

**SISTEMA DE AERONAVE REMOTAMENTE PILOTADA
PARA DISTRIBUIÇÃO DE CÁPSULAS DE
INIMIGOS NATURAIS**

ROMÁRIO VARGAS GARCIA

**UNIVERSIDADE ESTADUAL DO NORTE FLUMINENSE
DARCY RIBEIRO**

**CAMPOS DOS GOYTACAZES – RJ
MARÇO – 2020**

**SISTEMA DE AERONAVE REMOTAMENTE PILOTADA
PARA DISTRIBUIÇÃO DE CÁPSULAS DE
INIMIGOS NATURAIS**

ROMÁRIO VARGAS GARCIA

Dissertação apresentada ao Centro de Ciências e
Tecnologias Agropecuárias da Universidade
Estadual do Norte Fluminense Darcy Ribeiro,
como parte das exigências para obtenção do título
de Mestre em Produção Vegetal

Orientador: Prof. Ricardo Ferreira Garcia

CAMPOS DOS GOYTACAZES – RJ
MARÇO – 2020

FICHA CATALOGRÁFICA

UENF - Bibliotecas

Elaborada com os dados fornecidos pelo autor.

G216 Garcia, Romário Vargas.

Sistema de aeronave remotamente pilotada para distribuição de cápsulas de inimigos naturais / Romário Vargas Garcia. - Campos dos Goytacazes, RJ, 2020.

50 f. : il.

Bibliografia: 33 - 37.

Dissertação (Mestrado em Produção Vegetal) - Universidade Estadual do Norte Fluminense Darcy Ribeiro, Centro de Ciências e Tecnologias Agropecuárias, 2020.
Orientador: Ricardo Ferreira Garcia.

1. Precisão. 2. Aeronave. 3. Automatização. 4. Distribuição. 5. Parasitoide. I. Universidade Estadual do Norte Fluminense Darcy Ribeiro. II. Título.

CDD - 630

SISTEMA DE AERONAVE REMOTAMENTE PILOTADA
PARA DISTRIBUIÇÃO DE CÁPSULAS DE
INIMIGOS NATURAIS

ROMÁRIO VARGAS GARCIA

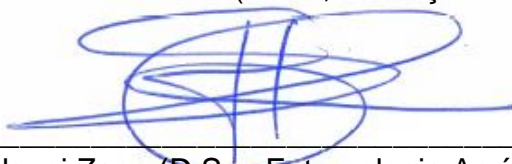
Dissertação apresentada ao Centro de Ciências e
Tecnologias Agropecuárias da Universidade
Estadual do Norte Fluminense Darcy Ribeiro,
como parte das exigências para obtenção do título
de Mestre em Produção Vegetal

Aprovada em 03 de março de 2020.

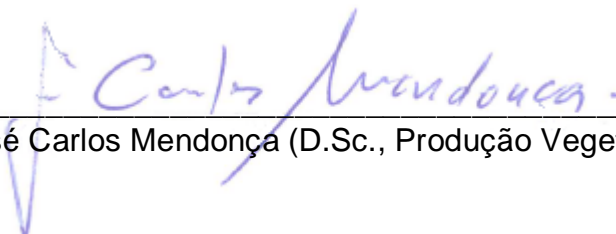
Comissão Examinadora:



Prof. Elias Fernandes de Sousa (D.Sc., Produção Vegetal) – UENF



Prof. Hugo Bolsoni Zago (D.Sc., Entomologia Agrícola) – UFES



Prof. José Carlos Mendonça (D.Sc., Produção Vegetal) – UENF



Prof. Ricardo Ferreira Garcia (D.Sc., Engenharia Agrícola) – UENF
(Orientador)

Dedico aos meus pais, Maria José Vargas
Garcia e José Francisco Vial Garcia.
In memoriam de meu Irmão Roberto Vargas
Garcia.
A minha Esposa Ariane Cardoso Costa.

AGRADECIMENTOS

Agradeço a Deus pela saúde, paz e ânimo para continuar meu caminho.

Agradeço à Universidade Estadual do Norte Fluminense Darcy Ribeiro, ao Programa de Pós-Graduação em Produção Vegetal pela oportunidade de obter esta titulação e ao Laboratório de Engenharia Agrícola (LEAG).

Agradeço ao meu Pai José e minha Mãe Maria, por todo apoio e incentivo que me deram em toda vida.

A minha esposa Ariane Cardoso Costa, pelo companheirismo, compreensão, dedicação, paciência e amor incondicional.

Ao professor Ricardo Ferreira Garcia por toda orientação, e apoio no projeto.

Ao professor Hugo Bolsoni Zago, por todo apoio na minha vida acadêmica, amizade e aprendizado.

Ao professor José Carlos Mendonça, por todo esforço e empenho na coleta de dados de vento, e contribuições neste trabalho.

Ao professor Elias Fernandes de Sousa, por todas as sugestões oferecidas neste trabalho.

Ao CNPq, pela concessão da bolsa de mestrado, a qual foi fundamental para obtenção desse título.

Não importa o que a vida fez de você,
importa o que você fez do que a vida fez de você
Sartre

SUMÁRIO

SUMÁRIO.....	v
RESUMO.....	vii
ABSTRACT	ix
1. INTRODUÇÃO	1
2. OBJETIVOS	3
2.1 Objetivo geral	3
2.2 Objetivo específico	3
3. REVISÃO DE LITERATURA	4
3.1 Aeronave remotamente pilotada.....	4
3.2 Classificação de RPAS	7
3.3 Componentes básicos de um RPAS	8
3.4 RPAS na agricultura de precisão.....	9
3.5 Controle biológico de pragas	13
3.6 Redes Neurais	15
4. MATERIAL E MÉTODOS	17
4.1 Localização.....	17
4.2 Desenvolvimento do sistema de aeronave remotamente pilotada	17
4.3 Construção do dispositivo de liberação de cápsulas	18
4.4 Avaliação do desempenho do RPAS e distribuição de cápsulas	19
4.5 Modelo preditivo para distribuição das cápsulas utilizando rede neural	21

5. RESULTADOS E DISCUSSÃO.....	23
5.1 Avaliação do RPAS durante a distribuição das cápsulas	23
5.2 Modelo preditivo para distribuição das cápsulas utilizando rede neural	25
6. RESUMO E CONCLUSÕES	32
7. REFERÊNCIAS BIBLIOGRÁFICAS	34

RESUMO

GARCIA, Romário Vargas, M.Sc., Universidade Estadual do Norte Fluminense Darcy Ribeiro, 03 março de 2020. Sistema de aeronave remotamente pilotada para distribuição de cápsulas de inimigos naturais. Orientador: Prof. Ricardo Ferreira Garcia.

O uso de sistemas de aeronaves remotamente pilotadas (RPAS) popularizou-se na agricultura. Os RPAS são uma alternativa para tornar o controle biológico mais competitivo, pois maximiza operações de distribuição dos inimigos naturais. De 2017 a 2018, o controle biológico de pragas cresceu 15% no Brasil e foi utilizado em 23 milhões de hectares em 2019. Os RPAS necessitam de ajustes para obter maior precisão em campo. Desta forma, modelos preditivos podem calcular qual a melhor rota para distribuir os inimigos naturais em campo, com base em dados climáticos de vento e posição espacial do RPAS. O objetivo do estudo foi avaliar o desempenho de um RPAS em campo e elaborar um modelo preditivo para distribuição de cápsulas utilizando redes neurais artificiais. Para avaliar o desempenho do RPAS, foram realizados voos automatizados com diferentes velocidades de 2,0 m/s, 3,5 m/s, 5,0 m/s, 6,5 m/s e 8,0 m/s, e diferentes alturas de 6,0 m, 12,0 m, 18,0 m e 24,0 m. O RPAS liberou as cápsulas em alvos com coordenadas geográficas pré-estabelecidas, e para planejamento das missões de voo, utilizou-se o software Mission Planner. Após a liberação, as distâncias entre a aterrissagem das cápsulas e o alvo foram aferidas no sentido de deslocamento

do RPAS (distância y), e no sentido perpendicular ao deslocamento (distância x). Para treinamento da rede neural, utilizaram-se as variáveis: velocidade do RPAS, altura do RPAS, velocidade e direção do vento, sendo realizadas 80 missões em diferentes alturas e velocidades. Para evitar sobreposição entre pontos e outros problemas, os resultados do desempenho do RPAS sugerem utilizar a velocidade de 5,54 m/s quando estiver voando à altura de 6 m, 4,4 m/s à 12 m, 3,44 m/s à 18 metros, e 2,63 m/s à 24 m. O modelo de rede neural mostrou que é possível prever com precisão onde as cápsulas irão aterrissar, quando submetidas a ação do vento, em diferentes alturas e velocidades de deslocamento.

ABSTRACT

GARCIA, Romário Vargas, M.Sc., Northern Fluminense State University Darcy Ribeiro, 02 March, 2020. Remotely piloted aircraft system for distributing capsules from natural enemies. Advisor: Prof. Ricardo Ferreira Garcia.

The use of remotely piloted aircraft systems (RPAS) has become popular in agriculture. RPAS are an alternative to make biological control more competitive, as it maximizes distribution operations for natural enemies. From 2017 to 2018, biological pest control grew by 15% in Brazil and it was used on 23 million hectares in 2019. RPAS need adjustments to obtain greater precision in the field. Therefore, predictive models can be used to calculate which is the best route to distribute natural enemies in the field, based on climatic data of wind and spatial position of the RPAS. The objective of the study was to evaluate the performance of an RPAS in the field, and to develop a predictive model for the distribution of capsules using artificial neural networks. To assess the performance of the RPAS, automated flights were performed at different speeds 2.0 m/s, 3.5 m/s, 5.0 m/s, 6.5 m/s and 8.0 m/s and different heights 6.0 m, 12.0 m, 18.0 m, 24.0 m. The RPAS released the capsules on targets with pre-established geographic coordinates for planning the flight missions, it was used the Mission Planner software. After the release, the distances between the landing of the capsules and the target were measured in the direction of displacement of the RPAS (distance y), and in the

direction perpendicular to the displacement (distance x). For training the neural network, the variables used were RPAS speed, RPAS height, wind speed and wind direction and 80 missions were carried out at different heights and speeds. To avoid overlap between points and other problems, the results of the RPAS performance suggested to use the speed of 5.54 m/s when flying at a height of 6 m, 4.4 m/s at 12 m, 3.44 m/s at 18 m and 2.63 m/s at 24 m. The neural network model showed that it is possible to accurately predict where the capsules will land, when subjected to the action of the wind, at different heights and speeds of the RPAS.

1. INTRODUÇÃO

Os sistemas de aeronaves remotamente pilotadas (RPAS - Remotely Piloted Aircraft System), mais conhecidos como drones, foram desenvolvidos inicialmente com objetivos militares, visando operações aéreas que oferecem riscos à vida humana (Eisenbeiss, 2004).

Os RPAS estão ganhando espaço na agricultura, em especial na obtenção de dados do campo. Os RPAS são utilizados principalmente no sensoriamento remoto e possibilitam a captura de imagens de alta resolução em um curto espaço de tempo necessitando apenas de condições climáticas favoráveis para voo (Jensen, 2009). As imagens capturadas por RPAS auxiliam na detecção rápida de problemas no cultivo, como pragas, doenças, estresse hídrico, nutrição de plantas, entre outros problemas (Sánchez *et al.*, 2015).

Segundo Mogili & Deepak (2018), os RPAS estão sendo incluídos cada vez mais na agricultura de precisão, pulverizam produtos químicos sobre lavouras de forma precisa e automatizada. Além destes fatos, permitem a diminuição dos riscos de contaminação do solo, alimentos e intoxicação do operador pelos agrotóxicos. Assim os RPAS oferecem menores desperdícios de insumos e maior segurança durante a operação.

Segundo a Associação Brasileira das Empresas de Controle Biológico (ABCBio), as indústrias brasileiras crescem todos os anos cerca de 15% de

comercialização dos insumos biológicos, com um volume de vendas de R\$ 464,5 milhões em 2018. Segundo a EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária Ministério da Agricultura, Pecuária e Abastecimento) o controle biológico de pragas foi realizado em 23 milhões de hectares no Brasil em 2019.

As liberações de insetos predadores e/ou parasitoides nas lavouras de grandes extensões são dificultadas pelo estágio das plantas e necessidade de caminhamento, requerendo tempo e mão de obra especializada. Portanto, para obter sucesso com controle biológico, é importante fazer uma boa distribuição de inimigos naturais dentro da área da lavoura (Pratissoli *et al.*, 2005). Deste modo, os RPAS se tornam uma importante ferramenta para viabilizar o uso desses agentes de controle biológicos em grandes áreas cultivadas.

Para o melhor desempenho do RPAS em condições de campo, é necessário construir modelos matemáticos para corrigir a posição espacial do RPAS, pois fatores como velocidade e direção do vento, altura e velocidade de voo do RPAS influenciam na distribuição de insumos agrícolas (Teske *et al.*, 2019). Tendo em vista estes problemas, o objetivo deste trabalho foi elaborar um modelo preditivo para liberação de cápsulas de inimigos naturais.

2. OBJETIVOS

2.1 Objetivo geral

O objetivo deste trabalho foi elaborar um modelo preditivo, para aumentar a precisão de distribuição de cápsulas de inimigos naturais em campo, utilizando um sistema de aeronave remotamente pilotada (RPAS).

2.2 Objetivo específico

Produzir uma metodologia para avaliar a distribuição de cápsulas de inimigos naturais liberadas por um RPAS.

Avaliar o desempenho de um RPAS em campo.

Treinar uma rede neural artificial para prever a distribuição de cápsulas de inimigos naturais, em diferentes condições de vento, altura e velocidades do RPAS.

3. REVISÃO DE LITERATURA

3.1 Aeronave remotamente pilotada

O termo drone foi empregado para pequenas aeronaves não tripuladas com alto grau de automação, quando estas aeronaves estão voando, emitem um som parecido com enxame de abelha ou um zangão, dando origem ao emprego do termo para estas aeronaves (Giones & Brem, 2017).

Os RPAS foram mencionados pela primeira vez em 1900, quando foram introduzidos como alvos para treinamento militar nos EUA, e com o avanço de novas tecnologias, aumentou a importância destas máquinas em conflitos armados e em operações militares (Figura 1).

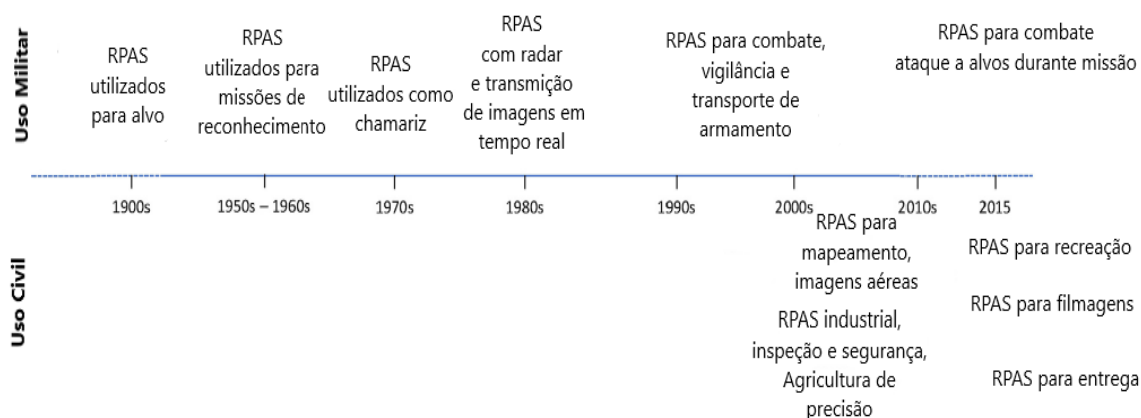


Figura 1. Linha do tempo de usos militares e civis dos RPAS. Fonte: Giones & Brem (2017).

A Agência Nacional de Aviação Civil (ANAC) criou regras para operação de aeronaves não tripuladas no Brasil. O Regulamento Brasileiro de Aviação Civil Especial nº 94/2017 (RBAC-E nº 94/2017) da ANAC é complementar às normas de operação de RPAS estabelecidas pelo Departamento de Controle do Espaço Aéreo (DECEA) e pela Agência Nacional de Telecomunicações (ANATEL).

Para regulamentar estas aeronaves, utiliza-se o termo técnico de aeronaves remotamente pilotadas (RPA - Remotely Piloted Aircraft), que são aeronaves não tripuladas com elevado grau de automação e são utilizadas para fins comerciais, experimentais e institucionais.

No ano de 1709, o Padre Bartolomeu Lourenço de Gusmão projetou e construiu balões de ar quente na cidade de Lisboa em Portugal, e fez demonstrações ao Rei Dom João V e toda a corte real (Visoni e Canalle, 2009).

Os balões de ar quente foram os primeiros RPAS utilizados em guerra. Em 1849, cerca de 200 balões austríacos liberaram bombas sobre a cidade Veneza (Itália) (Prisacariu, 2017).

Em 1858, balões foram utilizados para fotografias aéreas. As primeiras fotos foram realizadas pelo balonista Gaspard-Félix Tournachon, conhecido como "Nadar", na cidade de Paris (França), iniciando os primeiros aerolevantamentos, sendo o pioneiro do sensoriamento remoto. Os registros mais antigos que existem até hoje são as fotos de James Wallace Black e Samuel Archer King capturadas

em 13 de outubro de 1860. Fotografaram a cidade de Boston nos EUA a 630 m de altura (Tosun, 2016).

Em 1889, o francês Arthur Betut utilizou pela primeira vez pipas para obter fotografias aéreas a altura de 90 m do solo na cidade de Labruguière (França). O registro mais antigo e famoso de fotos aéreas capturadas por pipas, foi feita pelo fotógrafo George Lawerence, que produziu uma fotografia panorâmica da Cidade de São Francisco (EUA), após um terremoto. Foi utilizado cerca de 23 kg de equipamentos para obter as imagens. As pipas foram levantadas de um barco próximo à costa por meio de cabos de aço e os mesmos davam contato para o obturador da câmera (Braquinho & Hayakawa, 2012).

Em 1898, Nikolas Tesla descobriu em seu laboratório que enrolamentos de uma bobina podiam transmitir e receber sinais. Tesla conseguiu controlar um pequeno barco sem nenhum fio conectado entre transmissor e receptor, foi o primeiro dispositivo controlado por ondas de rádio na história. Em 1915, Nikolas Tesla já mencionava frotas de veículos aéreos não tripulados para defesa e ataque militar (Prisacariu, 2017).

Durante a Primeira Guerra Mundial, os EUA desenvolveram o RPAS chamado "Kettering Bug". O projeto decolava por meios próprios sem interferência de um piloto dentro da aeronave, e uma vez no ar, o nivelamento era mantido por um giroscópio que controlava a altitude com base nas leituras de um barômetro analógico. Calculava-se o número de voltas que a hélice deveria completar para atingir o alvo, e após as voltas necessárias, as asas dobravam-se e o RPAS mergulhava em direção ao solo (James, 2018).

Nos últimos estágios da Segunda Guerra Mundial, mísseis V1 construído pelos alemães foram lançados contra o Reino Unido a partir de rampas instaladas na França e Holanda. O míssil possuía sensores analógicos que garantia estabilidade, e os ataques resultaram em danos estruturais nas cidades e baixas civis significativas (Evans & Delaney, 2018).

No final de 1935, Reginald Denny fundou a primeira empresa que oferecia aeronaves rádio controladas de baixo custo para treinamento de artilheiros. Estas aeronaves serviram como base para os RPAS modernos que estão em conflitos de guerra atualmente (Prisacariu, 2017).

Os RPAS foram utilizados massivamente em conflitos mais recentes como no Afeganistão. Logo após os ataques terroristas nas torres gêmeas nos

EUA, em 11 de setembro 2001, ocorreram guerras contra o terrorismo. As constantes mortes de soldados americanos afetaram a opinião pública e levou a pressionar o fim das guerras terrestres. Os RPAS entraram como a principal arma para combate ao terrorismo, na vigilância do território atacando alvos estratégicos e neutralizando o inimigo (James, 2018).

A partir dos anos 2000, os RPAS começaram a ser utilizados por civis em diversas aplicações como em inspeção de cabos elétricos, segurança e agricultura. Em 2002, o RPAS Pathfinder-Plus, construído pela National Aeronautics and Space Administration (NASA), foi utilizado para realizar missões em lavouras de café no Havaí. O RPAS capturou imagens a cores e multiespectrais que foram úteis para detectar áreas com plantas daninhas, anomalias na irrigação, fertilização do solo e maturação dos frutos indicando o período de colheita (Herwitz *et al.*, 2004).

Depois de anos de desenvolvimento em comunidades de código aberto e por empresas privadas, os RPAS entraram no mercado tradicional. Fabricantes como a 3DRobotics, um dos principais fabricantes de RPAS, iniciou em 2009 com o ArduPilot, uma plataforma de piloto automático de código aberto para RPAS.

A empresa DJI (Dà-Jiāng Innovations Science and Technology), uma produtora chinesa de RPAS, experimentou o crescimento mais rápido e tornou-se líder na categoria. As aeronaves possuem GPS, câmera de vídeo e sensores capazes de detectar obstáculos. Destacam-se pelos aplicativos intuitivos, e a qualidade do produto. Os produtos são utilizados como ferramenta de trabalho, e são aplicados em diversas áreas (Rao *et al.*, 2016).

3.2 Classificação de RPAS

Existe um grande esforço para projetar e construir RPAS para atender as necessidades diárias, e atualmente, encontra-se uma grande quantidade de plataformas no mercado que podem ser classificados de várias formas como peso, tamanho, recursos, custo de produção, autonomia de voo, distância de voo, altura do voo e tipo de decolagem (Hassanalian & Abdelkefi, 2017).

Uma das principais características dos RPAS está na forma de sustentação no ar e são divididas em asas rotativas (VTOL- Vertical Take-Off

Landing) e asas fixas (HTOL-Horizontal Take-Off Landing), sendo que estes tipos de aeronaves, possuem comportamentos previsíveis e particularidades.

Os RPAS de asas rotativas incluem os tradicionais helicópteros com apenas um rotor e multirotores, que utilizam dois ou mais rotores dependendo do layout da aeronave. Estas aeronaves geram sustentação a partir da rotação de hélices, podem pairar, possuem alta manobrabilidade, decolam e pousam verticalmente em pequenos espaços, possuem pequenas dimensões, e como desvantagem, consomem mais energia, em consequência menor autonomia e menor velocidade de deslocamento quando comparados às aeronaves de asa fixa.

Já os RPAS de asas fixas utilizam asas para manter a sustentação na atmosfera como um avião que pousam e decolam horizontalmente. Estes possuem maior autonomia e cobrem maiores distâncias quando comparadas às aeronaves de asas rotativas. Porém, como desvantagem, não podem pairar e exigem uma pista para pouso e decolagem. Para melhorar a utilização destes equipamentos, foram projetadas aeronaves híbridas, que conseguem decolar e pousar na vertical, e após a decolagem, mantém a sustentação por asas fixas. Desta forma, as aeronaves híbridas possuem maior autonomia como os RPAS de asas fixas, e podem pousar e decolar na vertical em pequenos espaços, como os RPAS de asas rotativas (Hassanalian & Abdelkefi, 2017).

3.3 Componentes básicos de um RPAS

Dentre todas as diferentes plataformas de RPAS, cada classe segue um layout básico, em que os componentes são encontrados na maioria das plataformas. Nos RPAS de asas rotativas como os multirotores, necessitam de componentes básicos como frame, motores, controlador de rotação dos motores (ESC - Eletronic Speed Controller), controlador de voo, bateria, receptor de rádio, telemetria e receptor GNSS. É preciso de uma estação terrestre, para configurar o RPAS, planejar as missões e monitorar o voo (Figura 2).




Figura 2. Componentes básicos de um RPAS multirotor. Fonte: Ardupilot, 2019.

Para RPAS de asa fixa, o controle do voo é realizado por meio de superfícies de comando como leme, profundor e aleiron, e o movimento da superfície de comando é realizado por servo motor.

3.4 RPAS na agricultura de precisão

A agricultura de precisão (AP) visa o gerenciamento de informações agrícolas exatas e precisas. A AP é uma forma de gerenciamento de campos produtivos metro a metro, ou seja, trata a área de forma heterogênea considerando que existe variação espacial e temporal de nutrientes, tipos de solo, ataques de pragas e doenças no cultivo, e cada área deve ser manejada de forma diferente (Tschiedel e Ferreira, 2002).

É fundamental que os agricultores saibam, em tempo real, onde existem variações nas lavouras, para ajustar o manejo de acordo com a necessidade de cada área escolhendo a melhor técnica para estabilizar ou aumentar a produção agrícola, e ao mesmo tempo diminuir os impactos da atividade agrícola no meio ambiente. Algumas tecnologias, como aplicação variada e monitores de rendimento de grãos, podem resolver inúmeros problemas em campo.

O sensoriamento remoto é uma ferramenta muito utilizada na AP. As plataformas mais comuns para sensoriamento remoto incluem satélites, aviões, balões e helicópteros. Sensores ópticos são instalados nestas plataformas e as informações derivadas das imagens destes sensores oferecem, por exemplo, a biomassa, índice de área foliar, doenças, estresse hídrico entre outras informações (Zhang & Kovacs, 2012).

Imagens de alta resolução capturadas por satélites e outras plataformas possuem um custo alto para o produtor rural ou uma empresa. Imagens capturadas por pequenos RPAS demonstram-se uma alternativa mais viável, e está consolidando-se no mercado, devido ao baixo custo de operação, alta resolução espacial e temporal. Nos últimos anos houve vários estudos de imagens capturadas por RPAS, para aplicação na AP (Zhang & Kovacs, 2012).

Primicerio *et al.* (2012) utilizaram imagens capturadas por RPAS para determinar o potencial enológico em vinhedos. Foi utilizado o RPAS VIPtero® para realizar voos autônomos e capturar imagens multiespectrais. Os mapas resultantes mostraram heterogeneidade nos vinhedos e foi confirmado com observações de campo.

Em programas de monitoramento de gramados, os RPAS são excelentes ferramentas para capturar imagens aéreas em tempo real. O mapeamento oferece a resposta da planta a diferentes concentrações de aplicação de nitrogênio e variabilidade espacial de diferentes espécies de grama (Caturegli *et al.*, 2016).

As imagens de alta resolução são capazes de informar com precisão a distribuição de plantas daninhas nos cultivos de arroz. Novos algoritmos foram testados para detectar com maior precisão plantas daninhas no cultivo de arroz a partir de imagens capturadas por sensores instalados em um RPAS (Huang *et al.*, 2018).

A produção de mapas de plantas daninhas na cultura do milho é empregada para o planejamento e controle de plantas daninhas, e estas informações contribuem para o melhor uso de herbicidas e de doses adequadas aos níveis de infestações (Peña *et al.*, 2013).

Características geométricas de árvores agrícolas como área do dossel, altura da árvore e volume da copa, são importantes informações para os produtores de oliveira, estas variáveis são obtidas após um demorado trabalho de

campo. Sánchez *et al.* (2015) obtiveram mapas derivados de imagens capturadas por RPAS, otimizaram o tempo para obter as informações e conseguiram uma alta precisão. Os mapas podem ser usados para relacionar o crescimento das árvores, aos fatores de campo e orientar operações de manejo no contexto da agricultura de precisão.

Panagiotidis *et al.* (2016) processaram imagens capturadas por um RPAS, resultando em modelos de três dimensões, fornecendo estimativas precisas de diâmetro e altura das copas de árvores.

Além de capturar imagens, os RPAS são utilizados para pulverização aérea. Países como Brasil, Rússia, Austrália, Canadá e EUA possuem uma aviação agrícola bem desenvolvida, utilizam aeronaves tripuladas de asa fixa e asas rotativas, possuem vastas áreas agricultáveis que são pulverizadas com este tipo de aviação. Alguns países, como Japão, Coreia e China, possuem terreno montanhoso e pouco agricultável, e estas condições inviabilizam o uso de pulverização com aeronaves de asa fixa tripulada. Nestas áreas os RPAS predominam na pulverização aérea. Comparado com a aviação agrícola convencional, os RPAS possuem algumas vantagens - não exigem aeroporto, possuem boa manobrabilidade, pulverizam em altitude baixa e em terreno acidentado, possuem baixo peso, baixo custo de operação, evitam danos na cultura como esmagamento de plantas, compactação do solo e oferecem menor risco de intoxicação ao operador (Qin *et al.*, 2016).

Qin *et al.* (2016) realizaram pulverizações de inseticidas na cultura do arroz utilizando um RPAS. Observaram uniformidade de distribuição de gotículas sobre as plantas, e a deposição de gotículas na camada inferior das folhas foi maximizada pulverizando em uma altura de 1,5 m do solo e velocidade de voo de 5 m/s. A eficácia do inseticida e a permanência do inseticida em campo foi superior quando comparado com a pulverização manual.

Xinyu *et al.* (2014) avaliaram a deposição de gotículas e deriva de pulverização em um arrozal. Utilizaram um RPAS, a aeronave sobrevoou a cultura a 5 metros de altura e deslocava-se a uma velocidade de 3 m/s, e com velocidade do vento de 3 m/s. Os resultados mostraram que a corrente de ar derivada dos rotores aumentou a penetração das gotículas no interior das plantas, houve maior deposição do produto pulverizado tanto na parte superior e inferior da folha quando comparado com a pulverização manual. Cerca de 12,9 % da calda

depositou-se fora da área alvo, e, do total da deriva, 90% das gotas estavam a uma distância de 8 m da área alvo.

Em ambiente controlado, Lv *et al.* (2019) realizaram pulverizações com um RPAS e utilizaram imagens térmicas infravermelhas para detectar os padrões de deposição das gotículas para esclarecer como é a variação de características de deposição de gotículas sob diferentes velocidades de voo. As velocidades foram fixadas em 0,3 m/s, 0,5 m/s, 0,7 m/s, 0,9 m/s e 1 m/s, a uma altura de 1,4 m. A densidade da deposição, cobertura da deposição e o tamanho das gotículas diminuíram com o aumento da velocidade. O coeficiente de variação (CV) aumentou com aumento da velocidade demonstrando menor uniformidade das gotículas com aumento da velocidade.

A deriva durante a pulverização realizada por um RPAS é influenciada pela altura e velocidade da aeronave e principalmente por condições meteorológicas como direção do vento e velocidade do vento. Segundo Wang *et al.* (2018), quando a pulverização é realizada em condições de vento desfavoráveis, a porcentagem de desvio para as extremidades da linha alvo foi de 15,42% até 55,76% em seus experimentos na cultura do abacaxi. A altura que mais apresentou desvio de pulverização foi de 3,5 m, com gotículas atingindo até 46,5 m de distância em relação a faixa alvo. Na altura de 1,5 m e velocidade do vento de 2,2 m/s, o desvio da deriva foi quase nulo. Observou-se que, durante as operações de pulverização, a altura da aeronave não deve ultrapassar 2,5 m e a velocidade do vento deve estar a menos de 5 m/s.

Weicai *et al.* (2014) avaliaram pulverizações nos estádios finais de desenvolvimento da cultura do milho utilizando um RPAS alterando a altura de operação, e as amostragens foram colocadas em quatro alturas diferentes na planta do milho. Constataram que a melhor altura de operação é de 7 m e que houve maior deposição de gotículas nesta altura quando comparado com as alturas de 5 m e 9 m.

Geralmente é adotado posições estáticas para os RPAS durante as pulverizações, diminuindo a eficiência em ambientes com mudanças nas condições climáticas, como velocidade e direção do vento. Faiçal *et al.* (2017) propuseram modelos capazes de se adaptar automaticamente, fazendo com que a aeronave mudasse sua rota e depositasse as gotículas com maior precisão. Os resultados experimentais mostraram que o modelo, em um sistema baseado em

metaheurísticas de mudança de rota autônoma, fornecia mudanças mais precisas durante o voo do RPAS, com deposição mais precisa do pesticida, e diminuía os danos ambientais.

A dificuldade de liberação de inimigos naturais no campo ainda é um fator limitante para a adoção do controle biológico. O caminhamento dentro da lavoura pode ser dificultado pelo estágio da planta, clima, horário e relevo. Com a utilização mais eficiente de máquinas e equipamentos, e evolução da agricultura de precisão, busca-se identificar e encaminhar propostas de solução para os principais gargalos tecnológicos, buscando novos métodos de liberação de inimigos naturais.

Segundo Park *et al.* (2018), os RPAS possuem grande potencial para distribuição de inimigos naturais como insetos predadores e parasitoide. Em seus trabalhos, desenvolveram três RPAS para liberar insetos predadores *Rhinoncomimus latipes* (Coleoptera: Curculionidae) sobre reboleiras de planta daninha *Persicaria perfoliata* (Polygonaceae). O RPAS pode cobrir grandes áreas infestadas de plantas daninha e dispersar milhares de insetos predadores com precisão. Em trabalho de campo, observou-se baixa mortalidade dos predadores durante o transporte e distribuição das cápsulas e não houve perda de desempenho dos predadores após liberação.

Teske *et al.* (2019) realizaram liberações de ácaros predadores utilizando um RPAS, sendo que as amostras de ácaros foram misturadas com vermiculita e foram liberadas em diferentes alturas e velocidades do RPAS e em diferentes condições de vento sobre alvos no solo. Os dados de dispersão dos ácaros em relação ao alvo foram submetidos às técnicas de aprendizagem de máquina. O modelo resultante pode prever a dispersão dos ácaros e corrigir a posição do RPAS, aumentando a precisão e evitando problemas de deposição durante a operação da máquina podendo ser utilizado em controladores de voo do RPAS.

3.5 Controle biológico de pragas

O controle biológico é o fenômeno natural que regula o número de plantas e animais por meio de inimigos naturais, ou seja, é controlar organismos vivos utilizando-se outros organismos vivos (Parra *et al.*, 2002). O controle biológico

deve ser considerado como um programa de multidisciplinar de manejo integrado de pragas ao lado de outras medidas de controle de insetos praga.

A simplificação dos cultivos em monoculturas de grandes escalas, estão associadas a surtos de pragas e doenças, houve um crescente interesse no controle biológico nas últimas décadas, para minimizar os danos econômicos e diminuir o uso de pesticidas (Letourneau & Bothwell., 2008).

Os inimigos naturais são predadores, parasitoides, microrganismos e vírus. Todos esses inimigos naturais podem ser produzidos em laboratório e levados para campo. Os parasitoides são os mais utilizados, pois o custo de produção é menor quando comparado com outros inimigos naturais (Parra *et al.*, 2002).

Segundo Parra *et al.* (2002), existem três tipos de liberação de inimigos naturais: inoculativa, inundativa e inoculativa estacional, sendo que o tipo de liberação é selecionado de acordo com a cultura e local. A inoculação é utilizada para culturas de baixa variabilidade temporal, ou seja, utiliza-se em culturas perenes ou semiperenes e florestas. A liberação inundativa, é para culturas com alta variabilidade temporal, enquanto que a inoculativa estacional é normalmente realizada em casas de vegetação.

A forma de liberação é importante, pois pode influenciar a eficiência do inimigo natural e a capacidade de encontrar o hospedeiro. Dentre as técnicas de liberação de *Trichogramma* spp. para controle da broca da cana *Diatraea saccharalis* (Fabricius), a proteção dos parasitoides por cápsulas melhora o desempenho do parasitoide. Segundo Pinto *et al.* (2003), houve maior parasitismos quando utilizou cápsulas. As cápsulas proporcionaram maior segurança quanto as possíveis variações de temperaturas e de precipitações após a liberação oferece abrigo contra clima desfavorável e predação natural dos parasitoides.

A *Diatraea saccharalis* Fabri. (Lepidoptera: Crambidae) é uma das principais pragas da cana-de-açúcar. No Brasil, o controle é feito com parasitoide de larvas *Cotesia flavipes* (Cameron) (Hymenoptera: Braconidae). Este parasitoide possui grande capacidade de dispersão em campo, chegando a 15 m de distância a partir do ponto de liberação. Desta forma, com apenas oito pontos de liberação é possível cobrir uma área de um hectare (Miranda *et al.*, 2014).

A *Cryptolaemus montrouzieri* Mulsant (Coleoptera: Coccinellidae), popularmente conhecida como joaninha, são predadores consolidados sobre cochonilha *Planococcus citri* (Risso) (Hemiptera: Pseudococcidae). Maes *et al.* (2014) ofereceram outras pragas para testar a predação da joaninha. Houve predação nas seguintes espécies: pulgão da ervilha, *Acyrtosiphon pisum* (Harris) (Hemiptera: Aphididae), pulgão do tabaco, *Myzus persicae nicotianae* (Sulzer) (Hemiptera: Aphididae) e mosca-branca *Bemisia tabaci* (Gennadius) (Hemiptera: Aleyrodidae). Segundo Maes *et al.* (2014), o lado negativo é que, por apresentar hábito alimentar não específico, o predador pode atacar presas não visadas.

3.6 Redes Neurais

Em 1943, Warren McCulloch e o estatístico Walter Pitts, (1943) propuseram um modelo computacional inspirado no cérebro humano, iniciando-se então pesquisas para rede neural artificial (RNA). As redes neurais são capazes de aprender e podem resolver uma ampla gama de problemas complexos (Ding *et al.*, 2013).

Uma RNA consiste em uma rede de unidades de processamento chamadas de neurônios. Cada neurônio recebe e envia informação. Um neurônio é geralmente um elemento não linear de entrada múltipla e saída única. O neurônio artificial possui entradas que representam informações, sendo que cada entrada é multiplicada por um peso que assume qualquer valor, adquirindo um valor fixo quando a rede está treinada. A arquitetura de uma rede neural é determinada por todas as conexões da rede e pelas funções de ativação dos neurônios. A função de ativação define a saída dos neurônios. Existem várias funções de ativação que podem ser utilizadas como as funções: limiar, linear, rampa, sigmoide, entre outras.

Segundo Kumara *et al.* (2013), uma RNA típica consiste em uma camada de entrada responsável pelo recebimento dos dados para processamento. Uma ou mais camadas ocultas que tem por finalidade extrair as informações dos dados, sendo também responsável pela maior parte do processamento destes dados. A camada de saída agrega todos os cálculos e ativa uma resposta adequada. (Figura 3).




Figura 3. Estrutura de uma rede neural - inserção dos dados, processamento dos dados e resultado final do processamento. Fonte: Kumara *et al.*, (2013).

Para validação da RNA, separa-se a base de dados em dados de treinamento e dados de teste. A rede neural é treinada sem os dados de teste e após o treinamento da RNA, processa-se os dados de teste sem a variável resposta. Posteriormente, compara-se a variável resposta dos dados de teste com os resultados da RNA.

Rahnemoonfar & Sheppard (2017) construíram uma rede neural para contagens de tomates em campo, obtiveram 90% de precisão, através de imagens a rede neural consegue contar os frutos maduros na planta e conta até frutos sobrepostos, assim o algoritmo pode estimar a quantidade de frutos presentes nas lavouras e este pode ser implementado em veículos terrestres não tripulados e em RPAS, podendo gerar uma informação rápida e precisa da lavoura.

A detecção rápida, precisa e confiável de frutos é essencial para plataformas autônomas no meio agrícola, Sa *et al.* (2016) utilizaram redes neurais para detectar frutos de diversas espécies de plantas em campo, utilizando imagens de câmeras, e conseguiram maior precisão do que outros métodos já utilizados.

4. MATERIAL E MÉTODOS

4.1 Localização

O experimento foi realizado no Laboratório de Engenharia Agrícola (LEAG) e em uma área de vegetação rasteira no campus da Universidade Estadual do Norte Fluminense Darcy Ribeiro (UENF), localizado na Cidade Campos dos Goytacazes-RJ, latitude 21°45'48.3" Sul, longitude 41°17'21.1" Oeste e altitude de 11 m.

4.2 Desenvolvimento do sistema de aeronave remotamente pilotada

Foi utilizada uma aeronave remotamente pilotada do tipo quadrirotor customizada constituída por um modelo F450 DJI[®], receptor e rádio controle Flysky th 9x[®], kit 3DR com placa controladora Arducopter[®] APM 2.8, sistema de posicionamento global com bússola interna, transmissão de dados com telemetria de 420 Mhz, quatro motores brushless 2212-13T, quatro controladores de velocidade do motor ESC 30 A, UBEC de 5 V 2 A, hélices 10x4.5 CW e CCW, bateria lipo POWER[®] 4S 14,8 V, 4200 mAh (Figura 4). A configuração da placa controladora de voo e o gerenciamento do voo foram realizados pelo software Mission Planner[®] e foi utilizado um notebook como estação terrestre.



Figura 4. RPAS utilizada para avaliação.

4.3 Construção do dispositivo de liberação de cápsulas

Para distribuição das cápsulas, foi construído um dispositivo com um tubo de PVC de 1 pol e 200 mm de comprimento, um servo motor e placas de poliestireno extrudada. Após o corte das peças de poliestireno extrudada, foram encaixadas ao tubo de PVC e ao servo motor e foram unidas com cola quente. (Figura 5).




Figura 5. Dispositivo para liberação das cápsulas.

O dispositivo foi acoplado na aeronave por meio de uma cinta de velcro. O servo motor foi alimentado com um regulador de tensão LM 7805. O fio de conexão do sinal do servo foi conectado no pino A10 da controladora de voo APM 2.8. Foram empilhadas 20 cápsulas no interior do tubo de PVC. Os sinais de PWM foram ajustados para que o servo, ao receber o comando da controladora de voo, mantenha a cápsula presa ao dispositivo, ou libere a cápsula para fora do dispositivo.

As cápsulas foram construídas com papel de 3 mm de espessura, que foram cortadas e coladas com cola branca, formando um cilindro de 25 mm de

diâmetro e 9 mm de espessura, com peso de 2,75 g e furos de 1 mm de diâmetro para a passagem dos parasitoides (Figura 6).



Figura 6. Cápsula de papel com três camadas e interior oco para comportar o parasitoide e furos para a saída do parasitoide.

4.4. Avaliação do desempenho do RPAS e distribuição de cápsulas

Para a avaliação do desempenho do RPAS e distribuição das cápsulas, foi definida uma reta utilizando estacas e barbante. Ao longo da reta, foram marcados quatro pontos com cal virgem no sentido de oeste para leste, distantes 10 m entre si (Figura 7). Os pontos foram georreferenciados com um GPS modelo Garmin 60csx e utilizados na missão automatizada.

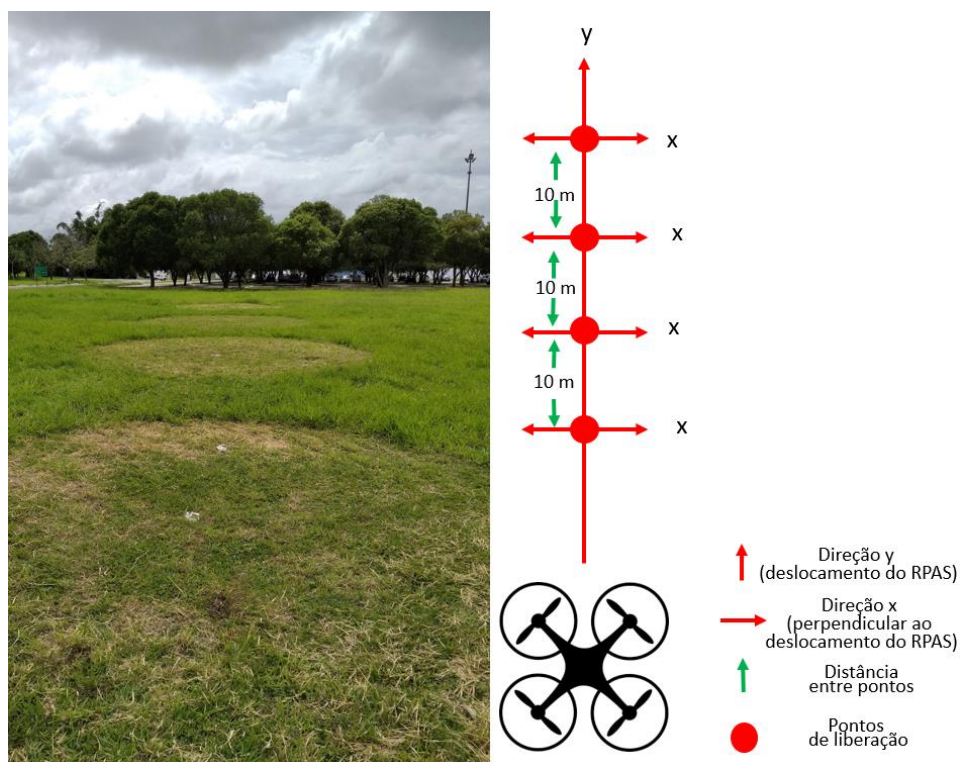


Figura 7. Pontos georreferenciados na reta e ilustração do deslocamento do RPAS em linha reta (eixo y) e perpendicular ao deslocamento do RPAS (eixo x).

A missão automatizada foi desenvolvida no software Mission Plane. Foi utilizado o comando entre waypoint DO_REPEAT_SERVO, que, quando acionado, envia sinal com valor configurado no planejador de missão de 1900 PWM para o servo motor liberar a cápsula, e, após a liberação da cápsula, o servo motor volta para a posição inicial, configurado em 1210 PWM no comando RC_10_TRIM. Quando o RPAS atinge os pontos 2, 4, 6 e 8, as cápsulas são liberadas (Figura 8).

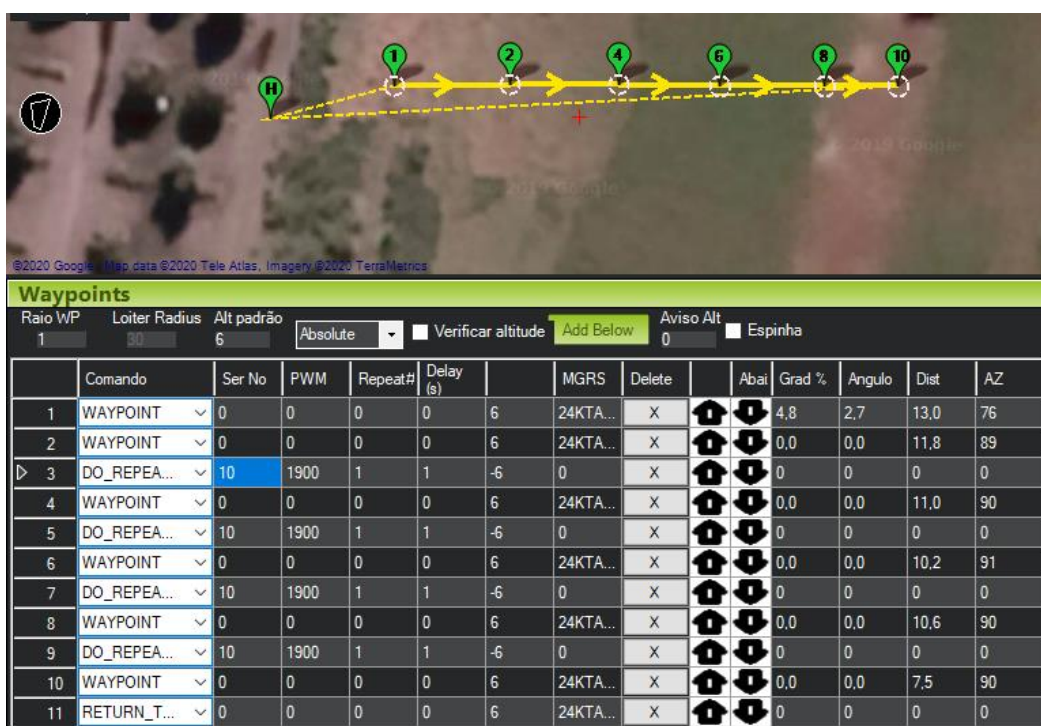


Figura 8. Missão automatizada no software Mission Plane.

A altitude foi modificada para os diferentes tratamentos no planejador de missão e a velocidade do RPAS foi alterada no comando velocidade de cruzeiro. A missão foi planejada para liberação das cápsulas nos pontos definidos em diferentes alturas de 6 m, 12 m, 18 m e 24 m à diferentes velocidades de 2 m/s, 3,5 m/s, 5 m/s, 6,5 m/s e 8 m/s.

Os voos foram realizados pela manhã para reduzir o efeito do vento. Após a missão automatizada, a distância entre alvo e o local em que as cápsulas aterrissaram foram medidas com uma trena, sendo a distância x perpendicular ao sentido de deslocamento do RPAS, e a distância y em relação ao sentido de

deslocamento do RPAS. O local em que as cápsulas aterrissaram foram georreferenciados, como mostrado na Figura 9.




Figura 9. Ilustração dos vetores de distância x e y entre o ponto de liberação e o local de aterrissagem da cápsula.

Posteriormente, foi construído um modelo de regressão tendo como variáveis respostas as distâncias x e y. Foi utilizado o modelo de superfície de resposta de acordo com a Equação 1. Os dados foram processados no software de estatística Rstudio.

$$Y_i = \beta_0 + \beta_1 A_i + \beta_2 V_i + \beta_3 A_i^2 + \beta_4 V_i^2 + \beta_5 V_i A_i + \epsilon_i \quad \text{Eq. 1}$$

Onde: Y é a variável distância x ou y, A é a altura, V é a velocidade, β são os coeficientes e ϵ é o erro.

4.5. Modelo preditivo para distribuição das cápsulas utilizando rede neural

As previsões de distribuição das cápsulas foram realizadas utilizando quatro variáveis que mais influenciam no erro de distribuição das cápsulas - velocidade do vento, direção do vento, velocidade do RPAS e altura da RPAS. Os dados de vento foram coletados de uma torre anemométrica distante 300 m do

local do experimento nas mesmas alturas do voo do RPAS. As cápsulas foram liberadas de diferentes alturas - 6 m, 12 m, 18 m e 24 m, e diferentes velocidades - 2 m/s, 3,5 m/s, 5 m/s, 6,5 m/s e 8 m/s, e foram realizadas 80 missões para treinamento da rede neural. Os dados foram coletados de quatro pontos da reta e foram registradas as distâncias x , perpendicular ao sentido de deslocamento do RPAS, e distância y , em relação ao sentido de deslocamento do RPAS.

Para uma abordagem mais prática, caso o usuário não possua uma torre anemométrica, os dados de velocidade de vento podem ser corrigidos para a altura de 2 m utilizando a Equação 2.

$$u_2 = u_z \frac{4,87}{\ln(67,8z - 5,48)} \quad \text{Eq. 2}$$

Onde: u_2 é a velocidade do vento na altura de 2 m (m/s), u_z é a velocidade do vento na altura z (m/s), z altura (m).

Foram implementadas duas redes neurais, uma para a distância em que a cápsula aterrissa no sentido de deslocamento do RPAS (distância y) e outra para prever onde aterrissará perpendicularmente ao sentido de deslocamento do RPAS (distância x).

Na fase de treinamento das redes neurais, adaptaram-se pesos sinápticos dos neurônios. Foi realizada utilizando o algoritmo *backpropagation* com o método do gradiente descendente para obtenção do mínimo da função erro. Para o treinamento da rede, foram realizados vários testes com diferentes números de neurônios, camadas ocultas e épocas até encontrar um resultado satisfatório. Para elaboração da rede neural, utilizou-se o software Rstudio e o pacote H₂O.

5. RESULTADOS E DISCUSSÃO

5.1. Avaliação do RPAS durante a distribuição das cápsulas

A avaliação do desempenho do RPAS em relação à distribuição das cápsulas foi realizada e os resultados estão dispostos na Figura 10, que apresenta a representação gráfica da relação entre a distância de deposição de cápsulas no sentido de deslocamento em relação ao alvo no solo e as duas variáveis contínuas altura e velocidade de deslocamento do RPAS.

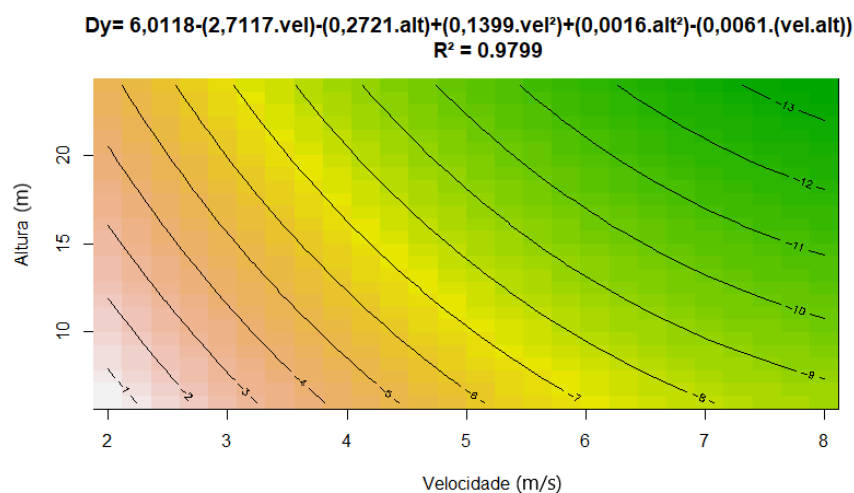


Figura 10. Gráfico da relação entre a distância de deposição de cápsulas no sentido de deslocamento em relação ao alvo no solo e as duas variáveis contínuas altura e velocidade de deslocamento do RPAS.

De acordo com os resultados obtidos, o RPAS apresentou acurácia para liberar as cápsulas, com coeficiente de variação de 97, 99%, em relação ao sentido de deslocamento. O RPAS quando submetido a uma velocidade e uma altura constantes, as distâncias de erro x e y, em relação aos alvos no solo, apresentam valores aproximados. O RPAS liberou as cápsulas aproximadamente na mesma posição em cada ponto durante a missão automatizada. Porém, a precisão diminuiu com o aumento da velocidade e altura do RPAS, ou seja, as cápsulas aterrissaram mais distantes do alvo quando a velocidade e altura do RPAS aumentaram.

Em algumas situações, as cápsulas aterrissaram a mais de 13 m de distância do ponto de liberação. Seguindo recomendações para liberação do *Trichogramma* sp. e com base no modelo, para evitar sobreposição entre os pontos, o RPAS avaliado deve utilizar a velocidade de 5,54 m/s (± 5 % de probabilidade) quando estiver voando a uma altura de 6 m. À 12 m de altura, a velocidade não deverá ultrapassar 4,4 m/s (± 5 % de probabilidade), à 18 m de altura, a velocidade não deverá ultrapassar 3,44 m/s (± 5 % de probabilidade), à em 24 m de altura, não deverá ultrapassar a velocidade de 2,63 m/s (± 5 % de probabilidade).

A distância y está mais sujeita a efeitos de velocidade e altura do RPAS, enquanto a distância x sofre maiores efeitos de vento e erros de navegação do RPAS. Durante a distribuição, o RPAS liberou as cápsulas antes de atingir o alvo,

e com o aumento da velocidade, o RPAS libera as cápsulas a maiores distâncias antes de atingir o alvo.

O erro de distribuição na direção x não adequou a nenhum modelo de regressão, pois as cápsulas depositaram-se ora de um lado e ora do outro sem um padrão aparente, e as aterrissagens das cápsulas foram próximas da rota de deslocamento do RPAS (direção y). Nesta situação, o erro do aparelho receptor GPS é a provável causa deste comportamento, pois durante as missões evitou-se o máximo a influência do vento.

Existem muitas formas para correção do erro de posicionamento de receptores do sistema global de navegação por satélites (Global Navigation Satellite System - GNSS). Alguns veículos, inteligentes, além do GNSS, utilizam um sistema de mapeamento móvel (Mobile Mapping System - MMS) que identificam faixas e placas nas rodovias. Ao contrário de carros, os RPAS não possuem caminhos específicos, dificultando o controle de posicionamento.

Visando melhorar o sistema de posicionamento de navegação em RPAS, Bae (2019) testou um sistema de posicionamento de GPS cinemático em tempo real baseado em rede (Network Based Real Time Kinematic - NRTK) em RPAS utilizados para mapeamento de alta precisão. Observou-se que o sistema foi mais preciso em vários centímetros em comparação a outros tipos de sistemas testados.

Padhy *et al.* (2018) comprovaram a eficácia de sistemas complexos de navegação em ambientes fechados utilizando imagens de uma câmera frontal, onde o vídeo passa por um modelo de rede neural e decide qual a próxima manobra que o RPAS deve fazer para completar o objetivo. Observaram que o RPAS foi capaz de desviar de obstáculos e atravessar um corredor sem utilizar outro tipo de sensor com um receptor de GNSS, por exemplo.

5.2 Modelo preditivo para distribuição das cápsulas utilizando rede neural

O resultado de treinamento do modelo preditivo para a distribuição das cápsulas utilizando rede neural está apresentado na Figura 11.

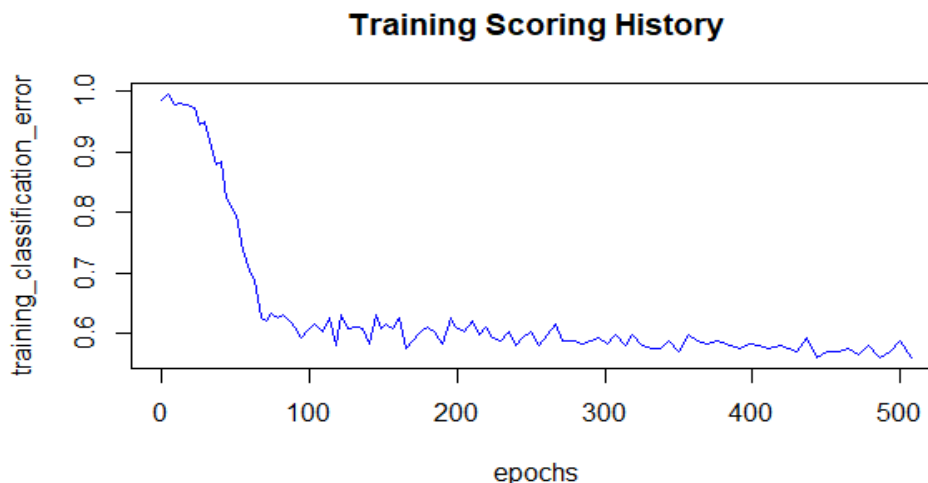


Figura 11. Treinamento da rede neural para distância y, onde Traing_classification_erro representa o número total de erros de cada época, epochs representa quantidade de vezes em que a rede ajustou os pesos sinápticos.

A rede neural foi capaz de prever a deposição das cápsulas (distância x e distância y). A rede neural foi composta por 5 camadas ocultas, com 1000 neurônios cada camada e 10000 épocas para treinamento. Com a evolução do treinamento, os pesos sinápticos ajustaram-se, após o treinamento da rede os erros foram próximos de zero, e as saídas da rede neural aproximaram-se dos dados reais (Figura 11).

Para validar a RNA após o treinamento, dados não treinados foram processados na RNA sem a variável resposta distância y, e os resultados dos cálculos da RNA foram comparados com os dados reais de campo para confirmar as previsões e garantir que a rede neural esteja fornecendo dados confiáveis como observado na Tabela 1.

Tabela 1. Comparação entre dados reais (distância y) e previsões da rede neural após treinamento.

AD(m)	VD(m/s)	VV(m/s)	DV(graus)	DR(m)	RRN(m)
6	2	1,02	65,8	-0,57	-0,52
6	8	1,06	75,5	-8,6	-8,5
12	3,5	3,32	345,6	-4,45	-4,49
18	6,5	1,55	100	-10,6	-10,5
18	6,5	1,75	100	-11,1	-10,9
24	3,5	3,56	288,8	-8,4	-8,6
24	5	2,56	288,8	-10,7	-10,2
24	8	3,5	251,4	-13,9	-13,5
6	8	4,1	101,2	-10,3	-10,3
12	2	5,0	212,64	0	0
12	5	5,04	212,6	7,1	7,1
18	2	0,95	110,6	-1,3	-1,2
18	6,5	1,58	331,8	7,2	7,2
24	6,5	2,306	232	0,3	0,4
6	2	2,43	324,3	-2,8	-2,8
6	3,5	2,42	224,3	-4,5	-4,6
12	2	5,61	189,5	-4,8	-4,5
24	6,5	2,96	24,1	-11,4	-11,3

AD= altura do RPAS; VD=velocidade do RPAS; VV= velocidade do vento; DV= direção do vento; DR= dados reais (distância y); RRN=resultados da rede neural (distância y).

A Figura 12 apresenta a correlação entre dados reais e resultados da rede neural.




Figura 12. Correlação entre dados reais (DR distância y) e resultados da rede neural (RRN). F-estatística 2.4⁴; p-valor < 2.2⁻¹⁶.

Observou-se que a rede neural provou prever onde as cápsulas irão depositar em inúmeras situações de vento e configuração de voo do RPAS. O coeficiente de correlação entre os dados reais de campo e os resultados do processamento da RNA na distância y foi de 99,96%.

A velocidade e a direção do vento alteram a distribuição das cápsulas. Por exemplo, vento de cauda ou de proa alteraram a distribuição das cápsulas na direção de deslocamento do RPAS (distância y). Vento lateral atingindo o RPAS altera a distribuição das cápsulas no sentido perpendicular ao deslocamento (distância x) do RPAS. Ou seja, quando o RPAS recebe vento de cauda a cápsula tende a aterrizar mais próximo do alvo na direção de deslocamento do RPAS (distância y), enquanto que em vento de proa, a cápsula tende a aterrizar em distâncias maiores do alvo na direção de deslocamento do RPAS (distância y), e em ventos laterais, a cápsula tende a aterrizar a maiores distâncias do alvo na direção perpendicular ao deslocamento do RPAS (distância x).

Na direção x , o fator que menos influência na distribuição das cápsulas é a velocidade de deslocamento do RPAS. Nesta direção, pode-se ter uma melhor ideia como a velocidade do vento, direção do vento e o erro de navegação influenciam na distribuição das cápsulas. Com ventos laterais mais fortes, as cápsulas aterrizaram até 8 m de distância na direção x em relação ao alvo.

Após o treinamento da rede neural, obteve-se as previsões com valores próximos aos dados reais de campo observados na Tabela 2.

Tabela 2. Comparação entre dados reais (distância x), previsões da rede neural após treinamento

AD(m)	VD(m/s)	VV(m/s)	DV(graus)	DR(m)	RRN(m)
6	5	1,1	78,8	-2,5	-2,5
6	6,5	1,1	75,1	-1,5	-1,8
18	6,5	1,54	100,3	0,5	-0,5
18	8	1,54	100,5	1	1,1
24	2	3,56	288,6	3	3
6	2	3,54	40,7	0,8	-0,4
12	2	5,0	212,6	-1,3	-1,5
12	2	5,3	218,8	-1,4	-1,5
12	5	5,0	251,4	-2,8	-2,7
12	5	5,0	231,2	-2,9	-2,7
18	5	0,95	110,4	-2,4	-2,5
18	8	1,58	331,2	1,1	1,4
18	6,5	3,0	336,1	-3,5	-3,7
24	5	3,8	267,5	2,5	2,5
24	5	2.313	151,8	1,4	1,4
6	6,5	8,22	230,5	8	7,5
12	2	5,61	189,5	-4,8	-4,5
18	8	4,43	246,1	4,4	4,8

AD= altura do RPAS; VD=velocidade do RPAS; VV= velocidade do vento; DV= direção do vento; DR= dados reais distância x; RRN=resultados rede neural distância x.

A Figura 13 apresenta a correlação entre dados reais (DR distância x) e resultados da rede neural (RRN).

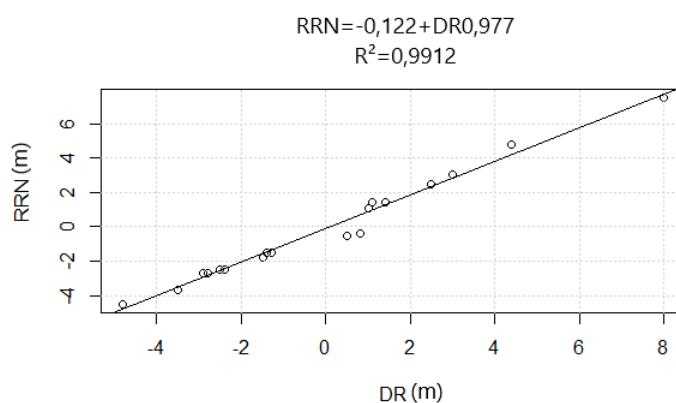


Figura 13: Correlação entre dados reais (DR distância x) e resultados da rede neural (RRN). F-estatística 905,1; p-valor < 1.64⁻¹⁵.

A rede neural provou prever onde as cápsulas irão depositar na distância x em inúmeras situações de vento e configuração de voo do RPAS. O coeficiente

de correlação entre os dados reais (distância x) de campo e os resultados do processamento da rede neural na distância x foi de 99,12% (Figura 13).

Todos os resultados apresentados neste trabalho apontam para o fato que as condições de voo e de vento afetam significativamente no padrão de distribuição das cápsulas liberadas pelo RPAS.

Supondo um cenário em que o RPAS não possua um sistema automático de correção durante a navegação, e o usuário não faça nenhuma correção durante a programação da missão automatizada, pode ocorrer sobreposição entre os pontos, e as bordas da área ficarem sem a presença do parasitoide. E durante a entrada do RPAS na lavoura, as cápsulas podem aterrizar fora da área desejada, ou durante a saída do RPAS aterrizar antes do ponto desejado, ficando áreas sem parasitoide para parasitar os ovos das pragas.

Em casos de aplicação variada, o RPAS pode distribuir mais cápsulas que o necessário, ou liberar menos cápsulas em áreas que necessitam de maior densidade populacional do parasitoide.

Estes fatos indesejáveis podem ser atenuados utilizando o modelo de rede neural proposto neste trabalho. Um controlador de voo poderá calcular qual o melhor posicionamento que o RPAS tomará para liberar a cápsula com maior precisão.

Park *et al.* (2018) desenvolveram um sistema de RPAS para liberar o predador *Rhinoncomimus latipes* (Coleoptera: Curculionidae) sobre reboleiras de *Persicaria perfoliata* (Polygonaceae). Propuseram uma estação móvel de trabalho onde captura imagens e permite avaliar a área de trabalho em tempo real, e logo após a avaliação, as cápsulas são liberadas com precisão nas reboleiras de *P.perfoliata*, sendo este sistema de baixo custo, automático e fácil de usar.

Existem várias formas de programar um controlador de voo. Faiçal *et al.* (2017) demonstraram em uma simulação que o modelo particle swarm optimisation (PSO) melhora a aplicação aérea de defensivos agrícolas realizada por RPAS. O modelo é capaz de corrigir a rota do RPAS em condições de vento evitando assim sobreposição ou áreas sem aplicação do defensivo causada por deriva.

Teske *et al.* (2019) desenvolveram um modelo preditivo para dispersão de ácaros predadores. O modelo baseia-se na velocidade e direção do vento, velocidade e altura do RPAS. O modelo pode ser usado para liberações em

cultivos de morangos evitando problemas de distribuição destes predadores na linha de plantio.

6. RESUMO E CONCLUSÕES

As condições do vento e configurações de voo do RPAS podem afetar significativamente, a distribuição de inimigos naturais em uma lavoura. Assim a liberação precisa de cápsulas contendo inimigos naturais, utilizando um RPAS, em pontos infestados por pragas, exigirá algum nível de correção baseada em um modelo.

O principal objetivo deste estudo foi desenvolver um modelo preditivo para uma distribuição precisa de cápsulas de inimigos naturais, levando em conta fatores como velocidade do vento, direção do vento, altura do RPAS e velocidade de deslocamento do RPAS, oferecendo uma distribuição homogênea do parasitoide *Trichogramma* sp. em áreas infestadas por praga.

Dois experimentos em campo foram realizados para fornecer dados da distribuição espacial de cápsulas de inimigos naturais, liberados por um RPAS, sob diferentes condições de vento e diferentes alturas e velocidades do RPAS. Os dados foram utilizados para avaliar o desempenho do RPAS em campo, e para treinar um modelo de aprendizagem de máquina supervisionado.

A avaliação do RPAS demonstrou que, mesmo o RPAS possuindo uma boa acurácia, este perde precisão à medida que aumenta a velocidade de deslocamento e a altura do RPAS. O modelo mostrou que é possível prever com

precisão onde as cápsulas irão aterrizar, quando submetidas a ação do vento, e diferentes alturas e velocidades do RPAS.

A metodologia deste trabalho pode ser empregada em outras pesquisas, onde RPAS estão sendo amplamente utilizados na agricultura de precisão minimizando custos de forma significativa, evitando desperdícios com insumos e danos ao meio ambiente.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- Bae, T, S. (2019) Network-based RTK Performance for Drone Navigation. E3S Web of Conferences 94, 01006.
- Braquinho, E.S., Hayakawa, E.H. (2012) Proposta didática de utilização de fotografias aéreas com pipas no ensino médio. Revista Geografares, nº12, p 69-101.
- Caturegli, L., Corniglia, M., Gaetani, M., Grossl, N., Magni, S., Migliazzi, M. (2016) Unmanned Aerial Vehicle to Estimate Nitrogen Status of Turfgrasses. PLoS ONE 11(6).
- Eisenbeiss, H. A. (2004) Mini unmanned aerial vehicle (UAV): system overview and image acquisition. International Workshop on “Processing and Visualization Using Higt-Resolution Imagery”. Pitsanulok. Proceedings.
- Evans, S. G., Delaney, k. B. (2018) The V1 (Flying Bomb) attack on London (1944–1945); the applied geography of early cruise missile accuracy. Applied Geography, Vol.99, pp.44-53
- Ding, S., Li, H., Su, C., Yu, J., Jin, F. (2013) Evolutionary artificial neural networks: a review. Artif Intell Rev 39:251–260.

- Faiçal, B.S., Freitas, H., Gomes, P.H., Mano, L.Y., Pessin, G., Carvalho, A.C.P.L.F., Krishnamachari, B., Ueyama, J. (2017) An adaptive approach for UAV-based pesticide spraying in dynamic environments. *Computers and Electronics in Agriculture*, 138; 210–223.
- Giones, F., Brem, A. (2017) From toys to tools: The co-evolution of technological and entrepreneurial developments in the drone industry. *Business Horizons*, 60, 875-884.
- Hassanalian, M., Abdelkefi, A. (2017) Classifications, applications, and design challenges of drones: A review. *Progress in Aerospace Sciences*, 91, 99–131.
- Herwitz, S. R., Johnson, L. F., Dunagan, S. E., Higgins, R. G., Sullivan, D. V., Zheng, J., Lobitz, B. M., Leung, J. G., Gallmeyer, B. A., Aoyagi, M., Slye, R. E., Brass, J. A. (2004) Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support. *Computers and Electronics in Agriculture*. Volume 44, Issue 1.
- Huang, H., Deng, J., Lan, Y., Yang, A., Deng, X., Zhang, L. A. (2018) A fully convolutional network for weed mapping of unmanned aerial vehicle (UAV) imagery. *PLoS ONE* 13(4).
- James, R. (2018) The Origins of Drone Warfare.(Kettering Bug)(History Matters). *History Today*, Vol.68(4), p.8(4).
- Jensen, J. R. (2009) Sensoriamento remoto do ambiente: uma perspectiva sobre recursos terrestres. São José dos Campos, SP. Ed. Parêntese.
- Kumara, R., Aggarwal, R. K., Sharma, J. D. (2013) Energy analysis of a building using artificial neural network: A review. *Energy and Buildings* 352–358.
- Letourneau, D. K., Bothwell, S. G. (2008) Comparison of organic and conventional farms: Challenging ecologists to make biodiversity functional. *Front Ecol Environ*. *Front Ecol Environ* ; 6(8): 430–438.
- Lv, M., Shupeixiao, S., Tang, Y., He, Y. (2019) Influence of UAV flight speed on droplet deposition characteristics with the application of infrared thermal imaging. *Int J Agric & Biol Eng*; 12(3): 10–17.
- Maes, S., Grégoire, J.C., Clercq, P. (2014) Prey range of the predatory ladybird *Cryptolaemus montrouzieri*. *BioControl* 59:729–738.

- Medeiros, F. A. (2008) Utilização de um veículo aéreo não-tripulado em atividades de imageamento georeferenciado. *Ciência Rural*, Santa Maria, v 38, n. 8, p. 2375-2378.
- Miranda, L. L. D., Fracasso, J. V., Costa, V. P., Lopes, D. O. T. (2014) Dispersal of *Cotesia flavipes* in sugarcane field and implications for parasitoid releases. *Plant Protection*. v. 73, n. 2, p.163-170.
- Mogili, U. R., Deepak, B.B.V.L. (2018) Review on Application of Drone Systems in Precision Agriculture. *Procedia Computer* 133, 502–509.
- Padhy, R, P., Verma, S., Ahmad, S., Choudhury, S, K., Sa, P, K. (2018) Deep Neural Network for Autonomous UAV Navigation in Indoor Corridor Environments. *Procedia Computer Science*, 133, 643–650.
- Panagiotidis, D., Abdollahnejad, A., Surovy, P., Chifeteculo, V. (2016) Determining tree height and crown diameter from high-resolution UAV imagery. *International Journal of Remote Sensing*. v, 38. p, 2392-2410.
- Parra, J. R. P., Botelho, P. S. M., Corrêa-Ferreira, S., bento, J. M. S. (2002) *Controle Biológico: Terminologia*. Manole, 635 p.
- Park, Y. L. S., Thistle, H., Chandrana, R., Reardonc, R. (2018) Aerial release of *Rhinoncomimus latipes* (Coleoptera: Curculionidae) to control *Persicaria perfoliata* (Polygonaceae) using na unmanned aerial system. *Pest Manag Sci* 74: 141–148.
- Peña; J. M., Sánchez, J.T., Castro, A.I., Kelly, M., López-Granados, F. (2013) Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. *PLoS ONE* 8(10).
- Pinto, A.S., Parra, J. R. P., Oliveira, H. N., Arrigoni, E.D. B. (2003) Comparação de Técnicas de Liberação de *Trichogramma galloi* Zucchi (Hymenoptera: Trichogrammatidae) Para o Controle de *Diatraea saccharalis* (Fabricius) (Lepidoptera: Crambidae). *Neotropical Entomology* 32(2):311-318.
- Pratissoli, D., Vianna, U. R., Zago, H. B., Pastori, P. L. (2005) Capacidade de dispersão de *Trichogramma* em tomateiro estaqueado. Nota científica. *Pesq. agropec. Bras.* Brasília, v.40, n.6, p.613-616.

- Primicerio, J., Di Gennaro, S. F., Fiorillo, E., Genesio, L., Lugato, E., Matese, A., Vaccari, F. P. A. (2012) Flexible unmanned aerial vehicle for precision agriculture. *Precision Agriculture*.
- Prisacariu, V. (2017) The history and the evolution of uavs from the beginning till the 70s. *Journal of Defense Resources Management*, Vol.8(1), p.181(9).
- Qin, W.C., Qiu, B.J., Xue, X, Y., Chen, C., Xu, Z.F., Zhou, Q.Q. (2016) Droplet deposition and control effect of insecticides sprayed with an unmanned aerial vehicle against plant hoppers. *Crop Protection* 85, 79-88.
- Rahnemoonfar, M., Sheppard, C. (2017) Deep count: fruit counting based on deep simulated learning. *Sensors*, 17, 905.
- Rao, B., Gopi, A.G., Maione, R. (2016) The societal impact of commercial drones. *Technology in Society* v 45, p 83-90.
- Sa, I. G. Z., Dayoub, F., Upcroft, B. Perez. (2016) Deepfruits: a fruit detection system using deep neural networks. *Sensors*, 16, 1222.
- Sánchez, J.T., Granados, F.L., Serrano, N., Arquero, O., Peña, J.M. (2015) High-Throughput 3-D Monitoring of Agricultural-Tree Plantations with Unmanned Aerial Vehicle (UAV) Technology. *PLOS ONE*, DOI: 10.1371.
- Teske, A, L., Chen, G., Nansen, C., Kong, Z. (2019) Optimised dispensing of predatory mites by multicopter UAVs in wind: A distribution pattern modelling approach for precision pest management. *Biosystems engineering*. 187; 226-238.
- Tosun, E. (2016) The history of technological innovations on aerial photography from the first photograph to nowadays and their usage purposes over the past years. *International Journal of Management and Applied Science*, ISSN: 2394-7926. Volume 2.
- Tschiedel, M., Ferreira, M. F. (2002) Introdução à agricultura de precisão: Conceitos e vantagens. *Ciência Rural*, v. 32, n. 1.
- Visoni, R. M., Canalle, J. B. G. (2009) Bartolomeu Lourenço de Gusmão: o primeiro cientista brasileiro. *Revista Brasileira de Ensino de Física*, v. 31, n. 3, 3604.

- Wang, J., Lan, Y., Zhang, H., Zhang, Y., Wen, S., Yao, W., Deng, J. (2018) Drift and deposition of pesticide applied by UAV on pineapple plants under different meteorological conditions. *Int J Agric & Biol Eng*; 11(6): 5–12
- Wang, Q. (2017) The Current Research Status and Prospect of Multi-rotor UAV. *Journal of Mechanical and Civil Engineering (IOSR-JMCE)*. ISSN: 2320-334X, Volume 14, 31-35.
- Weicai, Q., Xinyu, X., Lixin, Z., Songchao, Z., Zhu, S., Wei, K., Baokun, W. (2014) The influence of unmanned helicopter spray parameters on the distribution of corn canopy fog droplets. *Journal of Agricultural Engineering* ,30(5): 50-56
- Xinyu, X., Kang T., Qin Weicai, Q., Lan, Y., Zhang, H. (2014) Drift and deposition of ultra-low altitude and low volume application in paddy field. *International Journal of Agricultural and Biological Engineering*. Vol. 7 N^o.4 23.
- Zhang, C., Kovacs, J. M. (2012) The application of small unmanned aerial systems for precision agriculture: A review. *Precision Agric* 13:693–712.