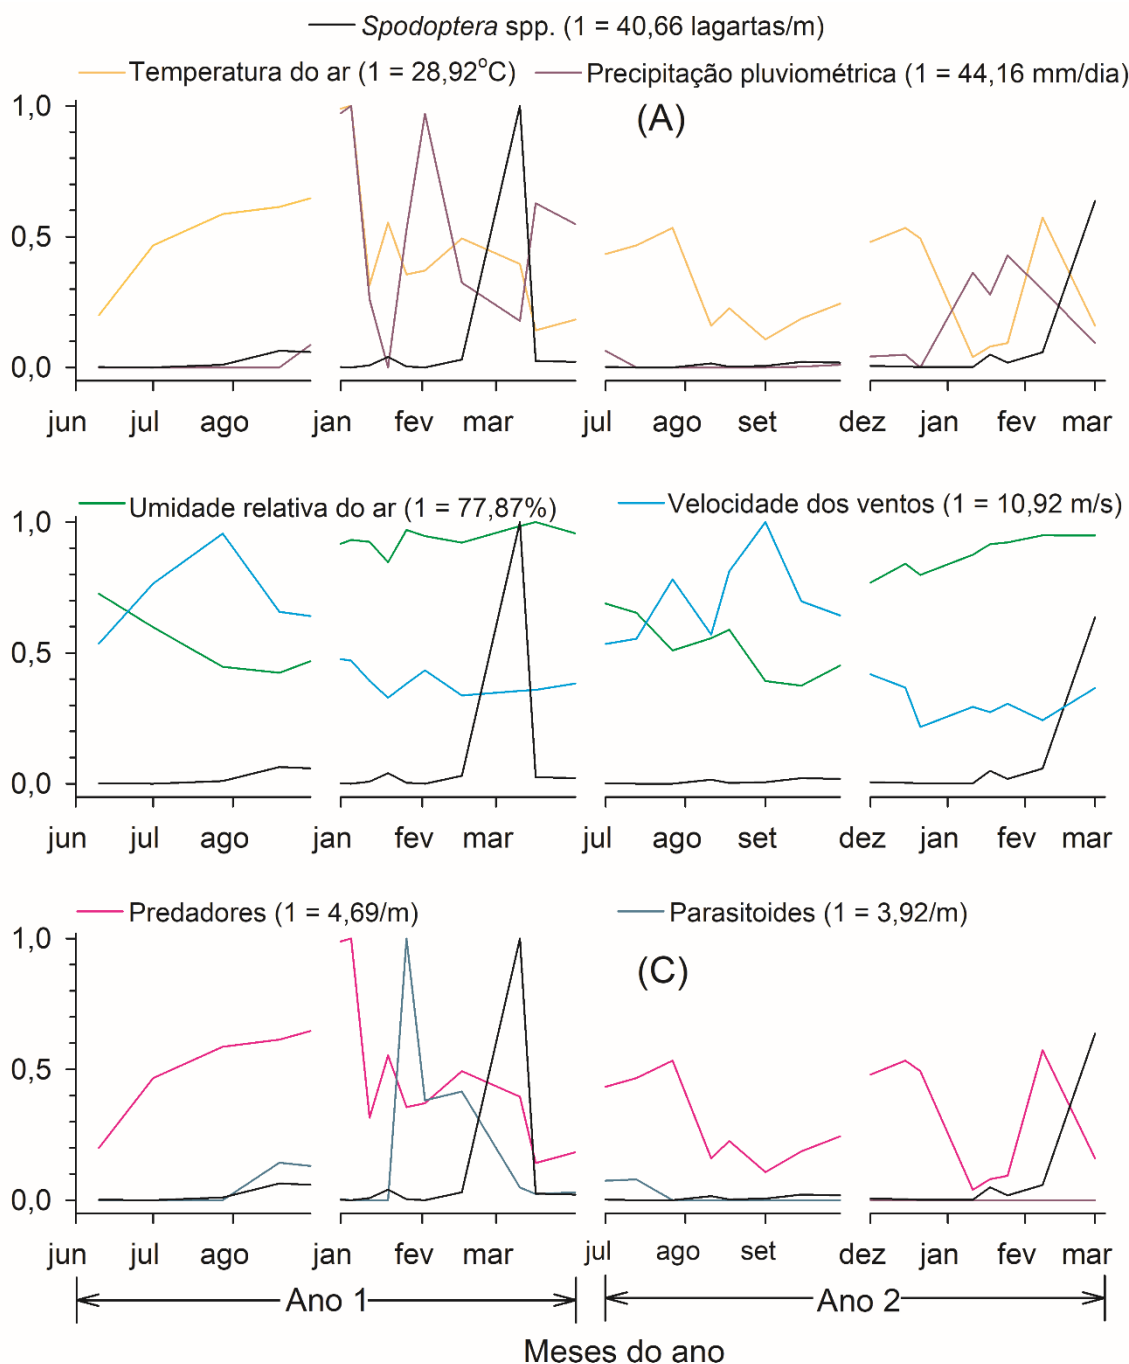


Figura 2. Variação sazonal das densidades de lagartas *Spodoptera* spp. variáveis meteorológicas (temperatura média do ar, precipitação pluviométrica, velocidade dos ventos e umidade relativa média do ar) durante dois anos. As variáveis y foram redimensionadas de 0 para 1 e os intervalos dos dados de cada uma delas são mostrados em suas legendas.

A importância relativa dos preditores para a variável resposta (*Spodoptera* spp.) está representada na Figura 3. Dentre os 7 preditores, a velocidade dos ventos foi o único não-significativo, não teve influência na flutuação populacional das lagartas *Spodoptera* spp. Os demais preditores foram significativos. A temperatura do ar foi o preditor climático que mais influenciou, negativamente, a dinâmica sazonal de *Spodoptera* spp. Quanto mais alta for a temperatura, a tendência é a redução da população das lagartas *Spodoptera* spp. Enquanto que, nos meses mais chuvosos e úmidos, amenizou a temperatura, aumentou a densidade da praga. Além disso, a idade das plantas foi favorável ao aumento da população de *Spodoptera* spp. O ataque das pragas na cultura da soja ocorre mais na fase reprodutiva. Já os predadores e parasitoides foram atraídos pela população de lagartas (Figura 3).

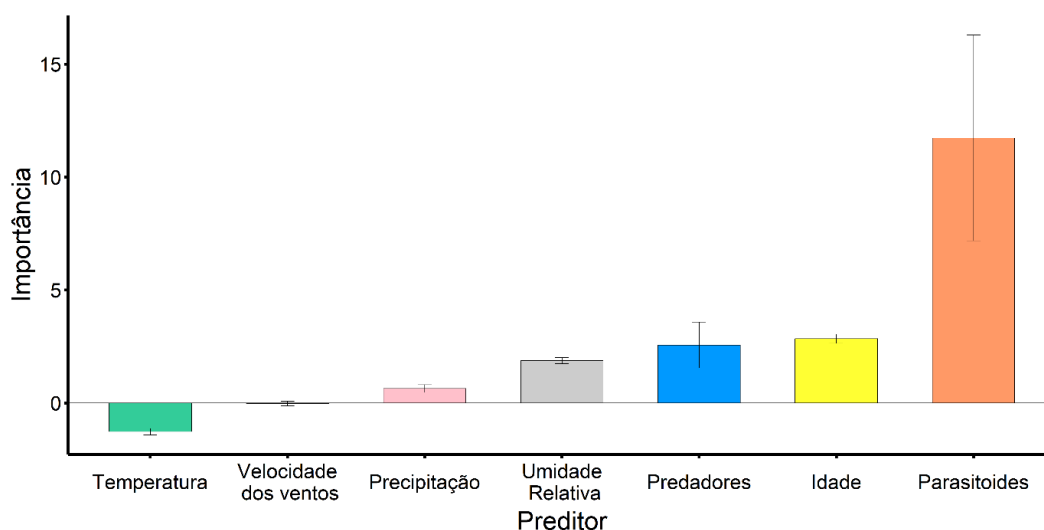


Figura 3. Importância relativa (média e intervalo de confiança de 95%) dos preditores para a variável de resposta estimada a partir dos pesos vencedores da rede neural artificial (RNA) por meio do método de Olden. Foram criadas 250 RNAs com diferentes pesos iniciais, e a importância dos preditores foi calculada e armazenada para permitir o cálculo de médias e intervalos de confiança.

Houve variação média da densidade de lagartas *Spodoptera* spp. em função das variáveis preditoras que foram significativas (Figura 4). O ataque das pragas aumentou quando as plantas estavam em estágio reprodutivo. Também com o aumento da densidade de lagartas *Spodoptera* spp., a densidade de predadores e

de parasitoides aumentaram. Em relação às variáveis climáticas, o ataque de lagartas aumenta quando a temperatura atinge seu ponto ótimo. Posteriormente, à medida que a temperatura continua aumentando, ocorre uma diminuição no ataque das pragas. Já, à medida que os níveis de precipitação e umidade relativa do ar aumentam, é observado um aumento na densidade de lagartas *Spodoptera* spp. (Figura 4).

O desempenho preditivo do modelo de redes neurais artificiais foi altamente eficaz em todo o conjunto de dados. O modelo da RNA previu o ataque de *Spodoptera* spp. em duas situações diversas (Figura 5). Nos cultivos de inverno seco (junho a setembro) as densidades observadas de lagartas foram baixas. Já nos cultivos de verão chuvoso (dezembro a março) as densidades observadas foram altas, em ambos os anos de avaliação. Assim, ao analisar as densidades de lagartas *Spodoptera* spp. previstas pelo modelo e observadas em campos de soja durante os dois anos de cultivo, verificou-se que os dados ajustados foram equivalentes aos dados observados. Desta forma, este modelo foi capaz de prever o ataque às lavouras tanto em baixas densidades quanto em altas densidades, evidenciando a eficácia das redes neurais na predição do modelo (Figura 5).

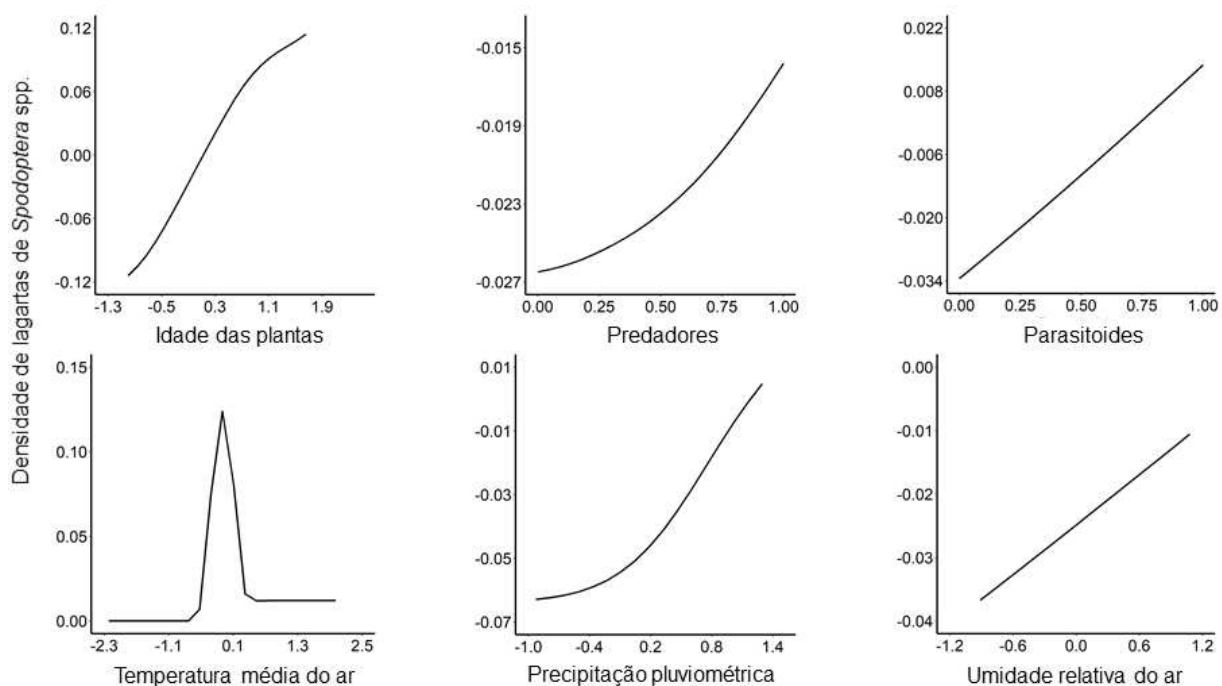


Figura 4. Gráficos da variação média da variável saída (densidade de lagartas de *Spodoptera* spp.) em função dos níveis das variáveis de entrada com efeitos significativos (idade das plantas de soja, densidades de predadores e parasitoides, temperatura média do ar, precipitação pluviométrica e umidade relativa do ar média).

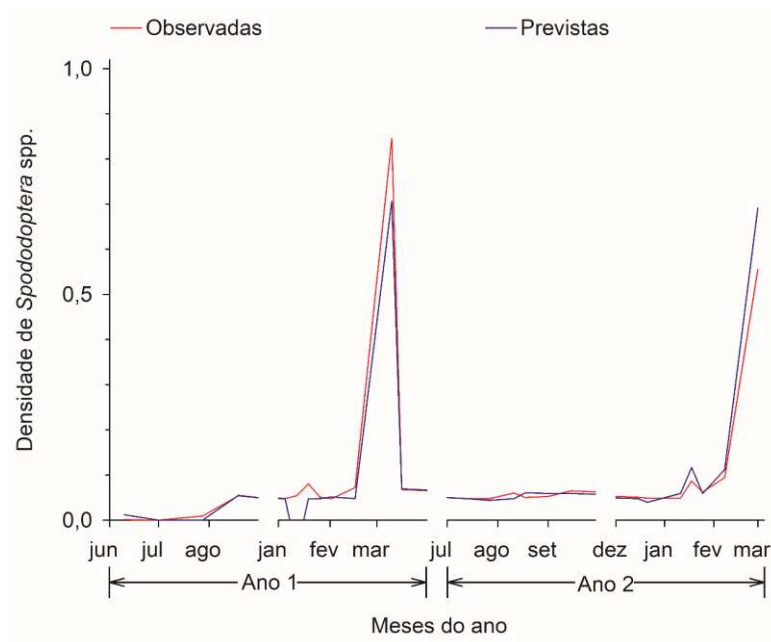


Figura 5. Densidades de lagartas de *Spodoptera* spp. previstas pelo modelo e observadas nos cultivos de soja durante dois anos.

4. DISCUSSÃO

A dinâmica sazonal das populações de insetos-praga e o comportamento destes afetam de forma intensa os cultivos. Fazer uma previsão desta dinâmica sazonal é de extrema importância para o manejo de pragas (Bacci et al., 2021). Nossa pesquisa apresenta uma abordagem baseada em redes neurais para prever a dinâmica sazonal de *Spodoptera* spp. em lavouras de soja. Utilizamos um conjunto de preditores, que inclui idade da planta, inimigos naturais (predadores e parasitoides) e condições climáticas, para realizar previsões das densidades *Spodoptera* spp. De acordo com Farias et al. (2022), é importante selecionar os preditores relevantes e significativos, como fatores bióticos e abióticos, que apresentam uma relação direta ou indireta com dinâmica sazonal de insetos-praga. A seleção cuidadosa dos preditores contribui para a precisão das previsões, permitindo que a rede neural aprenda e identifique os padrões corretos (Skawsang et al., 2019; Farias et al., 2022).

Neste estudo, o melhor modelo preditivo, de acordo com o $RMSE_v$, para avaliar a flutuação sazonal de lagartas *Spodoptera* spp., apresentou uma camada de entrada com sete preditores, uma camada oculta com dois neurônios e uma camada de saída com um único neurônio. A camada de saída da RNA fornece a estimativa ou previsão desejada com base nas informações processadas nas camadas anteriores (Aparecido et al., 2020). A seleção adequada dos preditores na camada de entrada e o número de neurônios na camada oculta desempenham um papel crucial na capacidade da RNA em prever a flutuação sazonal dos insetos-praga (Alemu et al., 2018; Carmo et al., 2020).

A camada oculta é responsável por processar as informações e realizar cálculos intermediários durante o treinamento e a previsão da rede neural (Alemu et al., 2018). O número de neurônios nessa camada pode afetar a capacidade da rede em aprender e modelar a complexidade dos dados (Alemu et al., 2018). Se houver poucos neurônios, a rede pode ter uma capacidade limitada para capturar os padrões e relações complexas dos dados, resultando em previsões imprecisas. Por outro lado, se houver muitos neurônios, a rede pode se tornar excessivamente complexa e propensa a ocorrência de sobreajuste, isto é, de memorizar os dados de treinamento em vez de generalizar os padrões (Alemu et al., 2018; Martins et al., 2019). Logo, é importante realizar uma análise cuidadosa e ajustar o número de neurônios na

camada oculta para obter previsões mais precisas da rede. As redes neurais artificiais são aplicadas para solucionar problemas complexos, por isso, problemas com maior complexidade, ao aumentar o número de camadas e de neurônios, consegue uma maior eficiência funcional, que acarreta maior esforço computacional (Souza et al., 2012).

A temperatura foi o principal preditor ambiental que impactou a dinâmica sazonal das populações de lagartas *Spodoptera* spp. Até uma temperatura, considerada ótima, observou-se um crescimento na população de *Spodoptera* spp. Depois, com o aumento da temperatura a população de *Spodoptera* spp. sofreu um declínio. Os picos populacionais de lagartas *Spodoptera* spp. estão relacionadas às variações de temperaturas, quanto mais alta a temperatura, maior a redução da população de lagartas. As lagartas *Spodoptera* spp. apresentam redução do ciclo de vida em altas temperaturas, por haver aceleração do metabolismo (Stecca, 2011). Bueno et al. (2017) explicam que para as lagartas do complexo *Spodoptera*, a faixa ideal de temperatura para o seu desenvolvimento é de 25-28°C. Temperaturas superiores a esses valores interferem negativamente na população dessas pragas. Quando *Spodoptera* spp. encontra boas condições, podem originar mais de 10 gerações anuais da praga (Bueno et al., 2017).

Dentre os demais preditores, a idade das plantas, a precipitação e a umidade relativa influenciaram positivamente as populações de *Spodoptera* spp. Um aumento na infestação de lagartas *Spodoptera* spp., em cultivos de soja, foi registrado em plantas no estágio reprodutivo. Durante o estágio reprodutivo, as vagens estão em desenvolvimento, contendo sementes que são ricas em nutrientes. Isso torna as plantas de soja um alvo atrativo para as lagartas em busca de uma fonte de alimento adequada, que se encontram preferencialmente no cartucho da planta (Eckel et al., 1992; Ahuja et al., 2011). Além disso, o estágio reprodutivo da soja geralmente coincide com períodos de clima favorável, como temperaturas, precipitação e condições de umidade adequadas (Mazza et al., 1999), o que foi observado nos cultivos de verão. Essas condições criam um ambiente propício para o desenvolvimento de suas populações, aumentando a probabilidade de ataques de lagartas em plantas de soja (Mazza et al., 1999; Carmo et al., 2019).

As populações de predadores (como aranhas, *Geocoris* sp. e *Orius incidiosus*) e parasitoides Hymenoptera: Braconidae também aumentaram com o

crescimento da população de *Spodoptera* spp. Geralmente os inimigos naturais são atraídos pelas pragas devido à disponibilidade de alimento, aos sinais químicos emitidos pelas pragas, à presença de um ambiente favorável e às interações entre esse sistema (Turlings et al., 1995; Fidelis et al., 2019; Zhang et al., 2019; Ayelo et al., 2021). Essa atração contribui para o controle biológico das pragas, à medida que os inimigos naturais se alimentam ou parasitam as pragas, ajudando a regular suas populações e a manter o equilíbrio ecológico (Vilela & Pallini, 2002; Haddad et al., 2016; Heinrichs & Muniappan, 2019).

O uso das redes neurais artificiais na predição da dinâmica populacional de lagartas *Spodoptera* spp. foi altamente relevante. Essas redes demonstram um valor biológico significativo, pois incluem fatores que influenciam diretamente no tamanho da população dessas pragas (Farias et al., 2022). O modelo foi capaz de prever o ataque de lagartas *Spodoptera* spp. nos cultivos de inverno seco (junho a setembro) e de verão chuvoso (dezembro a março), épocas que apresentaram baixas e altas densidades, respectivamente. Além disso, modelos de alerta de ataque de pragas são capazes de gerar informações para adoção de ações, de modo que reduza os danos e custos de controle (Aparecido et al., 2020; Farias et al., 2022).

Dessa forma, a identificação dos fatores que influenciam a dinâmica populacional da praga favorece a implementação do manejo integrado, permitindo determinar o momento adequado para realizar o seu monitoramento (Panizzi, 2013). Esse conhecimento é fundamental para auxiliar na tomada de decisão, que deve ser rápida e eficiente, principalmente em extensas áreas de cultivo de soja (Picanço et al., 2014).

5. CONCLUSÕES

O modelo de rede neural artificial determinado nesse trabalho é promissor para prever as intensidades de ataque de lagartas *Spodoptera* spp. em cultivos de soja. Esse modelo é capaz de prever de forma precisa as populações de *Spodoptera* spp. nos cultivos de soja em diferentes anos, locais e épocas. As populações de *Spodoptera* spp. nos cultivos de soja são reguladas pela temperatura do ar, precipitação pluviométrica, umidade relativa do ar, idade das plantas de soja e populações de predadores e parasitoides.

6. REFERÊNCIAS

- Ahuja, I., Rohloff, J., Bones, A. M. (2011). Defence mechanisms of *Brassicaceae*: implications for plant-insect interactions and potential for integrated pest management. **Sustainable Agriculture**, 2: 623-670.
- Alemu, H. Z., Wu, W., Zhao, J. (2018). Feedforward neural networks with a hidden layer regularization method. **Symmetry**, 10: 1-18.
- Anwar N., Ahmad I., Raja M.A.Z., Naz S., Shoaib M., Kiani A.K. (2022). Artificial intelligence knacks-based stochastic paradigm to study the dynamics of plant virus propagation model with impact of seasonality and delays. **The European Physical Journal Plus**, 137: 1-47.
- Aparecido, L. E. O., Rolim, G. S., Moraes, J. R. S. C., Costa, C. T. S., Souza, P. S. (2020). Machine learning algorithms for forecasting the incidence of *Coffea arabica* pests and diseases. **International Journal of Biometeorology**, 64: 671-688.
- Ayelo, P. M., Pirk, C. W., Yusuf, A. A., Chailleux, A., Mohamed, S. A., Deletre, E. (2021). Exploring the kairomone-based foraging behaviour of natural enemies to enhance biological control: A review. **Frontiers in Ecology and Evolution**, 9: 1-22.
- Bacci, L., Silva, E. M., Martins, J. C., Silva, R. S., Chediak, M., Milagres, C. C., Picanço, M. C. (2021). The seasonal dynamic of *Tuta absoluta* in *Solanum lycopersicon* cultivation: Contributions of climate, plant phenology, and insecticide spraying. **Pest Management Science**, 77: 3187-3197.
- Beck, M. W. (2018). NeuralNetTools: Visualization and analysis tools for neural networks. **Journal of Statistical Software**, 85: 1-20.
- Bergmeir, C., Benítez, J. M. (2012). Neural networks in R using the Stuttgart neural network simulator: RSNNS. **Journal of Statistical Software**, 46:1-26.
- Bueno, A. F., Bortolotto, O. C., Bueno, R. C. O. F., Hamada, E., Favetti, B. M., Silva, G. V. (2017). Efeitos do aquecimento global sobre pragas de oleaginosas. In: Bettiol, W., Hamada, E., Angelotti, F., Auad, A. M., Ghini, R. (Eds.). **Aquecimento global e problemas fitossanitários**. Brasília: Embrapa. pp. 280-347.
- Carmo, D. G., Farias, E. S., Costa, T. L., Queiroz, E. A., Nascimento, M., & Picanço, M. C. (2020). Instar determination of *Blaptostethus pallelescens* (Hemiptera: Anthocoridae) using artificial neural networks. **Annals of the Entomological Society of America**, 113: 50-54.
- Carmo, E. L., Silva, A. G., Braz, G. B. P., Procópio, S. O., Simon, G. A., Rocha, A. G. C., Barcellos, L. C. (2019). Phytosanitary risks and agronomic performance of soybeans associated with spatial arrangements of plants. **Bioscience Journal**, 35: 806-817.
- CONAB - Companhia Nacional de Abastecimento. (2023). Boletim da safra de grãos 2022/2023 - 8º Levantamento. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos>. Acessado em 10 maio 2023.

Eckel, C. S., Terry, L. I., Bradley Jr, J. R., Van Duyn, J. W. (1992). Changes in within-plant distribution of *Helicoverpa zea* (Boddie) (Lepidoptera: Noctuidae) on soybeans. **Environmental Entomology**, 21: 287-293.

FAO - Food and Agriculture Organization of the United Nations. (2023). Statistical databases. Disponível em: <http://www.fao.org/faostat/en/#data/QC>. Acessado em: 10 maio 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: 875-882.

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

Formentini, A. C., Sosa-Gómez, D. R., Paula-Moraes, S. V., Barros, N. M., Specht, A. (2015). Lepidoptera (Insecta) associated with soybean in Argentina, Brazil, Chile and Uruguay. **Ciência Rural**, 45: 2113-2120.

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

Haddad, C. R., Brabec, M., Pekár, S., Fourie, R. (2016). Seasonal population dynamics of a specialized termite-eating spider (Araneae: Ammoxenidae) and its prey (Isoptera: Hodotermitidae). **Pedobiologia**, 59: 105-110.

Heinrichs, E. A., Muniappan, R. (2019). Integrated pest management for tropical crops: soyabeans. **CABI Reviews**, 13: 1-44.

INMET - Instituto Nacional de Meteorologia. (2023). Banco de dados meteorológicos para ensino e pesquisa. Disponível em: <http://www.inmet.gov.br/projetos/rede/pesquisa>. Acessado em: 04 abril 2023.

IPEA - Instituto de Pesquisa Econômica Aplicada. (2022). **Mercados e preços agropecuários**. Rio de Janeiro: Ipea.

Martins, M. T., Marangon, G. P., Costa, E. A., Silveira, B. D., Cubas, R., Cavalli, J. P. (2019). Estimação da altura de plantios florestais de eucalipto por regressão e redes neurais artificiais. **BIOFIX Scientific Journal**, 5: 141-152.

Mazza, C. A., Zavala, J., Scopel, A. L., Ballaré, C. L. (1999). Perception of solar UVB radiation by phytophagous insects: behavioral responses and ecosystem implications. **Proceedings of the National Academy of Sciences**, 96: 980-985.

Narava, R., Kumar, D.V. S. R., Jaba, J., Kumar, P. A., Rao, G. V. R., Rao, V. S., Mishra, S. P., Kukanur, V. (2022). Development of temporal model for forecasting of *Helicoverpa armigera* (Noctuidae: Lepidoptera) using arima and artificial neural networks. **Journal of Insect Science**, 22: 1-9.

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: 389-397.

Panizzi, A. R. (2013). History and contemporary perspectives of the integrated pest management of soybean in Brazil. **Neotropical Entomology**, 42: 119-127.

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

Picanço, M. C., Bacci, L., Crespo, A. L. B., Miranda, M. M. M., Martins, J. C. (2007). Effect of integrated pest management practices on tomato production and conservation of natural enemies. **Agricultural and Forest Entomology**, 9: 327-335.

Picanço, M. C., Galdino, T. V. S., Silva, R. S., Benevenuto, J. S., Bacci, L., Pereira, R. R., Moreira, M. D. (2014). Manejo integrado de pragas. In: Zambolim, L., Silva, A. A., Picanço, M. C. (Eds.). **O que Engenheiros Agrônomos devem saber para orientar o uso de produtos fitossanitários**. Viçosa: UFV. p.389-436.

R Core Team.(2019). **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing.

Raymond, B., Vanbergen, A., Pearce, I., Hartley, S. E., Cory, J. S., Hails, R. S. (2002). Host plant species can influence the fitness of herbivore pathogens: the winter moth and its nucleopolyhedrovirus. **Oecologia**, 131: 533-541.

Russell, S., Norvig, P. (2010). **Artificial intelligence: a modern approach**. 3rd. New Jersey: Prentice Hall.

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

Skawsang, S., Nagai, M., K. Tripathi, N., Soni, P. (2019). Predicting rice pest population occurrence with satellite-derived crop phenology, ground meteorological observation, and machine learning: a case study for the Central Plain of Thailand. **Applied Sciences**, 9: 4846.

Souza, F. A., Araújo, R., Matias, T., Mendes, J. (2013). A multilayer-perceptron based method for variable selection in soft sensor design. **Journal of Process Control**, 23(10), 1371-1378.

Stecca, C. S. (2011). **Distribuição espaço temporal e flutuação populacional de lagartas desfolhadoras de soja**. Santa Maria: UFSM. 86p. (Dissertação de Mestrado em Agronomia).

Thorpe, K. W., Barbosa, P. (1986). Effects of high and low nicotine tobacco by *Manduca sexta* (Lepidoptera: Sphingidae) on survival of the gregarious endoparasitoid *Cotesia congregata* (Hymenoptera: Braconidae). **Journal Chemical Ecology**, 12:1327-1329.

Turlings, T. C., Loughrin, J. H., McCall, P. J., Röse, U. S., Lewis, W. J., Tumlinson, J. (1995). How caterpillar-damaged plants protect themselves by attracting parasitic wasps. **Proceedings of the National Academy of Sciences**, 92: 4169-4174.

Tuszynski, J. (2019). caTools: Tools: moving window statistics, GIF, Base64, ROC AUC, etc. Disponível em: <https://cran.r-project.org/package=caTools>. Acessado em: 10 abril 2023.

Vilela, E. F., Pallini, A. (2002). Uso dos semioquímicos no controle biológico de pragas. In: Parra, J. R. P., Botelho, P. S. M., Corrêa-Ferreira, B. S., Bento, J. M. S. (Eds.). Controle biológico no Brasil - parasitoides e predadores. São Paulo: Manole. p.529-542.

Wickham, H. (2018). Scales: Scale functions for visualization. Disponível em: <https://cran.r-project.org/package=scales>. Acessado em: 10 abril 2023.

Williams, I. S. (1999). Slow-growth, high-mortality - a general hypothesis, or is it?. **Ecological Entomology**, 24: 490-495.

Xiaoming, Z., Qiong, L. (2018). A brief introduction of main diseases and insect pests in soybean production in the global top five soybean producing countries. **Plant Diseases & Pests**, 9: 17-21.

Zhang, X., Van Doan, C., Arce, C. C., Hu, L., Gruenig, S., Parisod, C., Erb, M. (2019). Plant defense resistance in natural enemies of a specialist insect herbivore. **Proceedings of the National Academy of Sciences**, 116: 23174-23181.