

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
CÂMPUS DE CHAPADÃO DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

GABRIELLA SILVA DE GREGORI

**MÉTODO DE DETECÇÃO DE SEVERIDADE DE ATAQUE E
CONTROLE MICROBIANO DE *GLYCASPIS BRIMBLECOMBEI*
(HEMIPTERA: APHALARIDAE) EM *EUCALYPTUS UROPHYLLA***

CHAPADÃO DO SUL – MS

2024

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
CÂMPUS DE CHAPADÃO DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

GABRIELLA SILVA DE GREGORI

**MÉTODO DE DETECÇÃO DE SEVERIDADE DE ATAQUE E
CONTROLE MICROBIANO DE *GLYCASPIS BRIMBLECOMBEI*
(HEMIPTERA: APHALARIDAE) EM *EUCALYPTUS UROPHYLLA***

Orientadora: Profa. Dra. Elisângela de Souza Loureiro

Co-orientador: Prof. Dr. Luis Gustavo Amorim Pessoa

Dissertação apresentada à Universidade Federal de Mato Grosso do Sul, como parte dos requisitos para obtenção do título de Mestre em Agronomia, área de concentração: Produção Vegetal.

CHAPADÃO DO SUL – MS

2024



Serviço Público Federal
Ministério da Educação
Fundação Universidade Federal de Mato Grosso do Sul



PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

CERTIFICADO DE APROVAÇÃO

DISCENTE: Gabriella Silva de Gregori

ORIENTADOR: Dra. Elisangela de Souza Loureiro

TÍTULO: Método de detecção de severidade de ataque e controle biológico de *Glycaspis brimblecombei* (Hemiptera: Aphalaridae) em *Eucalyptus urophylla*.

AVALIADORES:

Prof. Dra. Elisangela de Souza Loureiro

Prof. Dr. Gileno Brito de Azevedo

Prof. Dra. Nadia Cristina de Oliveira

Chapadão do Sul, 29 de outubro de 2024.

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Gileno Brito de Azevedo, Professor do Magistério Superior**, em 29/10/2024, às 16:36, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Elisangela de Souza Loureiro, Professora do Magistério Superior**, em 29/10/2024, às 16:36, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Nádia Cris na de Oliveira, Usuário Externo**, em 30/10/2024, às 09:00, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

AGRADECIMENTOS

Neste momento tão especial da minha vida, gostaria de expressar minha profunda gratidão a todos que contribuíram para a realização deste sonho.

Primeiramente, agradeço aos meus pais, Celso de Gregori e Neuza Teotônio da Silva, pelo amor incondicional e pelo apoio constante ao longo de toda a minha jornada. Vocês sempre foram minha fonte de motivação, e sem o incentivo de vocês, eu não estaria aqui hoje. Obrigada por acreditarem em mim e por me ensinarem a importância da perseverança.

Agradeço também às minhas irmãs, Priscilla Maria da Silva Liber Lopes e Ana Cristina Silva de Gregori, por estarem ao meu lado em cada passo dessa caminhada. Vocês foram minhas melhores amigas e minhas inspirações, sempre prontas para me apoiar e me auxiliar nos momentos mais desafiadores.

Um agradecimento especial ao meu namorado, Gabriel Augusto Teixeira Devolio, que foi meu porto seguro durante todo esse processo. Sua paciência, compreensão e amor foram fundamentais para que eu pudesse me dedicar aos meus estudos. Obrigada por sempre acreditar em mim e por me incentivar a buscar meus objetivos.

Não posso deixar de mencionar meus orientadores Profa. Dra. Elisângela de Souza Loureiro e Prof. Dr. Luis Gustavo Amorim Pessoa e ao grupo de estudos que fazemos parte o Laboratório de Manejo Integrado de Pragas-LAMIP. As trocas de ideias, as discussões e todo o apoio foram essenciais para o meu crescimento acadêmico e pessoal. Sou grata por cada momento compartilhado e pelo aprendizado que obtive junto a vocês.

Aos meus amigos, o meu mais sincero obrigado. Vocês foram fundamentais para manter meu ânimo durante os momentos desafiadores. As risadas, os momentos de descontração e o apoio emocional que recebi de vocês tornaram essa jornada muito mais leve e divertida. Obrigada por estarem sempre presentes e por acreditarem em mim.

Por fim, agradeço à Fundação Universidade Federal de Mato Grosso do Sul pela oportunidade de fazer parte desta instituição tão respeitada. Sou grata aos professores e colegas que contribuíram para a minha formação e me inspiraram a ir além dos meus limites. Cada aula, cada orientação e cada desafio enfrentado aqui foram fundamentais para a construção do meu conhecimento.

LISTA DE FIGURAS

- Figura 1.** Diferentes níveis de infestação por psilídeo de concha (*Glycaspis brimblecombei*) em folhas de eucalipto. (A)—controle; (B)—N1; (C)—N2; (D)—N3. 15
- Figura 2.** Curva hiperespectral para cada nível de ataque do psilídeo de concha (*Glycaspis brimblecombei*). Os itens “A”, “B”, “C” e “D” correspondem às regiões espectrais destacadas. 18
- Figura 3.** Interação significativa para a métrica de precisão da classificação correta (CC) entre os algoritmos de aprendizado de máquina (ML) e as entradas testadas. 19
- Figura 4.** Interação significativa para a métrica de precisão do score F entre os algoritmos de aprendizado de máquina (ML) e as entradas testadas. 20
- Figura 5.** Interação significativa para a métrica de precisão do coeficiente kappa entre os algoritmos de aprendizado de máquina (ML) e as entradas testadas. 21
- Figura 6.** Matriz de confusão para classificação da severidade do ataque de *G. brimblecombei* para os algoritmos RL (A) e MVS (B) utilizando as entradas ALL. 21

LISTA DE TABELAS

Tabela 1. Médias de viabilidade na fase de ovo de *Glycaspis brimblecombei* em folhas de *Eucalyptus urophylla* após aplicação do fungo *Cordyceps fumosorosea*.....**Erro! Indicador não definido.**

Tabela 2. Médias de mortalidade na fase de ninfa de *Glycaspis brimblecombei* em folhas de *Eucalyptus urophylla* após aplicação do fungo *Cordyceps fumosorosea*.....**Erro! Indicador não definido.**

Tabela 3. Eficiência (%) de controle de *Cordyceps fumosorosea* sobre as fases de ovo e ninfa de *Glycaspis brimblecombei*.**Erro! Indicador não definido.**

RESUMO: Este estudo abordou dois aspectos importantes do manejo do psilídeo de concha (*Glycaspis brimblecombei*), uma praga florestal que afeta significativamente as plantações de eucalipto. Onde, no primeiro capítulo, foi avaliado o impacto dos diferentes níveis de infestação de *G. brimblecombei* sobre a refletância hiperespectral das folhas de *Eucalyptus urophylla*. Tais refletâncias podem ser observadas devido alterações em pigmentos como a clorofila, que causadas pelo ataque da praga afetam o comportamento espectral das folhas. O equipamento FieldSpec 3 Jr. utilizado na leitura hiperespectral das folhas, onde. O equipamento captura os comprimentos de onda emitidos pela folha. Para classificar os níveis de ataque de forma rápida e precisa, foram testados algoritmos de aprendizado de máquina (ML), incluindo redes neurais artificiais (RNA), árvores de decisão (REPTree e J48), floresta aleatória (RF), máquina de vetor de suporte (MVS) e regressão logística (RL). Os resultados mostraram diferenças claras no comportamento hiperespectral das folhas em função dos níveis de ataque, classificados como: Controle (sem ataque do inseto), N1-baixa infestação, N2-infestação intermediária e N3-alta infestação, no qual o nível mais alto de infestação apresentou os valores de refletância mais elevados. Dos algoritmos testados, a regressão logística (RL) e a máquina de vetor de suporte (MVS) obtiveram os melhores resultados na classificação dos níveis de infestação, com acurácia superior a 90%. Ambos os algoritmos tiveram F-score próximo de 0,90 e valores de Kappa superiores a 0,8, garantindo alta precisão na classificação quando toda a faixa espectral foi utilizada como entrada. No segundo experimento, foi avaliada a eficácia do fungo entomopatogênico *Cordyceps* (= *Isaria*) *fumosorosea* no controle de *G. brimblecombei* em condições de laboratório. Folhas de *Eucalyptus urophylla* contendo ovos e ninfas do psilídeo foram pulverizadas com três soluções: controle (água destilada esterilizada), 0,5 L.ha⁻¹ e 1,0 L.ha⁻¹ de *C. fumosorosea*. As doses de 0,5 e 1,0 L.ha⁻¹ causaram 40 e 60% de mortalidade das ninfas após 24 horas, atingindo 100% de mortalidade em 48 horas. A extrusão do fungo foi observada em todos os cadáveres dos insetos pulverizados. A viabilidade dos ovos também foi afetada, com taxas de 64,3% para a dose de 0,5 L.ha⁻¹ e 95,2% para a dose de 1,0 L.ha⁻¹, respectivamente, após 120 horas. No grupo controle, os insetos permaneceram vivos por 10 dias, com uma viabilidade dos ovos de 100%. O fungo *C. fumosorosea* é eficiente para o controle dos ovos e ninfas de *G. brimblecombei*.

Palavra-chave: Aprendizado de máquina. Sensoriamento remoto. Monitoramento de pragas. Fungo entomopatogênico.

ABSTRACT: This study addressed two important aspects of managing the red gum lerp psyllid (*Glycaspis brimblecombei*), a forest pest significantly affecting eucalyptus plantations. In the first experiment, the impact of different infestation levels of *G. brimblecombei* on the hyperspectral reflectance of *Eucalyptus urophylla* leaves was evaluated. Chlorophyll alterations caused by pest attacks affect the spectral behavior of the leaves. To classify infestation levels quickly and accurately, machine learning (ML) algorithms were tested, including artificial neural networks (RNA), decision trees (REPTree and J48), random forest (RF), support vector machines (MVS), and logistic regression (RL). The results showed clear differences in the hyperspectral behavior of the leaves depending on infestation levels, with the highest infestation level showing the highest reflectance values. Of the algorithms tested, logistic regression (RL) and support vector machines (MVS) achieved the best results in classifying infestation levels, with accuracy above 90%. Both algorithms had F-scores close to 0.90 and Kappa values above 0.8, ensuring high classification precision when the entire spectral range was used as input. In the second experiment, the efficacy of the entomopathogenic fungus *Cordyceps* (= *Isaria*) *fumosorosea* in controlling adult *G. brimblecombei* was evaluated under laboratory conditions. Leaves of *Eucalyptus urophylla* containing eggs and nymphs psyllids were treated with three solutions: control (sterilized distilled water), 0.5 L.ha⁻¹, and 1.0 L.ha⁻¹ of *C. fumosorosea*. The 0.5 and 1.0 L.ha⁻¹ doses caused 40 and 60% nymph mortality after 24 hours, reaching 100% mortality in 48 hours. Fungal extrusion was observed in all treated insect cadavers. Egg viability was also affected, with rates of 64.3% for the 0.5 L.ha⁻¹ dose and 95.2% for the 1.0 L.ha⁻¹ dose, respectively, after 120 hours. In the control group, insects remained alive for 10 days, with 100% egg viability. The fungus *C. fumosorosea* is effective against the eggs and nymphs of *G. brimblecombei*.

Keywords: Machine learning. Remote sensing. Pest monitoring. Entomopathogenic fungus

SUMÁRIO

CAPÍTULO 1	10
Método de Detecção de Severidade de Ataque <i>Glycaspis brimblecombei</i> (Hemiptera: Aphalaridae) em <i>Eucalyptus urophylla</i>	10
Method for Detecting Severity of <i>Glycaspis brimblecombei</i> (Hemiptera: Aphalaridae) Attack on <i>Eucalyptus urophylla</i>	11
INTRODUÇÃO	12
MATERIAIS E MÉTODOS	14
Coleção de dados	14
Análises de aprendizado de máquina	16
Análise estatística	17
RESULTADOS	17
DISCUSSÃO	21
CONCLUSÕES	23
REFERENCIAS	24
CAPÍTULO 2	29
Controle biológico de <i>Glycaspis brimblecombei</i> (hemiptera: aphalaridae) em <i>Eucalyptus urophylla</i>	29
Biological control of <i>Glycaspis brimblecombei</i> (hemiptera: aphalaridae) in <i>Eucalyptus urophylla</i>	30
INTRODUÇÃO	31
MATERIAL E MÉTODOS	33
RESULTADOS E DISCUSSÃO	Erro! Indicador não definido.
CONCLUSÃO	33
REFERÊNCIA	33

CAPÍTULO 1

Método de Detecção de Severidade de Ataque *Glycaspis brimblecombei* (Hemiptera: Aphalaridae) em *Eucalyptus urophylla*

RESUMO: A avaliação de diferentes níveis de psilídeo de concha (*Glycaspis brimblecombei*) pode influenciar a refletância hiperespectral das folhas de diferentes maneiras devido a alterações na clorofila. Para classificar esses níveis, o uso de algoritmos de aprendizado de máquina (ML) pode ajudar a processar os dados com mais rapidez e precisão. Os objetivos foram: avaliar o comportamento espectral dos níveis de ataque de *G. brimblecombei*; encontrar o algoritmo de ML mais preciso para classificar os níveis de ataque de pragas; encontrar a configuração de entrada que melhore o desempenho dos algoritmos. Os dados foram coletados em uma plantação clonal de *Eucalyptus urophylla*. Após a obtenção dos comprimentos de onda, eles foram agrupados em médias representativas em 28 bandas. Os dados foram submetidos aos seguintes algoritmos de ML: redes neurais artificiais (RNA), árvores de decisão REPTree (DT) e J48, floresta aleatória (RF), máquina de vetor suporte (MVS) e análise de regressão logística convencional (RL). Houve diferenças no comportamento hiperespectral das folhas para os diferentes níveis de ataque. O nível de ataque mais alto mostra a maior distinção e os valores de refletância mais altos. RL e MVS apresentam melhor precisão na classificação dos níveis de gravidade do ataque de *G. brimblecombei*. Para o percentual de classificação correta, os algoritmos RL e MVS tiveram melhor desempenho, ambos com acurácia acima de 90%. Ambos os algoritmos obtiveram valores de F-score próximos de 0,90 e acima de 0,8 para Kappa. Toda a faixa espectral garantiu a melhor precisão para ambos os algoritmos.

Palavras-chave: monitoramento de pragas. inteligência artificial. máquina de vetor suporte. regressão logística. sensoriamento remoto.

Method for Detecting Severity of *Glycaspis brimblecombei* (Hemiptera: Aphalaridae) Attack on *Eucalyptus urophylla*

ABSTRACT: Assessing different levels of red gum lerp psyllid (*Glycaspis brimblecombei*) can influence the hyperspectral reflectance of leaves in different ways due to changes in chlorophyll. In order to classify these levels, the use of machine learning (ML) algorithms can help process the data faster and more accurately. The objectives were: to evaluate the spectral behavior of the *G. brimblecombei* attack levels; find the most accurate ML algorithm for classifying pest attack levels; find the input configuration that improves performance of the algorithms. Data were collected from a clonal *Eucalyptus urophylla*, for which leaf spectral reflectances were obtained using a spectroradiometer. After obtaining the wavelengths, they were grouped into representative interval means in 28 bands. Data were submitted to the following ML algorithms: artificial neural networks (RNA), REPTree (DT) and J48 decision trees, random forest (RF), support vector machine (MVS), and conventional logistic regression (RL) analysis. There were differences in the hyperspectral behavior of the leaves for the different attack levels. The highest attack level shows the greatest distinction and the highest reflectance values. RL and MVS show better accuracy in classifying the severity levels of *G. brimblecombei* attack. For the correct classification percentage, the RL and MVS algorithms performed better, both with accuracy above 90%. Both algorithms achieved F-score values close to 0.90 and above 0.8 for Kappa. The entire spectral range guaranteed the best accuracy for both algorithms.

Keywords: pest monitoring. artificial intelligence. support vector machine. logistic regression. remote sensing.

INTRODUÇÃO

O cultivo de eucalipto tem grande importância para a economia do país, pois é a primeira colocada no ranking de exportação do país, as áreas plantadas cresceram significativamente, atingindo cerca de 7,8 milhão de hectares em 2023. Já para o estado de Mato Grosso do Sul, estes plantios se acumularam em 1.3 milhão de hectares apenas de eucalipto, com previsões de se tornar a “Capital da Celulose” devido a tal avanço (Ibá, 2024)

O psilídeo de concha (*Glycaspis brimblecombei* More, 1964) é uma praga altamente invasiva em plantas de eucalipto. Agências internacionais como a Organização para a Alimentação e Agricultura (FAO) das Nações Unidas já relataram preocupações sobre este inseto (Ferreira-Filho et al., 2017; MRNAu et al., 2018; Reguia et al., 2013). Os adultos e ninfas do inseto se alimentam da seiva do floema das plantas, causando danos à árvore. Em casos de infestação severa, causa desfolha (de 20 a 30%), morte de brotos e galhos e, em casos extremos, morte de algumas espécies altamente suscetíveis, com taxas de mortalidade de 20 a 95% (Do Amaral Dal et al., 2011; Frederico et al., 2003; Gill, 1998; Huerta et al., 2010; Reguia et al., 2013; Wilcken et al., 2015; Wylie & Speight, 2012). Lima Vieira et al. (2018) relataram que a deformação e o amarelecimento das folhas também podem ocorrer em decorrência da redução da fotossíntese causada pela sucção e da presença das “conchas” que protegem as ninfas, podendo também aparecer o fungo fumagina, que aparece devido ao *honeydew*, substância formadora das conchas, por ser uma estrutura açucarada e úmida, favorece o crescimento deste fungo.

Pode haver variações na infestação por *G. brimblecombei* entre espécies de *Eucalyptus* e entre locais de cultivo, mostrando que há certa seletividade por parte dos insetos na escolha da espécie e sua intensidade de ataque (Jere et al., 2020), causando diferentes níveis de danos à planta. Em decorrência dos danos causados às folhas, a planta terá comportamento espectral diferente devido às alterações causadas, principalmente na clorofila, na estrutura e no teor de água celular interna, sendo possível monitorar ou mapear a resposta da planta aos estresses bióticos utilizando sensores (Sankaran et al., 2010, Escalante-Ramirez, 2012).

Pandey & Prabhakar (2017), realizaram análises de reflectância em plantas saudáveis e infestadas de cigarrinhas, que mostraram diferenças significativas nas regiões do infravermelho próximo (NIR) e visível (VIS). As plantas infestadas apresentam diminuição dos pigmentos, tornando promissor o uso de técnicas de sensoriamento

remoto, especialmente aquelas que utilizam sensores hiperespectrais, para mapear rapidamente os níveis de ataque de pragas (Johnson; Naiker, 2020). Furuya et al. (2021) propuseram uma abordagem usando modelos baseados em aprendizado de máquina profundo para detectar e separar plantas danificadas por *Spodoptera frugiperda* e *Dichelops melacanthus* em plantas de milho. Os autores relataram que as regiões espectrais que mais contribuem para a observação de ataques na planta, estão localizadas na faixa do infravermelho próximo e, em menor extensão, no vermelho, verde e azul, nessa ordem específica.

Outra aplicação dos sensores é quantificar danos causados por ácaros. Estudos sobre a incidência de ácaro-aranha em folhas de pimenta (*Capsicum RNAuum*), feijão comum (*Phaseolus vulgaris*) e algodão, utilizando dados hiperespectrais (400–1000 nm) e multiespectrais (cinco bandas), mostraram 100% e 95% de sucesso na identificação de danos precoces em pimenta e feijão, respectivamente, e 92% de sucesso em pimenta com dados multiespectrais. Além disso, o sensor óptico multiespectral conseguiu distinguir diferentes níveis de infestação de ácaros no início do ciclo da cultura do algodão (Mahlein et al., 2018). Desta forma, as decisões de gestão podem ser tomadas rapidamente devido à disponibilidade de informações (Ali et al., 2019). Apesar dos avanços tecnológicos nas práticas agrícolas, as técnicas de avaliação fenotípica no campo ainda são manuais e envolvem menos automação, sendo propensas a serem subjetivas (Sai Reddy; Neeraja, 2022).

Combinar o uso de dados hiperespectrais com técnicas de aprendizado de máquina pode ser uma abordagem promissora para analisar dados desta natureza (Furuya et al., 2021). As técnicas de aprendizado de máquina são altamente eficientes quando se trabalha com dados de alta dimensão obtidos de sensores, e classificações altas podem ser alcançadas mesmo quando os dados podem parecer visualmente muito semelhantes (Adelabu et al., 2014), como pode acontecer entre plantas saudáveis no início do estresse biótico. A identificação de regiões espectrais isoladas é uma característica importante a ser incorporada em estudos que visam avaliar diferentes comportamentos em plantas. A ideia principal é propor bandas espectrais mais diretas e claras para serem associadas ao respectivo problema (Furuya et al., 2021).

A avaliação de diferentes níveis de ataque de psilídeos pode influenciar a refletância hiperespectral das folhas de diferentes maneiras devido a alterações na clorofila. Nesse contexto, o uso do aprendizado de máquina pode auxiliar no processamento dos dados de forma a classificar esses níveis com mais rapidez e precisão.

Os objetivos deste estudo foram: (I) avaliar o comportamento espectral dos níveis de ataque do psilídeo de concha (*G. brimblecombei*); (II) encontrar a técnica de aprendizado de máquina mais precisa para classificar os níveis de ataque de pragas; (III) encontrar a base de dados de entrada para os algoritmos que melhorem seu desempenho.

MATERIAIS E MÉTODOS

Coleção de dados

Os dados foram coletados em um plantio clonal de eucalipto (clone AEC 0144 – *Eucalyptus urophylla*), com 10,3 meses de idade, cultivado no espaçamento de 3,0 m x 3,0 m na área experimental da Universidade Federal de Mato Grosso do Sul, Campus Chapadão do Sul (coordenadas 18°46'15,46"S e 52°37'26,60"W). O plantio foi realizado em covas com 20 cm de diâmetro e 60 cm de profundidade. Para melhorar a fertilidade do solo, a adubação básica consistiu de 100 g de super simples, 100 g de NPK 8-28-16 e 3 g de ácido bórico, que foram incorporados ao solo preenchendo a cova. O experimento conta com 197 árvores, com diâmetro médio na base do caule de 6,28 cm e altura média das plantas de 4,83 m. O controle de plantas daninhas foi realizado por meio de capinas num raio de 60 cm das mudas e com uso de cultivadores rotativos semimecanizados nas entrelinhas.

O solo do local é classificado como latossolo vermelho de textura média. Segundo a classificação de Köppen, o clima é tropical úmido (Aw), com estações bem definidas, uma chuvosa no verão e outra seca no inverno, precipitação média anual de 1850 mm e temperatura média anual variando de 13 a 28 °C.

As folhas foram coletadas na parte da manhã no terço apical das plantas de eucalipto, distribuídas aleatoriamente pela área, evitando bordas. As folhas foram armazenadas em recipientes de papel etiquetados para que as conchas não fossem removidas.

Foram coletadas quarenta folhas de eucalipto para cada nível de infestação por *G. brimblecombei* (Figura 1): controle (sem concha); N1: baixa infestação (média de 10 conchas/folha); N2: infestação intermediária (média de 20 conchas/folha); e N3: alta infestação média de 35 conchas/folha). As conchas foram quantificadas usando um microscópio estereoscópico com ampliação de 40x.

Foram realizadas 80 avaliações amostrais dentro de cada nível de severidade, nas quais as informações espectrais foram obtidas por meio de um espectrorradiômetro

(FieldSpec 3 Jr da Analytical Spectral Devices, Longmont, CO, EUA). Em cada folha foram feitas duas leituras na face adaxial nas áreas onde havia maior concentração de insetos abaxial à folha. A faixa de leitura é de 1,4 nm na faixa de 50 a 1.050 nm e 2 nm na faixa de 1.000 a 2.500 nm. Possui resolução espectral de 3 nm na faixa de 350 a 700 nm e 30 nm na faixa de 1400 a 2100 nm, obtida por meio de uma sonda vegetal ASD, projetada para realizar medições espectrais de contato em materiais sólidos. O equipamento foi calibrado utilizando uma placa branca de sulfato de bário que reflete 100% da luz.




Figura 1. Diferentes níveis de infestação por psilídeo de concha (*Glycaspis brimblecombei*) em folhas de eucalipto. (A)—controle; (B)—N1; (C)—N2; (D)—N3.

Uma vez obtidos os comprimentos de onda, eles foram agrupados em intervalos de bandas representativas conforme sugerido por Da Silva Junior et al. (2018) em que as bandas estão relacionadas a processos fisiológicos importantes para a planta, relacionados à resposta espectral. Como citado por Da Silva Junior et al. (2018), essas faixas são

divididas de B1 a B28, sendo utilizadas como médias representativas dentro de cada faixa: B1: 350 a 369; B2: 370; B3: 371–419; B4: 420; B5: 421–424; B6: 425; B7: 426–444; B8: 445–475; B9: 480; B10: 481–500; B11: 501–530; B12: 531–539; B13: 540; B14: 541–649; B15: 650; B16: 661–670; B17: 675; B18: 676–684; B19: 685–689; B20: 690–700; B21: 701–709; B22: 710; B23: 711–730; B24: 960; B25: 1100; B26: 1400; B27: 1930; e B28: 2200.

Análises de aprendizado de máquina

Os dados foram submetidos à análise de aprendizado de máquina (ML) utilizando os seguintes algoritmos: redes neurais artificiais (RNA), árvore de decisão J48 (J48), REPTree (DT), floresta aleatória (RF) e máquina de vetores de suporte (MVS). Uma análise de regressão logística (RL) foi utilizada como modelo de controle. Os parâmetros dos algoritmos foram definidos conforme configuração padrão do software Weka 3.8.5 (Bouckaert et al., 2010), exceto para RNA, onde foram definidos 10 neurônios na primeira camada e 10 neurônios na segunda camada. Weka é um software de código aberto que reúne diversos algoritmos de aprendizado de máquina para tarefas de mineração de dados. Torna possível lidar com diversas tarefas com dados como classificação, regressão, clustering, mineração de regras de associação e visualização.

A RNA treinada foi do tipo perceptron multicamadas o qual foi utilizado o algoritmo de retropropagação com taxa de aprendizado igual a 0,3, momento igual a 0,2 e número de épocas igual a 500. J48 é um algoritmo classificador que usa uma etapa de poda adicional baseada em uma estratégia de redução de erros (Snousy et al., 2011). Para o algoritmo J48, o parâmetro adotado para o número mínimo de instâncias permitidas em um nó folha foi 4 e foi utilizada uma poda. REPTree (DT) é uma lógica de árvore de decisão que seleciona a melhor árvore usando ganho de informação e realiza poda de redução de erros como critério de divisão. O padrão do Weka para o algoritmo DT não usa restrição para profundidade de árvore e um peso total mínimo das instâncias em uma folha igual para 2,0. O algoritmo RF cria diversas árvores de predição e usa um esquema de votação entre todas as árvores aprendidas para prever novos valores (Belgiu; Drăgu, 2016). Para o algoritmo RF, o número de árvores geradas foi 100, o número de slots de execução a serem utilizados para a construção do conjunto foi igual a 1 e os demais hiperparâmetros foram ajustados usando configurações padrão. MVS realiza tarefas de classificação construindo hiperplanos no espaço multidimensional para distinguir diferentes classes (Rajvanshi; Chowdhary, 2017). A análise MVS foi realizada utilizando

a Biblioteca LibMVS (Chang; Lin, 2011) do Weka, adotando a configuração padrão do software, em que o tipo de kernel é função de base radial, o grau do kernel é igual a 3,0, tolerância do critério de terminação (eps) é $1,0 \times 10^{-4}$ e o parâmetro de custo é igual a 1,0.

Foram testadas duas configurações de entrada: utilizando apenas comprimentos de onda (ALL, 350–2500 nm) e utilizando bandas espectrais (SB, B1–B28), formadas pela refletância média da faixa espectral de cada banda, totalizando 28 bandas, buscando determinar a entrada que classifica os níveis de ataque com maior precisão. A variável de saída foram os níveis de gravidade do ataque de *G. brimblecombei*. A classificação foi realizada por meio de validação cruzada estratificada com $k\text{-fold} = 10$ e 10 repetições (totalizando 100 corridas).

Análise estatística

Para avaliar a precisão da classificação dos algoritmos, foram estimados o percentual de classificações corretas (CC), o escore F e o coeficiente kappa. Em seguida, foi realizada análise de variância, adotando-se delineamento inteiramente casualizado (DIC). Para o DIC foram considerados modelos de aprendizado de máquina (RNAs, J48, REPTree, RF e MVS) mais regressão logística (RL) aplicados às duas configurações de entrada. Para agrupamento das médias do CC e do escore F, adotou-se o teste de Scott-Knott a 5% de probabilidade. Posteriormente, foram gerados gráficos boxplot para os parâmetros de precisão (CC, F-score e kappa) para cada variável de saída e configuração de entrada. Posteriormente, foi construída uma matriz de confusão contendo os valores de classificação corretos para cada classe na diagonal principal e os erros fora da diagonal. O software Rbio versão 162 (Bhering, 2017) e os pacotes ExpDes.pt e ggplot2 do software R versão 4.1.0 (Ohmomo et al., 2022) foram utilizados para todas as análises estatísticas.

RESULTADOS

As curvas espectrais formadas pelas folhas de eucalipto para cada nível de severidade do ataque de *G. brimblecombei* foram diferentes. Na faixa de 350–700 nm, que corresponde à faixa visível (Figura 2A), há maior distinção entre o nível de controle e a curva N3; as curvas N1 e N2 são muito próximas e semelhantes nesta faixa em termos de refletância. Na faixa de 700–1300 nm, NIR, (Figura 2B) há uma distinção mais clara

entre as curvas N3 e N2, com um fator de refletância mais alto para a curva N3. N1 e controle estão próximos e possuem fator de refletância menor que as demais curvas.





Figura 2. Curva hiperespectral para cada nível de ataque do psíldeo de concha (*Glycaspis brimblecombei*). Os itens “A”, “B”, “C” e “D” correspondem às regiões espectrais destacadas.

Na faixa SWIR 1300–2500, o nível de severidade N3 apresenta maior distinção e maior refletância que os demais. Na Figura 2C, há maior proximidade entre N1 e o controle, enquanto na Figura 2D, a maior proximidade está entre as curvas N2 e N1. O nível de controle apresenta baixa refletância em toda a faixa espectral, enquanto o nível de severidade mais alto (N3) apresenta refletância mais alta.

Com a possibilidade de distinguir a gravidade do ataque de *G. brimblecombei*, os dados foram submetidos à análise de ML por meio de classificação. Para a métrica de acurácia da classificação correta (CC), quando a entrada utilizada foi toda a informação da faixa espectral avaliada, os algoritmos RL e MVS obtiveram o melhor desempenho de classificação. Quando a entrada testada foi SB, os algoritmos RL e RNA obtiveram o melhor desempenho de classificação.


Comparando ambas as entradas dentro de cada algoritmo da RNA, SB fornece um melhor desempenho para este algoritmo do que ALL. Os outros algoritmos apresentam melhor desempenho usando ALL como entrada do que SB (Figura 3). Assim, podemos sugerir que, mesmo na ausência de equipamentos como o FieldSpec 3 Jr., que realiza leituras multiespectrais, ainda é possível obter resultados satisfatórios utilizando RNA, considerando que o SB se destaca em análises banda a banda.



Médias seguidas pelas mesmas letras maiúsculas para as diferentes entradas e pelas mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste de Scott-Knott a 5% de probabilidade

Figura 3. Interação significativa para a métrica de precisão da classificação correta (CC) entre os algoritmos de aprendizado de máquina (ML) e as entradas testadas.


Quando ALL é usado como entrada, RL mostra os melhores resultados para a métrica de precisão do score F (Figura 4). Quando SB é utilizado, a RNA apresenta melhores resultados. Comparando as duas entradas dentro de cada técnica de ML, a RNA apresenta melhor precisão do que o SB. DT, J48 e RF não apresentam diferença de desempenho entre as entradas. RL e MVS apresentam melhores resultados quando a entrada utilizada é ALL.



Médias seguidas pelas mesmas letras maiúsculas para as diferentes entradas e pelas mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste de Scott-Knott a 5% de probabilidade.

Figura 4. Interação significativa para a métrica de precisão do escore F entre os algoritmos de aprendizado de máquina (ML) e as entradas testadas.

RL e MVS apresentam melhor precisão quando ALL é usado como entrada (Figura 5). RNA e RL apresentam melhores resultados quando SB é usado como entrada. Ao comparar as entradas dentro de cada algoritmo, todos os algoritmos, exceto RNA, apresentam melhor desempenho quando ALL é usado.



Médias seguidas pelas mesmas letras maiúsculas para as diferentes entradas e pelas mesmas letras minúsculas para os diferentes algoritmos de ML não diferem pelo teste de Scott-Knott a 5% de probabilidade.

Figura 5. Interação significativa para a métrica de precisão do coeficiente kappa entre os algoritmos de aprendizado de máquina (ML) e as entradas testadas.

No geral, os algoritmos RL e MVS apresentam os melhores resultados para as três métricas de precisão testadas, principalmente quando se utiliza a entrada ALL, que utiliza todas as informações fornecidas na faixa espectral avaliada. A Figura 6 mostra a matriz de confusão para os melhores algoritmos, RL e MVS, utilizando todas as informações espectrais como entrada do modelo. Valores com tons roxos escuros mostram o número de classificações corretas obtidas para cada cluster, enquanto tons rosas mais claros mostram a taxa de erro para a melhor configuração de cada algoritmo.




Figura 6. Matriz de confusão para classificação da severidade do ataque de *G. brimblecombei* para os algoritmos RL (A) e MVS (B) utilizando as entradas ALL.

DISCUSSÃO

Danos à planta que afetam fisiologicamente a clorofila ou o conteúdo de água ou causam danos às células interferem na resposta espectral da planta (Semeraro et al., 2019). Dessa forma, a resposta espectral muda de acordo com o estresse que a planta está sofrendo, seja por déficit hídrico, doença ou ataque de insetos (AbduRLidha et al., 2020). Plantas saudáveis refletem menos na faixa visível de 400 a 700 nm, devido à alta absorção desses comprimentos de onda pelos pigmentos fotossintetizantes. A curva espectral das folhas saudáveis refletiu menos nesta faixa (Figura 2A), o que não ocorreu com as plantas danificadas por *G. brimblecombei*. À medida que o dano aumentou, a refletância aumentou, ou seja, alterações na refletância foliar causadas por danos causados pelo ataque de pragas provocam uma diminuição nos pigmentos fotossintetizantes, alteram o conteúdo interno de água da planta e danificam a estrutura celular (Sankaran et al., 2010),

fazendo com que suas folhas reflitam mais. Conjuntos de dados hiperespectrais fornecem condições particularmente benéficas para aprendizado de máquina e aprendizado profundo devido à grande quantidade de dados, recursos complexos e relacionamentos desconhecidos (Mahlein et al., 2018).

Quando a planta sofre algum estresse, geralmente é caracterizada por uma maior refletância na região visível (400–700 nm) como resultado da menor concentração de pigmento (Liu et al., 2018). É comum que quando a planta sofre estresse biótico haja uma menor refletância nas regiões do infravermelho próximo (NIR, 700–1300 nm) e SWIR devido a alterações na parede celular, que se torna mais fina, e mais espaços de ar ocorrem na estrutura interna da folha (Liu et al., 2018). Porém, cada estresse biótico que a planta pode sofrer desencadeia reações diferentes, alterando a cor e a rugosidade da superfície foliar de diferentes maneiras, o que, por sua vez, influencia a radiação absorvida, transmitida ou refletida por ela. Em superfícies rugosas, o dano faz com que o feixe de luz reflita em valores mais elevados devido ao ângulo formado pelo feixe refletido no comprimento de onda (Zahir et al., 2022), o que explica a maior refletância na banda NIR em folhas com níveis de N2 e N3 de *G. brimblecombei* infestação.

Uma vez distinguida a refletância das folhas de acordo com o nível de severidade do ataque de *G. brimblecombei*, os dados foram submetidos à análise de ML na tentativa de garantir que os algoritmos alcançassem precisão satisfatória na distinção dos níveis. Os algoritmos que apresentaram melhor desempenho foram RL e MVS utilizando todas as informações da faixa espectral avaliadas como entrada. O uso de técnicas de ML tem sido proposto para contornar e resolver questões complexas na agricultura no que diz respeito à previsão e classificação de múltiplas variáveis (Christodoulou et al., 2019), especialmente ao tentar relacionar essas variáveis com informações espectrais.

O uso de sensores hiperespectrais pode fornecer uma grande quantidade de informações relevantes em toda a faixa espectral, permitindo uma melhor compreensão das características avaliadas (Ravikanth et al., 2016). Huang et al. (2017) relataram que o MVS é altamente eficaz e preciso na classificação de ataques bióticos às plantas. Além disso, a combinação de características espectrais com algoritmos de ML alcança altos níveis de precisão na diferenciação dos diferentes ataques bióticos que as plantas podem sofrer (Zhao et al., 2022). Esse algoritmo mostrou sensibilidade e precisão na detecção de doenças nos estágios iniciais do ataque, mesmo sem sinal físico, e seu desempenho foi aumentado com o uso de dados hiperespectrais (Khairunniza-Bejo et al., 2021). Além disso, os valores de refletância em diferentes comprimentos de onda garantem mais

informações para os algoritmos, melhorando seu desempenho. A detecção hiperespectral permite a detecção de estresses abióticos e bióticos, o que abre novas oportunidades para o manejo de pragas e doenças e fenotipagem de campo (Mahlein et al., 2018)

O uso de todas as informações disponíveis no sensor também proporcionou melhor desempenho para algoritmos como RNA e MVS na classificação de genótipos de soja quanto ao teor de óleo e proteína no grão (Santana et al., 2023). As redes neurais artificiais apresentaram bons resultados quando o SB foi utilizado como entrada do algoritmo. Assim, uma quantidade reduzida de informações para este algoritmo pode fornecer alta precisão (Khairunniza-Bejo et al., 2021). Abordagens poderosas de manipulação e análise de dados, como processamento de sinais, visão computacional, reconhecimento de padrões, aprendizado de máquina e mineração de dados, são tecnologias associadas que ajudam a implementar métodos modernos para a agricultura (Mahlein et al., 2018).

Este estudo traz uma abordagem inédita e preliminar sobre o comportamento espectral de plantas de eucalipto sob diferentes níveis de severidade de infestação por *G. brimblecombei*. Essas informações podem ser utilizadas como input para treinar algoritmos de aprendizado de máquina para identificar rapidamente o início da infestação e monitorar seu progresso, uma vez que tem o hábito de atacar as folhas mais novas, que ficam na parte mais externa da copa das plantas, associadas ao tamanho que o eucalipto pode atingir, o que pode facilitar a utilização desta técnica de amostragem e, conseqüentemente, pode permitir a adoção precoce de estratégias de controle. Tais algoritmos podem ser integrados em sistemas que envolvam o uso de sensoriamento remoto, ampliando as aplicações e benefícios desta abordagem. Este quadro integrado pode otimizar a recolha de dados e a análise remota, permitindo obter estimativas precisas sobre a gravidade da infestação, proporcionando uma base sólida e rápida para a tomada de decisões, o que contribui para aumentar o rendimento das plantações florestais. Pensar sobre RL- se ele é tradicional inviabiliza a utilização das demais técnicas?

CONCLUSÕES

O comportamento hiperespectral dos níveis de ataque do psilídeo de concha (*Glycaspis brimblecombei*) mostra diferenças entre plantas saudáveis, enquanto o nível um mostra comportamento semelhante. O nível de ataque mais alto apresenta a maior e mais clara diferença de refletância dos demais, possibilitando distinguir os níveis de ataque.

A regressão logística e a máquina de vetores de suporte apresentaram melhor precisão na classificação dos níveis de severidade do ataque de *G. brimblecombei*. Para a métrica classificação correta, os algoritmos RL e MVS tiveram melhor desempenho, ambos com precisão acima de 90. Ambos os algoritmos alcançaram valores de f-score próximos de 0,90 e para kappa, acima de 0,87–0,89. Toda a faixa espectral garantiu a melhor precisão para ambos os algoritmos.

REFERÊNCIAS

AbduRLidha, J.; Ampatzidis, Y.; Roberts, P.; Kakarla, S.C. Detecting Powdery Mildew Disease in Squash at Different Stages Using UAV-Based Hyperspectral Imaging and Artificial Intelligence. *Biosyst. Eng.* **2020**, *197*, 135–148.

Adelabu, S.; Mutanga, O.; Adam, E. Evaluating the Impact of Red-Edge Band from Rapideye Image for Classifying Insect Defoliation Levels. *ISPRS J. Photogramm. Remote Sens.* **2014**, *95*, 34–41.

Al Snousy, M.B.; El-Deeb, H.M.; Badran, K.; Al Khilil, I.A. Suite of Decision Tree-Based Classification Algorithms on Cancer Gene Expression Data. *Egypt. Inform. J.* **2011**, *12*, 73–82.

Ali, M.M.; Bachik, N.A.; Muhadi, N.; Yusof, T.N.T.; Gomes, C. Non-Destructive Techniques of Detecting Plant Diseases: A Review. *Physiol. Mol. Plant Pathol.* **2019**, *108*, 101426.

Belgiu, M.; Drăguț, L. Random Forest in Remote Sensing: A Review of Applications and Future Directions. *ISPRS J. Photogramm. Remote Sens.* **2016**, *114*, 24–31.

Bhering, L.L. Rbio: A Tool for Biometric and Statistical Analysis Using the R Platform. *Crop Breed. Appl. Biotechnol.* **2017**, *17*, 187–190.

Bouckaert, R.R.; Frank, E.; Hall, M.A.; Holmes, G.; Pfahringer, B.; ReutemRNA, P.; Witten, I.H. WEKA—Experiences with a Java Open-Source Project. *J. Mach. Learn. Res.* **2010**, *11*, 2533–2541.

Chang, C.C.; Lin, C.-J. LIBMVS: A Library for Support Vector Machines. *ACM Trans. Intell. Syst. Technol.* **2001**, *2*, 1–27.

Christodoulou, E.; Ma, J.; Collins, G.S.; Steyerberg, E.W.; Verbakel, J.Y.; Van Calster, B. A Systematic Review Shows No Performance Benefit of Machine Learning over Logistic Regression for Clinical Prediction Models. *J. Clin. Epidemiol.* **2019**, *110*, 12–22.

da Silva Junior, C.A.; NRNAi, M.R.; Shakir, M.; Teodoro, P.E.; de Oliveira-Júnior, J.F.; Cezar, E.; de Gois, G.; Lima, M.; Wojciechowski, J.C.; Shiratsuchi, L.S. Soybean Varieties Discrimination Using Non-Imaging Hyperspectral Sensor. *Infrared Phys. Technol.* **2018**, *89*, 338–350.

de Lima Vieira, R.; Pessoa, L.G.A.; de Souza Loureiro, E.; Poersh, N.L. Ocorrência de *Glycaspis Brimblecombei* Sobre *Eucalyptus* Em Chapadão Do Sul, Mato Grosso Do Sul. *Rev. Agric. Neotrop.* **2018**, *5*, 91–93.

do Amaral Dal, M.H.F.; Wilcken, C.F.; Gimenes, M.J.; de Souza Christovam, R.; Prado, E.P. Control of Red-Gum Lerp Psyllid with Formulated Mycoinsecticides under Semi-Field Conditions. *Int. J. Trop. Insect. Sci.* **2011**, *31*, 85–91.

Escalante-Ramirez, B. *Remote Sensing-Applications*; IntechOpen: Rijeka, Croatia, 2012; ISBN 9535106511.

Ferreira-Filho, P.J.; Wilcken, C.F.; Masson, M.V.; de Souza Tavares, W.; Guerreiro, J.C.; Do Carmo, J.B.; Prado, E.P.; Zanuncio, J.C. Influence of Temperature and Rainfall on the Population Dynamics of *Glycaspis Brimblecombei* and *Psyllaephagus Bliteus* in *Eucalyptus Camaldulensis* Plantations. *Rev. Colomb. Entomol.* **2017**, *43*, 1–6.

Fuentes, A.H.; Faúndez, M.; Araya, J.E. Susceptibility of *Eucalyptus* Spp. to an Induced Infestation of Red Gum Lerp Psyllid *Glycaspis Brimblecombei* Moore (Hemiptera: Psyllidae) in Santiago, Chile. *Cienc. Investig. Agrar. Rev. Latinoam. Cienc. Agric.* **2010**, *37*, 27–33.

Furuya, D.E.G.; Ma, L.; Pinheiro, M.M.F.; Gomes, F.D.G.; Gonçalves, W.N.; Junior, J.M.; de Castro Rodrigues, D.; Blassioli-Moraes, M.C.; Michereff, M.F.F.; Borges, M.; et al. Prediction of Insect-Herbivory-Damage and Insect-Type Attack in Maize Plants Using Hyperspectral Data. *Int. J. Appl. Earth Obs. Geoinf.* **2021**, *105*, 102608.

Gava, R.; Santana, D.C.; Cotrim, M.F.; Rossi, F.S.; Teodoro, L.P.R.; da Silva Junior, C.A.; Teodoro, P.E. Soybean Cultivars Identification Using Remotely Sensed Image and Machine Learning Models. *Sustainability* **2022**, *14*, 7125.

Gill, R.J. New State Record: Redgum Lerp Psyllid, *Glycaspis Brimblecombei*. *Calif. Plant Pest Dis. Rep.* **1998**, *17*, 7–8.

Huang, L.; Liu, W.; Huang, W.; Zhao, J.; Song, F. Remote Sensing Monitoring of Winter Wheat Powdery Mildew Based on Wavelet Analysis and Support Vector Machine. *Trans. Chin. Soc. Agric. Eng.* **2017**, *33*, 188–195.

IBÁ 2024 RELATÓRIO ANUAL. Instituto Brasileiro de Árvores, 2024. Disponível em: <https://www.iba.org/relatorio2024.pdf>. Acessado em 08 de outubro de 2024.

Jere, V.; Mhango, J.; Njera, D.; Jenya, H. Infestation of *Glycaspis Brimblecombei* (Hemiptera: Psyllidae) on Three Eucalyptus Species in Selected Ecological Zones in Malawi. *Afr. J. Ecol.* **2020**, *58*, 251–259.

Johnson, J.B.; Naiker, M. Seeing Red: A Review of the Use of near-Infrared Spectroscopy (NIRS) in Entomology. *Appl. Spectrosc. Rev.* **2020**, *55*, 810–839.

Khairunniza-Bejo, S.; Shahibullah, M.S.; Azmi, A.N.N.; Jahari, M. Non-Destructive Detection of Asymptomatic *Ganoderma boninense* Infection of Oil Palm Seedlings Using NIR-Hyperspectral Data and Support Vector Machine. *Appl. Sci.* **2021**, *11*, 10878.

Liu, Z.-Y.; Qi, J.-G.; Wang, N.-N.; Zhu, Z.-R.; Luo, J.; Liu, L.-J.; Tang, J.; Cheng, J.-A. Hyperspectral Discrimination of Foliar Biotic Damages in Rice Using Principal Component Analysis and Probabilistic Neural Network. *Precis. Agric.* **2018**, *19*, 973–991.

Mahlein, A.-K.; Kuska, M.T.; BehmRNA, J.; Polder, G.; Walter, A. Hyperspectral Sensors and Imaging Technologies in Phytopathology: State of the Art. *RNAu. Rev. Phytopathol.* **2018**, *56*, 535–558.

MRNAu, R.; Buffa, F.; Pinna, C.; Deiana, V.; Satta, A.; Floris, I. Preliminary Results on the Spatio-Temporal Variability of *Glycaspis Brimblecombei* (Hemiptera Psyllidae)

Populations from a Three-Year Monitoring Program in Sardinia (Italy). *Redia* **2018**, *101*, 107–114.

Moreira, M.A. *Fundamentos Do Sensoriamento Remoto e Metodologias de Aplicação*, 3rd ed.; UFV: Viçosa, Brazil, 2005.

Pandey, P.; Prabhakar, R. An Analysis of Machine Learning Techniques (J48 & AdaBoost)-for Classification. In Proceedings of the 2016 1st India International Conference on Information Processing (IICIP), Delhi, India, 12–14 August 2016; pp. 1–6.

R Core Team. *R: A Language and Environment for Statistical Computing*; R Foundation for Statistical Computing: Vienna, Austria, 2013; pp. 275–286.

Rajvanshi, N.; Chowdhary, K.R. Comparison of MVS and Naïve Bayes Text Classification Algorithms Using WEKA. *Int. J. Eng. Res.* **2017**, *6*, 141–143.

Ravikanth, L.; Jayas, D.S.; White, N.D.G.; Fields, P.G.; Sun, D.-W. Extraction of Spectral Information from Hyperspectral Data and Application of Hyperspectral Imaging for Food and Agricultural Products. *Food Bioprocess Technol.* **2017**, *10*, 1–33.

Reguia, K.; Peris-Felipo, F.J. *Glycaspis Brimblecombei* Moore, 1964 (Hemiptera Psyllidae) Invasion and New Records in the Mediterranean Area. *Biodivers. J.* **2013**, *4*, 501–506.

Sai Reddy, B.; Neeraja, S. Plant Leaf Disease Classification and Damage Detection System Using Deep Learning Models. *Multimed. Tools Appl.* **2022**, *81*, 24021–24040.

Sankaran, S.; Mishra, A.; Ehsani, R.; Davis, C. A Review of Advanced Techniques for Detecting Plant Diseases. *Comput. Electron. Agric.* **2010**, *72*, 1–13.

Santana, D.C.; Teodoro, L.P.R.; Baio, F.H.R.; dos Santos, R.G.; Coradi, P.C.; Biduski, B.; da Silva Junior, C.A.; Teodoro, P.E.; Shiratsuchi, L.S. Classification of Soybean Genotypes for Industrial Traits Using UAV Multispectral Imagery and Machine Learning. *Remote Sens. Appl.* **2023**, *29*, 100919.

Semeraro, T.; Mastroleo, G.; Pomes, A.; Luvisi, A.; Gissi, E.; Aretano, R. Modelling Fuzzy Combination of Remote Sensing Vegetation Index for Durum Wheat Crop Analysis. *Comput. Electron. Agric.* **2019**, *156*, 684–692.

Wilcken, C.F.; do Couto, E.B.; Orlato, C.; Ferreira-Filho, P.J.; Firmino, D.C. Ocorrência Do Psilídeo-de-Concha (*Glycaspis Brimblecombei*) Em Florestas de Eucalipto No Brasil. *Circ. Téc. IPEF* **2003**, *201*, 1–11.

Wilcken, C.F.; Firmino-Winckler, D.C.; Dal Pogetto, M.; Dias, T.K.R.; Lima, A.C.V.; de SÁ, L.A.N.; Ferreira Filho, P.J. Psilídeo-de-Concha-Do-Eucalipto, *Glycaspis Brimblecombei* Moore. In *Pragas Introduzidas No Brasil: Insetos e Ácaros*; FEALQ: Piracicaba, Brazil, 2015; pp. 883–897.

Wylie, F.R.; Speight, M.R. *Insect Pests in Tropical Forestry*; CABI: Wallingford, UK, 2012; ISBN 1845936361.

Zahir, S.A.D.M.; Omar, A.F.; Jamlos, M.F.; Azmi, M.A.M.; Muncan, J. A Review of Visible and Near-Infrared (Vis-NIR) Spectroscopy Application in Plant Stress Detection. *Sens. Actuators A Phys.* **2022**, *338*, 113468.

Zhao, X.; Zhang, J.; Huang, Y.; Tian, Y.; Yuan, L. Detection and Discrimination of Disease and Insect Stress of Tea Plants Using Hyperspectral Imaging Combined with Wavelet Analysis. *Comput. Electron. Agric.* **2022**, *193*, 106717.

CAPÍTULO 2

Controle microbiano de *Glycaspis brimblecombei* (Hemiptera: Aphalaridae) em *Eucalyptus urophylla*

RESUMO: O psilídeo de concha *Glycaspis brimblecombei*, uma praga florestal originária da Austrália, tem causado danos significativos às plantações de eucalipto nos últimos anos. Este estudo avaliou a eficácia do fungo entomopatogênico *Cordyceps* (= *Isaria*) *fumosorosea* no controle de ovos e ninfas do psilídeo em laboratório. Folhas de *Eucalyptus urophylla* (clone AEC 0144) contendo ovos e ninfas no interior das conchas de *G. brimblecombei* foram coletadas e pulverizadas com três soluções: T0- controle (água destilada esterelizada), T1-0,5 L ha⁻¹ e T2-1,0 L ha⁻¹ de *C. fumosorosea*, utilizando-se Torre de Potter, ajustada a pressão de 15 libras.pol⁻², sendo aplicados 3 mL em cada folha contendo 10 ninfas e 10 ovos. Após a aplicação, as placas de Petri foram mantidas em câmara climatizada a 25 ± 1 °C, UR 70 ± 10% e fotofase de 12 horas. O delineamento experimental foi inteiramente casualizado composto por 3 tratamentos e 5 repetições por tratamento, totalizando 150 ninfas e 150 ovos. A avaliação foi diária, calculando-se a mortalidade diária acumulada e mortalidade corrigida pela fórmula de Abbott. As doses de 0,5 e 1,0 L.ha⁻¹ causaram 40 e 60% de mortalidade, respectivamente, para ninfas após 24 horas, atingindo 100% de mortalidade em 48 horas. Observou-se a extrusão do fungo em todos os cadáveres. A viabilidade dos ovos foi de 64,3% na dose de 0,5 L.ha⁻¹ e 95,2% na dose de 1,0 L.ha⁻¹ após 120 horas, enquanto no controle os insetos permaneceram vivos por 10 dias e a viabilidade dos ovos foi de 100%. O fungo *C. fumosorosea* é eficiente para os ovos e ninfas de *G. brimblecombei*.

Palavras-chave: Psilídeo de concha. Monitoramento de pragas. Controle biológico. Fungo entomopatogênico.

**Microbial control of *Glycaspis brimblecombei* (Hemiptera: Aphalaridae) in
*Eucalyptus urophylla***

ABSTRACT: The red gum lerp psyllid *Glycaspis brimblecombei*, a forest pest native to Australia, has caused significant damage to *eucalyptus* plantations in recent years. This study evaluated the effectiveness of the entomopathogenic fungus *Cordyceps* (= *Isaria*) *fumosorosea* in controlling psyllid eggs and nymphs in the laboratory. Leaves of *Eucalyptus urophylla* (clone AEC 0144) containing eggs and nymphs within the lerps *G. brimblecombei* were collected and sprayed with three solutions: T0 - control (sterilized distilled water), T1 - 0.5 L ha⁻¹, and T2 - 1.0 L ha⁻¹ of *C. fumosorosea*, using a Potter Tower set to a pressure of 15 pounds per square inch, with 3 mL applied to each leaf containing 10 nymphs and 10 eggs. After application, the Petri dishes were kept in a climate-controlled chamber at 25 ± 1 °C, RH 70 ± 10%, and a photoperiod of 12 hours. The experimental design was completely randomized, consisting of 3 treatments and 5 replicates per treatment, totaling 150 nymphs and 150 eggs. Daily assessments were conducted, calculating the cumulative daily mortality and corrected mortality using Abbott's formula. The doses of 0.5 and 1.0 L ha⁻¹ caused 40% and 60% mortality, respectively, for nymphs after 24 hours, reaching 100% mortality within 48 hours. Fungus extrusion was observed in all cadavers. Egg viability was 64.3% at the 0.5 L ha⁻¹ dose and 95.2% at the 1.0 L ha⁻¹ dose after 120 hours, while in the control group, the insects remained alive for 10 days, and egg viability was 100%. The fungus *C. fumosorosea* is effective against the eggs and nymphs of *G. brimblecombei*.

Keywords: Red gum lerp psyllid. Pest monitoring. Biological control. Entomopathogenic fungus.

INTRODUÇÃO

As áreas de plantio de eucalipto (*Eucalyptus* sp.) vêm sendo expandidas gradativamente ao longo dos anos seja pela rentabilidade ou pela variabilidade de subprodutos gerados a partir da madeira (Rodrigues et al., 2021). O estado de Mato Grosso do Sul tem desempenhado um papel de destaque no cenário nacional, se consolidando como um dos maiores produtores de florestas plantadas do Brasil com mais de 1,4 milhão de hectares de florestas plantadas (SEMADESC, 2024). Sabe-se que esta produtividade está ligada a fatores genéticos seja pela resistência a clima, quantidade de lignina, dentre outras; e ambientais, onde encontramos as mais variadas ocorrências de fatores causadores de dano, escassez hídrica, nutrição, qualidade da muda, pragas e outras (Ibá, 2024).

O *Glycaspis brimblecombei* Moore, 1964 (Hemiptera: Aphalaridae), popularmente conhecido como psílideo de concha, é uma espécie nativa da Austrália (Kolar et al., 2021), tendo o início de sua propagação no Brasil por volta do ano de 2003 (Wilcken et al., 2003). *G. brimblecombei* ataca o eucalipto através da sua alimentação, que ocorre preferencialmente nas partes jovens das plantas, como folhas e brotos. A inserção do aparato bucal na planta resulta na extração de seiva trazendo grandes danos a planta a longo prazo (Dal-Pogetto et al., 2022). Este processo de alimentação compromete a capacidade fotossintética da planta, afetando seu vigor, redução da qualidade da madeira, secamento de ponteiros e conseqüentemente a diminuição no crescimento das árvores (Wilcken et al., 2015).

O ataque contínuo por *G. brimblecombei* pode levar a um enfraquecimento estrutural das árvores, tornando-as mais suscetíveis a outras doenças e pragas, além de trazer consigo danos secundários, onde, junto as excreções do inseto, conhecidas como “*honeydew*”, cria-se um ambiente propício para o crescimento de fungos como a fumagina, que cobrem as folhas e reduzem ainda mais a eficiência fotossintética (Queiroz, et al., 2021; Barcik et al., 2023).

Nos últimos anos *G. brimblecombei* tem se tornado uma preocupação significativa para a indústria do eucalipto em muitas regiões do mundo. Com o aumento das mudanças climáticas e o expressivo aumento nas áreas plantadas de *Eucalyptus*, as condições para a expansão e proliferação dessa praga podem ser ampliadas. O Manejo Integrado de Pragas (MIP), que combina práticas culturais, biológicas e químicas, onde permite uma abordagem mais eficaz para mitigar os impactos do *G. brimblecombei*. Além disso, a

pesquisa contínua e o monitoramento das populações de psilídeos são essenciais para antecipar futuros surtos (Domingues et al., 2022).

Com o aumento das práticas de manejo sustentável e aumento da aplicação de bioinseticidas, o fungo entomopatogênico *Cordyceps* (= *Isaria*) *fumosorosea* (Hypocreales: Cordycipitaceae), conhecido por sua capacidade de controle de pragas, como psilídeo asiático do citrus, *Diaphorina citri* (Hemiptera: Liviidae) (Conceschi et al., 2024), a mosca-branca *Bemisia tabaci* (Gennadius) Biotype B (Hemiptera: Aleyrodidae) (Boaventura et al., 2021) e cigarrinha do milho, *Dalbulus maidis* (Hemiptera: Cicadellidae) (Duarte et al., 2024), é uma possível tática no manejo de *G. brimblecombei*.

A diversidade de espécies do gênero *Cordyceps* é maior em regiões subtropicais e tropicais (Zou et al., 2022; Wang et al., 2023). O ciclo de vida deste fungo é complexo, várias enzimas são produzidas (Lopes et al., 2023), inicia-se quando os conídios germinam, entram em contato com o exoesqueleto do inseto hospedeiro, geralmente por meio de contato direto ou através da deposição dos conídios no ambiente, esses conídios germinam, penetram no corpo do inseto, colonizando internamente, levando-o à morte (Qasim et al., 2020; Saldanha, 2022).

Os fungos entomopatogênicos podem ser utilizados em conjunto com outros agentes de controle biológico de *G. brimblecombei*, como o predador *Chrysoperla externa* (Neuroptera: Chrysopidae) e o parasitoides *Psyllaephagus bliteus* (Hymenoptera: Encyrtidae) (Santos et al., 2021), para um manejo mais eficiente e com um período de ação maior quando comparado ao químico. O uso de agentes biológicos, como o *C. fumosorosea*, vem sendo aplicado devido ao aumento da procura por práticas agrícolas sustentáveis e à necessidade de diminuir o impacto ambiental dos produtos fitossanitários químicos (Rojas et al., 2023).

As projeções para o futuro apontam para um crescimento significativo na utilização de agentes biológicos no controle de pragas, pois oferecem uma maneira eficaz e sustentável de combater as pragas, reduzindo o risco de seleção de indivíduos resistentes em comparação com os produtos fitossanitários químicos. Nesse sentido, a pesquisa teve como objetivo verificar a eficiência de controle do fungo entomopatogênico *C. fumosorosea* sobre ovos e ninfas de *G. brimblecombei*, em condições de laboratório.

MATERIAL E MÉTODOS

Por se tratar de Propriedade Intelectual e Inovação Tecnológica não serão apresentados os seguintes itens: Material e Métodos, Resultados e Discussão.

CONCLUSÃO

A aplicação do fungo entomopatogênico demonstra ser efetivo para ovos e ninfas de *Glycaspis brimblecombei*, proporcionado 100% de eficiência para ninfas com as conchas dois dias após a aplicação. Quanto à viabilidade dos embriões, a maior dosagem resultou em 95,2% de eficiência de controle cinco dias após a aplicação.

REFERÊNCIA

ABBOTT, W. S. A method of computing the effectiveness of an insecticide. *Journal of Economic Entomology*, v. 18, n. 2, p. 265-267, 1925. <https://doi.org/10.1093/jee/18.2.265a>.

ANGEL-CUAPIO, A., FIGUEROA-MONTERO, A., FAVELA-TORRES, E., VINIEGRA-GONZÁLEZ, G., PERRAUD-GAIME, I., LOERA, O. Critical values of porosity in rice cultures of *Isaria fumosorosea* by adding water hyacinth: effect on conidial yields and quality. *Appl Biochem Biotechnol* 177:446–457, 2015. <https://doi.org/10.1007/s12010-015-1754-4>

BARCIK, L. Z.; DE CAMARGO, M. B.; GARRETT, A. T. A.; GARCIA, F. A. O.; UKAN, D. Flutuação populacional de *Glycaspis brimblecombei* mais em híbridos de *Eucalyptus camaldulensis* x *E. grandis* na região Sul do Brasil. *OBSERVATÓRIO DE LA ECONOMÍA LATINOAMERICANA*, v. 21, n. 9, p. 11880-11894, 2023. DOI: 10.55905/oelv21n9-074.

BOAVENTURA, H.A., QUINTELA, E.D., SANTOS, E.N., SILVA, J.F.A.; HUMBER, R.A. Susceptibility of all nymphal stages of *Bemisia tabaci* Biotype B (Hemiptera: Aleyrodidae) to three Brazilian isolates of *Cordyceps* sp. (Hypocreales: Cordycipitaceae) in a greenhouse under variable temperature and moisture conditions. *Neotropical Entomology*, v. 50, n. 1, p. 100-113, 2021. <https://doi.org/10.1007/s13744-020-00823-5>.

CONCESCHI, M. R.; IWANICKI, N. S.; MORAL, R. A.; D'ALESSANDRO, C. P.; DELALIBERA JUNIOR, I. Improvement of the entomopathogenic fungus *Cordyceps javanica* efficacy against *Diaphorina citri* (Hemiptera: Liviidae) under ultraviolet-B radiation and lower relative air humidity provided by oil formulations. *BioControl*, v. 1. p. 1-12. <https://doi.org/10.1007/s10526-024-10278-x>

DAL-POGETTO, M.H.F.A., TAVARES, W.S., ZANUNCIO, J.C., SILVA, W.M., MASSON, M.V., FERREIRA-FILHO, P.J., BARBOSA, L.R. and WILCKEN, C.F., 2022. High population levels lead *Glycaspis brimblecombei* (Hemiptera: Aphalaridae) to unrecorded feeding and oviposition behaviors on *Eucalyptus urograndis* plants. *Brazilian Journal of Biology*, v. 84, p. e250931. <http://dx.doi.org/10.1590/1519-6984.250931>.

DOMINGUES; M. M.; SANTOS; P. L.; GÊA; B. C. C.; CARVALHO, V. R.; OLIVEIRA, F. N.; SOLIMAN, E. P.; SILVA, W. M.; ZANUNCIO, J. C.; SANTOS JUNIOR, V. C.; WILCKEN, C. F. Isolation and molecular characterization of *Cordyceps* sp. from *Bemisia tabaci* (Hemiptera: Aleyrodidae) and pathogenic to *Glycaspis brimblecombei* (Hemiptera: Aphalaridae). *Brazilian Journal of Biology*, v. 84, e253028, 2024. <https://doi.org/10.1590/1519-6984.253028>

DOMINGUES, M. M.; SANTOS, P. L.; GÊA, B. C. C.; CARVALHO, V. R.; OLIVEIRA, F. N.; SOLIMAN, E. P.; SERRÃO, J. E.; ZANUNCIO, J. C.; ZANETTI, R.; WILCKEN, C. F. Entomopathogenic Fungi, Isolated From Soils and *Bemisia tabaci* (Hemiptera: Aleyrodidae) Adults, to Manage the *Eucalyptus* Red Gum Lerp Psyllid *Glycaspis brimblecombei* (Hemiptera: Aphalaridae). *Journal of Economic Entomology*, v. 115, n. 6, p. 1886-1893, 2022. <https://doi.org/10.1093/jee/toac165>

DUARTE, E. R; PEÑA, G. D.; SIQUEIRA, F. S. N.; SILVA, M. H.; SILVA, M. A. A. MANEJO DA CIGARRINHA DO MILHO (*DALBULUS MAIDIS*) UTILIZANDO ÓLEO DE NEEM ASSOCIADO AOS FUNGOS ENTOMOPATOGÊNICOS *BEAUVERIA BASSIANA* E *ISARIA FUMOSOROSEA*. *RECIMA21 - Revista Científica Multidisciplinar - ISSN 2675-6218*, [S. l.], v. 5, n. 7, p. e575523, 2024. DOI: 10.47820/recima21.v5i7.5523.

HAJEK, A. E., DAVIS C. I., EASTBURN, C. C., VERMEYLEN, F. M. Deposition and germination of conidia of the entomopathogen *Entomophaga maimaiga* infecting larvae of gypsy moth, *Lymantria dispar*. J Invertebr Pathol. 79(1):37-43, 2002. doi: 10.1016/S0022-2011(02)00010-1. PMID: 12054785.

IBÁ. Instituto Brasileiro de Árvores. RELATÓRIO ANUAL. Disponível em: <https://www.iba.org/relatorio2024.pdf>. Acessado em 08 de outubro de 2024.

KOLAR, A., HLEBEC, D., DOLINA, K., FRANJEVIĆ, M. and KUČINIĆ, M., 2021. First DNA barcoding of a new alien species *Glycaspis brimblecombei* Moore, 1964 (Hemiptera: Aphalaridae) in Croatia with a distribution note. *Ecologica Montenegrina*, v. 43, p. 59-68. <http://dx.doi.org/10.37828/em.2021.43.9>.

LIN, R., ZHANG, X., XIN, B., ZOU, M., GAO, Y., QIN, F., HU, Q., XIE, B.; CHENG, X., 2019. Genome sequence of *Isaria javanica* and comparative genome analysis insights into family S53 peptidase evolution in fungal entomopathogens. *Applied Microbiology and Biotechnology*, v. 103, n. 17, p. 7111-7128. <http://dx.doi.org/10.1007/s00253-019-09997-4>. PMid:31273397

LI, Y., P. ZHAO, S. LIU, Z. DONG, J. CHEN, Z. XIANG, E Q. XIA. A novel protease inhibitor in *Bombyx mori* is involved in defense against *Beauveria bassiana*. *Insect Biochemistry and Molecular Biology*, v. 42, p. 766-775, 2012.

LOPES, R. B.; SOUZA, D. A.; INGLIS, P. W.; FARIA, M. Diversity of anamorphic *Cordyceps* (formerly *Isaria*) isolated from Brazilian agricultural sites. *Journal Invertebrate Pathology*, v. 200, p. 107956, 2023.

LOUREIRO, E.S.; MOINO JÚNIOR, A. Consumption of *Aphis gossypii* Glover, 1877 and *Myzus persicae* (Sulzer, 1776) infected with entomopathogenic fungi by *Orius insidiosus* (Say, 1832) (Hemiptera, Anthocoridae). *Arquivos do Instituto Biológico*, v. 75, p. 497-504, 2008.

MASCARIN, G. M., LOPES, R. B., DELALIBERA, I., FERNANDES, E. K. K., LUZ, C., FARIA, M. Current status and perspectives of fungal entomopathogens used for microbial control of arthropod pests in Brazil. *Journal Invertebrate Pathology*, v. 165, p. 46-53, 2019. <https://doi.org/10.1016/j.jip.2018.01.001>

ORDAZ-HERNÁNDEZ, A.; MONTESINOS-MATÍAS, A. R.; MELLÍN-ROSAS, M. A. PÉREZ-AGUIRRE, T.; LOERA, O.; ANGEL-CUAPIO, A. Improvement of the production and quality of *Cordyceps javanica* conidia for the control of *Diaphorina citri* adults. *World Journal of Microbiology and Biotechnology*, v. 40, p. 115, 2024. <https://doi.org/10.1007/s11274-024-03922-2>

PACHECO, C. Mortalidade de *Diaphorina citri* em resposta à *Isaria fumosorosea*: um estudo de diferentes funções de ligação em modelos para dose-resposta dicotômica. *Sigmae*, v. 13, n. 2, p. 118-127, 2024.

PORTO, N. S.; GARCIA, E. Q. Efeito de doses do fungo *Beauveria bassiana* no controle populacional de *Euschistus heros* (Hemiptera: Pentatomidae). *Cerrado Agrociências*, v. 13, p. 75-82, 2022.

QASIM, M., S.; U. ISLAM, W.; ISLAM, A.; NOMAN, K. A.; KHAN, M.; HAFEEZ, D.; HUSSAIN, C. K.; DASH, B. S.; BAMISILE, K. S. Characterization of mycotoxins from entomopathogenic fungi (*Cordyceps fumosorosea*) and their toxic effects to the development of asian citrus psyllid reared on healthy and diseased citrus plants. *Toxicon*. 188: 39-47, 2020.

QUEIROZ, D. L.; SOLIMAN, E. P.; BURCKHARDT, D. *Blastopsylla occidentalis* e *Ctenarytaina* spp. In: LEMES, P. G.; ZANUNCIO, J. C. (ed.). *Novo manual de pragas florestais brasileiras*. Montes Claros: Universidade Federal de Minas Gerais, Instituto de Ciências Agrárias, p. 794-816, 2021.

RODRIGUES, G. S. S. C.; ROSS; J. L. S.; TEIXEIRA; G.; SANTIAGO, O. R. P. L.; FRANCO, C. *Eucalipto no Brasil: expansão geográfica e impactos ambientais*. Comoser: Uberlândia, 178 p., 2021.

ROJAS, V. M. A.; IWANICKI, N. S., D'ALESSANDRO, C. P.; FATORETTO, M. B.; DEMÉTRIO, C. G. B., DELALIBERA JÚNIOR, I. Characterization of Brazilian *Cordyceps fumosorosea* isolates: Conidial production, tolerance to ultraviolet-B radiation, and elevated temperature. *Journal of Invertebrate Pathology*, v. 197, p. 107888, 2023. <https://doi.org/10.1016/j.jip.2023.107888>.

SALDANHA, M. A.; COSTA, E. C.; MUNIZ, M. F. B.; QUEVEDO, A. C.; SARZI, J. S. Caracterização morfofisiológica de fungos entomopatogênicos. *Acta Biológica Catarinense*, [S. l.], v. 9, n. 1, p. 87–96, 2022. DOI: 10.21726/abc.v9i1.1705. Disponível em: <https://periodicos.univille.br/ABC/article/view/1705>.

SANTOS, F. A., CORREA, A. S., NANINI, F., NASCIMENTO, D. A., JUNQUEIRA, L. R.; WILCKEN, C. F. Genetic diversity of *Glycaspis brimblecombei* (Hemiptera: Aphalaridae) and its parasitoid *Psyllaephagus bliteus* (Hymenoptera: Encyrtidae) in Brazil. *Brazilian Journal of Biology*, v. 81, n. 3, p. 838-841, 2021. <http://dx.doi.org/10.1590/1519-6984.230486>.

SEMADESC. Secretaria de Meio Ambiente, Desenvolvimento, Ciência, Tecnologia e Inovação. MS é reconhecido como Vale da Celulose em evento nacional da cadeia produtiva florestal. 2024. <https://www.semadesc.ms.gov.br/ms-e-reconhecido-como-vale-da-celulose-em-evento-nacional-da-cadeia-produtiva-florestal>. Acesso 10 de outubro de 2024.

TIAN, J.; DIAO, H.; LIANG, LI.; ARTHURS, S.; MA, R. Pathogenicity of *Isaria fumosorosea* to *Bemisia tabaci*, with some observations on the fungal infection process and host immune response. *Journal of Invertebrate Pathology*, v. 130, p. 147-153, 2015.

VESTERGAARD, S.; GILLESPIE, A.T.; BUTT, T.M.; SCHREITER, G.; EILENBERG, J. Pathogenicity of the Hyphomycete fungi *Verticillium lecanii* and *Metarhizium anisopliae* to the western thrips, *Frankliniella occidentalis*. *Biocontrol Science and Technology*, v.5, p.185-192, 1995.

WANG, X.; XU, J.; WANG, X.; QIU, B.; WU, J.; ALI, S. *Isaria fumosorosea*-based zero-valent iron nanoparticles affect the growth and survival of sweet potato whitefly, *Bemisia tabaci* (Gennadius). *Pest Management Science*, v. 75, n.8, p. 2174-2181, 2019. <http://dx.doi.org/10.1002/ps.5340>.

WANG, Y.; DONG, Q.-Y.; LUO, R.; FAN, Q.; DUAN, D.-E.; DAO, V.-M.; WANG, Y.-B.; YU, H. Molecular Phylogeny and Morphology Reveal Cryptic Species in the *Cordyceps militaris* Complex from Vietnam. *Journal Fungi*, v. 9, p. 676, 2023. <https://doi.org/10.3390/jof9060676>

WILCKEN, C. F.; E. B. COUTO; C. ORLATO; P. J. FERREIRA-FILHO & D. C. FIRMINO. Ocorrência do psilídeo-de-concha (*Glycaspis brimblecombei*) (Hemiptera: Psyllidae) em florestas de eucalipto no Brasil. Circular Técnica – IPEF 201: 1–11, 2003.

WILCKEN, C. F.; FIRMINO-W INCKLER, D. C.; DAL POGETTO, M. H. F. A.; DIAS, T. K. R.; LIMA, A. C. V.; SÁ, L. A. N. DE; FERREIRA FILHO, P. J. Psilídeo-de-concha-do-eucalipto, *Glycaspis brimblecombei* Moore. VILELA FILHO, E.; ZUCCHI, RA Pragas introduzidas no Brasil: insetos e ácaros. Piracicaba: FEALQ, p. 883-897, 2015.

WU, J., YANG, B., XU, J., CUTHBERTSON, A.G. and ALI, S. Characterization and toxicity of crude toxins produced by *Cordyceps fumosorosea* against *Bemisia tabaci* (Gennadius) and *Aphis craccivora* (Koch). *Toxins*, v. 13, n. 3, p. 220, 2021. <http://dx.doi.org/10.3390/toxins13030220>.

XIONG, Q.; Y. XIE, Y. ZHU, J. XUE; J. LI, E R. FAN. Morphological and ultrastructural characterization of *Carposina sasakii* larvae (Lepidoptera: Carposinidae) infected by *Beauveria bassiana* (Ascomycota: Hypocreales: Clavicipitaceae). *Micron*. 44: 303-311, 2013.

ZOU, W.Q.; TANG, D.X.; XU, Z.H.; HUANG, O.; WANG, Y.B.; TRAN, N.-L.; YU, H. Multigene phylogeny and morphology reveal *Ophiocordyceps hydrangea* sp. nov. and *Ophiocordyceps bidoupensis* sp. nov. (Ophiocordycipitaceae). *MycKeys*, v. 92, p. 109-130, 2022.