

Sistema Especialista com Redes Bayesianas para Apoio à Decisão na Aplicação de Fungicidas na Soja

Carolinne Victória Santos Oliveira
Instituto Federal do Paraná (IFPR)
Telêmaco Borba, Brasil
carolinevictoria1224@gmail.com

Gregory Vinicius Conor Figueiredo
Instituto Federal do Paraná (IFPR)
Telêmaco Borba, Brasil
gregory.figueiredo@ifpr.edu.br

Abstract—Asian soybean rust (*Phakopsora pachyrhizi*) is one of the main diseases affecting soybean productivity in Brazil. Among its management strategies, fungicide application throughout the crop cycle is one of the most widely used control measures. This paper presents the development of an expert system based on Bayesian networks to support decision-making regarding the need for fungicide application. The model was implemented in Python, using the PyMC library for probabilistic inference, with an interactive interface built in Flask. Tests with random samples and user-provided evidence demonstrated that the system responds consistently to variations in inputs, adjusting the final inference based on dependencies between variables. The results demonstrate the viability and usefulness of systems based on Bayesian networks as a decision-support tool in scenarios of uncertainty in agriculture.

Keywords—asian rust; bayesian networks; expert systems.

Resumo—A ferrugem asiática (*Phakopsora pachyrhizi*) é uma das principais doenças que comprometem a produtividade da soja no Brasil. Entre suas estratégias de manejo, a aplicação de fungicidas ao longo do ciclo é uma das medidas mais utilizadas no controle. Este trabalho apresenta o desenvolvimento de um sistema especialista baseado em redes bayesianas para apoiar a tomada de decisão quanto à necessidade de aplicação de fungicidas. O modelo foi implementado em Python, utilizando a biblioteca PyMC para inferência probabilística, com interface interativa construída em Flask. Testes com amostras aleatórias e evidências fornecidas por usuários demonstraram que o sistema responde de forma coerente às variações nas entradas, ajustando a inferência final conforme as dependências entre variáveis. Os resultados evidenciam a viabilidade e a utilidade de sistemas baseados em redes bayesianas como ferramenta de apoio à decisão em cenários de incerteza na agricultura.

Palavras-chave—ferrugem asiática; redes bayesianas; sistemas especialistas.

I. INTRODUÇÃO

A ocorrência de doenças fúngicas é um dos principais fatores que comprometem o rendimento da soja no Brasil. Entre as doenças que mais geram prejuízos, destaca-se a ferrugem asiática (*Phakopsora pachyrhizi*), considerada uma das mais agressivas da cultura, causando desfolha precoce e perdas de até 90% na produtividade se não for devidamente controlada

[1]. Devido à fácil disseminação do fungo pelo vento, a doença ocorre em praticamente todas as regiões produtoras. Entre suas estratégias de manejo, a aplicação de fungicidas ao longo do ciclo é uma das medidas mais utilizadas no controle. No entanto, a frequência dessas aplicações varia conforme a região e a decisão de aplicação se torna complexa ao envolver fatores agrônômicos, climáticos e fitossanitários. Muitas vezes essa tomada de decisão é feita de forma ineficaz, se baseando em recomendações genéricas ou intuição, levando a aplicações excessivas, aumento de custos e impactos ambientais. Nesse contexto, o uso de sistemas especialistas apresenta potencial no apoio a decisões mais precisas e baseadas em evidências. Na agricultura, eles têm sido usados para diagnosticar e prevenir doenças, armazenando e transferindo conhecimento de especialistas, o que permite atualização constante e maior eficácia nos diagnósticos [2]. Sistemas especialistas são ferramentas de softwares que utilizam uma base de conhecimento codificada e experiências de especialistas em uma determinada área, para abordar tarefas complexas de diagnósticos a fim de fornecer recomendações para a tomada de decisões [3]. Entre essas ferramentas, destacam-se os sistemas especialistas baseados em redes bayesianas, capazes de lidar com incertezas. Essas redes representam relações causais entre variáveis por meio de grafos acíclicos direcionados, com distribuições condicionais em cada nó. São aplicadas para apoiar decisões mesmo com informações incompletas, sendo construídas a partir de uma fase qualitativa (estrutura) e outra quantitativa (probabilidades condicionais) [4]. O presente trabalho visa implementar um sistema especialista baseado em redes bayesianas para apoiar decisões sobre a aplicação de fungicidas, utilizando a biblioteca PyMC para inferências probabilísticas a partir de evidências do usuário. A proposta se baseia no modelo construído na dissertação intitulada “Modelo Probabilístico Bayesiano para Simular o Conhecimento de Especialistas no Controle da Ferrugem Asiática da Soja no Estado do Paraná” [5].

II. METODOLOGIA


O desenvolvimento do sistema seguiu etapas voltadas à compreensão, seleção e implementação do modelo, que apresenta as variáveis associadas à ferrugem asiática e suas respectivas tabelas de probabilidade condicional (TPC). Inicialmente, foi realizada uma revisão de literatura sobre redes bayesianas e sistemas especialistas aplicados à agricultura, analisando 12 artigos de bases como Science Direct e Periódico Capes (2023-2025). Com base nesse conhecimento, foram realizados testes de modelagem e inferência de redes bayesianas usando GeNIe e a biblioteca Jsmile, que possibilitou simular a estrutura, observando as relações condicionais e suas dependências de forma visual. Além de permitir testar cenários com evidências fornecidas manualmente. Posteriormente, analisaram-se linguagens e bibliotecas disponíveis para a implementação do sistema, considerando: documentação, funcionalidades, performance, confiabilidade, licenciamento e integração. Entre as alternativas avaliadas estavam a biblioteca JSmile em Java, o PyMC em Python e o software de código aberto Weka. Ao fim, optou-se por Python com PyMC, devido à robustez, flexibilidade, suporte a modelagem bayesiana e algoritmos de inferência como MCMC [6] e Monte Carlo Sequencial [7]. O PyMC é uma biblioteca de código aberto para Python que permite construir modelos bayesianos completos, com suporte a algoritmos modernos de inferência. Desempenhando um papel significativo como incubadora para outras bibliotecas, facilitando o desenvolvimento de ferramentas especializadas, como o ArviZ, que surgiu como uma biblioteca focada para análise de modelos bayesianos [8]. Destaca-se também por sua facilidade de uso, tendo um desempenho otimizado com PyTensor e execução em GPU, além de oferecer recursos variados, como distribuições de probabilidade. Foram realizados testes com diferentes estruturas de redes bayesianas e simulações de inferência utilizando essa biblioteca. Essa etapa teve como objetivo validar e verificar o seu funcionamento. Para os testes, uma parte do modelo proposto inicialmente foi adaptado para a linguagem utilizada. Essa adaptação consistiu na tradução das variáveis e suas dependências para o formato do PyMC, respeitando suas relações de causalidade definidas no modelo original. Em seguida, a partir da interpretação das variáveis e de suas relações e dependências condicionais, a estrutura lógica da rede bayesiana foi adaptada e codificada, integrando-se à interface construída em Flask.

III. RESULTADOS E DISCUSSÃO

A construção do sistema especialista baseou-se na adaptação do modelo já mencionado anteriormente, representado por uma rede bayesiana. O modelo considera variáveis relevantes para a decisão de aplicação de fungicidas, tais como as

condições climáticas, o estágio de desenvolvimento da soja, a ocorrência de ferrugem asiática e a suscetibilidade do cultivar. Após a estruturação do sistema utilizando Flask e a modelagem probabilística com PyMC, foram realizados testes de inferência para simular diferentes cenários relacionados à aplicação de fungicidas. Essas simulações foram conduzidas com conjuntos variados de evidências, permitindo observar como a probabilidade de infecção por ferrugem asiática e a decisão pela aplicação do fungicida se comportavam conforme os valores das variáveis de entrada. Inicialmente, testes preliminares utilizaram amostras aleatórias geradas pelo algoritmo MCMC (`pm.sample(draws=4000, tune=2000, chains=2)`) para validar o modelo. Cada cadeia descartou as primeiras 2000 amostras (tuning), resultando em 8000 amostras úteis no total. Esses testes mostraram que a rede respondeu conforme as probabilidades definidas, com variáveis neutras, como Previsão do Tempo (PT), apresentando distribuições balanceadas. No PyMC, essas variáveis aleatórias são definidas a partir de distribuições probabilísticas e podem pertencer a um conjunto que compreende sete grupos, sendo: contínuas, discretas, multivariadas, misto, séries temporais, censurado, simulador, e distribuições simbólicas. Essa flexibilidade permite que o modelo represente de forma correta a variabilidade das variáveis, possibilitando a amostragem tanto das distribuições posteriores quanto das preditivas, facilitando a validação e simulação do sistema sem exigir qualquer intervenção do usuário [8]. Os gráficos apresentados ilustram a distribuição das variáveis

Fig. 1. Distribuição da variável D (Detecção).




Fonte: Elaborado pelo autor (2025).

resultantes das simulações da rede bayesiana. A Figura 1 mostra a frequência da variável Detecção (D), em que o eixo X representa as categorias possíveis da variável (presença ou ausência de detecção de ferrugem) e o eixo Y indica a quantidade de ocorrências simuladas, evidenciando os cenários em que a doença foi identificada ou não nas simulações. Já a Figura 2 apresenta a variável de decisão Aplicação de

Fungicida (A1), também com o eixo X indicando as categorias possíveis (aplicar ou não aplicar) e o eixo Y expressando a frequência das decisões inferidas pelo modelo. A relação entre os dois gráficos é direta, pois a ocorrência da ferrugem influencia significativamente a decisão de aplicação, visto que a rede bayesiana utiliza a variável de detecção como uma das principais evidências para calcular a necessidade do tratamento.


Fig. 2. Distribuição da variável A1 (Necessidade da Primeira Aplicação).



Fonte: Elaborado pelo autor (2025).

Após a validação do funcionamento da estrutura da rede com amostragens aleatórias, o modelo foi adaptado para entrada de evidências pelo usuário, com interface interativa em Flask, a fim de facilitar a interação com o sistema. As figuras 3, 4 e 5 ilustram a interface da aplicação, evidenciando sua estrutura e funcionalidades.

Fig. 3. Tela inicial da Interface da Aplicação.



Fonte: Elaborado pelo autor (2025).

A interface desenvolvida permitiu testar de forma prática a usabilidade do sistema, possibilitando que diferentes combinações de evidências fossem inseridas pelos usuários. Os testes práticos demonstraram que a rede ajusta a inferência final de acordo com diferentes cenários, respondendo de forma coerente às alterações nas evidências e confirmando a viabilidade do modelo implementado.

Apesar dos avanços alcançados, o sistema apresenta algumas limitações que precisam ser consideradas. Embora seja eficaz

Fig. 4. Tela de Coleta de Dados para Avaliação da Aplicação.

Fonte: Elaborado pelo autor (2025).

Fig. 5. Resultado da Análise após a Coleta de Dados.

Fonte: Elaborado pelo autor (2025).

em simular o conhecimento de especialistas e gerar inferências probabilísticas, ele depende fortemente de informações pré-existentes, refletindo eventuais lacunas ou vieses presentes no conhecimento codificado. A validação até o momento foi realizada apenas com amostras simuladas, sem testes em condições de campo, o que limita a comprovação da precisão em situações reais. Além disso, o sistema ainda não integra dados em tempo real, exigindo que as evidências sejam inseridas manualmente, e simplifica certas variáveis complexas do manejo agrícola, como a suscetibilidade de cultivares, o que pode impactar a exatidão das recomendações. A expansão do modelo também apresenta desafios, pois o acréscimo de variáveis pode aumentar significativamente a complexidade das tabelas de probabilidade condicional e o custo computacional. Por fim, por operar com probabilidades pré-definidas, o sistema não possui capacidade de aprendizado automático, permanecendo limitado à interpretação do conhecimento previamente codificado.

IV. CONCLUSÃO

O sistema mostrou-se eficaz como ferramenta de apoio à decisão em cenários de incerteza, como o manejo de fungicidas para a ferrugem asiática. A integração do modelo com uma interface interativa tornou a aplicação acessível a usuários sem conhecimento técnico aprofundado, permitindo testar diferentes cenários e evidências de forma prática. No entanto, é importante ressaltar que o sistema, por enquanto, não tem a pretensão de substituir o especialista e não deve ser aplicado em situações

reais. Seu objetivo principal é verificar se consegue representar com fidelidade o conhecimento do especialista.

Como trabalhos futuros, recomenda-se fortalecer a validação empírica, atualmente restrita a amostras aleatórias e cenários simulados, por meio de dados reais de campo ou de uma avaliação estruturada por especialistas. Além disso, seria útil detalhar métricas de desempenho para avaliar a utilidade do sistema em condições práticas, tais como: o tempo de resposta, para garantir aplicabilidade em situações operacionais; a confiabilidade das inferências, comparando as probabilidades calculadas com dados observados ou avaliações de especialistas; e os impactos econômico-ambientais, estimando custos de produção, desperdício de insumos e efeitos ambientais.

Por fim, a integração com bases de dados externas em tempo real, como previsões meteorológicas automatizadas, poderia aumentar a autonomia e a precisão do sistema, reforçando a importância de soluções inteligentes e adaptáveis para o setor agrícola e promovendo avanços no desenvolvimento de ferramentas digitais para tomada de decisão.

AGRADECIMENTOS

Aos meus pais, pelo amor e incentivo, e ao meu orientador, por sua valiosa orientação e dedicação, que tornaram possível a concretização deste trabalho, deixo aqui minha sincera gratidão.

REFERÊNCIAS

- [1] C. Daniel, G. Maturana, and E. H. M. Pena, "Utilizando aprendizado de máquina explicável para previsão de severidade de ferrugem asiática da soja," in *Anais do 14º Congresso Brasileiro de Agroinformática (SBLA-GRO)*. Natal/RN: Sociedade Brasileira de Computação, 2023, pp. 16–23.
- [2] D. T. Muhamediyeva, L. U. Safarova, and R. F. Ruzikulov, "Expert systems for diagnostics of infectious diseases in cattle," in *BIO Web of Conferences*, vol. 71, 2023, p. 01073. [Online]. Available: https://www.bio-conferences.org/articles/bioconf/abs/2023/16/bioconf_cibta2023_01073/bioconf_cibta2023_01073.html
- [3] G. Sottocornola, S. Baric, F. Stella, and M. Zanker, "Development of a knowledge-based expert system for diagnosing post-harvest diseases of apple," *Agriculture*, vol. 13, no. 1, p. 177, 2023. [Online]. Available: <https://www.mdpi.com/2077-0472/13/1/177>
- [4] H. J. Mayfield *et al.*, "Designing an expert-led bayesian network to understand interactions between policy instruments for adoption of eco-friendly farming practices," *Environmental Science and Policy*, vol. 141, pp. 11–22, Mar. 2023. [Online]. Available: <https://www.sciencedirect.com/science/article/abs/pii/S1462901122003872>
- [5] G. V. C. Figueiredo, "Modelo probabilístico bayesiano para simular o conhecimento de especialistas no controle da ferrugem asiática da soja no estado do paran ," Disserta  o (Mestrado em Computa  o Aplicada), Universidade Estadual de Ponta Grossa, Ponta Grossa, 2014.
- [6] W. K. Hastings, "Monte carlo sampling methods using markov chains and their applications," *Biometrika*, vol. 57, pp. 97–109, 1970.
- [7] N. Chopin and O. Papaspiliopoulos, *An introduction to sequential Monte Carlo*. Cham: Springer International Publishing, 2020.
- [8] O. Abril-Pla *et al.*, "Pymc: a modern, and comprehensive probabilistic programming framework in python," *PeerJ Computer Science*, vol. 9, no. 15, p. e1516, Sep. 2023. [Online]. Available: <https://peerj.com/articles/cs-1516/>