

Classificador em tempo real do tamanho de gota de um pulverizador agrícola baseado em redes neurais artificiais

Deniver R. Schutz^{1,4} Elmer A. G. Penaloza² Heitor V. Mercaldi³
Lucas J. R. Silva¹ Vilma A. Oliveira¹ Paulo E. Cruvinel⁴

¹ Departamento de Engenharia Elétrica e Computação, Escola de Engenharia de São Carlos, Universidade de São Paulo, SP
(e-mail: deniver@usp.br, voliveira@usp.br, lucasjonys@usp.br).

² Universidade Federal de Pelotas (e-mail: eagpenaloza@ufpel.edu.br)

³ Universidade Federal de São Carlos (e-mail: heitor@ufscar.br)

⁴ Embrapa Instrumentação (e-mail: paulo.cruvinel@embrapa.br)

Abstract: Among the different stages involved in agricultural production processes, agricultural spraying used for phytosanitary control encompasses a significant portion of the total production cost, and its incorrect execution can increase human and biological risks. Therefore, research is necessary to ensure the proper use of agricultural pesticides, ensuring the quality of their application. Among the quality indicators provided by the droplet spectrum, the volumetric median diameter (VMD) is one of the most commonly used. However, its analysis is based on post-application tests, thus preventing action during pesticide spraying. This research aims to implement an artificial neural network (ANN) architecture in an agricultural sprayer with direct injection technology, in order to perform real-time classification of droplet sizes based on measurements of flow rate, pressure, and fluidic resistance from the instruments on the sprayer, as well as historical operational characteristics of the machinery. Therefore, training and testing are performed based on experimental results and tables from manufacturers' technical manuals of the nozzles. The obtained results allow us to characterize that the utilized methodology provides accurate estimations of droplet sizes, thereby enhancing the quality of the application.

Resumo: Dentre as diferentes etapas envolvidas nos processos produtivos agrícolas, a pulverização agrícola utilizada para o controle fitossanitário abrange grande parte do custo total de produção e sua incorreta execução pode aumentar os riscos humanos e biológicos. Assim, pesquisas são necessárias para garantir o uso adequado de defensivos agrícolas, assegurando a qualidade da aplicação. Dentre os indicadores de qualidade, fornecidos pelo espectro de gotas, o diâmetro médio volumétrico (DMV) é um dos mais utilizados. Porém, sua análise é baseada em testes pós aplicação, consequentemente impedindo a atuação no momento da pulverização do agrotóxico. Esta pesquisa tem como objetivo a implementação de uma arquitetura de rede neural artificial (RNA) em um pulverizador agrícola com tecnologia de injeção direta, de modo a efetuar a classificação do tamanho de gotas em tempo real baseadas em medições de vazão, pressão e resistência fluídica provenientes dos instrumentos no pulverizador e históricos de características operacionais do maquinário. Assim, treinamentos e testes são realizados com base em resultados experimentais e tabelas provenientes de manuais técnicos dos fabricantes dos bicos. Resultados obtidos permitem caracterizar que a metodologia usada propiciam estimativas adequadas do tamanho de gotas, aumentando a qualidade de aplicação.

Keywords: Diâmetro médio volumétrico; Redes neurais artificiais; Sistemas inteligentes; Pulverização agrícola; Agricultura de precisão

Palavras-chaves: volume mean diameter; Artificial neural networks; Intelligent systems; Agricultural spraying; Precision agriculture.

1. INTRODUÇÃO

Esforços relacionados com a aplicação de novas tecnologias, metodologias e técnicas, aplicadas ao aumento da qualidade e eficiência no processo de aplicação de agrotóxicos têm-se mostrado promissores no uso racional de insumos agrícolas e na obtenção de ganhos em produtividade e sustentabilidade (Fountas et al., 2015; Cruvinel et al., 2020). Neste contexto, aplicações incorretas podem gerar impactos de aumento dos riscos biológicos, humanos e ambientais, assim como gerar grandes custos econômicos na lavoura.

Para uma abordagem eficiente no controle de pragas, é fundamental que as gotas apresentem um tamanho uniforme, uma vez que o tamanho de gotas influencia diretamente o depósito e a dispersão de pesticidas na lavoura. Nesse contexto, um dos descritores mais utilizados na análise de distribuição espacial do espectro de gotas é o diâmetro médio volumétrico (DMV) (Chen et al., 2020).

Diferentes métodos de medição de tamanho de gotas vem sendo apresentados na literatura explorando diferentes princípios de funcionamento. No geral os instrumentos de medição do espectro de gotas pode ser dividido entre intrusivos e não intrusivos e visam inferir qualidade no processo de pulverização agrícola (Pascuzzi et al., 2021). O método por difração de laser (Fritz and Hoffmann, 2016; Sirmour and Verma, 2019) e análise de partículas Doppler (PDPA) (Nuyttens et al., 2009), caracterizam-se como instrumentos de medição não intrusivos e são estratégias comumente empregadas em ensaios de laboratório pela alta confiabilidade. No entanto, tendem a ser de difícil implementação prática por demandarem a implementação de um laser para cada bico e pela sensibilidade à trepidações causadas pelo movimento do pulverizador. Com a ascensão das câmeras de alta velocidade, técnicas de medição do DMV baseadas em processamento de imagens foram difundidas (Vulgarakis Minov et al., 2016; Sijs et al., 2021). No entanto, esse método exige um elevado custo de processamento, além de softwares e equipamentos apropriados para sua implementação.

As medições por equipamentos intrusivos, em geral, apresentam custos de implementação relativamente menores (Privitera et al., 2023). Na agricultura de campo o monitoramento de qualidade de aplicação quanto ao tamanho de gotas é principalmente realizado após o processo de pulverização ser executado pelo uso de papeis hidrosensíveis (Mangado et al., 2013; Sijs et al., 2021). Apesar de ser um método de fácil implementação e de baixo custo, o mesmo impossibilita a execução de ações de controle e de correção em tempo real, gerando retrabalho quando aplicado incorretamente (Guler et al., 2012).

Recentemente, pesquisas veem sendo realizadas com o objetivo de desenvolver sistemas inteligentes para medir o tamanho de gotas de forma não intrusiva. Dong et al. (2023) discutem o uso de uma rede neural artificial (RNA) para relacionar o diâmetro do bico e as características intrínsecas do líquido (como viscosidade e condutividade) com o diâmetro de gota em um sistema de atomização

eletrohidrodinâmica (EHDA). Já G Peñaloza et al. (2021) desenvolve um *soft sensor* baseado em modelos paramétricos de regressão, capaz de gerar previsões de descritores de qualidade de aplicação em tempo real. No entanto, para o desenvolvimento de *soft sensors* é necessário um conjunto elevado de dados experimentais para cada tipo de bico sob diferentes valores de pressão e vazão.

No presente trabalho, é proposto um classificador de DMVs que opera em tempo real durante o processo de pulverização. Esse classificador é desenvolvido com base em uma RNA do tipo perceptron multicamadas (PMC), e seu treinamento é fundamentado na tabela de especificações disponibilizada pelo fabricante dos bicos de pulverização.

Este artigo está organizado como segue. Na Seção 2, são apresentados conceitos relacionados à avaliação da qualidade de aplicação quanto ao espectro de gotas, sendo explorados a análise através do DMV e os parâmetros que influenciam na formação da gota. Na Seção 3, é detalhada a arquitetura do classificador proposto para a estimação do DMV tendo seu processo de treinamento discutido na Seção 4. Posteriormente, na Seção 5, os resultados dos testes do classificador são analisados com base em dados experimentais. Por fim, na Seção 6, são apresentadas as conclusões decorrentes deste trabalho.

2. PRELIMINARES

Durante o processo de controle fitossanitário de forma pulverizada, o espectro de gotas resultante possui uma grande variedade de diâmetros, sendo que uma porcentagem do líquido é sempre aplicado como gotas finas, independente do modelo ou tipo de bico utilizado.

A avaliação da uniformidade do espectro de gotas é realizada em termos de DV0.1, DV0.5 e DV0.9, os quais se referem aos diâmetros que compreendem às porcentagens de 10%, 50% e 90% da distribuição do tamanho de gotas. Em termos práticos o momento estatístico DV0.5 representa o DMV da aplicação (Cruvinel et al., 2020). A Figura 1 ilustra o desenvolvimento do espectro de gotas para três diferentes aplicações. Apesar das três aplicações apresentarem o mesmo DMV a distribuição entre gotas grossas e finas são diferentes. Logo ainda que o DMV seja um importante descritor da qualidade de aplicação, outros descritores ainda devem ser utilizados na aferição da qualidade de aplicação.

A Sociedade Americana de Engenheiros Agrícolas (ASAE), do inglês *American Society of Agricultural Engineers*, através da sua norma ANSI/ASAE S5271, classifica as gotas com base no DMV como Extremamente Fino *XF*, Muito Fino *VF*, Fino *F*, Médio *M*, Grosso *C*, Muito Grosso *VC*, Extremamente Grosso *XC* e Ultra Grosso *UC* (ASABE, 2009). Na Tabela 1 estão descritas as categorias de classificação de diâmetros, a caracterização por cores e a simbologia de cada tamanho de gotas.

Do ponto de vista prático, ter conhecimento sobre a distribuição do espectro de gotas no processo de pulverização é de grande importância pela propensão da deriva, causada pela ação do vento em gotas pequenas, e deposição incorreta do produto na planta, devido à maior energia cinética em gotas grandes. O espectro de gotas está diretamente ligada a qualidade e a eficiência da aplicação, que por sua

* Esta pesquisa contou com o suporte da CNPq processo 88887.703189/2022-00, Embrapa Instrumentação processo 11.14.09.001.05.06.001 e FAPESP processo 2022/00628-9.

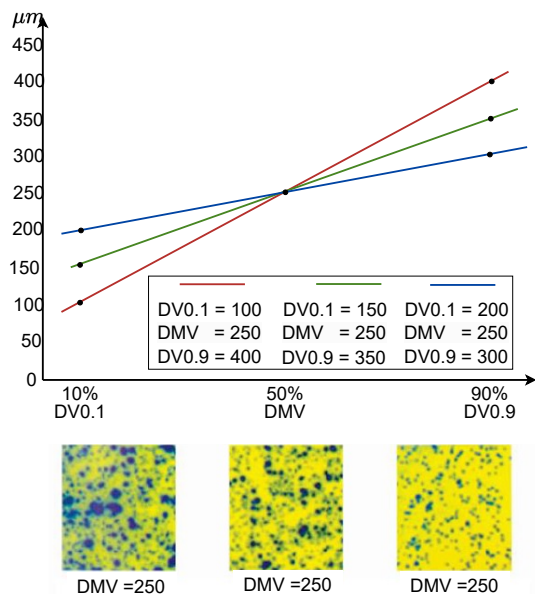


Figura 1. Discordância na distribuição do espectro de gotas em três processos de aplicação com o mesmo DMV (Cruvinel et al., 2020).

Tabela 1. Classificação de tamanho de gotas

Categorias	Simbologia	Cor	Tamanho
Extremamente fina	XF	Roxo	-
Muito fina	VF	Vermelho	$< 100\mu m$
Fina	F	Laranja	$100 - 175\mu m$
Médio	M	Amarelo	$175 - 250\mu m$
Grossa	C	Azul	$250 - 375\mu m$
Muito grossa	VC	Verde	$375 - 450\mu m$
Extremamente grossa	XC	Branco	$> 450\mu m$
Ultra Grossa	UC	Preto	-

Fonte: ASABE (2009).

vez relaciona-se com o tipo de cultura cultivada, por exemplo, no cultivo do algodão para produtos pré-emergentes¹ ou sistêmicos² a aplicação de gotas grossas ou muito grossas é a mais indicada (Costa and Sofiatti, 2015). Já gotas médias ou finas são indicadas para produtos pós-emergentes³ e de contato⁴.

A uniformidade de distribuição das gotículas depende de fatores internos, associados ao maquinário agrícola, e fatores externos, correlacionados com o clima e características do terreno. Gaytan et al. (2018) avaliam os efeitos da pressão de trabalho, temperatura do fluido, tipo de bico e tamanho do orifício da ponta na qualidade de distribuição das gotículas de pulverização. Resultados evidenciam maior concentração de gotas finas quando operado a alta temperatura e/ou alta pressão, enquanto em aplicações de

¹ Herbicidas pré-emergentes visam controlar plantas daninhas no início da instalação da lavoura, de modo que as plantas daninhas não compitam com as sementes emergentes.

² Produtos absorvidos pelas raízes e folhas e transportados para a planta (Lingenfelter and Hartwig, 2017).

³ Herbicidas pós-emergentes são indicados para controlar plantas daninhas após a germinação da cultura, sem que essa seja afetada (Costa and Sofiatti, 2015).

⁴ Produto que entra em contato direto com a folhagem da planta, sem afetar as raízes.

baixa temperatura e/ou baixa pressão a distribuição de gotas grossas é maior. O estudo de Nuyttens et al. (2009) demonstram que a velocidade de ejeção das gotas varia de acordo com o tipo e tamanho do bico, mesmo quando a pressão de operação é a mesma. Evidenciando que, as propriedades físicas do bico estão diretamente relacionadas à quantidade de distribuição do líquido, ao risco de dispersão indesejada e à profundidade de penetração na cultura.

De forma específica fatores internos estão relacionados as condições operacionais do pulverizador, como pressão na barra, vazão nos bicos, temperatura interna, os quais no geral podem ser controlados ou regulados. Em contrapartida, fatores externos não podem ser controlados ou regulados e contribuem ao efeito de deriva e na variação do tamanho de gotas, como exemplos estão a força e a direção do vento, umidade e temperatura, inclinação do terreno e mudanças topográficas. No entanto, efeitos negativos do ambiente podem ser minimizados selecionando o tipo correto de bico, com base no tipo de aplicação e prescrição necessária (Cruvinel et al., 2020).

3. TOPOLOGIA DO CLASSIFICADOR BASEADO EM RNA PARA O RECONHECIMENTO DO DMV

Dentre as arquiteturas de RNA a PMC é uma das mais conhecidas devido a sua versatilidade e flexibilidade de aplicações, sendo muito utilizada em problemas de classificação de padrões. A aplicação da PMC demonstra grande potencial para classificar o tamanho das gotas, dado que as classes já estão definidas previamente e apresentam valores que podem ser linearizados conforme as categorias da Tabela 1. As PMC's caracterizam-se pela associação entre duas ou mais camadas de neurônios artificiais, sendo pelo menos uma dessas, uma camada intermediária (camada oculta) localizada entre as camadas neurais de entrada e saída (Da Silva et al., 2017). A partir da interconexão de neurônios e de um conjunto de informações, a PMC é capaz de adquirir e conservar conhecimento (Da Silva et al., 2017), permitindo a utilização desse tipo de RNA em sistemas de classificação de resultados.

A Figura 2 apresenta a topologia da rede PMC, com uma camada de entrada, uma camada oculta e uma camada de saída, aplicada na estimação do DMV. A arquitetura proposta possui como entradas a pressão na barra de bicos P_b , a vazão de calda Q_b e a resistência fluidica do bico K_{qn} . Essas entradas são determinadas com base nos estudos de Nuyttens et al. (2009) e Gaytan et al. (2018), que demonstram que o tipo de bico, associado com a vazão e a pressão, são fatores determinantes do tamanho de gotas. A resistência fluidica é utilizada como o parâmetro que descreve o orifício e o tipo de bico.

As saídas do modelo RNA geram o vetor de codificação sequencial contendo o diâmetro médio volumétrico estimado \widehat{DMV} , classificados com base na informação da Tabela 1. Logo é estabelecido uma topologia com três entradas e m saídas. A quantidade de neurônios e de camadas escondidas são estipuladas durante o processo de treinamento, visando menor erro quadrático médio e melhor generalização da rede.

Adicionalmente, a entrada K_{qn} foi incluída para permitir a entrada de outros tipos de bicos, e assim obter uma versão




Figura 2. Rede perceptron multicamadas proposta, adaptado de Da Silva et al. (2017).

mais generalizada da rede. Com base nisso a PMC será treinada para os bicos tipo cone cheio da MagnoJet[®]: M059/01-CH0.5 à M063/1-CH06 e para os bicos tipo jato plano da ARAG[®]: 422SF11001 à 422SF11010. Os bicos são escolhidos de modo a generalização para diferentes bicos, sobre diferentes valores de pressão e vazão. Inicialmente são treinadas uma rede específica para os bicos jato plano e outra para os bicos cone cheio. Posteriormente, os dados provenientes das duas classes são combinados, visando avaliar a capacidade de desenvolver uma rede neural capaz de classificar o DMV para diferentes tipos de bicos.

4. PROCESSO DE TREINAMENTO DA RNA PARA CLASSIFICAÇÃO DO DMV

Com base na arquitetura proposta e ilustrada na Figura 2 resultados preliminares evidenciam menor erro ao utilizar $n_1 = 15$. São realizados quatro treinamentos, e ao final é selecionada a matriz de peso com o menor erro quadrático médio (EQM) e maior porcentagem de acertos na fase de validação. No processo de treinamento, são utilizados os dados das tabelas dos fabricantes dos bicos jato plano da ARAG[®] e cone cheio da MagnoJet[®]. Afim de aumentar o número de amostras de treinamento é realizada uma interpolação linear sobre os valores de vazão, variando-se a pressão nos bicos em 0.01 bar a cada amostra interpolada, resultando em um total de 1428 amostras para os bicos ARAG[®] e 816 amostras para os bicos MagnoJet[®]. Dos dados disponíveis 90% são destinados para o treinamento e 10% para validação. Para a fase de testes serão utilizados dados experimentais apresentados na Seção 5. Vale ressaltar que os valores de validação não são utilizados no processo de treinamento.

Os dois primeiros treinamentos são gerados para os dois tipos de bicos, jato plano e cone cheio, separadamente. Em seguida, um terceiro treinamento é efetuado utilizando os dados dos dois tipos de bicos em conjunto. Para cada neurônio, é utilizada a função de ativação logística, taxa de aprendizagem de $\eta = 0,01$ e como critérios de parada do treinamento precisão $\varepsilon = 10^{-12}$ e 6000 épocas.

As informações da execução dos treinamentos e os resultados dos erros quadráticos médios são apresentados na Tabela 2 para o bico ARAG[®], MagnoJet[®] e ambos em conjunto.

As validações utilizando os bicos ARAG[®] e MagnoJet[®], apresentaram no melhor dos casos 93,01% e 98,78% de acerto respectivamente. Sendo ambos tendo atendendo o EQM como critério de parada. Já com a união dos

Tabela 2. Resultados dos treinamentos.

Treinamento	EQM ($1e^{-12}$)	Épocas	Tempo (s)	Acerto na validação (%)
Arag[®]				
a	4,07	3241	371,87	88,12
b	6,98	3867	444,61	90,91
c	6,75	4635	538,70	93,01
d	3,87	2634	301,2	89,51
MagnoJet[®]				
a	6,65	1048	69,67	96,34
b	1,02	993	65,5	96,34
c	1,59	4193	274,36	98,78
d	1,60	6000	391,88	97,56
Conjunto: Arag[®] e MagnoJet[®]				
a	4,87	3450	623,97	81,7
b	28,1	6000	1074,18	86,16
c	2,31	1728	309,12	81,25
d	3,64	1877	33,13	79,1

dados dos dois fabricantes todos os treinamentos realizados apresentaram uma porcentagem de acerto menor que 90%. Isso evidencia que adição do K_{qn} como uma das entradas ao modelo de classificação, mostra-se eficiente quanto a distinção do bico utilizado, porém a aplicabilidade quanto à dois tipos diferentes de bicos pode trazer ambiguidade de resultados, uma vez que bicos de formato diferentes podem apresentar a mesma resistência fluidica contudo tamanho de gotas distintos.

5. ANÁLISE EM RESULTADOS EXPERIMENTAIS

Através de um sistema de desenvolvimento de pulverizadores agrícolas (SDPA), apresentada em Felizardo et al. (2013) e Cruvinel et al. (2020), são coletados dados de vazão e pressão utilizando os bicos MagnoJet. Em seguida esses dados são enviados à RNA afim de testar a classificação do DMV em resultados experimentais.

Os diagramas de blocos apresentados na Figura 3 ilustram os componentes do conjunto modulo de pulverização do SPDA e o modelo do classificador do diâmetro DMV. Maiores detalhes da arquitetura de *hardware* e *software* do SPDA utilizados são apresentados em Schutz et al. (2021), Schutz et al. (2022) e Felizardo et al. (2013).

Os ensaios foram realizados com os bicos CH06, CH03, CH01 e CH0,5 utilizando o controlador GPC para controlar a vazão, conforme apresentado em Schutz et al. (2021). A Tabela 3 apresenta os parâmetros utilizados nos ensaios experimentais. O experimento foi executado 5 vezes, por fim uma média dos parâmetros é obtida. Cada experimento possui um tempo de duração de 129 segundos, com amostragem realizada a cada 0,3 segundos. Isso resulta em um total de 430 amostras por ensaio. Os resultados são apresentados nas Figuras 4 5, 6 e 7 e ilustram a vazão nos bicos Q_b , a pressão na barra P_b e o DMV estimado para os quatro bicos. São escolhidos os pesos sinápticos da rede de treinamento c geradas a partir do catálogo do fabricante Magnojet[®].

Nas Figuras 4 5, 6 apesar de ter-se valores de leitura de pressão e vazão abaixo do disponibilizado pela tabela do fabricante, pode-se observar que a RNA apresentou resultados de estimativa coerentes, uma vez que é esperado um aumento do DMV para valores baixos de pressão, conforme destacado por Gaytan et al. (2018).

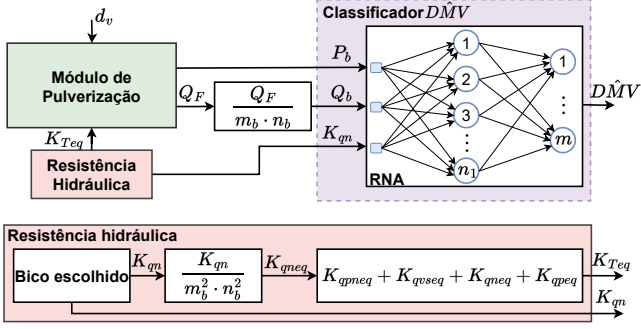


Figura 3. Diagrama de blocos: A vazão na barra de pulverização Q_F é controlada por um duty-cycle d_v advindo de um sinal PWM de um controlador GPC, conforme apresentado em Schutz et al. (2021, 2022). A resistência fluídica equivalente total K_{Teq} é dada pela somatória das resistências fluídicas equivalentes dos componentes do sistema de pulverização: válvulas de seção K_{vseq} , nas tubulações entre os bicos K_{qpneq} , na tubulação entre as válvulas de seção e os bicos K_{qppeq} e a resistência equivalente dos n_b bicos de pulverização K_{qneq} distribuídos nas m_b barras.

Tabela 3. Parâmetros do módulo de pulverização (Felizardo et al., 2013).

Parâmetros	Valores
K_{qvseq}	10, 210 ⁻³
K_{qpneq}	54, 510 ⁻³
m_b	2
n_b	2 rad/V
K_{qneq}	2310 ⁻⁴
K_{qppeq}	11, 3310 ⁻²
K_{qn} (CH0.5)	1080, 1818 KPa/(l/min) ²
K_{qn} (CH01)	338, 74 KPa/(l/min) ²
K_{qn} (CH03)	157, 02 KPa/(l/min) ²
K_{qn} (CH06)	62, 47 KPa/(l/min) ²

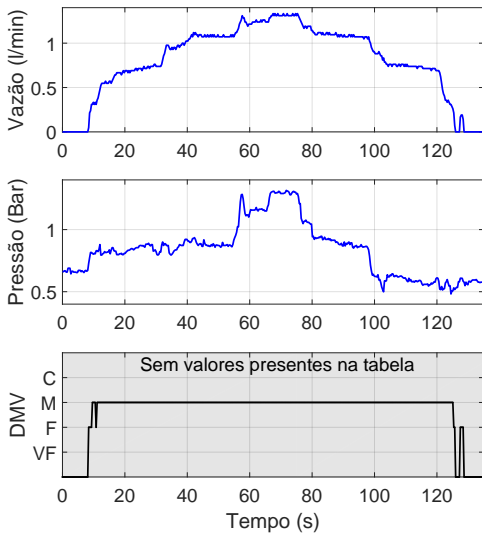


Figura 4. Resultados experimentais: MagnoJet[®] CH06.




Figura 5. Resultados experimentais: MagnoJet[®] CH03.

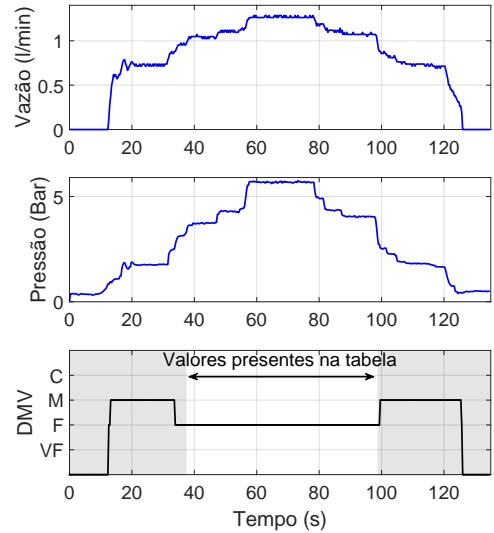


Figura 6. Resultados experimentais: MagnoJet[®] CH01.




Figura 7. Resultados experimentais: MagnoJet[®] CH05.

6. CONCLUSÃO

Neste projeto, a implementação de uma RNA do tipo PMC como classificador de DMVs foi discutida e avaliada. A rede neural é treinada a partir dos dados fornecidos pela tabela de prescrição do próprio fabricante dos bicos de pulverização, sendo utilizados bicos do tipo cone cheio da MagnoJet[®] e jato plano da Arag[®]. Resultados mostraram-se promissores para a estimação do DMV durante o processo de aplicação de agrotóxicos na lavoura, facilitando o controle de qualidade e permitindo intervenções durante a pulverização, visando qualidade da aplicação.

A utilização da resistência fluidica como parâmetro de entrada para a rede neural possibilitou o aprendizado para bicos do mesmo tipo porém com diâmetros de abertura diferentes. Porém, quando utilizado bicos de diferentes classes (como por exemplo cone cheio e jato plano), à porcentagem de acerto diminui, uma vez que para os mesmos valores de P_s , Q_b e K_{qn} , bicos de classes diferentes apresentam DMV distintos. Logo, para trabalhos futuros é proposta a implementação de uma nova entrada capaz de generalizar a RNA para diferentes classes de bicos. Pretende-se também formar uma base de treinamento mais robusta com base em testes em campo. Além disso, serão avaliados a utilização de outros algoritmos para a classificação como Floresta Aleatória e o SVM (*Support Vector Machine*).

REFERÊNCIAS

- ASABE (2009). Spray nozzle classification by droplet spectra.
- Chen, S., Lan, Y., Zhou, Z., Ouyang, F., Wang, G., Huang, X., Deng, X., and Cheng, S. (2020). Effect of droplet size parameters on droplet deposition and drift of aerial spraying by using plant protection uav. *Agronomy*, 10(2), 195.
- Costa, A.G.F. and Sofiatti, V. (2015). *Manejo de Plantas Daninhas na Cultura do Algodoneiro (Management of Weeds in the Cotton Crop)*. Embrapa, Brasília, DF.
- Cruvinel, P.E., Mercaldi, H.V., Andrade, P.B., and Peñaloza, E.A. (2020). Real-time evaluation of failure and reliability in agricultural sprayers using embedded sensors and controller area bus protocol. *International Journal on Advances in Systems and Measurements*, 13, 15.
- Da Silva, I.N., Spatti, D.H., Flauzino, R.A., Liboni, L.H.B., and dos Reis Alves, S.F. (2017). Artificial neural networks. *Cham: Springer International Publishing*, 39.
- Dong, T., Wang, J.X., Wang, Y., Tang, G.H., Cheng, Y., and Yan, W.C. (2023). Development of machine learning based droplet diameter prediction model for electrohydrodynamic atomization systems. *Chemical Engineering Science*, 268, 118398.
- Felizardo, K.R., Mercaldi, H.V., Oliveira, V.A., and Cruvinel, P.E. (2013). Modeling and predictive control of a variable-rate spraying system. In *2013 8th EUROSIM Congress on Modelling and Simulation*, 202–207. Cardiff, UK.
- Fountas, S., Carli, G., Sørensen, C.G., Tsiropoulos, Z., Cavalaris, C., Vatsanidou, A., Liakos, B., Canavari, M., Wiebensohn, J., and Tisserye, B. (2015). Farm management information systems: Current situation and future perspectives. *Computers and Electronics in Agriculture*, 115, 40–50.
- Fritz, B.K. and Hoffmann, W.C. (2016). Measuring spray droplet size from agricultural nozzles using laser diffraction. *JoVE (Journal of Visualized Experiments)*, (115), e54533.
- G Peñaloza, E.A., A Oliveira, V., and Cruvinel, P.E. (2021). Using soft sensors as a basis of an innovative architecture for operation planning and quality evaluation in agricultural sprayers. *Sensors*, 21(4), 1269.
- Gaytan, I., Nicolas, B., Gouriou, F., Leru, J., and Mallarach, J. (2018). Effect of working pressure, fluid temperature, nozzle type and nozzle orifice size, on spray characteristics using viscous feed additive dl-2-hydroxy-4-(methylthio)-butanoic-acid. *Powder Technology*, 336, 383–392.
- Guler, H., Zhu, H., Ozkan, H.E., and Ling, P. (2012). Characterization of hydraulic nozzles for droplet size and spray coverage. *Atomization and Sprays*, 22(8).
- Lingenfelter, D.D. and Hartwig, N.L. (2017). Weed management. Accessed 21 July 2017.
- Mangado, J., Arazuri, S., Arnal, P., Jarén, C., and López, A. (2013). Measuring the accuracy of a pesticide treatment by an image analyzer. *Procedia Technology*, 8, 498–502.
- Nuyttens, D., De Schampheleire, M., Verboven, P., Bruselman, E., and Dekeyser, D. (2009). Droplet size and velocity characteristics of agricultural sprays. *Transactions of the ASABE*, 52(5), 1471–1480.
- Pascuzzi, S., Manetto, G., Santoro, F., and Cerruto, E. (2021). A brief review of nozzle spray drop size measurement techniques. In *2021 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgri-For)*, 351–355. IEEE.
- Privitera, S., Manetto, G., Pascuzzi, S., Pessina, D., and Cerruto, E. (2023). Drop size measurement techniques for agricultural sprays: A state-of-the-art review. *Agronomy*, 13(3), 678.
- Schutz, D.R., Mercaldi, H.V., Penaloza, E.A., Oliveira, V.A., and Cruvinel, P.E. (2022). An intelligent fuzzy-gpc control for agricultural sprayers: Comparison between GPC and PID fuzzy controllers. In *APCA International Conference on Automatic Control and Soft Computing*, 272–284. Springer.
- Schutz, D.R., Oliveira, V.A., Mercaldi, H.V., Penaloza, E.A., and Cruvinel, P.E. (2021). Controlador preditivo para uso em pulverizadores agrícolas com simulador operando em hardware-in-the-loop. In *Simpósio Brasileiro de Automação Inteligente (SBAI)*, volume 1 of 1. doi: 10.20906/sbai2021/216343.
- Sijs, R., Kooij, S., Holterman, H., Van De Zande, J., and Bonn, D. (2021). Drop size measurement techniques for sprays: Comparison of image analysis, phase doppler particle analysis, and laser diffraction. *AIP advances*, 11(1).
- Sirmour, A. and Verma, A. (2019). Droplet size characterization of agricultural sprays using laser diffraction. *Int. J. Chem. Stud.*, 7, 2895–2899.
- Vulgarakis Minov, S., Cointault, F., Vangeyte, J., Pieters, J.G., and Nuyttens, D. (2016). Spray droplet characterization from a single nozzle by high speed image analysis using an in-focus droplet criterion. *Sensors*, 16(2), 218.