



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM FITOTECNIA
DOUTORADO EM FITOTECNIA

ALEX LIMA MONTEIRO

**USO DE REGRESSÃO LINEAR MÚLTIPLA E REDES NEURAS ARTIFICIAIS
NA ESTIMATIVA DA INTERFERÊNCIA DE PLANTAS DANINHAS EM
CULTIVOS AGRÍCOLAS**

MOSSORÓ

2020

ALEX LIMA MONTEIRO

**USO DE REGRESSÃO LINEAR MÚLTIPLA E REDES NEURAS ARTIFICIAIS
NA ESTIMATIVA DA INTERFERÊNCIA DE PLANTAS DANINHAS EM
CULTIVOS AGRÍCOLAS**

Tese apresentada ao Programa de Pós-Graduação em Fitotecnia da Universidade Federal Rural do Semi-Árido como requisito para obtenção do título de Doutor em Fitotecnia.

Linha de Pesquisa: Proteção de plantas

Orientador: Prof. D. Sc. Aurélio Paes Barros Júnior.

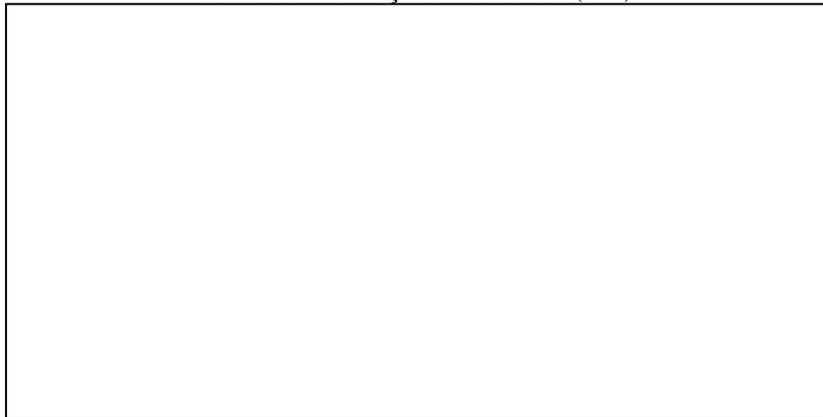
Co-orientador: Prof. D. Sc. Daniel Valadão Silva.

MOSSORÓ

2020

©Todos os direitos estão reservados à Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996, e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tornar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata, exceto as pesquisas que estejam vinculadas ao processo de patenteamento. Esta investigação será base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) seja devidamente citado e mencionado os seus créditos bibliográficos.

Dados Internacionais de Catalogação na Publicação (CIP)
Biblioteca Central Orlando Teixeira (BCOT)
Setor de Informação e Referência (SIR)

A large, empty rectangular box with a black border, intended for the CIP (International Cataloguing in Publication) data.

Bibliotecário-Documentalista
Nome do profissional, Bib. Me. (CRB-15/10.000)

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

ALEX LIMA MONTEIRO

**USO DE REGRESSÃO LINEAR MÚLTIPLA E REDES NEURAIIS NA
ESTIMATIVA DA INTERFERÊNCIAS DE PLANTAS DANINHAS EM
CULTIVOS AGRÍCOLAS**

Tese apresentada ao Programa de Pós-Graduação em Fitotecnia da Universidade Federal Rural do Semi-Árido como requisito para obtenção do título de Doutor em Fitotecnia.

Linha de Pesquisa: Proteção de plantas

Defendida em: 18 / 12 / 2020

BANCA EXAMINADORA



Prof. D. Sc. Aurélio Paes Barros Junior (UFERSA)
Presidente (Orientador)



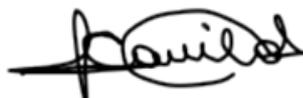
Prof. D. Sc. Daniel Valadão Silva (UFERSA)
Membro Examinador Interno (Co-orientador)



Matheus de Freitas Souza, Dr. (UFERSA)
Membro Examinador Interno



Stefeson Bezerra de Melo, Prof. Dr. (UFERSA)
Membro Examinador Externo



Camila Ferreira de Pinho, Prof.^a Dra. (UFRRJ)
Membro Examinadora Externa

Ao meu pai, Francisco Hercílio Monteiro, que hoje estaria muito feliz em saber que seu esforço para me manter no caminho do conhecimento me levou a muito longe (In Memoriam).

Dedico

A minha Mãe, Maria Lúcia Lima Monteiro, a minha esposa, Karla Munique Paula Barros Monteiro, pela confiança e apoio na realização deste sonho.

AGRADECIMENTOS

A Deus, pela saúde que me concede a cada dia para desempenhar o meu trabalho.

Aos meus pais, Maria Lucia Lima Monteiro e Francisco Hercílio Monteiro, por todo o esforço para me manter estudando.

A minha família pelo incentivo e apoio.

À Universidade Federal Rural do Semi-Árido, pela oportunidade de concluir mais uma formação acadêmica.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa.

Aos professores Aurélio Paes Barros Junior e Daniel Valadão Silva, pela oportunidade, apoio e confiança na condução dos trabalhos de pesquisa. Ao amigo Matheus de Freitas Souza, por sua grande ajuda no desenvolvimento deste e de outros trabalhos e por todo o ensinamento repassado durante o período de doutorado. À professora Lindomar Maria da Silveira, por toda a ajuda e ensinamentos.

A todos os professores e funcionários do programa de Pós-graduação em Fitotecnia, pelos ensinamentos, ajuda e por se mostrarem sempre disponíveis.

Ao Grupo de Estudos e Pesquisa em Produção Agrícola e Recursos Genéticos Vegetais (GEPPARG), Flavio Silveira, Pedro Ramon, Welder de Araújo, Manoel Galdino, Gisele Santos, Silvana Fraga, José Artur, Michele Barboza, Valécia Nogueira, Francisco Adênio, Fernanda Larisse, José Ricardo, Hamurábi Anizio, Ênio Flôr, Anna Kézia e Ester dos Santos, por toda a ajuda na condução dos experimentos.

Ao Núcleo de Estudos em Matologia no Semiárido (NOMATO), Ana Beatriz, Hamurábi Lins, Tatiane Silva, Taliane Teófilo, Héliida Campos, Maria Alice, Bruno Caio, Paulo Chagas, Cássia Araújo, Cydianne Pinheiro, Fernando Sarmiento, Karoline Viana, Lidiane Martins, Jesley Bandeira, Quésia Pavão, Mateus Pará, Beatriz Menezes, Odonil, Márcio Abraão, Cláudia Daianny, Juliana Pamplona, Maiara Borges, Antônio Bisneto e Murilo Soares, por todo o apoio na condução dos experimentos.

Aos funcionários Sr. Antônio, Alderí, Nanan, Josimar e Flabênio, pela contribuição essencial na condução do trabalho em campo.

Aos técnicos da UFERSA Francisco das Chagas e Renan Paulino, por todo o apoio.

A minha esposa, Karla Munique Paula Barros, pelo companheirismo, apoio, paciência e acreditar em minhas escolhas.

Agradeço aos professores membros da banca examinadora, pelos ensinamentos e contribuição no desenvolvimento deste estudo.

Enfim, agradeço a todos os que de alguma forma contribuíram para que esse sonho se tornasse possível.

RESUMO

A eficiência no controle das plantas daninhas nos cultivos agrícolas depende da adoção do método de controle na época correta, minimizando a interferência da comunidade infestante. Todavia, a definição do início e fim da época de controle é de difícil mensuração pelo produtor devido às particularidades da comunidade infestante, das culturas e das condições de manejo e edafoclimáticas de cada local de cultivo. Uma das alternativas para a solução deste problema é o uso de modelos baseados em métodos estatísticos ou métodos de aprendizado de máquina desenvolvidos no campo da inteligência artificial que possam ser adequados para fazer previsões da perda de rendimento de culturas agrícolas em virtude da interferência de plantas daninhas. Dessa forma, este estudo tem como objetivo comparar a eficácia de modelos matemáticos empíricos como as Regressões Lineares Múltiplas (RLM) com modelos de Redes Neurais Artificiais (RNAs) para modelagem da interferência de plantas daninhas em estimar o início do controle de plantas daninhas em diferentes classes de perdas de produtividades aceitáveis de culturas agrícolas. Os experimentos foram realizados durante os anos de 2016, 2017 e 2018, usando para o estudo as culturas do melão, gergelim e cebola. O delineamento utilizado foi em blocos ao acaso, com três repetições. Os tratamentos do primeiro experimento, referente à cultura da cebola foram compostos por seis períodos para o início do controle de plantas daninhas (0, 7, 14, 21, 28, 32 e 42) e expressos em dias após a emergência (DAE), ao passo que no segundo experimento, para as culturas do gergelim e do meloeiro, os períodos foram (130, 260, 390, 520, 650, 1300 e (130, 260, 390, 520, 972), respectivamente, expressos em graus dias (GD) após a semeadura do gergelim e o transplântio das mudas de melão. Os resultados demonstraram que modelos RLM baseados em entradas não destrutivas e destrutivas sobre a comunidade de plantas daninhas são capazes de estimar as perdas de produtividade da cebola, porém com baixa precisão. Os modelos de RNAs considerando apenas o período de convivência e sistema de irrigação possuem desempenho similar a modelos de Regressão Linear Múltipla. No entanto, a inserção das variáveis relacionadas à densidade de plantas daninhas (não destrutiva) e a matéria fresca (destrutiva) nos modelos de RNAs eleva a capacidade preditiva das redes para valores próximos a 99% de acerto. O modelo de RNAs que fizeram a combinação de entradas não-destrutiva (Densidade) e destrutiva (Matéria Fresca) dispensa outras entradas mais específicas, como a relação de espécies C3/C4 e Monocotiledôneas/Eudicotiledôneas (M/E). O período de interferência de plantas daninhas é o principal fator para inferir o grau de interferência das plantas daninhas nas culturas do gergelim e meloeiro. Os modelos de RNAs com melhor performance podem indicar o início do controle de plantas daninhas, uma vez que são capazes de estimar com precisão as perdas causadas pela interferência das plantas daninhas.

Palavras-chave: Modelagem, período crítico, inteligência artificial.

ABSTRACT

The efficiency of weed control in agricultural crops depends on the adoption of the control method at the right time, minimizing the interference of the weed community. However, a definition of the beginning and end of the control season is difficult to measure by the producer due to the particularities of the weed community, the crops, and the management and edaphoclimatic conditions of each cultivation site. One of the alternatives to solve this problem is the use of models based on statistical methods or methods of machine learning developed in the field of artificial intelligence that can be adequate to predict the loss of yield of agricultural cultures due to the interference of weeds. Thus, the objective was to verify if the RLM and RNAs models can predict the beginning of weed control, compare the effectiveness of RNAs with traditional sigmoidal models and also evaluate the ability of RNAs to estimate weed control for different crops and acceptable productivity loss classes and thereby validate a new alternative for modeling and predicting competition between weeds and agricultural crops. The experiments were conducted at the Rafael Fernandes Experimental Farm, Mossoró, RN. The design used was in randomized blocks, with three replications. The treatments consisted of six periods for the beginning of weed control (0, 7, 14, 21, 28, 32 and 42) days after emergence (DAE) for the onion culture and for the sesame and the melon foramen (130, 260, 390, 520, 650, 1300) and (130, 260, 390, 520, 972) degrees days (GD) after sowing sesame and transplanting melon seedlings, respectively. The RLM models based on non-destructive and destructive inputs on the weed community are able to estimate losses of onion productivity, however with low precision. The ANN models considering only the coexistence period and the irrigation system have similar performance to the Multiple Linear Regression models. However, the inclusion of variables related to weed density (non-destructive) and fresh matter (destructive) in RNA models raises the predictive capacity of networks to values close to 99% correct. The RNA model, which made a combination of non-destructive (density) and destructive (Matter Fresh) inputs, dispenses with other more specific inputs such as the C3 / C4 and Monocotyledons / Eudicotyledons (M / E) species. The weed interference period is the main factor to infer the degree of weed interference in the Sesame and Melon cultures. The models of RNAs with the best performance can indicate the beginning of weed control, since they are able to accurately estimate losses caused by weed interference.

Keywords: Modeling, critical period, artificial intelligence.

LISTA DE FIGURAS

CAPÍTULO 1

- Figura 1 - Temperatura média do ar (°C), umidade relativa (%) e precipitação (mm) durante o ciclo da cultura da cebola em 2016, 2017 e 2018. Dados obtidos na estação meteorológica na fazenda experimental.....24
- Figura 2 - Produção relativa prevista e observada da cebola cultivada sob gotejamento e microaspersão, obtidas por modelo de regressão linear múltipla com entradas não destrutivas e destrutivas, durante a fase de treinamento (esquerda) e validação (direita).37
- Figura 3 - Produção relativa prevista e observada da cebola cultivada sob gotejamento ou microaspersão, obtidas pelas redes neurais artificiais (RNAs) com entradas não destrutivas, durante a fase de treinamento, teste e validação.....41
- Figura 4 - Produção relativa prevista e observada da cebola cultivada sob gotejamento ou microaspersão, obtidas pelas redes neurais artificiais (RNAs) com entradas destrutivas, durante a fase de treinamento, teste e validação.....42
- Figura 5 - Modelos sigmoidais log-logístico (A), Weibull-1 (B) e Weibull-2 (C) aplicados para avaliar a produtividade relativa da cebola, cultivada em gotejamento e microaspersão, ao longo de períodos crescentes em convivência com plantas daninhas.....43
- Figura 6 - Desempenho das redes neurais artificiais (A e B) e o modelo sigmoidal log-logístico (C) para estimar as perdas de produção relativa da cebola, cultivadas sob gotejamento ou microaspersão, devido à competição durante a fase de validação.....44
- Figura 7 - Importância relativa das entradas para composição das redes neurais MLP 5-10-1 (não destrutivas) e MLP 5-18-1 (Destrutiva).....46

CAPÍTULO 2

- Figura 1 - Temperatura média do ar ($^{\circ}$ C), umidade relativa (%) e precipitação (mm) durante o ciclo da cultura da cebola em 2016 e 2017. Dados obtidos na estação meteorológica do campo experimental da UFERSA.....59
- Figura 2 - Visão geral da RNA – MLP para o modelo misto (entradas não destrutivas e destrutivas).....65
- Figura 3 - Pseudo-probabilidade (direta) e Curva Característica Operacional do Receptor (COR, esquerda) da rede neural artificial MLP com melhor desempenho (Cultura, Período, Densidade e C3/C4) para estimar o controle de plantas daninhas considerando o método não destrutivo. Linha vermelha determina o limite para pseudo-probabilidade (0,5).....70
- Figura 4 - Pseudo-probabilidade (direta) e Curva Característica Operacional do Receptor (COR, esquerda) da rede neural artificial MLP com melhor desempenho (Cultura, Período, Matéria fresca, e C3/C4) para estimar o controle de plantas daninhas considerando o método destrutivo. Linha vermelha determina o limite para pseudo-probabilidade (0,5).....75
- Figura 5 - Pseudo-probabilidade (direta) e Curva Característica Operacional do Receptor (COR, esquerda) da rede neural artificial MLP selecionada (Cultura, Período, Densidade, e matéria fresca) para estimar o controle de plantas daninhas considerando o método não destrutivo e destrutivo.....78
- Figura 6 - Importância normalizada e absoluta das variáveis de entrada para a rede neural artificial MLP com melhor desempenho pelos métodos não destrutivo (A), destrutivo (B) e não destrutivo e destrutivo (C).....80

LISTA DE TABELAS

CAPÍTULO 1

- Tabela 1 - Análises físico-químicas de solo cultivado com cebola para os anos 2016, 2017, 2018. Mossoró - RN, 2019.....23
- Tabela 2 - Correlação de Pearson para as variáveis dependentes e independentes avaliadas.....32
- Tabela 3 - Modelo de regressão linear múltipla e índice de desempenho (R^2 , MAE e RMSE) para estimar as perdas de produtividade relativa da cebola cultivada sob gotejamento e microaspersão devido à interferência com plantas daninhas.....33
- Tabela 4 - Desempenho das redes neurais artificiais (RNAs) durante as etapas de treinamento, validação e teste para estimar as perdas de produtividade relativa da cebola cultivada sob gotejamento ou microaspersão considerando entradas não destrutivas.....38
- Tabela 5 - Desempenho das redes neurais artificiais (RNAs) durante as etapas de treinamento, validação e teste para estimar as perdas de produtividade relativa da cebola cultivada sob gotejamento ou microaspersão considerando entradas destrutivas.....40

CAPÍTULO 2

- Tabela 1 - Caracterização química do solo na área de cultivo do melão e gergelim. UFERSA, 2016 e 2017.....59
- Tabela 2 - Correlação de Pearson e estatística descritiva das variáveis de entrada obtidas usadas na construção das redes neurais artificiais MLP para as culturas do gergelim e melão.....67
- Tabela 3 - Desempenho das redes neurais artificiais MLP nas etapas de treinamento, validação e teste para perdas aceitáveis de 2,5, 5 e 10%,

considerando diferentes variáveis de entrada pelo método não destrutivo.....69

Tabela 4 - Desempenho das redes neurais artificiais MLP nas etapas de treinamento, validação, e teste para perdas aceitáveis de 2,5, 5 e 10%, considerando diferentes variáveis de entrada pelo método destrutivo.....72

Tabela 5 - Desempenho da rede neural artificial MLP nas etapas de treinamento, validação e teste para perdas aceitáveis de 2,5, 5 e 10%, considerando as variáveis de entrada pelo método não-destrutivo e destrutivo.....77

SUMÁRIO

INTRODUÇÃO GERAL	14
REFERÊNCIAS.....	16
CAPÍTULO 1: MODELOS DE REGRESSÃO LINEAR MÚLTIPLA E REDES NEURAIAS NA PREDIÇÃO DA ÉPOCA DO CONTROLE DAS PLANTAS DANINHAS NA CULTURA DA CEBOLA	18
RESUMO	18
ABSTRACT	19
1. INTRODUÇÃO	20
2. MATERIAL E MÉTODOS	23
2.1. Condições experimentais e escolha da cultura modelo.....	23
2.2. Tratamento e desenho experimental.....	25
2.3. Irrigação, plantio e tratos culturais.....	25
2.4. Coleta de dados.....	27
2.5. Construção dos modelos de Regressão Linear Múltipla (RLM).....	28
2.6. Construção das Redes Neurais Artificiais (RNAs).....	28
2.7. Desempenho dos modelos RLM e RNAs.....	29
3. RESULTADOS E DISCUSSÃO	31
3.1. Relação entre as variáveis avaliadas.....	31
3.2. Uso de RLM para estimar as perdas de produtividade de cebola devido à competição por plantas daninhas.....	33
3.3. Uso de RNAs na estimativa da perda de produtividade de cebola devido à competição por plantas daninhas.....	37
3.4. Comparação entre RNAs e modelos log-logísticos tradicionais para modelar a interferência de plantas daninhas.....	43
4. CONCLUSÕES	47
REFERÊNCIAS.....	48
CAPÍTULO 2: UMA NOVA ALTERNATIVA PARA DETERMINAR O CONTROLE DE PLANTAS DANINHAS EM SISTEMAS AGRÍCOLAS BASEADAS EM REDES NEURAIAS ARTIFICIAIS (RNAs)	53
RESUMO	53
ABSTRACT	54

1.	INTRODUÇÃO	55
2.	MATERIAL E MÉTODOS	58
2.1.	Áreas experimentais, condições ambientais e escolha das culturas.....	58
2.2.	Plantio e tratos culturais.....	60
2.2.1	Gergelim.....	60
2.2.2	Melão	60
2.3.	Tratamentos e desenho experimental.....	61
2.4.	Irrigação dos experimentos.....	62
2.5.	Coleta de dados.....	62
2.6.	Construção das redes neurais artificiais (RNAs).....	63
3.	RESULTADOS E DISCUSSÃO.....	66
3.1.	Correlações das variáveis independentes e a produtividade relativa das culturas de gergelim e meloeiro.....	66
3.2.	Determinação do controle de plantas daninhas baseados em variáveis não destrutivas e destrutivas.....	68
3.3.	Determinação do controle de plantas daninhas baseados em variáveis mistas (não destrutivas + destrutivas).....	76
3.4.	Análise de sensibilidade das variáveis considerando as melhores redes neurais artificiais obtidas através de cada método.....	79
4.	CONCLUSÕES.....	82
	REFERÊNCIAS.....	83
	CONSIDERAÇÕES FINAIS.....	90
	APÊNDICE.....	91

1 INTRODUÇÃO GERAL

2

3 As plantas daninhas são um dos principais fatores bióticos responsáveis pela
4 redução da produtividade e qualidade dos produtos agrícolas, seja devido à competição
5 por luz, água, nutrientes, espaço ou por efeito de substâncias alelopáticas às culturas
6 (JHA et al., 2017). Devido às grandes perdas ocasionadas pela interferência de plantas
7 daninhas em cultivos agrícolas, os produtores têm utilizado práticas de manejo de
8 acordo com as condições técnicas e econômicas disponíveis para o controle dessas
9 plantas sempre que necessário, mesmo que essas práticas de controle representem um
10 custo de produção. Estima-se que o valor médio para o controle de plantas daninhas
11 varia de 5 a 20% do custo total para produção para diversos alimentos agrícolas; esses
12 custos são ainda mais elevados nos cultivos orgânicos nos quais o controle das plantas
13 daninhas é feito principalmente de maneira mecânico manual (GIANESSI; REIGNER,
14 2007). Saber como e quando controlar as plantas daninhas pode ajudar na tomada de
15 decisão para um manejo mais sustentável e eficiente.

16 Os métodos de controle físico (HAIDAR; SIDAHMED, 2000), químico
17 (HARKER; O'DONOVAN, 2013), mecânico (HUSSAIN et al., 2018), cultural
18 (ROSSET; GULDEN, 2020) e biológico (ZHU et al., 2020), utilizados de maneira
19 isolada ou integrados, têm sido empregados para o manejo de plantas daninhas em
20 diferentes culturas agrícolas e quando utilizados de forma adequada e no momento certo
21 exercem bom efeito no controle dessas plantas (LAMICHHANE et al., 2016). Para
22 conhecer o momento ideal do controle das plantas daninhas, é necessário determinar o
23 período crítico de prevenção à interferência, que determina o momento em que a cultura
24 deve ser mantida no limpo, no qual estudos indicam ser o momento ideal para conhecer
25 o real momento de iniciar e também finalizar o controle de plantas daninhas (RENTON;
26 CHAUHAN, 2017), reduzindo sua interferência sobre a cultura e os custos com capinas
27 que muitas vezes são desnecessárias. Portanto, determinar o período ideal de controle
28 pode evitar danos significativos à lavoura.

29 Modelos matemáticos empíricos (lineares, sigmóides e hiperbólicos) têm sido
30 amplamente usados para modelar o impacto das plantas daninhas na produtividade das
31 culturas, como já foi relatado para a batata doce (*Ipomoea batatas*) (MEYERS;
32 SHANKLE, 2015), milho (*Zea mays* L.) (TURSUN et al., 2016) e gergelim (*Sesamo*
33 *indicum*) (LINS et al., 2019). No entanto, o período de controle pode sofrer variações de

34 acordo com a cultura, cultivar, sistema de cultivo, práticas de manejo adotadas e
35 condições ambientais (RENTON; CHAUHAN, 2017). Renton; Chauhan (2017)
36 destacaram a limitada capacidade desses modelos em compreender essas variações,
37 reduzindo a capacidade de prever o rendimento das culturas e restringido sua
38 aplicabilidade como ferramenta de tomada de decisão para estimar o período de controle
39 de plantas infestantes (DHAKAL; SCANLAN, 2015). No entanto, fatores como o tipo e
40 densidade da comunidade infestante, tempo de emergência e a duração da interferência
41 influenciam o grau de redução na produção (RAHMAN et al., 2012; SOUZA et al.,
42 2020), e esses modelos são incapazes de detectar relações não lineares entre as variáveis
43 preditoras e a variável resposta (MATSUMURA et al., 2015). Isso é um problema
44 porque acaba impactando diretamente na tomada de decisão para o controle das plantas
45 daninhas. De certo modo, relações existentes entre os sistemas agrícolas e o
46 estabelecimento de plantas daninhas são muitas vezes complexas.

47 Nos últimos anos, o desenvolvimento computacional facilitou a implementação
48 de modelos capazes de entender relações altamente complexas, como, por exemplo,
49 com uso de aprendizagem supervisionada como as Redes Neurais Artificiais (RNAs)
50 (ÖZESMI et al., 2006), para o estudo de previsões da perda de rendimento das culturas
51 agrícolas em função da interferência de plantas daninhas. Em diferentes áreas das
52 ciências agrárias, diversos modelos de aprendizagem de máquinas já foram testados
53 como alternativa para responder a problemas complexos, e as RNAs estão entre as mais
54 citadas. Como vantagens desse modelo, tem-se o potencial de aprendizagem e sua
55 capacidade de generalização quando são bem treinadas, aproximar funções não lineares
56 entre os preditores e a resposta e modelar problemas altamente complexos da relação
57 entrada-saída (SÖZEN, 2009; PANDEY; MISHRA, 2017), como, por exemplo,
58 variáveis envolvidas na competição entre plantas daninhas e culturas.

59 Portanto, deve-se fazer uso de entradas que representam bem uma dada resposta
60 (saída) para construção das redes (ÖZESMI et al., 2006). A escolha de variáveis pode
61 ser um empecilho para a aplicação dessa metodologia em estudos de período de controle
62 de plantas daninhas, porque o levantamento de todas as possíveis variáveis envolvidas
63 na competição entre plantas daninhas e cultura requer muito tempo e trabalho, ou ainda,
64 elas podem não estar facilmente disponíveis.

65 Dessa forma, objetivou-se verificar se os modelos RLM e RNAs conseguem
66 prever o início do controle de plantas daninhas, comparar a eficácia das RNAs com
67 modelos sigmoidais tradicionais e avaliar também a capacidade das RNAs em estimar o

68 controle de plantas daninhas para diferentes culturas e classes de perdas de
69 produtividade aceitáveis e com isso validar uma nova alternativa para modelagem e
70 predição da competição entre plantas daninhas e culturas agrícolas.

71

72 REFERÊNCIAS

73

74 DHAKAL, B.; SCANLAN, J. Assessment of functional forms of crop yield loss models
75 of invasive plant species applied in decision support tools and bioeconomic
76 modelling. **Agricultural Systems**, v. 138, p. 100-115, 2015.

77

78 GIANESSI, L. P.; REIGNER, N. P. The value of herbicides in US crop production.
79 **Weed Technology**, v. 21, n. 2, p. 559-566, 2007.

80

81 HAIDAR, M. A.; SIDAHMED, M. M. Soil solarization and chicken manure for the
82 control of *Orobanche crenata* and other weeds in Lebanon. **Crop Protection**, v. 19, n. 3,
83 p. 169-173, 2000.

84

85 HARKER, K. N.; O'DONOVAN, J. T. Recent weed control, weed management, and
86 integrated weed management. **Weed Technology**, v. 27, n. 1, p. 1-11, 2013.

87

88 HUSSAIN, M.; FAROOQ, S.; MERFIELD, C.; JABRAN, K. Mechanical weed control.
89 **Non-Chemical Weed Control**, p. 133-155, 2018.

90

91 JHA, P.; KUMAR, V.; GODARA, R. K.; CHAUHAN, B. S. Weed management using
92 crop competition in the United States: A review. **Crop Protection**, v. 95, p. 31-37,
93 2017.

94

95 LINS, H. A.; SOUZA M. F.; ALBURQUERQUE, J. R. T.; SANTOS, M. G.; BARROS
96 JÚNIOR A. P.; SILVA D. V. Weed interference periods in sesame crop. **Ciência e**
97 **Agrotecnologia**, v. 43, e819, 2019.

98

99 MATSUMURA, K. et al. Maize yield forecasting by linear regression and artificial
100 neural networks in Jilin, China. **The Journal of Agricultural Science**, v. 153, n. 3, p.
101 399-410, 2015.

102

103 MEYERS, S. L.; SHANKLE, M. W. Interference of Yellow Nutsedge (*Cyperus*
104 *esculentus*) in 'Beauregard' Sweet Potato (*Ipomoea batatas*). **Weed Technology**, v. 29,
105 n. 4, p. 854-860, 2015.

106

107 ÖZESMI, S. L.; TAN, C. O.; ÖZESMI, U. Methodological issues in building, training,
108 and testing artificial neural networks in ecological applications. **Ecological Modelling**,
109 v. 195, n. 1, p. 83-93, 2006.

110

111 PANDEY, A.; MISHRA, A. Application of artificial neural networks in yield prediction
112 of potato crop. **Russian Agricultural Sciences**, v. 43, n. 3, p. 266-272, 2017.

113

- 114 RAHMAN, H. U. et al. Relationship between manual weeds removal timings and onion
115 yield. **Pakistan Journal of Weed Science Research**, v. 18, n. 2, p. 201-207, 2012.
116
- 117 RENTON, M.; CHAUHAN, B. S. Modelling crop-weed competition: Why, what, how
118 and what lies ahead? **Crop Protection**, v. 95, p. 101-108, 2017.
119
- 120 SOUZA, M. F. et al. Soil water availability alter the weed community and its
121 interference on onion crops. **Scientia Horticulturae**, v. 272, p. 109573, 2020.
122
- 123 SÖZEN, A. Future projection of the energy dependency of Turkey using artificial neural
124 network. **Energy policy**, v. 37, n. 11, p. 4827-4833, 2009.
125
- 126 ROSSET, J. D.; GULDEN R. H. Cultural weed management practices shorten the
127 critical weed free period for soybean grown on the northern great plains. **Weed Science**,
128 v. 68, n. 1, p. 79-91, 2020.
129
- 130 TURSUN, N.; DATTA, A.; SAKINMAZ, M. S.; KANTARCI, Z.; KNEZEVIC, S. Z.;
131 CHAUHAN, B. S. The critical period for weed control in three corn (*Zea mays* L.)
132 types. **Crop protection**, v. 90, p. 59-65, 2016a.
133
- 134 ZHU, H.; MA, Y.; GUO, Q.; XU, B. Biological weed control using *Trichoderma*
135 *polysporum* strain HZ-31. **Crop protection**, v. 134, 105161, 2020.
136
137
138
139
140
141
142
143
144
145
146
147
148
149
150
151
152
153
154
155
156
157
158
159
160
161
162
163

CAPÍTULO 1

MODELOS DE REGRESSÃO LINEAR MÚLTIPLA E REDES NEURAIAS ARTIFICIAIS NA PREDIÇÃO DA ÉPOCA DO CONTROLE DAS PLANTAS DANINHAS NA CULTURA DA CEBOLA

RESUMO

A infestação de plantas daninhas é uma grande limitação para uma maior produtividade da cebola. Essa limitação pode ainda ser intensificada pelo sistema de irrigação empregado, aumentando o grau de interferências das plantas daninhas sobre a cultura quando um manejo correto deixa de ser adotado. Assim, para identificar o período de início de controle de plantas daninhas, modelos baseados em métodos estatísticos e de aprendizado de máquina podem ser empregados para auxiliar o produtor na tomada de decisão. Desta maneira, os objetivos deste estudo foram: (1) identificar se modelos de Regressão Linear Múltipla e Redes Neurais Artificiais conseguem prever o início do controle de plantas daninhas considerando a cebola como cultura modelo sob dois sistemas de irrigação e (2) comparar a eficácia de modelos sigmoidais tradicionais com modelos de aprendizagem de máquinas para modelagem da interferência de plantas daninhas. Estudos de campo foram conduzidos na Fazenda Experimental Rafael Fernandes, localizada em Mossoró-RN, durante os anos de 2016, 2017 e 2018, em delineamento de blocos casualizados com três repetições. Os tratamentos foram compostos dos seguintes períodos para início do controle de plantas daninhas: 0, 7, 14, 21, 28, 32 e 42 dias após a emergência da cultura. Os resultados mostraram que os modelos de Regressão Linear Múltipla baseados em entradas não destrutivas e destrutivas sobre a comunidade de plantas daninhas são capazes de estimar as perdas de produtividade da cebola devido à competição, porém com baixa precisão. Os modelos de Redes Neurais Artificiais considerando apenas o período de convivência e sistema de irrigação possuem desempenho similar a modelos de Regressão Linear Múltipla. No entanto, a inserção das variáveis relacionadas à densidade de plantas daninhas (não destrutiva) e a matéria fresca (destrutiva) eleva a capacidade preditiva das redes neurais para valores próximos a 99% de acerto. Os modelos de Redes Neurais Artificiais de melhor performance podem indicar o início do controle de plantas daninhas, uma vez que são capazes de estimar com precisão as perdas devido à competição com plantas daninhas.

Palavras-chave: Modelagem, período crítico, plantas infestantes, *Allium cepa*.

206 **MODELS OF MULTIPLE LINEAR REGRESSION AND NEURAL**
207 **NETWORKS IN THE PREDICTION OF THE TIME FOR THE CONTROL OF**
208 **WEEDS IN ONION CULTURE**

209
210 **ABSTRACT**

211
212 Weed infestation is a major constraint for increased onion productivity. This limitation
213 can be further intensified by the irrigation system employed, increasing the degree of
214 weed interference with the crop when correct management is no longer adopted. Thus,
215 to identify the period of beginning weed control, models based on statistical and
216 machine learning methods can be used to assist the producer in decision making. Thus,
217 the objectives of this study were: (1) to identify whether Multiple Linear Regression and
218 Artificial Neural Network models are able to predict the beginning of weed control
219 considering onion as a model crop under two irrigation systems and (2) to compare
220 effectiveness of traditional sigmoidal models with machine learning models for
221 modeling weed interference. Field studies were conducted at Fazenda Experimental
222 Rafael Fernandes, located in Mossoró-RN, during the years 2016, 2017 and 2018, in a
223 randomized block design with three replications. The treatments were composed of the
224 following periods for the beginning of weed control: 0, 7, 14, 21, 28, 32 and 42 days
225 after the emergence of the crop. The results showed that the Multiple Linear Regression
226 models based on non-destructive and destructive inputs on the weed community are
227 able to estimate the productivity losses of the onion due to competition, however with
228 low precision. The models of Artificial Neural Networks considering only the
229 coexistence period and irrigation system have similar performance to the Multiple
230 Linear Regression models. However, the insertion of variables related to weed density
231 (non-destructive) and fresh matter (destructive) raises the predictive capacity of neural
232 networks to values close to 99% correct. The best performing Artificial Neural Network
233 models can indicate the beginning of weed control, since they are able to accurately
234 estimate losses due to competition with weeds.

235
236
237 **Keywords:** Modeling, critical period, weed, *Alium cepa*.

238
239
240
241
242
243
244
245
246
247
248

249 1. INTRODUÇÃO

250

251 A cebola (*Allium cepa* L.) é uma das mais importantes hortaliças comerciais,
252 cultivada em mais de 150 países com uma produção mundial de cerca de 120 milhões
253 de toneladas em 2018. O Brasil é o 13º maior produtor de cebola com uma área plantada
254 de 48.494 hectares, produção de 1.549.597 toneladas e produtividade de 31.954 kg ha⁻¹
255 (FAOSTAT, 2018). No entanto, a infestação de plantas daninhas é uma grande
256 limitação para uma maior produtividade, sendo responsável por mais de 60% da perda
257 de rendimento potencial da cebola (QASEM et al., 2006). Assim, a interferência de
258 plantas daninhas é o maior fator limitante que afeta o rendimento da cebola (BROWN;
259 GALLANDT, 2018). Todavia, o grau de redução na produção relacionado às plantas
260 daninhas pode variar de acordo com tipo e densidade da comunidade infestante, tempo
261 de emergência e a duração da interferência (RAHMAN et al., 2012; SOUZA et al.,
262 2020).

263 A baixa capacidade competitiva da cultura da cebola com as plantas daninhas se
264 deve ao seu sistema radicular superficial e um dossel de folhas aberto (SIVESIND et al.,
265 2012), principalmente quando a cebola é propagada por sementes, com crescimento
266 inicial muito lento e a ausência de folhagem adequada na fase inicial de
267 desenvolvimento para fechar o dossel e suprimir o crescimento das plantas daninhas
268 (KHOKHAR et al., 2006). Dessa forma, a competição por água, nutrientes, luz e espaço
269 começa a ocorrer nos estágios iniciais de desenvolvimento da cebola, reduzindo
270 consideravelmente o rendimento, a qualidade e o valor da cultura por meio do aumento
271 dos custos de produção e colheita (PANNACCI et al., 2020). O grau de interferência
272 das plantas daninhas na cultura da cebola também pode ser intensificado pelo sistema de
273 irrigação adotado, devido a alterações na diversidade de plantas daninhas e na seleção
274 de uma comunidade infestante mais bem adaptada (ARMENGOT et al., 2016).

275 Souza et al. (2020) investigaram as mudanças na comunidade de plantas
276 daninhas causadas por dois sistemas de irrigação ao longo de três safras de cebola,
277 observando que a redução nos índices de produtividade foi agravada pela maior
278 diversidade de plantas daninhas no sistema de microaspersão e a dominância de
279 algumas espécies intensificou a competição no sistema de irrigação por gotejamento.
280 Dessa forma, os diferentes sistemas de irrigação podem alterar a dinâmica de plantas
281 daninhas na área de cultivo e, conseqüentemente, o período crítico de prevenção à
282 interferência, ou seja, o período de tempo em que a cultura deve ser mantida livre de

283 plantas daninhas para evitar perdas inaceitáveis de rendimento (KNEZEVIC et al.,
284 2002).

285 O rendimento das safras diminui com o aumento da competição com plantas
286 daninhas (BERTUCCI et al., 2019; CHARLES et al., 2019). Portanto, determinar o
287 período crítico de prevenção à interferência causada por plantas daninhas é fundamental
288 para evitar danos significativos à lavoura. Alguns modelos básicos (lineares, sigmóides
289 e hiperbólicos) têm sido amplamente usados para modelar o impacto das plantas
290 daninhas na produtividade das culturas (DHAKAL; SCANLAN, 2015; MEYERS;
291 SHANKLE, 2015; TURSUN et al., 2016; LINS et al., 2019), mas estes modelos têm
292 problemas para prever a perda de rendimento das culturas em diversas densidades de
293 plantas daninhas (DHAKAL; SCANLAN, 2015), o que pode ser um problema devido à
294 densidade de plantas daninhas variar em função de fatores ambientais, biológicos e de
295 manejo, impactando diretamente na capacidade competitiva das culturas (RENTON;
296 CHAUHAN, 2017) e na tomada de decisão quanto ao controle das plantas daninhas.

297 Os modelos baseados em métodos estatísticos ou métodos de aprendizado de
298 máquina desenvolvidos no campo da inteligência artificial podem ser adequados para
299 fazer previsões da perda de rendimento de culturas agrícolas em função da interferência
300 de plantas daninhas. Modelos de regressão linear múltipla (RLM) são amplamente
301 usados para prever o rendimento de culturas agrícolas com base em variáveis preditoras
302 de clima e solo (KERN et al., 2018; FENG et al., 2018). No entanto, os modelos
303 lineares são incapazes de detectar relações não lineares entre as variáveis preditoras e a
304 variável de resposta (MATSUMURA et al., 2015). Dessa forma, os métodos de
305 aprendizado de máquina, como as redes neurais artificiais (RNAs), podem aproximar
306 funções não lineares entre os preditores e a resposta, modelando problemas complexos
307 da relação entrada-saída (SÖZEN, 2009; PANDEY; MISHRA, 2017), como, por
308 exemplo, variáveis envolvidas na competição entre plantas daninhas e cultura.

309 As Redes Neurais Artificiais já foram testadas para o entendimento de diversos
310 problemas complexos na agricultura, como, por exemplo, na previsão da produção de
311 frutos de pimenta (GHOLIPOOR; NADALI, 2019), produção de sementes de cártamo
312 (ABDIPOUR et al., 2019), identificação de doenças em plantas (ZHANG et al., 2019),
313 erosão espacial do solo (GHOLAMI et al., 2018), sorção e dessorção de herbicidas em
314 solos (SILVA et al., 2019), dinâmica populacional de plantas daninhas
315 (MANSOURIAN et al., 2017), detecção de plantas daninhas em campos agrícolas
316 (ASAD; BAIS, 2019), dentre outros. Porém, nenhum estudo aplicou modelos de RLM e

317 RNA para predição do momento ideal de início do controle de plantas daninhas com
318 base nas perdas de produtividade relativa de cebola devido à competição existente.

319 A cebola foi escolhida como cultura modelo deste estudo porque é altamente
320 sensível à competição de plantas daninhas (BROWN; GALLANDT, 2018). Além disso,
321 foi considerado o cultivo da cebola sob dois sistemas de irrigação (microaspersão e
322 gotejamento) mais utilizados na região do estudo para avaliar a capacidade de predição
323 dos modelos de Regressão Linear Múltipla e Redes Neurais Artificiais em mais de uma
324 condição de manejo. Dessa forma, levantamos a hipótese de que, usando a modelagem
325 para modelos de RLM e RNA, é possível prever o início do controle de plantas
326 daninhas com boa precisão e poder de previsão. Assim, os objetivos deste estudo foram:
327 (1) identificar se os modelos de RLM e RNA poderiam prever efetivamente o início do
328 controle de plantas daninhas considerando a cebola como cultura modelo sob dois
329 sistemas de irrigação e (2) comparar a eficácia de modelos sigmoidais tradicionais com
330 modelos de RNA para modelagem da interferência de plantas daninhas na cultura da
331 cebola.

332

333

334

335

336

337

338

339

340

341

342

343

344

345

346

347

348

349

350

351 **2. MATERIAL E MÉTODOS**

352

353 **2.1. Condições experimentais e escolha da cultura modelo**

354

355 Os ensaios de campo foram realizados na fazenda experimental, localizada em
 356 5°03'37" S, 37°23'50" W e altitude de 72 m, durante os anos de 2016, 2017 e 2018. O
 357 clima é caracterizado como seco e muito quente (PEEL et al., 2007). O solo do campo
 358 experimental é classificado como Latossolo Vermelho Amarelo Estrófico Abrupto
 359 (EMBRAPA, 2013). Amostras do solo foram coletadas para análise físico-química e os
 360 resultados foram apresentados na tabela 1. Os dados climatológicos entre as safras de
 361 cebola foram medidos e apresentados na figura 1.

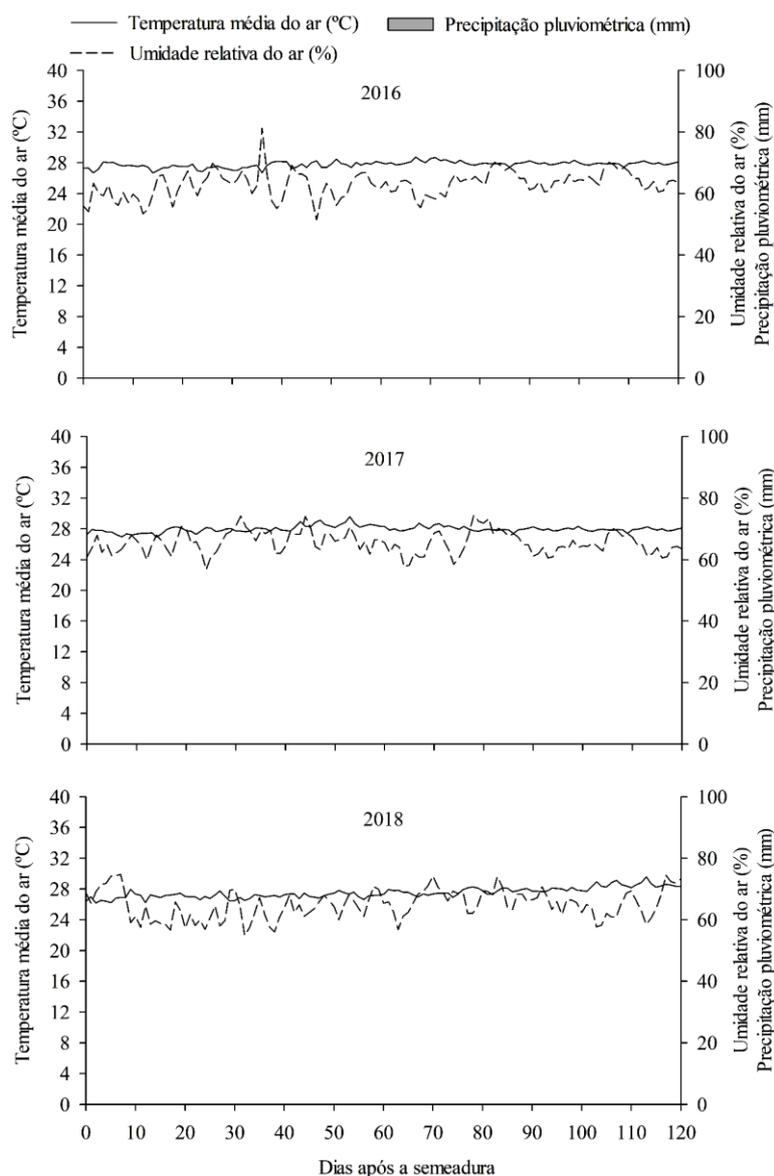
362

363 **Tabela 1.** Análises físico-químicas de solo cultivado com cebola para os anos 2016,
 364 2017, 2018. Mossoró - RN, 2019.

Ano	N	MO	K	P	Na	Ca	Mg	pH	CE
	g kg ⁻¹	g kg ⁻¹	-----mg dm ⁻³ -----			---cmolc dm ⁻³ ---		H ₂ O	ds m ⁻¹
2016	0,14	7,23	52,01	4,47	8,1	2,10	0,55	6,50	0,06
2017	0,22	9,78	58,8	3,0	4,8	1,00	1,80	5,63	0,07
2018	0,31	8,21	68,8	3,5	4,7	1,20	1,40	5,83	0,08
Textura									
Classes textural		Areia (%)		Silte (%)		Argila (%)			
Franco-Arenoso		72		4		24			

365 *Extrator: Mehlich-1

366



367

368 **Figura 1.** Temperatura média do ar (°C), umidade relativa (%) e precipitação (mm)
 369 durante o ciclo da cultura da cebola em 2016, 2017 e 2018. Dados obtidos na estação
 370 meteorológica na fazenda experimental.

371

372 A cebola foi utilizada para obtenção dos dados e criação dos modelos matemáticos.
 373 Os critérios para essa decisão foram: i) Essa cultura é muito sensível à competição por
 374 plantas daninhas devido ao crescimento inicial lento, morfologia tubular de suas folhas,
 375 e pequeno porte; ii) Poucos herbicidas são registrados, exigindo o controle manual ou

376 mecânico em muitas situações; iii) Alta adaptabilidade às condições edafoclimáticas da
377 região onde foram conduzidos os ensaios. O sistema de cultivo implementado foi
378 similar ao adotado por produtores da região (detalhes abaixo).

379

380 **2.2 Tratamento e desenho experimental**

381

382 Dois experimentos foram conduzidos nos anos de 2016, 2017 e 2018, em
383 delineamento de blocos casualizados (DBC) com três repetições. Um experimento foi
384 composto por áreas de cebola cultivada sob gotejamento e outra sob microaspersão.
385 Esses dois sistemas de irrigação foram escolhidos porque são frequentemente usados
386 pelos produtores de cebola. Esse fato também gerou maior variabilidade dos dados
387 amostrados, abrangendo maior número de condições possíveis referentes à infestação de
388 plantas daninhas. Os tratamentos desses experimentos foram constituídos por seis
389 períodos para iniciar o controle de plantas daninhas. Os intervalos foram definidos
390 como 0, 7, 14, 21, 28, 32 e 42 dias após a emergência da cebola.

391

392 **2.3 Irrigação, plantio e tratos culturais**

393

394 A irrigação da cultura sob gotejamento ou microaspersão foi realizada de acordo
395 com a necessidade hídrica da cultura em cada fase fenológica. No sistema por
396 gotejamento, foram utilizadas quatro fitas gotejadoras espaçadas em 0,20 m entre linhas
397 e 0,30 m entre gotejadores. Para microaspersão, os emissores foram espaçados em 1,5 m
398 entre linhas x 1,5 m na linha. A vazão dos gotejadores foi de 1,7 L h⁻¹ e a vazão dos
399 microaspersores foi de 58 L h⁻¹. A evapotranspiração da cultura (ET_c) foi calculada em
400 cada estágio de crescimento, de acordo com Allen et al. (1998) (Equação 1). A
401 determinação da lâmina bruta diária (LB) foi calculada considerando a eficiência dos
402 sistemas empregados (Equação 2). O turno e tempo de irrigação foram calculados de
403 acordo com o espaçamento dos gotejadores e microaspersores, a vazão e a eficiência do
404 sistema em fornecer a água desejada (80 e 95% para microaspersão e gotejamento),
405 segundo Koumanov et al., (1997) e Camp (1998).

406

407 Equação (1): $ET_c = ET_o \times K_c$

408 Onde Etc é a evapotranspiração da cultura, ETo é a evapotranspiração de referência
409 (mm dia⁻¹) e Kc é o coeficiente de cultivo corresponde a cada estágio de
410 desenvolvimento da cebola.

411 Equação (2): $LB = E_{Tc}/E_f$

412 Onde E_{Tc} é a evapotranspiração da cultura (mm dia⁻¹) e E_f é a eficiência do sistema de
413 irrigação.

414 O sistema de condução foi o convencional, realizando a aração, gradagem e
415 formação dos canteiros (1,20 m de largura, 18,90 m de comprimento e 0,20 m de altura)
416 com enxada rotativa. A cultura foi semeada manualmente em julho para todos os anos,
417 utilizando três sementes por cova em oito linhas por canteiro. O espaçamento utilizado
418 foi de 0,10 m entre linhas e 0,06 m entre plantas. Após a emergência, o desbaste foi
419 realizado mantendo apenas uma planta por cova para garantir uma população de
420 1.666.666 planta ha⁻¹. Uma fertilização antes do plantio foi realizada no pré-plantio com
421 180 kg ha⁻¹ de P₂O₅ (superfosfato simples), 3,0 kg ha⁻¹ de zinco (sulfato de zinco) e 1,10
422 kg ha⁻¹ de boro (ácido bórico). A adubação de cobertura foi realizada por fertirrigação
423 utilizando-se 165 kg ha⁻¹ de N (MAP) e 30 kg de K₂O ha⁻¹ (KCl) parcelada duas vezes
424 por semana, utilizando um injetor tipo Venturi. Esta fertilização foi usada em todos os
425 anos de cultivo. Os tratamentos culturais e controle fitossanitário foram realizados de
426 acordo com as recomendações técnicas e as necessidades da cultura. O controle de
427 plantas daninhas foi iniciado conforme cada tratamento proposto. Após o início do
428 controle, as parcelas foram mantidas sem competição por plantas daninhas até a
429 colheita. As capinas foram realizadas manualmente.

430 A safra começou a apresentar sinais de maturidade (queda de mais de 70% do
431 topo verde) aos 110 DAE nos três anos de cultivo. Os sistemas de irrigação foram
432 retirados na mesma semana e os bulbos permaneceram em campo por mais 10 dias até
433 completar o processo de cura. Após este processo, aos 120 DAE, as seis linhas (área
434 útil) de cada parcela foram colhidas. Os bulbos foram classificados em tamanhos
435 comercializáveis (> 3,5 cm) (LUENGO et al., 2018). Os bulbos com diâmetros
436 inferiores a 3,5 cm e com defeitos graves (podridão, mancha negra, mofado) foram
437 considerados “fora do padrão” e descartados. Apenas os bulbos com características
438 comerciais foram considerados na análise de produtividade. O rendimento comercial de

439 bulbos por hectare foi estimado considerando o peso total e o número de bulbos
440 colhidos.

441

442 **2.4 Coleta de dados**

443

444 As dimensões da área útil de cada parcela foram 0,60 x 2,5 m, totalizando 1,5
445 m². No momento estabelecido para iniciar o controle, as plantas daninhas foram
446 coletadas em amostras randomizadas com área equivalente a 0,5 x 0,5 m (0,25 m²)
447 dentro da área útil. Três amostragens foram realizadas em cada parcela para representar
448 a distribuição da comunidade de plantas daninhas. As plantas daninhas foram coletadas,
449 identificadas, contadas e pesadas em balança de precisão (0,001). Esse procedimento
450 permitiu o cálculo da densidade e matéria fresca de plantas daninhas. As espécies
451 coletadas nas áreas durante os três anos foram: *Aechynomene rudis* Benth., *Amaranthus*
452 *hybridus* var. *paniculatus* (L.) Uline & W.L.Bray, *Blainvillea* spp., *Centrocema*
453 *pascuorum* Mart. ex Benth, *Chloris barbata* Sw, *Dactyloctenium aegyptium* (L.) Willd,
454 *Digitaria horizontalis* Wild, *Eragrostis pilosa* (L.) P.Beauv, *Hybanthus calceolaria* (L.)
455 Paula Souza, *Ipomoea purpurea* (L.) Roth, *Ipomoea triloba* L., *Jacquemontia tamnifolia*
456 (L.) Griseb, *Merremia aegyptia* (L.) urb, *Mollugo verticillata* L., *Portulaca oleracea* L.,
457 *Richardia brasiliensis* Gomes, *Senecio brasiliensis* Less., *Senna obtusifolia* (L.) H.S.
458 Irwin & Barneby, *Sida* spp., *Urochloa plantaginea* (Link) R. Ebster, *Cynodon dactylon*
459 (L.) Pers e *Waltheria indica* L..

460 As variáveis obtidas ao final de cada coleta foram a densidade de plantas
461 daninhas (DP, plantas/m²) e matéria fresca de plantas daninhas (MF, gramas/m²). A
462 partir da densidade e matéria fresca, as razões entre monocotiledôneas e
463 eudicotiledôneas (M/E) e espécies C4 e C3 (C4/C3) foram calculadas para cada parcela,
464 considerando a densidade e a matéria fresca. A cebola foi colhida 120 após a
465 semeadura, quando as plantas se encontravam com as folhas amareladas em estágio de
466 estalo. A área útil de cada canteiro foi de 2,7 metros de comprimento e 1 metro de
467 largura. Os bulbos presentes na área útil de cada parcela foram coletados e classificados
468 de acordo com o diâmetro em comerciais e não comerciais (LUENGO et al. 1999).
469 Posteriormente, a produtividade de bulbos comerciais por hectare foi estimada
470 considerando o peso total e número de bulbos colhidos na área útil de cada parcela.

471 O rendimento relativo de cada unidade experimental foi calculado com base na
472 produtividade das parcelas sem a coexistência durante todo o ciclo de cultivo (controle).

473 A produtividade relativa (%) foi calculada por meio da relação da produtividade de cada
474 tratamento e controle (Equação 3).

475

476 Eq. (3):
$$PR (\%) = (P_{\text{Tratamento}}/P_{\text{controle}}) \times 100$$

477 Onde: $P_{\text{Tratamento}}$ é a produtividade de cada tratamento e P_{Controle} é a produtividade do
478 controle.

479

480 **2.5 Construção dos modelos de Regressão Linear Múltipla (RLM)**

481

482 A RLM é uma análise preditiva que tenta modelar a relação entre duas ou mais
483 variáveis independentes (explicativas) e uma variável dependente (resposta), ajustando
484 uma equação linear aos dados observados (ANTANASIJEVIĆ et al., 2013). A variável
485 dependente considerada foi a produtividade relativa da cebola das parcelas para cada
486 tratamento. Os RLM podem ser expressões segundo a Equação 4:

487 Eq. (4):
$$y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon_i$$

488 Onde: y_i é a PR, $\beta_0 - \beta_n$ são os coeficientes de regressão, $x_1 - x_n$ são as variáveis de
489 entrada e ε é o erro associado à i -ésima observação.

490 As variáveis DP, MF, M/E, C4/C3 e o período de coexistência determinado
491 pelos tratamentos (PI) foram usadas como entradas dos modelos. Desta maneira, as
492 perdas na produtividade relativa da cebola foram estimadas com base em variáveis
493 referentes às plantas daninhas no momento definido pelos tratamentos. Dois tipos de
494 modelos foram criados a partir dessas variáveis. Os modelos não destrutivos foram
495 obtidos a partir das entradas PI, DP e as razões M/E^{ND} e $C4/C3^{ND}$ calculadas a partir da
496 densidade (variáveis coletadas sem necessidade de remoção das plantas daninhas). Os
497 modelos destrutivos foram obtidos por meio das entradas PI, MF e as razões M/E^D e
498 $C4/C3^D$ calculadas a partir da matéria fresca (variáveis coletadas com a necessidade de
499 remoção das plantas daninhas). Um modelo de RLM foi criado para cada sistema de
500 irrigação (gotejamento e microaspersão).

501

502 **2.6 Construção das Redes Neurais Artificiais (RNAs)**

503

504 Modelos RNAs também foram aplicados para predição das perdas na
505 produtividade relativa da cebola considerando as variáveis referentes à comunidade de
506 plantas daninhas e o período como entradas. Além disso, o sistema de irrigação foi
507 adicionado como variável categórica, resultando em uma RNA capaz de distinguir as
508 duas condições de irrigação. As RNAs criadas também se basearam em entradas não
509 destrutivas e destrutivas. A arquitetura usada para as RNAs foi a *multilayer perceptron*,
510 um tipo de aprendizagem supervisionada, que aplica a retropropagação do erro
511 (backpropagation) durante a fase de treinamento do modelo. Essas RNAs possuíram três
512 camadas principais (entrada, oculta e saída) de neurônios com funções de ativação
513 lineares e não lineares (TAYEBI et al., 2019). A aprendizagem e o treinamento
514 funcionam devido à mudança nos pesos de conexão, baseando-se nos erros calculados
515 dos valores observados, partindo da saída até a entrada. As entradas (inputs) utilizadas
516 foram as variáveis mencionadas anteriormente e a saída (outputs) foi a produtividade
517 relativa da cebola. Todos os dados foram normalizados (0 a 1) para que o modelo
518 atribuisse os pesos representativos às variáveis, eliminando o problema de variáveis
519 com diferentes unidades de medida (BONELLI et al., 2017).

520 Das RNAs aplicadas, os quatro melhores modelos foram selecionados para a
521 saída estabelecida. Os números de neurônios e camadas ocultas foram estabelecidos
522 através de um valor mínimo e máximo, permitindo que aqueles com melhor
523 desempenho fossem escolhidos. Além disso, as RNAs foram testadas considerando
524 diferentes funções de ativação, tanto para entrada quanto para saída. As funções não
525 lineares testadas foram: sigmoide, logística, exponencial, tangente, identidade e seno
526 (Apêndice I). O número total de dados obtidos foi igual a 126 observações. Esse
527 conjunto de dados foi separado em três subconjuntos: treinamento (70%), validação
528 (15%) e teste (15%) (Apêndice II). As observações usadas no teste eram independentes
529 das demais observações aplicadas no treinamento e validação, permitindo a avaliação da
530 capacidade de generalização da rede treinada.

531

532 **2.7 Desempenho dos modelos RLM e RNAs**

533

534 Os modelos de RLMs e RNAs foram comparados por meio de parâmetros
535 estatísticos aplicados na avaliação de modelos. Os critérios para o desempenho dos
536 modelos foram o erro relativo absoluto médio (RMSE), erro absoluto médio (MAE) e

537 coeficiente de determinação (R^2), obtidos por meio das Equações (5), (6) e (7),
 538 respectivamente:

539

540 Equação (5):
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}$$

541

542 Equação (6):
$$MAE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)$$

543

544 Equação (7):
$$R^2 = \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2 - \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2}}$$

545

546 Onde n é o número de observações, Y_i é o valor da produtividade relativa mensurada, e
 547 \hat{Y}_i é o valor da produtividade estimado pelo modelo.

548

549 O R^2 fornece a medida da variabilidade dos dados reproduzidos pelos modelos
 550 previstos e os observados. Um modelo é considerado mais eficiente e preciso quando os
 551 valores de R^2 estão mais próximos a um (ABDIPOUR et al., 2018). O MAE e RMSE
 552 mediram os erros residuais, e menores valores para esses parâmetros são considerados
 553 superiores para seleção do modelo com menor erro (CHALOULAKOU et al., 2003). Os
 554 modelos com melhor desempenho, seja por RLM ou RNAs, também foram comparados
 555 com modelos tradicionais usados para avaliar as perdas na produção causadas pela
 556 interferência de plantas daninhas. Os modelos log-logístico, Weibull-1 e Weibull-2
 557 foram aplicados aos dados do subconjunto de treinamento. Os dados do subconjunto teste
 558 foram usados para avaliar a capacidade preditiva do modelo sigmoidal de melhor
 559 desempenho (log-logístico, Weibull-1 ou Weibull-2). Todas as análises implementadas
 560 no estudo foram realizadas utilizando o *software* Statistica®, versão 13.0 (STATSOFT
 561 Inc., Tulsa, OK, USA).

562

563

564

565

566

567 **3 RESULTADOS E DISCUSSÃO**

568

569 **3.1 Relação entre as variáveis avaliadas**

570

571 Uma análise geral das variáveis estudadas é apresentada na tabela 2. A
572 produtividade relativa média da cebola cultivada sob ambos os sistemas de irrigação foi
573 de 62%, nos tratamentos controle (sem interferência de plantas daninhas). Houve
574 tratamentos com perdas de produtividade próximas a 100% devido à presença de plantas
575 daninhas para ambos os sistemas de irrigação (Apêndice II), resultando em grande
576 variação dos dados (Desvio padrão ± 37.06). As variáveis densidade e matéria fresca de
577 plantas daninhas apresentaram as maiores variações observadas, com desvio padrão
578 equivalente a 2785,96 plantas/m² e 739,20 g/m², durante os três anos de condução dos
579 ensaios (Tabela 2). As variáveis relacionadas à determinação da razão entre as espécies
580 de plantas daninhas de mecanismo fotossintéticos C4 e C3 em relação à densidade de
581 plantas (C4/C3^D) e a relação de espécies monocotiledônea e eudicotiledôneas em
582 relação à matéria fresca de plantas daninhas (M/E^{MF}) também mostraram alta variação
583 em relação à média observada.

584 A alta variação para os dados amostrados é uma característica importante em
585 estudos de modelagem, pois permite uma interpretação ampla das diferentes situações
586 possíveis para um dado problema (MEHTA et al., 2019). Estudos já relataram como
587 diferentes variáveis estão envolvidas na relação entre interferência de plantas daninhas e
588 culturas, tais como a comunidade infestante (STORKEY; NEVE, 2018), o sistema de
589 produção e cultura (FREITAS SOUZA et al., 2020; ARMENGOT et al., 2016), e as
590 condições de ambiente (MAHAUT et al., 2019; CIRILLO et al., 2018). Todavia, não
591 existem determinações sobre um valor padrão de variação para a modelagem de dados.
592 Mesmo sem essa referência, a variação dos dados coletados indica que situações
593 contrastantes foram englobadas durante os três anos de cultivo da cebola sob
594 gotejamento e microaspersão, permitindo o estudo do caso entre a interferência de
595 plantas daninhas e a cebola.

596 As variáveis que mostraram correlação significativa com a produtividade relativa foram
 597 o período (-0.85) e relação M/E obtidos a partir da densidade (-0,61) e matéria fresca
 598 (Tabela 2). A densidade e matéria fresca de plantas não apresentaram correlações
 599 significativas com a produtividade da cebola (Tabela 2).

600

601 **Tabela 2.** Correlação de Pearson para as variáveis dependentes e independentes
 602 avaliadas.

	Médias	Desvio padrão	Período	Produtividade relativa	Correlações					
					Densidade	^a C4/C3 ^D	^b M/E ^D	^a C4/C3 ^{MF}	^b M/E ^{MF}	Matéria fresca
Período	42.86	37.06	1	-0.85*	-0.16	0.38	0.41	0.39	0.41	0.30
Produtividade relativa	62.09	35.10		1	-0.15	0.38	0.61*	-0.40	0.63*	-0.37
Densidade	1878.27	2785.96			1	0.49	0.39	0.48	0.40	0.11
^a C4/C3 ^D	0.56	0.33				1	0.55	0.98*	0.55	0.25
^b M/E ^D	0.27	0.31					1	0.56	0.99*	0.41
^a C4/C3 ^{MF}	0.27	0.30						1	0.56	0.27
^b M/E ^{MF}	0.53	0.31							1	0.42
Matéria fresca	300.57	739.20								1

603 *Correlações significativas $p < 0,05$. ^aRelação entre plantas daninhas classificadas como C4 e C3.

604 ^bRelação entre plantas daninhas classificadas como monocotiledôneas e eudicotiledôneas.

605

606 As variáveis referentes à densidade e matéria fresca de plantas daninhas são
 607 componentes importantes nos sistemas de cultivo. Geralmente, campos agrícolas com
 608 altas infestações iniciais de plantas daninhas tendem a exercer maior interferência sobre
 609 as culturas (BENARAGAMA et al., 2016; SOLTANI et al., 2018; PANNACCI et al.,
 610 2018; BENARAGAMA et al., 2016).

611 Essa relação não foi observada por meio da análise de correlação para os dados
 612 obtidos durante os três anos de cultivo da cebola. Provavelmente, a interação entre a
 613 densidade e matéria fresca de plantas daninhas e a produtividade da cebola deve
 614 envolver relações não lineares e mais complexas.

615 A alta correlação negativa entre produtividade e o período ocorreu devido à
 616 maior interferência exercida pela comunidade de plantas daninhas sobre a cultura. O
 617 tempo no qual a cultura permanece crescendo juntamente com plantas daninhas é um
 618 dos fatores chave durante a interferência. Quanto maior for o tempo de coexistência,
 619 maior será a redução da produtividade. Esse componente já foi intensamente estudado
 620 para diversas culturas em trabalhos que buscaram definir o período de controle de
 621 plantas daninhas necessário para evitar a competição (LINS et al., 2019; SINGH et al.,
 622 2018; SEYYEDI et al., 2016; TURSUN et al., 2016). No entanto, outros fatores
 623 relacionados às plantas daninhas também mostraram estreita relação linear com a
 624 produtividade da cebola, tais como a relação entre as espécies de plantas daninhas
 625 monocotiledôneas e eudicotiledôneas. O aumento na proporção de monocotiledôneas,
 626 tanto para a densidade quanto para matéria fresca, provocou maiores perdas de
 627 produtividade.

628

629 **3.2 Uso de RLM para estimar as perdas de produtividade de cebola devido à** 630 **competição por plantas daninhas.**

631

632 As variáveis significativas dos modelos de RLM para a cebola cultivada sob
 633 gotejamento são apresentados na Tabela 3. Em ambos os modelos de RLM, apenas as
 634 variáveis período e relação M/E foram selecionadas para explicar a produtividade
 635 relativa da cebola considerando a significância ao $p < 0,05$. Os pesos para a variável
 636 M/E foram superiores (59,21 e 50,72) comparado ao período (0,54 e 0,56) considerando
 637 os modelos não destrutivos e destrutivos, respectivamente (Tabela 3).

638

639 **Tabela 3.** Modelo de regressão linear múltipla e índice de desempenho (R^2 , MAE e
 640 RMSE) para estimar as perdas de produtividade relativa da cebola cultivada sob
 641 gotejamento e microaspersão devido à interferência com plantas daninhas.

Método	Parâmetros	Valores	Erro padrão	Gotejamento					
				Teste			Validação		
				R^2	MAE	RMSE	R^2	MAE	RMSE
Não destrutivo	Intercepto	102.05*	4,06						
	Período	-0.54*	0,07	0,79	11,4	16,3	0,82	10,5	14,7
	M/E ND	-59.21*	9,39						
Destrutivo	Intercepto	103.97*	4,04	0,78	13,4	17,3	0,75	15,2	19,1

		Período	-0.56*	0,08						
		M/E ^D	-50.72*	10,53						
		Microaspersão								
Método	Parâmetros	Valores	Erro padrão	Teste			Validação			
				R ²	MAE	RMSE	R ²	MAE	RMSE	
Não-destrutivo	Intercepto	95,42*	2,68	0,87	7,4	10	0,8	9,4	13	
	Período	- 0,74*	0,05							
Destrutivo	Intercepto	99,60*	2,26	0,88	7,54	11,2	0,82	10,4	14,06	
	Período	- 0,79*	0,04							

642 *Significativo no valor de $p \leq 0,05$. Std.error = Erro padrão; R² = coeficiente de determinação; MAE =
643 Erro absoluto médio; RMSE = Erro médio quadrático da raiz; M/END = Relação entre número de espécies
644 daninhas monocotiledôneas e dicotiledôneas; M/E^D = Relação entre massa fresca de espécies daninhas
645 monocotiledôneas e eudicotiledôneas.

646

647 O valor negativo atribuído às variáveis Período e M/E sugere que o aumento do
648 tempo de coexistência e da proporção de plantas daninhas monocotiledôneas reduz a
649 produtividade da cebola cultivada sob gotejamento. Além disso, o maior peso para a
650 variável M/E mostra que a cebola cultivada sob gotejamento é extremamente sensível a
651 mudanças na comunidade de plantas daninhas. Pequenos aumentos na relação M/E,
652 obtidos por meio da densidade de plantas ou matéria fresca, resultam em altas perdas de
653 produtividade. As demais variáveis não foram atribuídas aos modelos devido à baixa
654 significância delas para explicar a variável dependente, no caso, a produtividade
655 relativa. Esse resultado era esperado, uma vez que a densidade, razão C4/C3 e matéria
656 fresca tiveram baixa correlação com a produtividade da cebola.

657 Os modelos RLM obtidos para cebola cultivada sob microaspersão incluíram
658 apenas a variável Período considerando $p < 0,05$ (Tabela 3). O peso para essa variável
659 foi 0,74 e 0,79 para entradas não destrutivas e destrutivas, respectivamente (Tabela 3).
660 Esses valores em módulo foram superiores ao cultivo sob gotejamento (0,54 e 0,56).
661 Similar ao gotejamento, o período de convivência também exerceu efeito negativo sobre
662 a produtividade da cebola quando cultivada sob microaspersão. A diferença entre os
663 dois sistemas está na sensibilidade da cebola a essa variável. No cultivo com
664 microaspersão, as perdas causadas pelo tempo de convivência com plantas daninhas são
665 maiores do que no gotejamento.

666 A distribuição localizada de água no gotejamento possivelmente favoreceu o
667 desenvolvimento da cultura, intensificando o controle cultural sobre as plantas
668 daninhas. Esse efeito já foi observado para aplicação de nitrogênio. Blackshaw et al.

669 (2020) observaram que a aplicação localizada de N elevou a absorção desse nutriente
670 em plantas de trigo, elevando a competitividade e o controle cultural de plantas
671 daninhas. Além disso, a irrigação localizada já mostrou desfavorecer o crescimento de
672 plantas daninhas. Sutton et al. (2006) observaram que a irrigação localizada por
673 gotejamento subsuperficial permitiu menor biomassa de plantas daninhas na área, na
674 comparação à irrigação superficial por sulco. Desta maneira, o maior controle cultural e
675 o menor crescimento de plantas daninhas sob gotejamento podem permitir a cebola
676 tolerar a convivência durante maior tempo, comparado à microaspersão.

677 Os índices de desempenho do modelo baseado em entradas não destrutivas
678 foram 0,79, 11,40 e 16,30 para R^2 , MAE e RMSE, respectivamente, durante a fase de
679 teste para a cebola cultivada sob gotejamento. O modelo construído de entradas
680 destrutivas apresentou desempenho similar, com valores de 0,78, 13,40 e 17,30 para R^2 ,
681 MAE e RMSE, respectivamente (Tabela 3). No entanto, melhor desempenho foi
682 observado para o modelo de entradas não destrutivas ($R^2 = 0,82$, MAE = 10,50 e RMSE
683 = 14,70) comparado a entradas destrutivas ($R^2 = 0,75$, MAE = 15,2 e RMSE = 19,1)
684 durante a validação. Para cebola cultivada sob microaspersão, apenas o Período foi
685 selecionado como variável de entrada, resultando em desempenho muito similar entre os
686 métodos com entradas não destrutivas e destrutivas para as fases de teste e validação
687 (Tabela 3).

688 Os modelos de RLM consideraram poucas variáveis de entrada e,
689 independentemente do sistema de irrigação, alcançaram valores superiores a 0,70 para
690 R^2 durante o teste e validação. Esses patamares de desempenho foram considerados
691 bons para outros estudos que aplicaram a modelagem preditiva para determinação da
692 respiração do solo (EBRAHIMI et al., 2019), produtividade de sementes de girassol
693 (WENZHI et al., 2018) e biomassa de trigo (ZHOU et al., 2016). No entanto, esse
694 desempenho não é ideal quando a proposta é criar modelos para tomada de decisão
695 sobre o controle de plantas daninhas. Geralmente, as perdas aceitáveis, que consideram
696 o custo de controle e o valor agregado da cultura, variam entre 2,5 a 10% da
697 produtividade total sem a interferência de plantas daninhas (ROSSET; GULDEN, 2020;
698 LINS et al., 2019; TURSUN et al., 2016). Assim, os modelos obtidos por regressão
699 linear múltipla podem levar a falsas interpretações uma vez que os erros associados a
700 eles são superiores ao limite máximo estabelecido (RMSE superior a 13,00 para todos
701 modelos durante a validação).

702 Outro detalhe importante que deve ser observado é o baixo desempenho dos
703 modelos RLM para previsões considerando o limite entre 80 a 100% de produtividade.
704 Os valores preditos pelos modelos, durante o teste e validação, foram distantes dos
705 observados quando o objetivo foi prever produtividades relativas superiores a 80%.
706 Esse comportamento foi observado para ambos os sistemas de irrigação (Figura 2), com
707 previsões mais distantes para a cebola cultivada sob gotejamento, quando comparada à
708 microaspersão. Esse desempenho não diferiu entre os modelos construídos a partir de
709 entradas não destrutivas e destrutivas (Figura 2). Os resultados sugerem que os modelos
710 de RLM não são capazes de detectar todas as relações existentes entre a produtividade
711 da cebola e as variáveis referentes à comunidade de plantas daninhas avaliadas nesse
712 trabalho.

713 Apesar de grande parte da variação na produtividade da cebola estar associada
714 ao período e relação M/E no gotejamento e período na microaspersão, provavelmente
715 outras relações complexas e não lineares estão envolvidas e não foram identificadas
716 pelos modelos. Esse fato limitou melhor desempenho dos modelos lineares para
717 previsão das perdas causadas pela interferência de plantas daninhas.

718

719

720

721

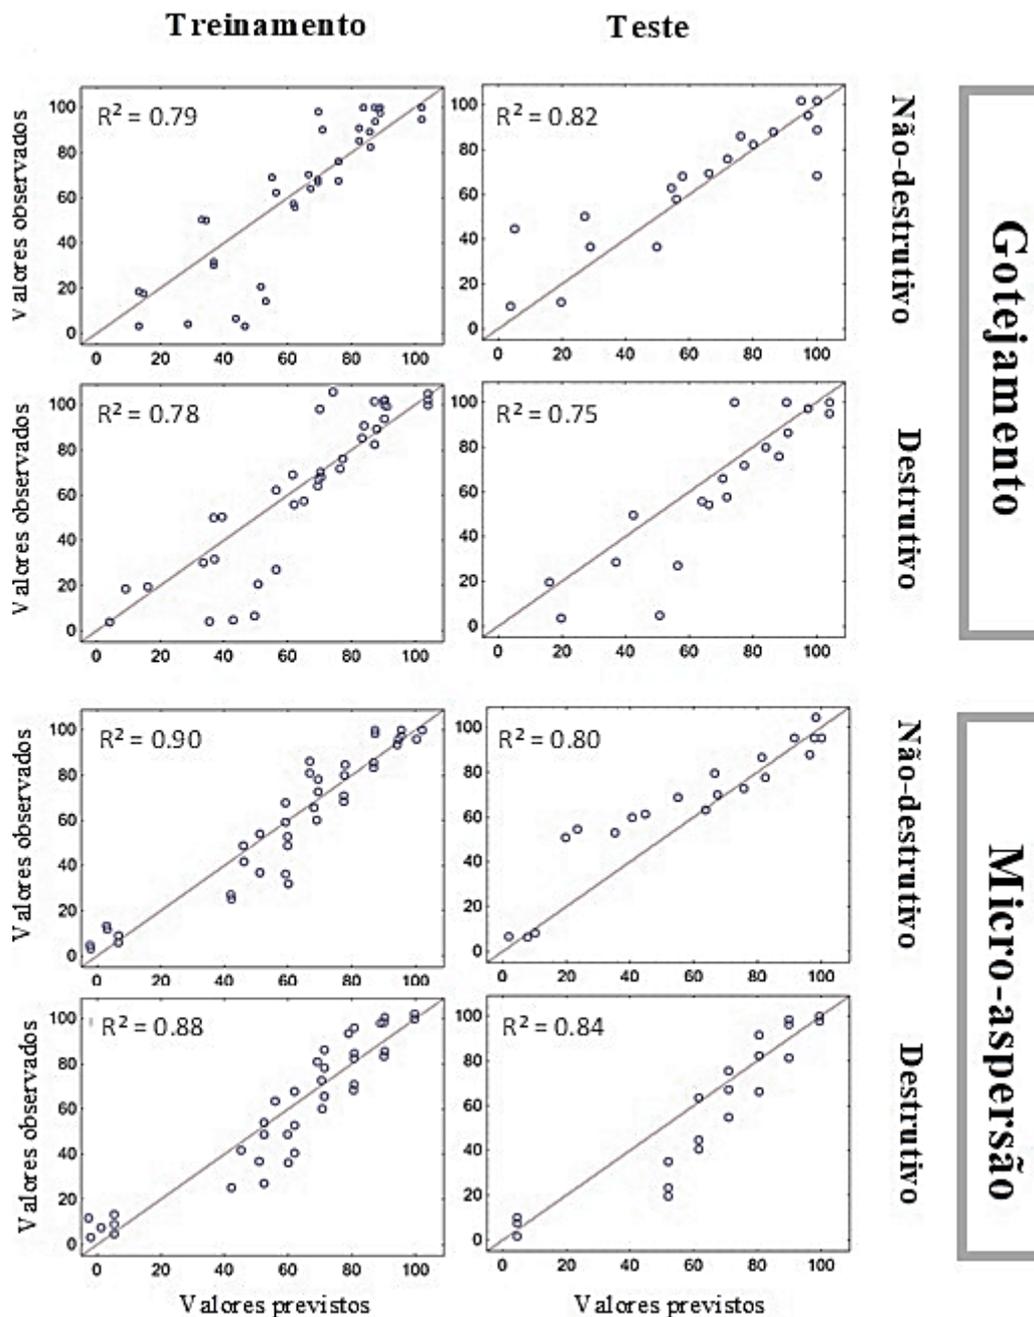
722

723

724

725

726



727 **Figura 2.** Produção relativa prevista e observada da cebola cultivada sob gotejamento e
 728 microaspersão, obtidas por modelo de regressão linear múltipla com entradas não
 729 destrutivas e destrutivas, durante a fase de treinamento (esquerda) e validação (direita).

730

731 **3.3 Uso de RNAs na estimativa da perda de produtividade de cebola devido à** 732 **competição por plantas daninhas**

733

734 As características e desempenho das redes neurais construídas a partir de
 735 entradas não destrutivas podem ser observados na tabela 4. As RNAs variaram quanto

736 ao número de entradas consideradas. O modelo com duas variáveis mostrou o pior
 737 desempenho comparado às demais redes, com valores de R^2 equivalentes a 0,79, 0,77 e
 738 0,81, MAE 10,46, 11,31, 10,57 e RMSE 15,25, 15,76, 14,80 para o treinamento,
 739 validação e teste (Tabela 4). A adoção de três variáveis aumentou o R^2 (0,96, 0,96, 0,95)
 740 e diminuiu o MAE (4,48, 6,01, 5,83) e RMSE (5,99, 7,93, 7,75) durante o treinamento,
 741 validação e teste. Os modelos com 3, 4 e 5 entradas mostraram poucas diferenças para o
 742 R^2 , porém os valores de MAE e RMSE foram menores nos modelos com 4 e 5 entradas,
 743 na comparação com o modelo com três entradas (Tabela 4).

744

745 **Tabela 4.** Desempenho das redes neurais artificiais (RNAs) durante as etapas de
 746 treinamento, validação e teste para estimar as perdas de produtividade relativa da cebola
 747 cultivada sob gotejamento ou microaspersão considerando entradas não destrutivas.

	Número de variáveis de entrada			
	2	3	4	5
Função de ativação (Camada oculta)	Tangente	Logística	Logística	Tangente
Função de ativação (Camada de saída)	Exponencial	Logística	Tangente	Logística
Arquitetura da rede	2-12-1	3-20-1	4-16-1	5-10-1
Entradas	PI; SI	PI; DP; SI	PI; DP; M/E ND ; SI	PI; DP; M/E ND ; C4/C3 ND ; SI
Treinamento				
R^2	0,79	0,96	0,96	0,99
MAE	10,46	4,48	1,28	1,30
RMSE	15,25	5,99	2,12	1,95
Validação				
R^2	0,77	0,96	0,96	0,97
MAE	11,31	6,01	4,74	4,85
RMSE	15,76	7,93	6,41	6,49
Teste				
R^2	0,81	0,95	0,96	0,97
MAE	10,57	5,83	5,29	4,96
RMSE	14,80	7,75	6,94	6,93

748 PI = Período de interferência; SI = Sistemas de irrigação; DP = Densidade de plantas daninhas
 749 (plantas/m²); M/END = Relação entre número de espécies daninhas monocotiledôneas e eudicotiledôneas;
 750 C4/C3ND = Relação entre o número de espécies daninhas C4/C3; R^2 = Coeficiente de determinação; MAE
 751 = Erro absoluto médio; RMSE = Erro quadrático médio da raiz.

752

753 A rede com duas variáveis de entradas necessitou de 12 neurônios na camada
 754 oculta para convergir a uma solução. A adoção de dois ou mais neurônios na camada
 755 oculta é recorrente em problemas não lineares (SHARMA, 2017; SEMENOV et al.,
 756 2017). Conseqüentemente, as perdas de produtividade da cebola são resolvidas por
 757 regressões lineares quando as variáveis período de convivência e sistema de irrigação
 758 são usadas como entradas. Apesar da RNA com duas entradas ter alcançado uma
 759 solução, o desempenho dessa rede foi similar aos modelos de RLM obtidos a partir de
 760 cada sistema de irrigação, restringindo o uso dessa rede para tomada de decisão. Esse
 761 cenário foi completamente diferente para as RNAs com três ou mais entradas. A
 762 variável densidade de plantas daninhas permitiu aumento considerável na capacidade
 763 preditiva das redes. Além disso, incrementos menores também foram alcançados devido
 764 à adição das relações M/E^{ND} e $C4/C3^{ND}$. Esses resultados mostram a limitação dos
 765 modelos lineares para interpretar as relações entre as perdas de produtividade devido a
 766 interferência de plantas daninhas. As RNAs foram capazes de captar variações oriundas
 767 da densidade e demais parâmetros relacionados à comunidade de plantas daninhas e
 768 convergir para um modelo com alto padrão de previsão.

769 As características e desempenho das redes neurais construídas a partir de
 770 entradas destrutivas são mostrados na tabela 5. Os índices de desempenho do modelo
 771 foram superiores para RNAs com variáveis destrutivas, na comparação a variáveis não
 772 destrutivas. As RNAs com três, quatro e cinco entradas tiveram valores de R^2 superiores
 773 a 0,97 nas fases de treinamento, validação e teste, com valor máximo de 0,99 para as
 774 redes com quatro e cinco variáveis. A RNA com cinco variáveis de entrada mostrou o
 775 melhor desempenho, comparada às demais redes, com maior R^2 (0,99) e menor MAE
 776 (0,52, 3,09 e 3,02) e RMSE (0,79, 4,70 e 4,48) durante o treinamento, validação e teste
 777 (Tabela 5).

778

779 **Tabela 5.** Desempenho das redes neurais artificiais (RNAs) durante as etapas de
 780 treinamento, validação e teste para estimar as perdas de produtividade relativa da cebola
 781 cultivada sob gotejamento ou microaspersão considerando entradas destrutivas.

	Número de variáveis de entrada			
	2	3	4	5
Função de ativação (Camada oculta)	Tangente	Tangente	Logística	Logística

Função de ativação (Camada de saída)	Identidade	Exponencial	Tangente	Tangente
Arquitetura da rede	2-12-1	3-18-1	4-17-1	5-18-1
Entradas	PI; SI	PI; FM; SI	PI; FM; M/E ^D ; SI	PI; FM; M/E ^D ; C4/C3 ^D ; SI
Treinamento				
R ²	0.79	0.98	0.99	0.99
MAE	10.46	2.71	1.22	0.52
RMSE	15.25	3.74	2.01	0.79
Validação				
R ²	0.77	0.97	0.98	0.99
MAE	11.31	5.23	4.40	3.09
RMSE	15.76	6.95	5.88	4.70
Teste				
R ²	0.81	0.98	0.99	0.99
MAE	10.57	4.79	4.82	3.02
RMSE	14.80	6.05	5.91	4.48

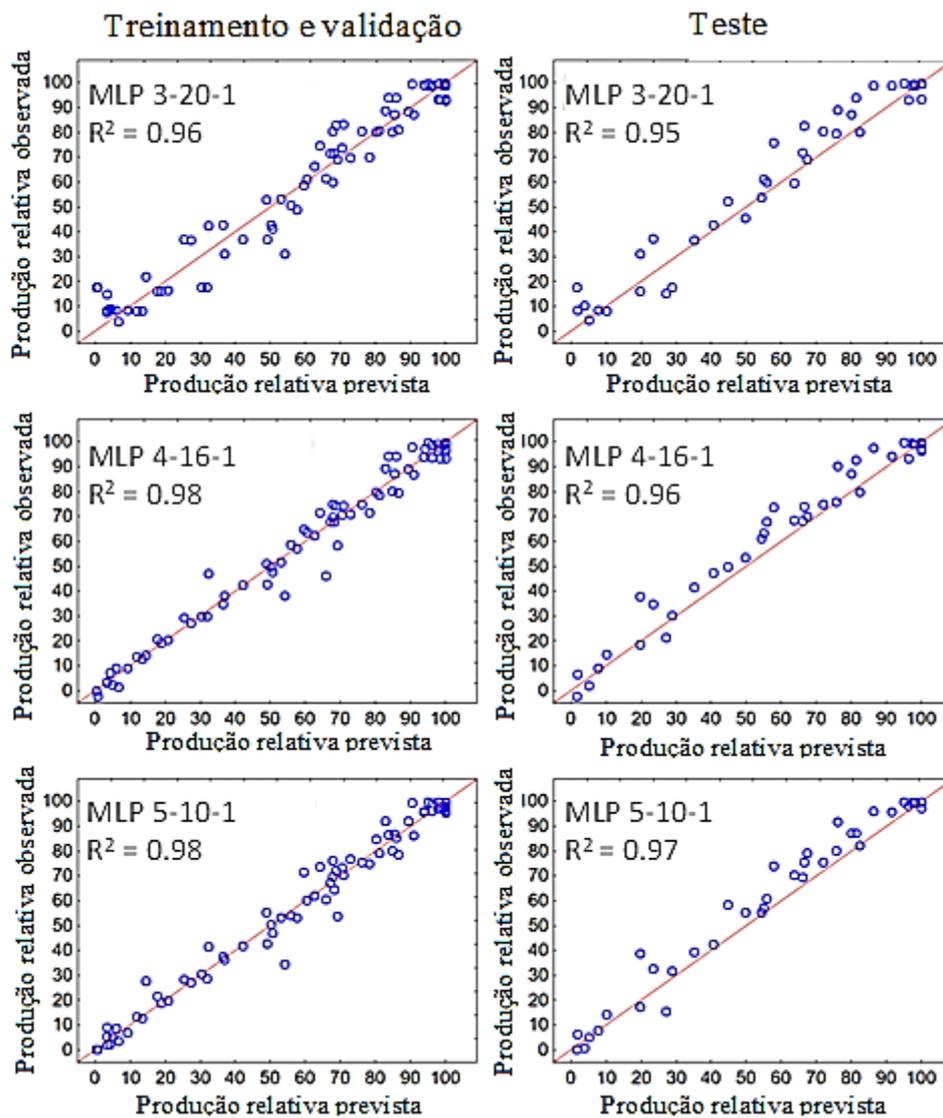
782 PI = Períodos de interferência de plantas daninhas; SI = Sistema de irrigação; FM = Matéria fresca de
783 plantas daninhas; M/E^D = Relação entre a matéria fresca de espécies daninhas monocotiledôneas e
784 eudicotiledôneas; C3/C4^D = Relação entre a matéria fresca de espécies C4/C3. R² = Coeficiente de
785 determinação; MAE = Erro absoluto médio; RMSE = Erro médio quadrático da raiz.

786

787 De maneira similar às RNAs construídas a partir de variáveis não destrutivas, a
788 adoção de parâmetros relacionados à comunidade de plantas daninhas, como matéria
789 fresca acumulada de plantas daninhas e suas relações M/E^D e C4/C3^D, resultaram na
790 maior capacidade preditiva para as perdas de produtividade da cebola. No entanto, as
791 RNAs formadas por variáveis destrutivas foram ligeiramente superiores às RNAs não
792 destrutivas. Ambos os parâmetros, densidade e matéria fresca de plantas daninhas,
793 podem fornecer informações sobre nível de infestação de plantas daninhas (FREITAS
794 SOUZA et al., 2020). Todavia, a matéria fresca possui maior capacidade de avaliar
795 como a comunidade de plantas daninhas cresce em uma área, indicando indiretamente a
796 quantidade de carbono fixado e água e minerais absorvidos durante o convívio com a
797 cultura (AIKIO et al., 2009; RÖHRIG; STÜTZEL, 200). Essa maior precisão
798 relacionada à matéria fresca, comparada à densidade, provavelmente permitiu o melhor
799 desempenho de RNAs baseada em variáveis destrutivas.

800 As RNAs geradas a partir de variáveis não destrutivas e destrutivas e um número
801 mínimo de três entradas possuem potencial para aplicação em modelos de tomada de
802 decisão. No entanto, as redes com menor erro para previsões considerando o limite

803 superior de produtividade (variando entre 80 a 100%) são preferíveis, como discutido
 804 anteriormente para os modelos de RLMs. Para RNAs não destrutivas, as redes com
 805 quatro e cinco entradas tiveram menor erro para o limite superior (Figura 3). Dentre as
 806 RNAs destrutivas, a rede com cinco entradas mostrou melhor capacidade preditiva para
 807 esse platô (Figura 4).
 808



809

810

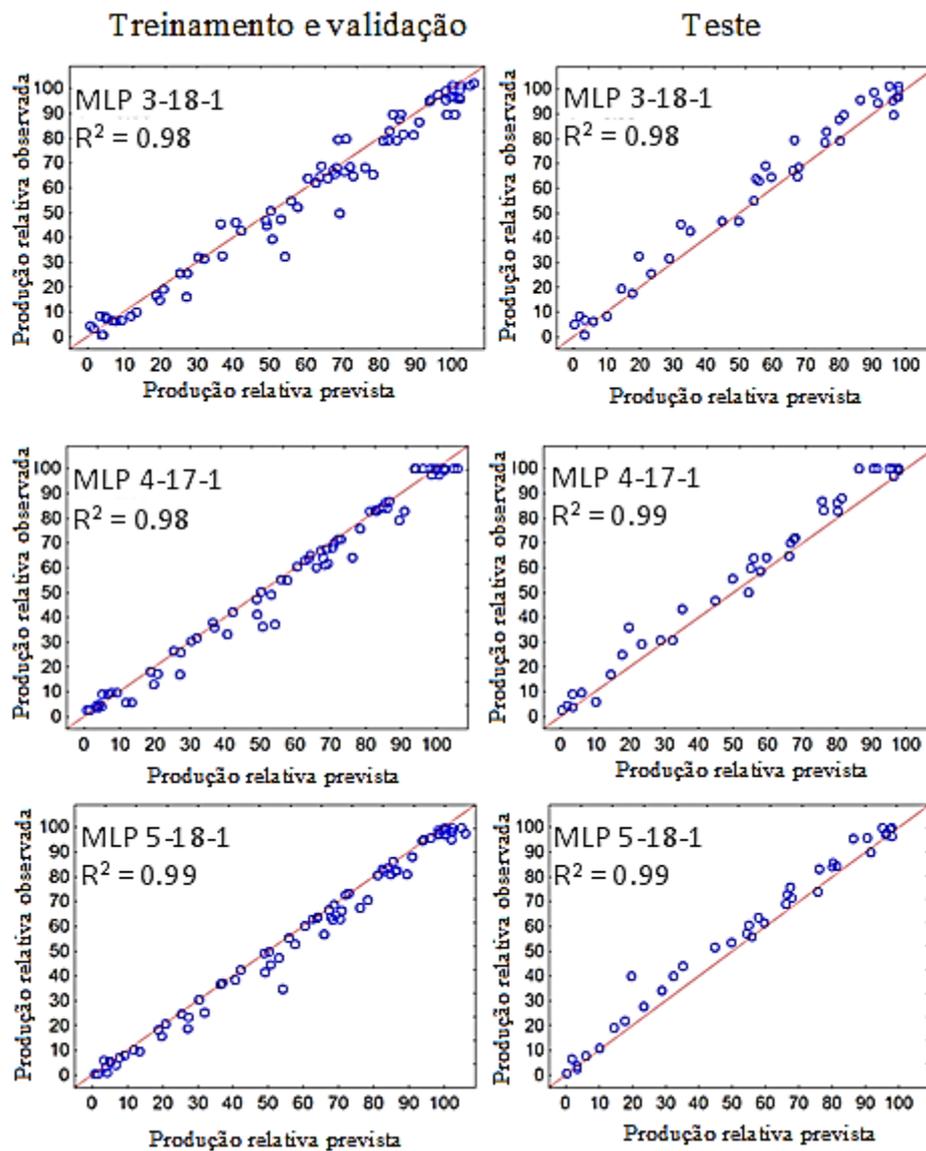
811 **Figura 3.** Produção relativa prevista e observada da cebola cultivada sob gotejamento
 812 ou microaspersão, obtidas pelas redes neurais artificiais (RNAs) com entradas não
 813 destrutivas, durante a fase de treinamento, teste e validação.

814

815

816

817
818
819
820
821



822
823
824
825
826
827
828
829

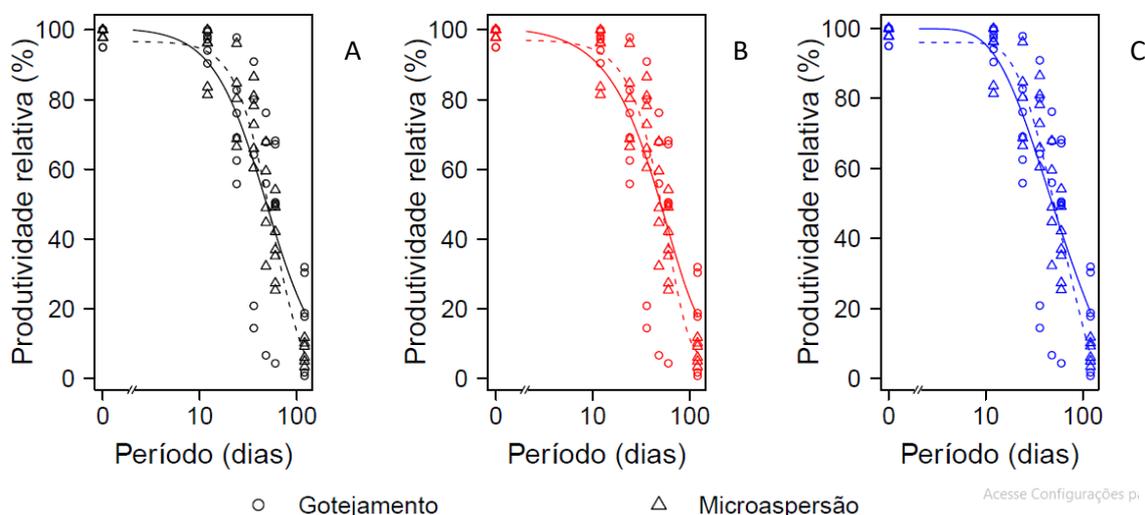
Figura 4. Produção relativa prevista e observada da cebola cultivada sob gotejamento ou microaspersão, obtidas pelas redes neurais artificiais (RNAs) com entradas destrutivas, durante a fase de treinamento, teste e validação.

830 3.4 Comparação entre RNAs e modelos Log-logísticos tradicionais para modelar a 831 interferência de plantas daninhas

832

833 Modelos tradicionais baseados em sigmóides foram aplicados aos dados de
834 treinamento para interpretação dos dados coletados, conforme mostrado na figura 5. Os
835 dados usados para o treinamento das redes mostraram padrão de distribuição sigmóidal.
836 Esse padrão é recorrente em estudos envolvendo a produtividade das culturas ao
837 longo do tempo (LINS et al., 2019; SINGH et al., 2018; SEYYEDI et al., 2016;
838 TURSUN et al., 2016). Os modelos log-logístico, Weibull-1 e Weibull-2 mostraram
839 nível de ajuste similar para os dados, com valores de R^2 e RMSE (Apêndice III).

840



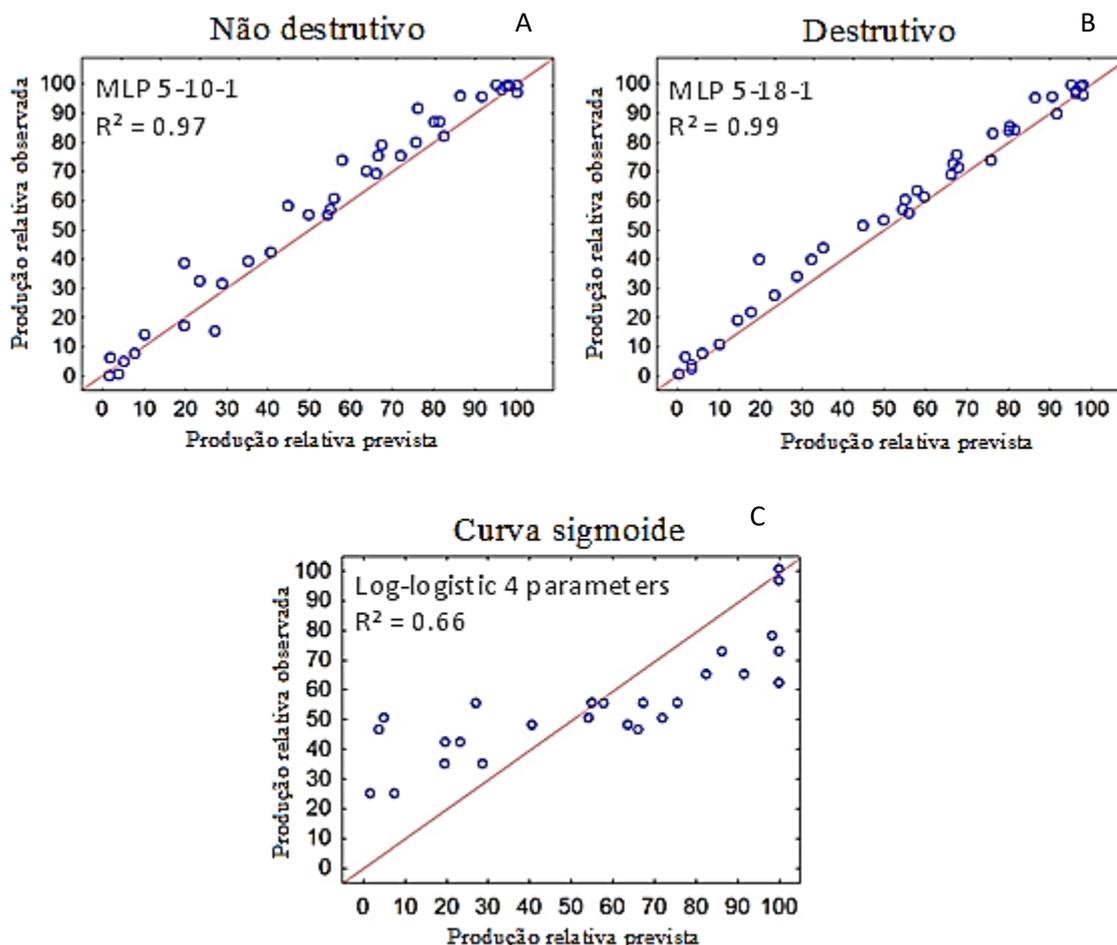
841

842 **Figura 5.** Modelos sigmóidais log-logístico (A), Weibull-1 (B) e Weibull-2 (C)
843 aplicados para avaliar a produtividade relativa da cebola, cultivada em gotejamento e
844 microaspersão, ao longo de períodos crescentes em convivência com plantas daninhas.

845

846 Mesmo considerando um modelo para cada sistema de irrigação, grande parte dos
847 pontos observados está distante da curva gerada pelas sigmóides, resultando nos baixos
848 valores para de R^2 e alto para RMSE. Notavelmente, os modelos baseados apenas na
849 produtividade relativa e período de convivência não foram capazes de detectar toda
850 variação existente para os dados coletados nos campos de cebola ao longo dos três anos
851 de cultivo e sob dois sistemas de irrigação. Desta maneira, modelos sigmóides e
852 hiperbólicos devem se restringir a estudos empíricos que buscam entender e explicar a
853 competição de plantas daninhas sob condições específicas e previamente determinadas.

854 As RNAs apresentaram alta precisão para a previsão da produtividade da cebola na
 855 fase de teste, com R^2 equivalente a 0,97 e 0,99 para as redes de entradas não destrutivas
 856 e destrutivas, respectivamente (Figuras 6A e 6B). Para o modelo sigmoidal Log-
 857 logístico, a correlação observada entre os valores observados e preditos foi igual a 0,66
 858 (Figura 6C).
 859



860
 861 **Figura 6.** Desempenho das redes neurais artificiais (A e B) e o modelo sigmoidal log-
 862 logístico (C) para estimar as perdas de produção relativa da cebola, cultivadas sob
 863 gotejamento ou microaspersão, devido à competição durante a fase de validação.

864

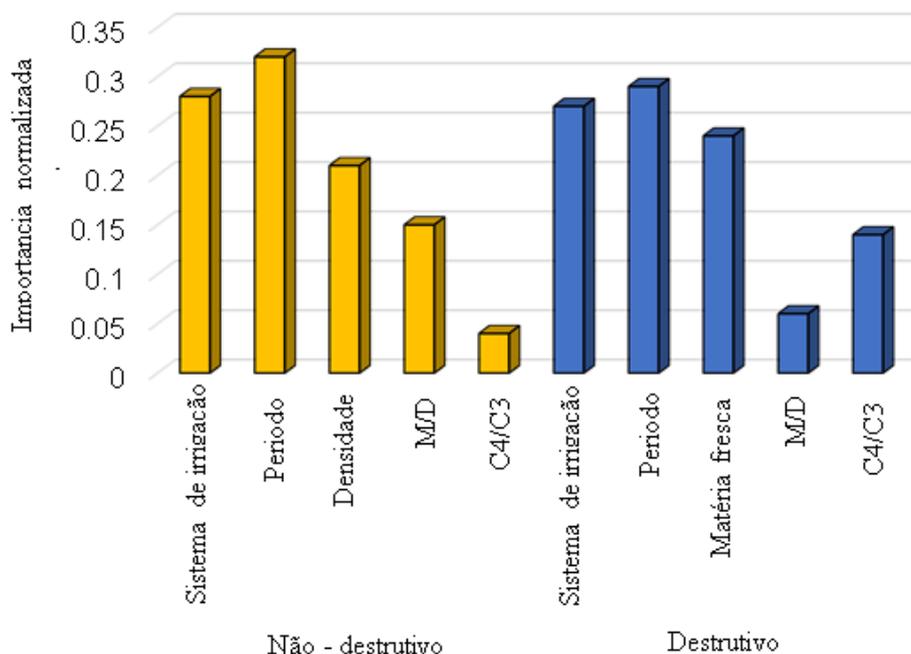
865 A capacidade preditiva dos modelos de RNAs para os métodos não destrutivos e
 866 destrutivos foi elevada e precisa. Esse padrão não foi alcançado para os modelos
 867 sigmoides tradicionais, com previsões bem distantes para as perdas de produtividade da
 868 cebola durante a fase de teste. Um desafio importante na modelagem de competição de
 869 plantas daninhas é a capacidade limitada dos modelos atuais em generalizar resultados

870 para as condições heterogêneas existentes nos campos agrícolas (RENTON;
871 CHAUHAN, 2017).

872 No entanto, os resultados comparativos entre as RNAs e as sigmóides
873 tradicionais sugerem fortemente que esse desafio pode ser superado aplicando modelos
874 de aprendizagem de máquinas. A principal vantagem das RNAs sobre modelos
875 tradicionais foi a possibilidade de adicionar diferentes inputs envolvidos na competição
876 entre planta daninhas e cultura (COLBACH et al., 2019; BRIM-DEFOREST et al.,
877 2017). Variáveis como sistema de irrigação, densidade e matéria fresca e outras
878 informações sobre a comunidade de plantas daninhas permitiram que as RNAs
879 realizassem uma interpretação mais ampla dos dados, resultando em alta previsão,
880 mesmo para situações heterogêneas. Essa análise considerando diferentes inputs não é
881 aplicada em modelos sigmóides mais simplistas utilizados para modelagem da
882 competição entre plantas daninhas e culturas. Consequentemente, os demais parâmetros
883 relacionados às plantas daninhas são discutidos apenas descritivamente (RENTON;
884 CHAUHAN, 2017).

885 Apesar da maior abstração das RNAs devido a relações mais complexas entre
886 entradas, neurônios, nós e saídas, a importância de cada entrada pode ser avaliada
887 mediante a análise de sensibilidade (SILVA et al., 2019). Na RNA com cinco entradas
888 não destrutivas, a variável Período teve maior importância relativa (0,32), seguido pelo
889 sistema de irrigação (0,28), Densidade (0,21), M/E (0,15) e C4/C3 (0,04) (Figura 7).
890 Para as entradas destrutivas, a ordem decrescente de importância das variáveis foi
891 Período > sistema de irrigação > matéria fresca > C4/C3 > M/E (Figura 7).

892



893

894 **Figura 7.** Importância relativa das entradas para composição das redes neurais MLP 5-
 895 10-1 (não destrutivas) e MLP 5-18-1 (Destrutiva).

896

897 A análise de sensibilidade confirmou a importância de outras variáveis, além do
 898 período de convivência, para a construção das RNAs. Mesmo que atribuindo maior
 899 importância ao período de convivência, os pesos relativos das demais entradas
 900 representaram 68% e 71% para redes não destrutivas e destrutivas. Além das variáveis
 901 densidade e matéria fresca de plantas daninhas, a razão da distribuição das espécies
 902 monocotiledôneas e eudicotiledôneas e com ciclo fotossintético C4 e C3 contribuíram
 903 com 20% do peso relativo para determinar as perdas na produtividade da cebola. Essa
 904 informação dificilmente seria extraída por meio de outros modelos sigmóides e
 905 hiperbólicos simples, uma vez que eles não consideram a contribuição conjunta de
 906 várias variáveis (RENTON; CHAUHAN, 2017).

907

908 Os resultados deste estudo mostram a limitação de modelos lineares, mesmo
 909 aplicados a multivariáveis, para estimar as perdas relativas da cebola devido à
 910 competição com plantas daninhas. Essa limitação ocorre devido a relações não lineares
 911 para algumas variáveis relacionadas à comunidade de plantas daninhas. Por exemplo, a
 912 densidade, matéria fresca e razão C4/C3 não tiveram correlação linear com a
 913 produtividade da cebola para os dados coletados. No entanto, a modelagem por RNAs
 914 indicou alta importância relativa dessas variáveis para estimar as perdas relativas
 causadas pela competição com plantas daninhas. As RNAs com melhor desempenho,

915 tanto baseadas em entradas não destrutivas quanto destrutivas, foram capazes de
916 aprender e aplicar as possíveis correlações não lineares existentes em sua arquitetura. O
917 resultado dessa aprendizagem foi o elevado desempenho das RNAs, superior a 97% de
918 acerto, para as fases de treinamento, validação e teste. Esse fato sugere que essas redes
919 podem ser aplicadas para decidir ou não o controle de plantas daninhas, mesmo para
920 condições altamente heterogêneas como observado nesse estudo. Encorajamos estudos
921 futuros implementando a tomada de decisão para controle de plantas daninhas baseadas
922 no levantamento digital da comunidade, uma vez que algoritmos de reconhecimento
923 estão cada vez mais precisos para identificar e classificar plantas daninhas em campos
924 agrícolas (WANG et al., 2019; BAKHSHIPOUR; JAFARIL, 2018).

925

926 **4 CONCLUSÕES**

927

928 Modelos RLM baseados em entradas não destrutivas e destrutivas sobre a
929 comunidade de plantas daninhas são capazes de estimar as perdas de produtividade da
930 cebola devido à competição, porém com baixa precisão.

931 O desempenho das RNAs para estimar as perdas de produtividade devido à
932 interferência de plantas daninhas varia de acordo com as variáveis de entrada
933 consideradas.

934 Modelos de RNAs com apenas as variáveis período de convivência e sistemas de
935 irrigação possuem desempenho similar a modelos RLM.

936 No entanto, a inserção das variáveis relacionadas à densidade de plantas
937 daninhas (RNA não destrutiva) e a matéria fresca (RNA destrutiva) eleva a capacidade
938 preditiva das redes para valores próximos a 99% de acerto.

939 As RNAs de melhor performance podem indicar o início do controle de plantas
940 daninhas, uma vez que são capazes de estimar com precisão as perdas devido à
941 competição.

942

943

944

945

946

947

948 **REFERÊNCIAS**

949

950 AIKIO, S.; RÄMÖ, K.; MANNINEN, S. Dynamics of biomass partitioning in two
951 competing meadow plant species. **Plant Ecology**, v. 205, n. 1, p. 129-137, 2009.

952

953 ARMENGOT, L.; BLANCO-MORENO, J. M.; BÀRBERI, P.; BOCCI, G.; CARLESI,
954 S.; AENDEKERK, R., ...; KRANZLER, A. Tillage as a driver of change in weed
955 communities: a functional perspective. **Agriculture, Ecosystems & Environment**, v.
956 222, p. 276-285, 2016.

957

958 ASAD, M. H.; BAIS, A. Weed detection in canola fields using maximum likelihood
959 classification and deep convolutional neural network. **Information Processing in**
960 **Agriculture**, 2019.

961

962 ABDIPOUR, M. et al. Artificial neural networks and multiple linear regression as
963 potential methods for modeling seed yield of safflower (*Carthamus tinctorius*
964 L.). **Industrial crops and products**, v. 127, p. 185-194, 2019.

965

966 ARMENGOT, L. et al. Tillage as a driver of change in weed communities: a functional
967 perspective. **Agriculture, Ecosystems & Environment**, v. 222, p. 276-285, 2016.

968

969 BAKHSHIPOUR, A.; JAFARI, A. Evaluation of support vector machine and artificial
970 neural networks in weed detection using shape features. **Computers and Electronics in**
971 **Agriculture**, v. 145, p. 153-160, 2018.

972

973 BERTUCCI, M. B. et al. Critical period for weed control in grafted and nongrafted
974 watermelon grown in plasticulture. **Weed Science**, v. 67, n. 2, p. 221-228, 2019.

975

976 BENARAGAMA, D.; SHIRTLIFFE, S. J.; JOHNSON, E. N.; DUDDU, H. S. N.;
977 SYROVY, L. D. Does yield loss due to weed competition differ between organic and
978 conventional cropping systems? **Weed Research**, v. 56, n. 4, p. 274-283, 2016.

979

980 BLACKSHAW, R. E.; SEMACH, G.; JANZEN, H. H. Fertilizer application method
981 affects nitrogen uptake in weeds and wheat. **Weed Science**, v. 50, n. 5, p. 634-641,
982 2002.

983

984 BRIM-DEFOREST, W. B.; AL-KHATIB, K.; FISCHER, A. J. Predicting yield losses
985 in rice mixed-weed species infestations in California. **Weed Science**, v. 65, n. 1, p. 61-
986 72, 2017.

987

988 BROWN, B.; GALLANDT, E. R. A systems comparison of contrasting organic weed
989 management strategies. **Weed Science**, v. 66, n. 1, p. 109-120, 2018.

990

991 CHARLES, G. W. et al. Determining the critical period for weed control in high-
992 yielding cotton using common sunflower as a mimic weed. **Weed Technology**, v. 33, n.
993 6, p. 800-807, 2019.

994

995 CIRILLO, V.; MASIN, R.; MAGGIO, A.; ZANIN, G. Crop-weed interactions in saline
996 environments. **European Journal of Agronomy**, v. 99, p. 51-61, 2018.

997

- 998 COLBACH, N.; GARDARIN, A.; MOREAU, D. The response of weed and crop
999 species to shading: Which parameters explain weed impacts on crop production?. **Field**
1000 **Crops Research**, v. 238, p. 45-55, 2019.
1001
- 1002 DHAKAL, B.; SCANLAN, J. Assessment of functional forms of crop yield loss models
1003 of invasive plant species applied in decision support tools and bioeconomic
1004 modelling. **Agricultural Systems**, v. 138, p. 100-115, 2015.
1005
- 1006 EBRAHIMI, M.; SARIKHANI, M. R.; SINEGANI, A. A. S.; AHMADI, A.;
1007 KEESSTRA, S. Estimating the soil respiration under different land uses using artificial
1008 neural network and linear regression models. **Catena**, v. 174, p. 371-382, 2019.
1009
- 1010 FAOSTAT – Food Agricultural Organization Statistical, 2018. Agricultural Data.
1011 Disponível em: <<http://www.fao.org/faostat/en/#data/QC>>. Acesso em: 08 out. 2020.
1012
- 1013 FENG, P. et al. Impacts of rainfall extremes on wheat yield in semi-arid cropping
1014 systems in eastern Australia. **Climatic change**, v. 147, n. 3-4, p. 555-569, 2018.
1015
- 1016 FERREIRA, G. O. et al. Evaluation of onion accessions for resistance to thrips in
1017 Brazilian semi-arid regions. **The Journal of Horticultural Science and**
1018 **Biotechnology**, v. 92, n. 5, p. 550-558, 2017.
1019
- 1020 FREITAS SOUZA, M.; SILVA, T. S.; SANTOS, J. B.; CARNEIRO, G. D. O. P.;
1021 REGINALDO, L. T. R. T.; BANDEIRA, J. N.; SILVA, D. V. Soil water availability
1022 alter the weed community and its interference on onion crops. **Scientia Horticulturae**,
1023 v. 272, 109573, 2020.
1024
- 1025 GHOLAMI, V. et al. Spatial soil erosion estimation using an artificial neural network
1026 (ANN) and field plot data. **Catena**, v. 163, p. 210-218, 2018.
1027
- 1028 GHOLIPOOR, M; NADALI, F. Fruit yield prediction of pepper using artificial neural
1029 network. **Scientia Horticulturae**, v. 250, p. 249-253, 2019.
1030
- 1031 KERN, A. et al. Statistical modelling of crop yield in Central Europe using climate data
1032 and remote sensing vegetation indices. **Agricultural and forest meteorology**, v. 260-
1033 261, p. 300-320, 2018.
1034
- 1035 KNEZEVIC, S. Z. et al. Critical period for weed control: the concept and data
1036 analysis. **Weed science**, v. 50, n. 6, p. 773-786, 2002.
1037
- 1038 KHOKHAR, K. M. et al. Evaluation of integrated weed management practices for
1039 onion in Pakistan. **Crop Protection**, v. 25, n. 9, p. 968-972, 2006.
1040
- 1041 LINS, H. A. et al. Weed interference periods in sesame crop. **Ciência e**
1042 **Agrotecnologia**, v. 43, e000819, 2019.
1043
- 1044 MAHAUT, L.; GABA, S.; FRIED, G. A functional diversity approach of crop
1045 sequences reveals that weed diversity and abundance show different responses to
1046 environmental variability. **Journal of Applied Ecology**, v. 56, n. 6, p. 1400-1409, 2019.

- 1047 MANSOURIAN, S. et al. Comparison of artificial neural networks and logistic
1048 regression as potential methods for predicting weed populations on dryland chickpea
1049 and winter wheat fields of Kurdistan province, Iran. **Crop Protection**, v. 93, p. 43-51,
1050 2017.
- 1051
1052 MATSUMURA, K. et al. Maize yield forecasting by linear regression and artificial
1053 neural networks in Jilin, China. **The Journal of Agricultural Science**, v. 153, n. 3, p.
1054 399-410, 2015.
- 1055
1056 MEHTA, P.; BUKOV, M.; WANG, C. H.; DAY, A. G.; RICHARDSON, C.; FISHER,
1057 C. K.; SCHWAB, D. J. A high-bias, low-variance introduction to machine learning for
1058 physicists. **Physics reports**, v. 810, p. 1-124, 2019.
- 1059
1060 MEYERS, S. L.; SHANKLE, M. W. Interference of Yellow Nutsedge (*Cyperus*
1061 *esculentus*) in 'Beauregard' Sweet Potato (*Ipomoea batatas*). **Weed Technology**, v. 29,
1062 n. 4, p. 854-860, 2015.
- 1063
1064 PANDEY, A; MISHRA, A. Application of artificial neural networks in yield prediction
1065 of potato crop. **Russian Agricultural Sciences**, v. 43, n. 3, p. 266-272, 2017.
- 1066
1067 PIRI, H.; NASERIN, A. Effect of different levels of water, applied nitrogen and
1068 irrigation methods on yield, yield components and IWUE of onion. **Scientia**
1069 **Horticulturae**, v. 268, 109361, 2020.
- 1070
1071 PANNACCI, E. et al. Mechanical weed control in onion seed production. **Crop**
1072 **Protection**, v. 135, 105221, 2020.
- 1073
1074 PANNACCI, E.; TEI, F.; GUIDUCCI, M. Evaluation of mechanical weed control in
1075 legume crops. **Crop Protection**, v. 104, p. 52-59. 2018.
- 1076
1077 QASEM, J. R. Chemical weed control in seedbed sown onion (*Allium cepa* L.). **Crop**
1078 **Protection**, v. 25, n. 6, p. 618-622, 2006.
- 1079
1080 RENTON, M.; CHAUHAN, B. S. Modelling crop-weed competition: Why, what, how
1081 and what lies ahead? **Crop Protection**, v. 95, p. 101-108, 2017.
- 1082
1083 RAO, K. V. R. et al. Growth, yield, economics and water use efficiency of onion
1084 (*Allium cepa* L.) under different micro irrigation systems. **Journal of Pharmacognosy**
1085 **and Phytochemistry**, v. 8, n. 3, p. 3866-3869, 2019.
- 1086
1087 RAHMAN, H. U. et al. Relationship between manual weeds removal timings and onion
1088 yield. **Pakistan Journal of Weed Science Research**, v. 18, n. 2, p. 201-207, 2012.
- 1089
1090 RENTON, M.; CHAUHAN, B. S. Modelling crop-weed competition: Why, what, how
1091 and what lies ahead? **Crop Protection**, v. 95, p. 101-108, 2017.
- 1092
1093 RÖHRIG, M.; STÜTZEL, H. Dry matter production and partitioning of *Chenopodium*
1094 *album* in contrasting competitive environments. **Weed Research**, v. 41, n. 2, p. 129-
1095 142, 2001.
- 1096

- 1097 ROSSET, J. D.; GULDEN, R. H. Cultural weed management practices shorten the
1098 critical weed-free period for soybean grown in the Northern Great Plains. **Weed**
1099 **Science**, v. 68, n. 1, p. 79-91, 2020.
1100
- 1101 SEMENOV, V. P.; CHERNOKULSKY, V. V.; RAZMOCHAEVA, N. V. Research of
1102 artificial intelligence in the retail management problems. In 2017 IEEE II International
1103 Conference on Control in Technical Systems (CTS), p. 333-336, 2017.
1104
- 1105 SEYYEDI, S. M.; MOGHADDAM, P. R.; MAHALLATI, M. N. Weed competition
1106 periods affect grain yield and nutrient uptake of Black Seed (*Nigella Sativa* L.).
1107 **Horticultural Plant Journal**, v. 2, n. 3, p. 172-180, 2016.
1108
- 1109 SHARMA, S. Activation functions in neural networks. **Towards Data Science**, v. 4, n.
1110 12, p. 310-316, 2017.
1111
- 1112 SILVA, T. S. et al. Use of neural networks to estimate the sorption and desorption
1113 coefficients of herbicides: A case study of diuron, hexazinone, and sulfometuron-methyl
1114 in Brazil. **Chemosphere**, v. 236, 124333, 2019.
1115
- 1116 SINGH, K.; KAUR, T.; BHULLAR, M. S.; BRAR, A. S. The Critical period for weed
1117 control in spring maize in North-West India. **Maydica**, v. 61, n. 1, p. 7, 2018.
1118
- 1119 SÖZEN, A. Future projection of the energy dependency of Turkey using artificial neural
1120 network. **Energy policy**, v. 37, n. 11, p. 4827-4833, 2009.
1121
- 1122 SIVESIND, E. C. et al. Impact of selective flame weeding on onion yield, pungency,
1123 flavonoid concentration, and weeds. **Crop Protection**, v. 39, p. 45-51, 2012.
1124
- 1125 SOUZA, M. F. et al. Soil water availability alter the weed community and its
1126 interference on onion crops. **Scientia Horticulturae**, v. 272, p. 109573, 2020.
1127
- 1128 SOLTANI, N.; DILLE, J. A.; GULDEN, R. H.; SPRAGUE, C. L.; ZOLLINGER, R.
1129 K.; MORISHITA, D. W.; SIKKEMA, P. H. Potential yield loss in dry bean crops due to
1130 weeds in the United States and Canada. **Weed Technology**, v. 32, n. 3, p. 342-346,
1131 2018.
1132
- 1133 STORKEY, J.; NEVE, P. What good is weed diversity? **Weed Research**, v. 58, n. 4, n.
1134 p. 239-243, 2018.
1135
- 1136 SUTTON, K. F.; LANINI, W. T.; MITCHELL, J. P.; MIYAO, E. M.; SHRESTHA, A.
1137 Weed Control, Yield, and Quality of Processing Tomato Production under Different
1138 Irrigation, Tillage, and Herbicide Systems1. **Weed technology**, v. 20, n. 4, p. 831-838,
1139 2006.
1140
- 1141 TURSUN, N.; DATTA, A.; SAKINMAZ, M. S.; KANTARCI, Z.; KNEZEVIC, S. Z.;
1142 CHAUHAN, B. S. The critical period for weed control in three corn (*Zea mays* L.)
1143 types. **Crop protection**, v. 90, p. 59-65, 2016a.
1144

- 1145 TURSUN, N.; DATTA, A.; BUDAK, S.; KANTARCI, Z.; KNEZEVIC, S. Z. Row
1146 spacing impacts the critical period for weed control in cotton (*Gossypium hirsutum*).
1147 **Phytoparasitica**, v. 44, n. 1, p. 139-149, 2016b.
1148
- 1149 TRIPATHI, P. C. et al. Microirrigation in onion (*Allium cepa*) and garlic (*A. sativum*)-a
1150 review. **Current Horticulture**, v. 5, n. 1, p. 3-14, 2017.
1151
- 1152 WANG, A.; ZHANG, W.; WEI, X. A review on weed detection using ground-based
1153 machine vision and image processing techniques. **Computers and Electronics in
1154 Agriculture**, v. 158, p. 226-240, 2019.
1155
- 1156 WENZHI, Z. E. N. G.; CHI, X. U.; GANG, Z. H. A. O.; JINGWEI, W. U.; HUANG, J.
1157 Estimation of sunflower seed yield using partial least squares regression and artificial
1158 neural network models. **Pedosphere**, v. 28, n. 5, p. 764-774, 2018.
1159
- 1160 ZHANG, S. et al. Cucumber leaf disease identification with global pooling dilated
1161 convolutional neural network. **Computers and Electronics in Agriculture**, v. 162, p.
1162 422-430, 2019.
1163
- 1164 ZHENG, J. et al. Effects of water deficits on growth, yield and water productivity of
1165 drip-irrigated onion (*Allium cepa* L.) in an arid region of Northwest China. **Irrigation
1166 Science**, v. 31, n. 5, p. 995-1008, 2013.
1167
- 1168 ZHOU, X.; ZHU, X.; DONG, Z.; GUO, W. Estimation of biomass in wheat using
1169 random forest regression algorithm and remote sensing data. **The Crop Journal**, v. 4,
1170 n. 3, p. 212-219, 2016.
1171
1172
1173
1174
1175
1176
1177
1178
1179
1180
1181
1182
1183
1184
1185
1186
1187

CAPÍTULO 2

UMA NOVA ALTERNATIVA PARA DETERMINAR O CONTROLE DE PLANTAS DANINHAS EM SISTEMAS AGRÍCOLAS COM BASE EM REDES NEURAIAS ARTIFICIAIS (RNAS)

RESUMO

O controle de plantas daninhas é uma prática necessária para evitar as perdas de produção nas culturas. Quando o controle das plantas daninhas deixa ser realizado, as perdas podem atingir até 100% da produção. Assim, duas perguntas sempre surgem e devem ser respondidas: quando iniciar e como realizar o controle de plantas daninhas para evitar perdas não aceitáveis? Atualmente, não existem modelos de aprendizagem para auxiliar o produtor a responder tal questão. Desta maneira, este trabalho estabeleceu os seguintes objetivos: 1) avaliar a capacidade de Redes Neurais Artificiais em estimar o início do controle de plantas daninhas considerando culturas modelos e diferentes classes de perdas aceitáveis; 2) validar uma nova alternativa para modelagem e predição da competição entre plantas daninhas e culturas agrícolas. Estudos de campo foram conduzidos na Fazenda Experimental Rafael Fernandes, localizada em Mossoró-RN, durante os anos de 2016 e 2017, em delineamento de blocos casualizados com três repetições utilizando duas culturas modelos. Os tratamentos foram constituídos por seis intervalos expressos em graus-dias (GD), para cada cultura. Os intervalos considerados para o gergelim e melão foram 130, 260, 390, 520, 650, 1300 GD e 130, 260, 390, 520, 972 GD após a semeadura do gergelim e transplântio do melão, respectivamente. Os resultados mostraram que as Redes Neurais Artificiais são eficientes para determinar o momento ideal para controlar plantas daninhas baseadas em variáveis não destrutivas e destrutivas coletadas no campo. O mix de entradas não destrutivas (Densidade) e destrutivas (Matéria Fresca) dispensa outras entradas mais específicas, como a relação de espécies C3/C4 e Monocotiledôneas/Eudicotiledôneas. O Período é o principal fator para inferir o grau de interferência das plantas daninhas no gergelim e melão. A Densidade e Matéria Fresca, apesar de frequentemente correlacionadas, trazem diferentes interpretações sobre a dinâmica populacional de plantas daninhas para a Rede Neural Artificial quando usadas como variáveis de entrada.

PALAVRAS-CHAVE: Interferência de plantas daninhas, inteligência artificial, modelagem, tomada de decisão.

1230 **A NEW ALTERNATIVE TO DETERMINE THE CONTROL OF WEEDS IN**
1231 **AGRICULTURAL SYSTEMS BASED ON ARTIFICIAL NEURAL NETS**
1232 **(RNAS)**

1233

1234 **ABSTRACT**

1235

1236 Weed control is a necessary practice to avoid yield losses in crops. When the weed
1237 control is not accomplished, these losses can reach up to 100% of production. Thus, two
1238 questions must be answered: when should we start and how to accomplish the weed
1239 control in order to avoid unacceptable losses? Currently, there are no learning models to
1240 assist the producer to answer this question. In this way, this work established the
1241 objectives: 1) to evaluate the capacity of Artificial Neural Networks to estimate the
1242 beginning of weed control considering model cultures and different classes of
1243 acceptable losses; 2) validate a new alternative for modeling and predicting competition
1244 between weeds and agricultural crops. Field studies were conducted at Fazenda
1245 Experimental Rafael Fernandes, located in Mossoró-RN, during the years 2016 and
1246 2017, in a randomized block design with three replications using two model cultures.
1247 The treatments consisted of six intervals expressed in degree-days (DG), for each
1248 culture. The intervals considered for sesame and melon were 130, 260, 390, 520, 650,
1249 1300 GD and 130, 260, 390, 520, 972 GD after sowing the sesame and transplanting the
1250 melon, respectively. The results showed that Artificial Neural Networks are efficient to
1251 determine the ideal moment to control weeds based on non-destructive and destructive
1252 variables collected in the field. The mix of non-destructive (Density) and destructive
1253 (Fresh matter) inputs does not require other more specific inputs such as the C3 / C4
1254 and Monocotyledons / Eudicotyledons species. The Period is the main factor to infer the
1255 degree of weed interference in sesame and melon. Density and Fresh Matter, although
1256 frequently correlated, bring different interpretations about weed population dynamics to
1257 the Artificial Neural Network when used as input variables.

1258

1259 **KEYWORDS:** Weed interference, artificial intelligence, modeling, decision making.

1260

1261

1262

1263

1264

1265

1266

1267

1268

1269

1270

1271

1272 1. INTRODUÇÃO

1273

1274 As plantas daninhas são um dos principais fatores que restringem a produção de
1275 alimentos nos sistemas agrícolas em todo o mundo. Quando crescem simultaneamente
1276 com as culturas, as plantas daninhas fazem decrescer a produtividade e a qualidade do
1277 produto colhido, seja devido à competição por água, luz solar, nutrientes, espaço e/ou
1278 alelopatia (JHA et al., 2017). A alternativa para evitar ou reduzir essa interferência
1279 negativa sobre cultivos agrícolas é utilizar métodos de controle adequados (HARKER;
1280 O'DONOVAN, 2013). Todavia, essa prática eleva os custos de produção. Estima-se que
1281 o valor médio para controle de plantas daninhas varia de 5 a 20% do custo total gasto
1282 pelo produtor para produção de diversos alimentos (GIANESSI; REIGNER, 2007). Em
1283 cultivos para produção orgânica de alimentos, esses custos de controle são ainda mais
1284 elevados devido à adoção exclusiva do controle mecânico manual das plantas daninhas
1285 (GIANESSI; REIGNER, 2007).

1286 Apesar de oneroso ao produtor, o controle de plantas daninhas precisa ser
1287 implementado em algum momento, uma vez que a interferência sobre os cultivos pode
1288 ocasionar perdas de até 100% na produção. Muitos estudos já mostraram que a não
1289 adoção do controle de plantas daninhas reduziu a produtividade da soja em 70%
1290 (VITORINO et al., 2017), da cebola em 100% (SOUZA et al., 2019), do milho em 70%
1291 (TURSUN et al., 2016a), gergelim em 20% (LINS et al., 2019), algodão em 18%
1292 (TURSUN et al., 2016b), dentre outras (SEYYEDI et al., 2016; CHAUDHARI et al.,
1293 2016; MERINO et al., 2019).

1294 Considerando as drásticas perdas devido à interferência, os produtores são
1295 orientados a gastar parte de seus recursos para controlar plantas daninhas sempre que
1296 necessário. No entanto, duas questões cruciais surgem durante a tomada de decisão:
1297 Como controlar? Quando controlar? As informações para responder à primeira questão
1298 são encontradas em diversas publicações (artigos científicos e boletins técnicos) que
1299 buscam avaliar o desempenho de métodos de controle, sejam químicos (HARKER;
1300 O'DONOVAN, 2013), mecânicos (HUSSAIN et al., 2018) e físicos (HAIDAR;
1301 SIDAHMED, 2000) para diferentes culturas. A segunda questão pode ser esclarecida
1302 mediante determinação do período crítico de prevenção à interferência, na qual os
1303 resultados indicam qual o período ideal para iniciar e terminar o controle (RENTON;
1304 CHAUHAN, 2017).

1305 O período crítico de prevenção à interferência já foi definido para diversas
1306 culturas agrícolas, principalmente para espécies anuais (SOUZA et al., 2021; ROSSET;
1307 GULDEN, 2020; CHARLES et al., 2020; BERTUCCI et al., 2019). Geralmente,
1308 modelos matemáticos empíricos (regressões hiperbólicas e sigmóides) são construídos
1309 para estimar as perdas relativas da cultura apenas em função do tempo de coexistência
1310 com plantas daninhas (KNEZEVIC et al., 2002). Esse período de controle pode sofrer
1311 variações de acordo com a cultura, cultivar, sistema de cultivo, práticas de manejo e
1312 condições ambientais, e muitos estudos aplicaram essas variações a fim de compreender
1313 as relações entre ambiente, cultura e comunidade de plantas daninhas (RENTON;
1314 CHAUHAN, 2017). No entanto, Renton; Chauhan (2017) destacaram a limitada
1315 capacidade de generalização desses modelos devido a essas muitas variações,
1316 restringido sua aplicabilidade como ferramenta de tomada de decisão para estimar o
1317 período de controle de plantas infestantes. De certo modo, relações existentes entre os
1318 sistemas agrícolas e estabelecimento de plantas daninhas são muitas vezes complexas.
1319 Todavia, nos últimos anos, o desenvolvimento computacional facilitou a implementação
1320 de modelos capazes de entender relações altamente complexas, como, por exemplo, a
1321 aprendizagem supervisionada (ÖZESMI et al., 2006).

1322 Os modelos de aprendizagem são construídos com base na premissa de que eles
1323 podem aprender e entender relações existentes entre variáveis de tratamento e resposta,
1324 encontrando padrões amplamente generalizáveis para muitas condições (ÖZESMI et al.,
1325 2006; SEWSYNKER-SUKAIET et al., 2017). Modelos de aprendizagem já foram
1326 testados como alternativa para responder a problemas complexos em diferentes ramos
1327 das ciências agrárias, estando as redes neurais artificiais entre as mais populares. Por
1328 exemplo, redes neurais artificiais foram aplicadas com sucesso na predição da
1329 produtividade de batata (ABROUGUI et al., 2019), estimativa da seca agrícola no
1330 sudeste da Austrália (FENG et al., 2019), valor energético de silagens para substrato em
1331 usinas de biogás (KOWALCZYK-JUŚKO et al., 2020), identificação de sementes de
1332 milho haploides e diploides (ALTUNTAŞ et al., 2019) e classificação de doenças de
1333 culturas (PICON et al., 2019). Na ciência de plantas daninhas, as redes neurais
1334 artificiais têm sido empregadas para identificar espécies de plantas daninhas
1335 (DYRMANN et al., 2016; YU et al., 2019), determinação da distribuição espacial para
1336 aplicação de herbicidas (HUANG et al., 2018; OLSEN et al., 2019) e para estimar a
1337 sorção e dessorção de herbicidas em solos agrícolas (SILVA et al., 2019). No entanto,

1338 nenhum estudo buscou aplicar qualquer técnica de aprendizagem de máquina para
1339 predição do período crítico de controle de plantas daninhas.

1340 A principal vantagem das redes neurais é seu potencial de aprendizagem e sua
1341 capacidade de generalização quando são bem treinadas, mesmo para relações altamente
1342 complexas entre as variáveis entrada e saída (STEPHENSON, 2018). Para isso, entradas
1343 que representam bem uma dada resposta (saída) devem ser selecionadas para construção
1344 das redes (ÖZESMI et al., 2006). A seleção das variáveis pode ser um empecilho para a
1345 aplicação dessa metodologia em estudos de período de controle de plantas daninhas
1346 porque o levantamento de todas as possíveis variáveis envolvidas na competição entre
1347 plantas daninhas e cultura requer muito tempo e mão de obra ou ainda porque elas
1348 podem não estar facilmente disponíveis.

1349 Independentemente das possíveis variações presentes nos sistemas agrícolas,
1350 elas moldarão diretamente a comunidade de plantas daninhas que se estabelecerá na
1351 área. Essa comunidade, por sua vez, irá determinar o grau de interferência sobre as
1352 culturas (ARMENGOT et al., 2016). Se a comunidade infestante e o grau de
1353 interferência são pontos chave para definir o período de controle de plantas daninhas,
1354 levantamos a seguinte hipótese: seria possível que as redes neurais artificiais
1355 apreendessem a complexa relação entre a comunidade de plantas daninhas e o grau de
1356 interferência a fim de determinar o momento ideal para iniciar o controle em cultivos
1357 agrícolas? Nesse cenário, nós alimentaríamos a rede com entradas simples e facilmente
1358 mensuráveis relacionadas à comunidade de plantas daninhas para obter a resposta se
1359 devemos iniciar ou não o controle. Assim, os objetivos do nosso trabalho foram: 1)
1360 avaliar a capacidade das redes neurais artificiais em estimar o início do controle de
1361 plantas daninhas considerando culturas modelos e diferentes classes de perdas aceitáveis
1362 devido à interferência de plantas daninhas; 2) validar uma nova alternativa para
1363 modelagem e predição da competição entre plantas daninhas e culturas agrícolas.

1364

1365

1366

1367

1368

1369

1370

1371

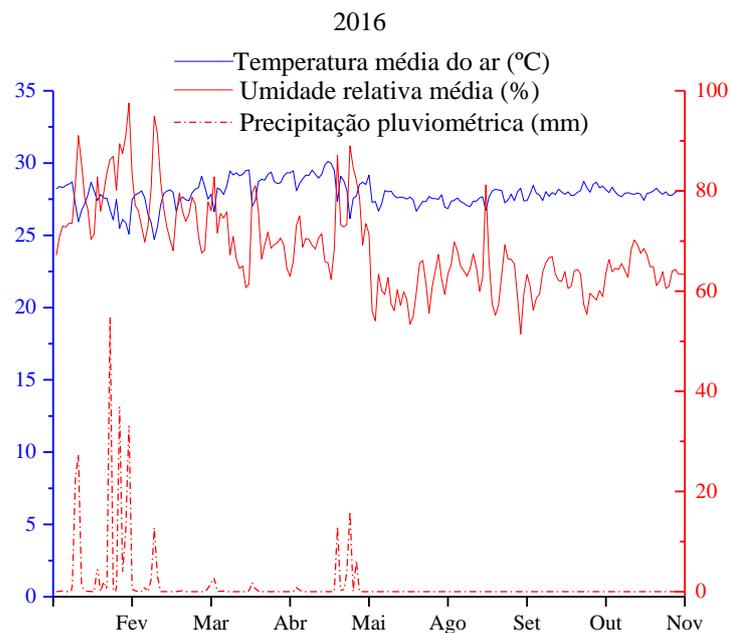
1372 **2. MATERIAL E MÉTODOS**

1373

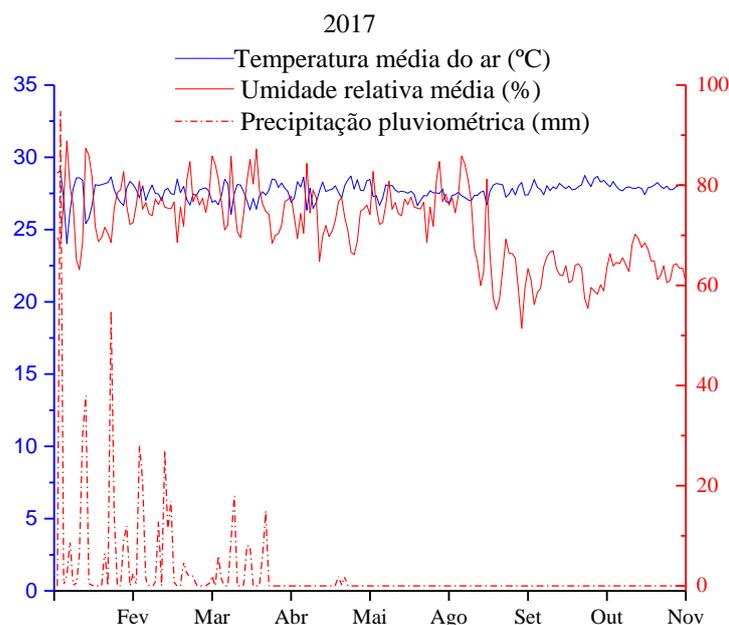
1374 **2.1 Áreas experimentais, condições ambientais e escolha das culturas**

1375

1376 Estudos de campo foram conduzidos na Fazenda Experimental Rafael Fernandes
 1377 (5° 03'37" S, 37° 23'50" W e 81m), pertencente à Universidade Federal Rural do Semi-
 1378 Árido, localizada em Mossoró-RN, durante os anos de 2016 e 2017. O clima da região,
 1379 de acordo com a classificação de Köppen, é do tipo BSh, quente e seco, com
 1380 precipitação pluviométrica média anual de 673,9 mm (ALVARES et al., 2013). Dados
 1381 de temperatura máxima, temperatura média, temperatura mínima, precipitação e
 1382 umidade relativa constam na figura 1. O solo é classificado como Latossolo Vermelho-
 1383 Amarelo Eutrófico Abrupto, textura areia franca (EMBRAPA, 2013). Uma amostragem
 1384 composta foi realizada em diferentes talhões para análise física e química do solo. Os
 1385 dados da análise de solo são apresentados na tabela 1.



1386



1387

1388 **Figura 1.** Temperatura média do ar (°C), umidade relativa (%) e precipitação (mm) durante o
 1389 ciclo da cultura da cebola em 2016 e 2017. Dados obtidos na estação meteorológica em campo
 1390 experimental da UFERSA.

1391 **Tabela 1.** Caracterização química do solo na área de cultivo do melão e gergelim.
 1392 UFERSA, 2016 e 2017.

Análise de solo para área de cultivo do melão										
Ano	pH	MO	K	P	Na	Ca	Mg	Al ³⁺	H+Al ³⁺	CTC
	H ₂ O	g kg ⁻¹	-----mg dm ⁻³ -----			-----cmol _c dm ⁻³ -----				
2016	6,6	6,6	2,6	33,8	6,9	0,5	0,7	0,0	0,0	1,3
2017	6,9	2,9	2,3	39,1	7,3	1,1	0,4	0,0	0,17	1,8
Análise de solo da área de cultivo do gergelim										
Ano	N	MO	K	P	Na	Ca	Mg	pH	CE	
	g kg ⁻¹	g kg ⁻¹	-----mg dm ⁻³ -----			---cmol _c dm ⁻³ --		H ₂ O	ds m ⁻¹	
2016	0,1	7,2	52,0	4,5	8,1	2,1	0,6	6,5	0,6	
2017	0,4	12,8	58,8	3,0	4,8	1,0	1,8	5,6	0,7	

1394 *Extrator: Mehlich-1

1395 As culturas modelos escolhidas para condução dos experimentos foram o
 1396 Gergelim e o Meloeiro. Dois motivos impulsionaram a escolha dessas culturas.
 1397 Primeiro, ambas as culturas são amplamente cultivadas e adaptadas ao semiárido
 1398 brasileiro. Segundo, os sistemas de cultivo dessas culturas são extremamente diferentes
 1399 (detalhes na seção 2.2), gerando contrastes suficientes para o estabelecimento de distintas
 1400 comunidades de plantas daninhas. Além disso, dois cultivares para cada cultura foram
 1401 selecionados para proporcionar outra fonte de variação sobre a comunidade de plantas
 1402 daninhas.

1403

1404 **2.2 Plantio e tratos culturais**

1405

1406 2.2.1 Gergelim

1407

1408 Duas cultivares de gergelim foram usadas para o experimento. Os cultivares
1409 selecionados foram a ‘CNPA G2’ e ‘BRS Seda’, ambas adaptadas às condições
1410 ambientais e distintas quanto à sua habilidade competitiva com plantas daninhas em
1411 ensaios previamente conduzidos na região (dados não publicados). O solo foi preparado
1412 por aração e gradagem. A fertilização foi realizada de acordo com as necessidades de
1413 cada cultivar de gergelim e baseados na análise de solo (Tabela 1), seguindo
1414 recomendações propostas por Cavalcanti (2008). Antes do plantio, uma fertilização foi
1415 aplicada, com 80 kg de P_2O_5 ha⁻¹ (fosfato monoamônico), além de duas adubações de
1416 cobertura com 25 kg de N ha⁻¹ (ureia) e 60 kg de K_2O ha⁻¹ (KCl), ambas via
1417 fertirrigação. Essa fertilização foi adotada em ambas as safras.

1418 As sementes foram realizadas manualmente em agosto e fevereiro nos anos de
1419 2016 e 2017, respectivamente. As sementes foram alocadas a 2 cm de profundidade,
1420 com oito a dez sementes por cova. Dez dias após a emergência, o desbaste foi realizado
1421 deixando apenas duas plantas por cova. A parcela útil mediu 3 m de comprimento com
1422 quatro fileiras de plantas, totalizando uma área de 7,2 m² (3,0 por 2,4 m). O
1423 espaçamento entre plantas utilizado foi de 0,30 por 0,60 m. O controle fitossanitário de
1424 pragas e doenças foi realizado de acordo com as recomendações técnicas e necessidades
1425 da cultura.

1426

1427 2.2.2 Melão

1428

1429 De maneira similar ao gergelim, duas cultivares de melão foram usadas para o
1430 experimento. Os cultivares selecionados foram ‘Amarelo’ e ‘Pele de Sapo’, ambas
1431 adaptadas às condições ambientais e distintas quanto à sua habilidade competitiva com
1432 plantas daninhas em ensaios previamente conduzidos na região (dados não publicados).
1433 O preparo do solo constou de uma aração e gradagem, seguidas do levantamento dos
1434 canteiros por meio de enxada rotativa. A adubação foi realizada conforme as
1435 necessidades dos cultivares e com base na análise de solo (Tabela 1), seguindo
1436 recomendações de Cavalcanti (2008). Antes do plantio, foram aplicados 180 kg ha⁻¹ de

1437 P₂O₅ (superfosfato simples), 3 kg ha⁻¹ de zinco (ZnSO₄) e 1,1 kg ha⁻¹ de boro (ácido
1438 bórico). Além disso, uma adubação de cobertura com 165 kg ha⁻¹ de N (ureia) e 30 kg
1439 ha⁻¹ de K₂O (KCl) foi realizada via fertirrigação. Essa fertilização foi utilizada para
1440 ambos os anos de cultivo.

1441 Após a montagem da irrigação, foi colocado o mulching (filme de polietileno)
1442 sobre os canteiros, dupla face preto e branco, deixando a face branca para cima e a preta
1443 para baixo. Os furos para o plantio das mudas existentes no mulching foram de fábrica e
1444 espaçados em 0,4 m com 5 cm de diâmetro. As mudas dos meloeiros foram produzidas
1445 em bandejas de polipropileno com 200 células de 20 cm³, utilizando substrato
1446 comercial. O transplântio das mudas (5 cm de altura e presença da primeira folha
1447 verdadeira) foi realizado aos 12 dias após a sementeira, em espaçamento de 0,4 m entre
1448 plantas e 2 m entrelinhas. Cada parcela útil foi constituída de três canteiros, medindo
1449 2,8 x 1 m (comprimento x largura). O controle fitossanitário de pragas e doenças foi
1450 realizado de acordo com as recomendações técnicas e necessidades da cultura.

1451

1452 **2.3 Tratamentos e desenho experimental**

1453

1454 Quatro experimentos foram conduzidos para cada cultura e cultivar. Os quatro
1455 experimentos foram conduzidos dois anos (2016 e 2017), em delineamento de blocos
1456 casualizados (DBC) com três repetições. Os tratamentos foram constituídos por seis
1457 períodos para iniciar o controle de plantas daninhas. Os intervalos foram expressos em
1458 graus-dias (GD) e calculados a partir da Equação (1) para cada cultura. Os intervalos
1459 considerados para o gergelim e meloeiro foram 130, 260, 390, 520, 650, 1300 GD e
1460 130, 260, 390, 520, 972 GD após a sementeira do gergelim e transplântio das mudas de
1461 meloeiro, respectivamente. Assim, o controle de plantas daninhas era estabelecido na
1462 parcela sempre que o valor de GD era alcançado.

1463

1464 Equação (1):
$$GDD = \sum \left[\frac{(T_{\text{dia}} \frac{DL}{12}) + (T_{\text{noite}} \frac{NL}{12})}{2} \right] - T_{\text{base}}$$

1465

1466 Onde: T_{dia} e T_{noite} são temperaturas diurnas e noturnas (° C), respectivamente; DL e NL
1467 são duração do dia e noite, respectivamente; T_{base} é a temperatura base (° C). Para o
1468 gergelim e o melão, a temperatura base estabelecida foi de 10 ° C.

1469

1470 2.4 Irrigação dos experimentos

1471

1472 O sistema de irrigação utilizado foi o gotejamento para ambas as culturas. As
 1473 fitas de gotejo foram espaçadas em 0,60 m, com 0,30 m entre gotejadores para o
 1474 gergelim. Para o meloeiro, uma fita foi usada por canteiro, com gotejadores espaçados
 1475 em 0,30 m. A vazão dos gotejadores foi 1,7 L h⁻¹. A lâmina total de água aplicada para
 1476 cada cultura foi calculada de acordo com a ETc estimada da cultura (ETc = ETo x Kc).
 1477 Os valores de Kc para o gergelim e melão foram considerados para os estágios de
 1478 desenvolvimento (AMARAL; SILVA, 2008; PEREIRA et al., 2017).

1479

1480 2.5 Coleta de dados

1481

1482 No momento no qual o controle de plantas daninhas foi iniciado, as plantas
 1483 daninhas foram coletadas em amostras compostas (4 subamostras de 0,25 m²) para cada
 1484 parcela de gergelim. No melão, a coleta ocorreu nos furos do mulching (19,63 cm²) em
 1485 todas as plantas da área útil. Após a coleta, as plantas daninhas em cada amostra
 1486 composta foram identificadas, contadas e pesadas em balança de precisão (0,001 g). A
 1487 densidade em cada parcela foi calculada a partir do número total de indivíduos por
 1488 espécie dividido pela área total. A densidade e a matéria fresca das plantas daninhas em
 1489 cada parcela foram extrapoladas para número de plantas/m² e gramas de matéria
 1490 fresca/m², respectivamente. A relação entre plantas C3/C4 (classificação quanto ao ciclo
 1491 fotossintético) e M/E (classificação botânica entre plantas monocotiledôneas e
 1492 eudicotiledôneas) de cada parcela foi calculada, tanto para a variável densidade quanto
 1493 matéria fresca.

1494 As plantas daninhas que ocorreram nas áreas foram: *Mimosa pudica* L., *Mollugo*
 1495 *verticillata* L., *Blainvillea lanceolata* (L.), *Portulaca oleracea* L., *Sida spinosa* L.,
 1496 *Aeschynomene rudis* (Benth), *Cyperus rotundus* L., *Ipomoea triloba* L., *Macroptilium*
 1497 *atropurpureum* (Sessé & Moc.), *Senna alata* (L.), *Commelina Benghalensis* (L.),
 1498 *Cynodon dactylon* (L.) Pers. para áreas cultivadas com gergelim, e *Eleusine indica* (L.)
 1499 Gaertn, *Portulaca oleracea* L., *Digitaria horizontalis* Wild., *Senna obtusifolia* (L.) H.S.
 1500 Irwin & Barneby, *Ipomoea triloba* L., *Merremia aegyptia* (L.) urb., *Trianthema*
 1501 *portulacastrum* Linn., *Blainvillea sp.*, *Urochloa plantaginea* (Link) R. Ebster,
 1502 *Alternanthera tenella* Colla, *Mimosa pudica* L. para áreas cultivadas com melão,
 1503 durante as duas safras.

1504 A colheita dos cultivares de gergelim em 2016 e 2017 foi realizada aos 1300
1505 GDD, quando as plantas de gergelim se encontravam com as cápsulas basais amarelas e
1506 iniciando a abertura. Para o meloeiro, a colheita foi realizada aos 972 GDD, quando o
1507 teor de sólidos solúveis dos frutos produzidos possuía aproximadamente 10° Brix. A
1508 umidade dos grãos de gergelim foi corrigida para 6% (GRILO JÚNIOR; AZEVEDO,
1509 2013), e apenas melões com peso aproximado de 0,9 kg sem defeitos foram
1510 considerados comercializáveis (FILGUEIRA, 2000). A produtividade de ambas as
1511 culturas para cada parcela foi estimada em kg ha⁻¹.

1512

1513 **2.6 Construção das redes neurais artificiais (RNAs)**

1514

1515 Os modelos de redes neurais artificiais são ferramentas interessantes de
1516 modelagem de dados devido ao seu potencial para encontrar relações complexas entre
1517 variáveis dependentes e independentes, solucionando problemas não lineares (OCHOA-
1518 MARTINEZ; AYALA-APONTE, 2007). Dentre suas variações, a rede neural artificial
1519 utilizada nesse estudo foi “Multilayer Perceptron (MLP)”. Nessa técnica, a
1520 aprendizagem da rede é supervisionada durante a fase de treinamento, denominando-se
1521 de retropropagação (backpropagation) do modelo. Existem três camadas principais de
1522 neurônios na MLP (entrada, ocultação e saída) com funções de ativação lineares e não
1523 lineares (SILVA et al., 2019). O desenvolvimento de um modelo de rede neural
1524 artificial requer a geração de dados para o treinamento/validação do modelo, modulados
1525 por uma configuração de parâmetros, para o teste final do modelo em um conjunto de
1526 dados independente.

1527 Três redes neurais artificiais foram construídas a partir de métodos não
1528 destrutivos (variáveis de entrada não destrutivas), destrutivos (variáveis de entrada
1529 destrutivas) e misto (combinação de variáveis não destrutivas + destrutivas). As
1530 variáveis de entrada selecionadas foram escolhidas devido à sua facilidade e
1531 simplicidade para obtenção no campo. No método não destrutivo, foram a Densidade de
1532 Plantas Daninhas (plantas/m²), relação de plantas C3/C4 e M/E (ambos baseados na
1533 densidade de plantas daninhas). No método destrutivo, as variáveis de entrada foram a
1534 Matéria Fresca de Plantas Daninhas (g/m²), relação C3/C4 e M/E (ambos baseados na
1535 Matéria Fresca de plantas daninhas). No Método misto, a Densidade e Matéria Fresca
1536 foram consideradas como entrada. Além das variáveis de entrada específicas de cada
1537 método, duas outras foram consideradas em todas as redes testadas: a Cultura e Período

1538 (correspondente ao início do controle de plantas daninhas em cada tratamento em
1539 GDD). Além disso, combinações dessas variáveis foram usadas para buscar a melhor
1540 relação entre número de entradas e desempenho para predição. Detalhes das redes em
1541 cada método são mostrados nos Apêndice IV, Apêndice V, Apêndice VI. Para evitar
1542 problemas relacionados às unidades das variáveis de entrada, a normalização dos dados
1543 em intervalos de 0 a 1 foi realizada segundo a Equação (2):

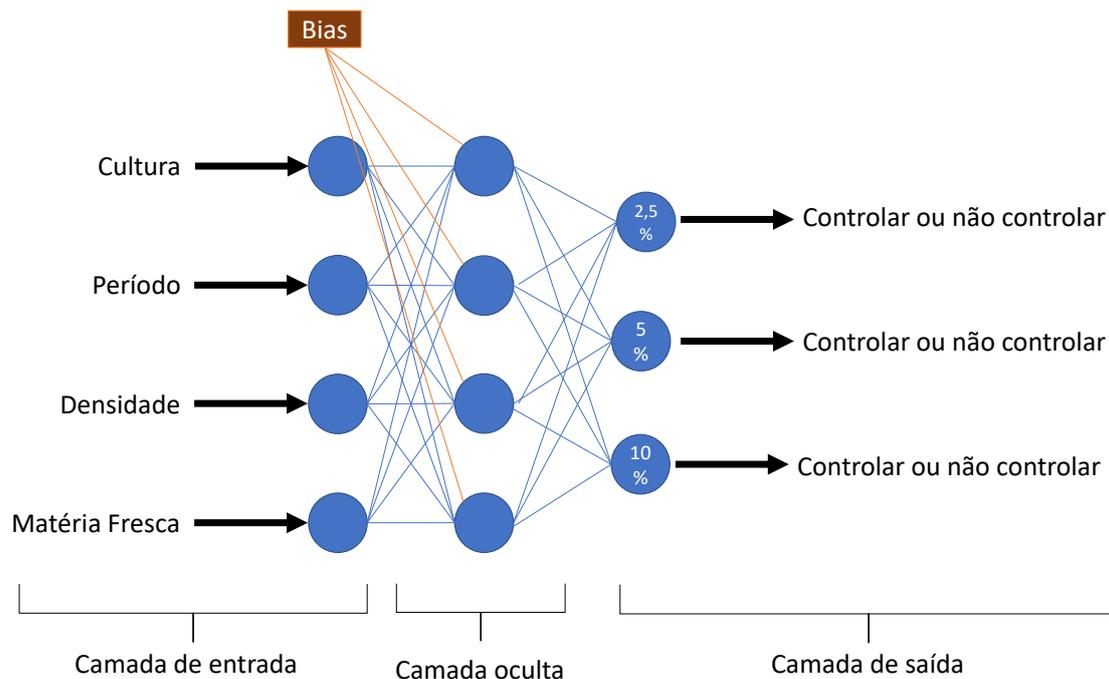
1544 Equação (2):
$$N = \frac{X - X_{min}}{X_{max} - X_{min}}$$

1545 Onde: N são os dados normalizados, X é o valor medido; Xmin e Xmax são os valores
1546 mínimo e máximo para o intervalo de dados da variável.

1547

1548 Um total de 156 dados foi obtido dos tratamentos, culturas, cultivares e
1549 repetições. Esses dados foram divididos em conjuntos de treinamento, validação
1550 cruzada e teste do modelo na proporção de usaram 50, 30 e 20%, respectivamente
1551 (SILVA et al., 2019). A validação é uma etapa importante durante o treinamento porque
1552 interrompe o treinamento quando o erro começa a aumentar. Depois do treinamento e
1553 validação, as redes foram testadas quanto sua capacidade de generalização pelo
1554 conjunto teste, constituídos de dados independentes. A saída da rede foi estabelecida
1555 como a decisão de iniciar o controle (Controlar) e não iniciar o controle (Não controlar),
1556 considerando a perda aceitável de 2,5, 5 e 10% na produção relativa. A perda da
1557 produção relativa (%) das parcelas foi calculada com base em tratamentos controle, sem
1558 competição com plantas daninhas durante todo o ciclo das culturas. A figura 2 mostra o
1559 esquema geral das redes.

1560



1561

1562 **Figura 2.** Visão geral da RNA – MLP para o modelo misto (entradas não destrutivas e
1563 destrutivas).

1564

1565 O desempenho das RNAs nas etapas de treinamento, validação e teste foram
1566 avaliadas métricas abaixo:

Acurácia (eficiência geral):

$$\frac{VP + VN}{VP + FP + FN + VN}$$

Especificidade (eficiência para amostras
negativas):

$$\frac{VN}{VN + FP}$$

F-score (média entre precisão e recuperação):

$$\frac{2 * (VP)}{2 * (VP + FP + FN)}$$

1567 Onde: VP é o verdadeiro positivo, VN é o verdadeiro negativo, FP é o falso positivo, e
1568 FN é o falso negativo. Os valores de acurácia, especificidade e F-score variam de 0 a 1,
1569 e aqueles próximos a 1 indicam a boa performance do modelo.

1570 Após a seleção da rede com melhor desempenho para cada tipo de variável de
1571 entrada, curvas ROC (característica de operação do receptor) foram aplicadas para
1572 avaliar o desempenho devido à distribuição de classes desiguais. A ROC foi gerada

1573 pelos valores de especificidade versus sensibilidade (CÖMERT; KOCAMAZ, 2018). O
1574 valor de AUC (área sob a curva) e a pseudo-probabilidade também foram calculadas
1575 para confirmar o desempenho dos melhores modelos. Valores de AUC devem ser os
1576 mais próximos possível de um. As RNAs foram aplicadas utilizando o *software*
1577 *Statistica®*, versão 13.0.

1578

1579 **3. RESULTADOS E DISCUSSÃO**

1580

1581 **3.1 Correlações das variáveis independentes e a produtividade relativa das** 1582 **culturas de gergelim e meloeiro**

1583

1584 Houve correlações significativas entre a produtividade relativa das culturas e as
1585 variáveis densidade de plantas daninhas (-0,58), matéria fresca de plantas daninhas (-
1586 0,62), e período (-0,79) (Tabela 2). As demais correlações não foram significativas. A
1587 máxima produtividade observada foi 100%, referente à testemunha sem competição
1588 com plantas daninhas, para ambas as culturas. A mínima produtividade foi equivalente a
1589 7,5%, encontrada para o gergelim e a menor produtividade relativa para o melão foi de
1590 20% (dados não mostrados). Os máximos valores para densidade e matéria fresca foram
1591 144,0 plantas/m² e 1.217,4 g/m² (Tabela 2).

1592

Tabela 2. Correlação de Pearson e estatística descritiva das variáveis de entrada obtidas usadas na construção das redes neurais artificiais MLP para as culturas do gergelim e melão.

Correlação de Person	Período	Produtividade relativa (%)	Densidade	C3/C4 (Não destrutivo)	Mono/Eudi (Não destrutivo)	C3/C4 (Destrutivo)	Mono/Eudi (Destrutivo)	Matéria fresca
Período	1	-0,79*	0,49	0,23	0,06	0,09	-0,005	0,52
Produtividade relativa		1	-0,58*	-0,25	-0,11	-0,12	-0,01	-0,62*
Densidade			1	0,09	-0,07	0,08	0,05	0,67*
C3/C4 (Não destrutivo)				1	-0,09	-0,005	-0,007	0,68*
Mono/Eudi (Não destrutivo)					1	0,27	0,33	0,08
C3/C4 (Destrutivo)						1	0,36	-0,02
Mono/Eudi (Destrutivo)							1	-0,02
Matéria fresca								1
Estatística descritiva das variáveis de entrada	Período	Produtividade relativa (%)	Densidade	C3/C4 (Não destrutivo)	M/E (Não destrutivo)	C3/C4 (Destrutivo)	M/E (Destrutivo)	Matéria fresca
Média	31,5	66,8	33,6	2,2	0,18	0,9	0,7	120,0
Desvio padrão	26,6	27,3	37,7	5,1	0,36	2,3	3,8	169,4
Máximo	100,0	100,0	144,0	39,0	3,2	22,3	36,8	1.217,4
Mínimo	0	7,5	0	0	0	0	0	0

*Correlação significativa ao p-valor < 0,05.

1 A correlação negativa entre a produtividade relativa e as variáveis período,
2 densidade e matéria fresca de plantas daninhas sugere que elas reduzem a produção de
3 ambas as culturas na medida em que o tempo e plantas daninhas crescem na área. Esse
4 efeito é resultado da maior interferência exercida pela comunidade de plantas daninhas,
5 limitando os recursos para o pleno crescimento da cultura, tais como água, luz e
6 nutrientes (JHA et al., 2017; KARKANIS et al., 2018). A relação linear entre essas
7 variáveis já foi descrita por muitos estudos que abordaram a relação da interferência de
8 plantas daninhas e culturas (TURSUN et al., 2016; SOLTANI et al., 2016; LINS et al.,
9 2019).

10 As variáveis usadas para classificar o tipo de comunidade infestante (relação
11 C3/C4 e M/E) não tiveram relação linear com a produtividade das culturas. Mesmo não
12 apresentando uma correlação significativa com a produtividade, as espécies de plantas
13 daninhas que constituem a comunidade podem ter forte influência na competição. Por
14 exemplo, Freitas Souza et al. (2020) observaram que a mudança da comunidade de
15 plantas daninhas intensificou a competição e aumentou as perdas relativas na cultura da
16 cebola, devido principalmente à maior ocorrência de plantas com ciclo fotossintético
17 C4. O tipo da comunidade infestante pode não possuir um comportamento linear
18 perante a competição; além disso, modelos não lineares e mais complexos, como as
19 redes neurais artificiais, podem ajudar a entender melhor essa relação.

20

21 **3.2 Determinação do controle de plantas daninhas baseados em variáveis não** 22 **destrutivas e destrutivas**

23

24 Os valores de Acurácia e F-score durante a fase de treinamento e validação para
25 as redes com três, quatro e cinco variáveis de entrada pelo método não destrutivo foram
26 superiores a 0,90, considerando todas as perdas aceitáveis (Tabela 3). Os valores de
27 especificidade variaram entre 0,72 (menor valor) a 0,96 (maior valor) durante o
28 treinamento das redes, e a rede com quatro entradas (Cultura, Período, Densidade e
29 C3/C4) apresentou os maiores valores para perdas aceitáveis de 2,5, 5 e 10% (Tabela 3).
30 Para a validação, todas as redes apresentaram valores de acurácia, especificidade e F-
31 score superiores a 0,90 (Tabela 3). Os maiores valores durante o teste para acurácia e F-
32 score foram observados na rede com quatro variáveis de entrada (Cultura, Período,
33 Densidade e C3/C4), considerando perdas aceitáveis de 2,5, 5 e 10% (Tabela 3),
34 resultando no melhor desempenho entre as redes criadas. Essa rede também mostrou

35 alto poder para evitar erros de classificação, com poucas pseudo-classificações (apenas
 36 2, 3, 3 para 2,5, 5 e 10% de perdas aceitáveis, respectivamente) e bons valores para
 37 AUC (próximas a 1 para todas classes de perdas aceitáveis) (Figura 3).

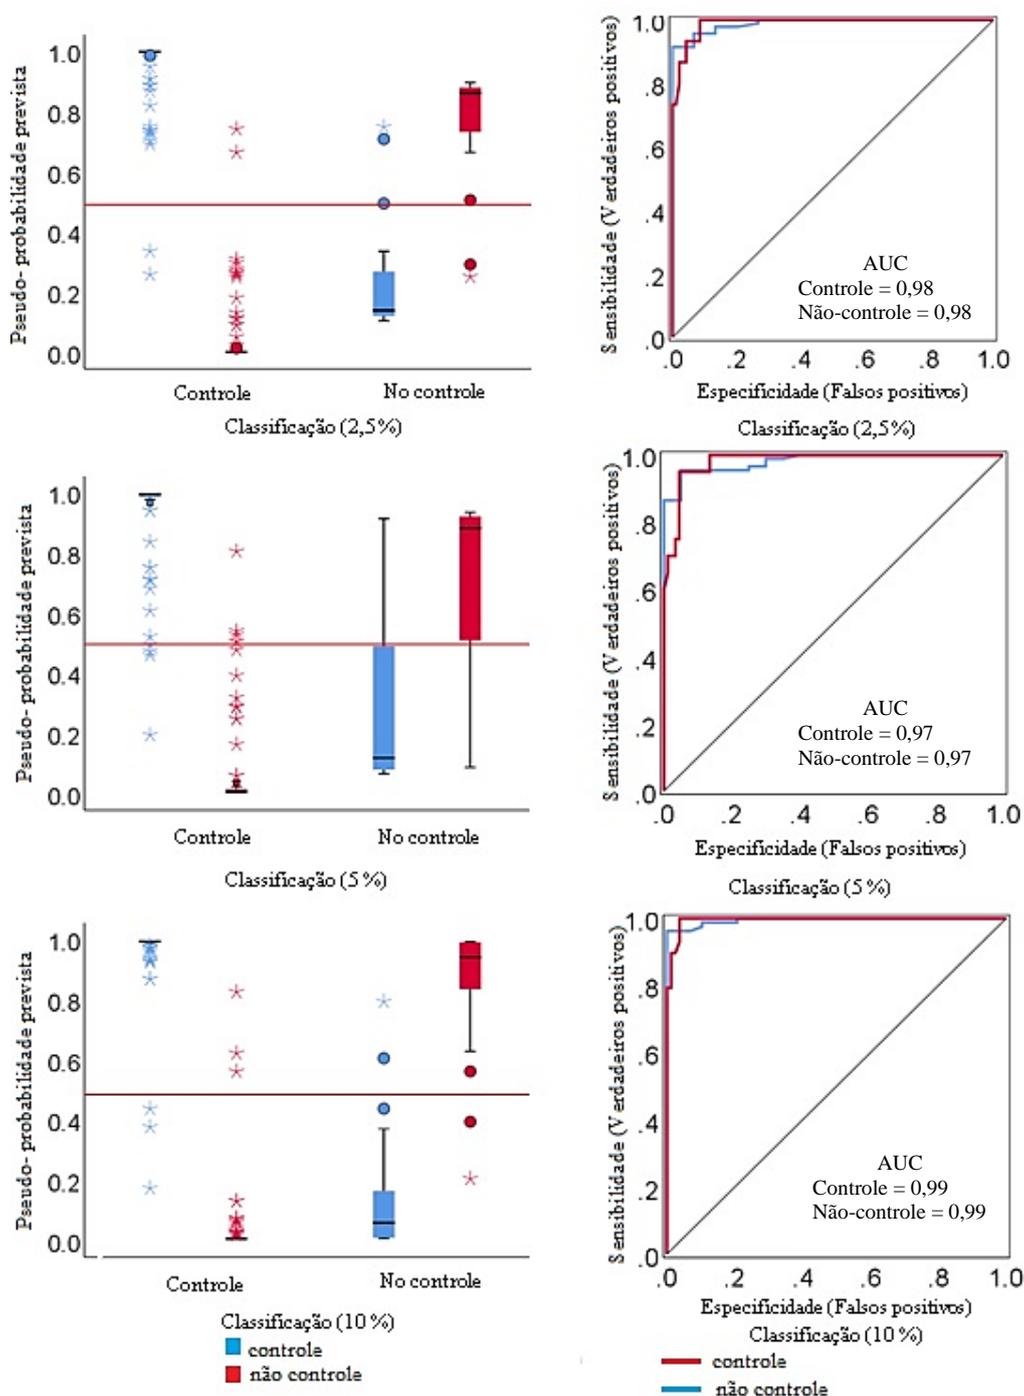
38

39 **Tabela 3.** Desempenho das redes neurais artificiais MLP nas etapas de treinamento,
 40 validação, e teste para perdas aceitáveis de 2,5, 5 e 10%, considerando diferentes
 41 variáveis de entrada pelo método não destrutivo.

Variáveis de entrada	Etapa	Perda (%)	Acurácia	Especificidade	F-score
Cultura, Período e Densidade	Treinamento	2,5	0,95	0,77	0,97
		5	0,92	0,89	0,95
		10	0,95	0,88	0,96
	Validação	2,5	1,00	1,00	1,00
		5	1,00	1,00	1,00
		10	1,00	1,00	1,00
	Teste	2,5	0,96	1,00	0,97
		5	0,94	1,00	0,95
		10	0,98	0,94	0,98
	Etapa	Perda (%)	Acurácia	Especificidade	F-score
Cultura, Período, Densidade e C3/C4	Treinamento	2,5	0,95	0,87	0,97
		5	0,92	0,89	0,95
		10	0,96	0,96	0,97
	Validação	2,5	1,00	1,00	1,00
		5	1,00	1,00	1,00
		10	1,00	1,00	1,00
	Teste	2,5	0,98	1,00	0,99
		5	1,00	1,00	1,00
		10	0,98	0,94	0,98
	Etapa	Perda (%)	Acurácia	Especificidade	F-score
Cultura, Período, Densidade e M/E	Treinamento	2,5	0,95	0,77	0,97
		5	0,92	0,89	0,95
		10	0,95	0,92	0,96
	Validação	2,5	1,00	1,00	1,00
		5	1,00	1,00	1,00
		10	1,00	1,00	1,00
	Teste	2,5	0,96	1,00	0,97
		5	0,94	1,00	0,95
		10	0,98	0,94	0,98
	Etapa	Perda (%)	Acurácia	Especificidade	F-score
Cultura, Período, Densidade, C3/C4 e M/E	Treinamento	2,5	0,96	0,85	0,97
		5	0,90	0,72	0,94
		10	0,95	0,92	0,96
	Validação	2,5	1,00	1,00	1,00
		5	1,00	1,00	1,00

		10	1,00	1,00	1,00
		2,5	0,98	1,00	0,99
	Teste	5	0,96	1,00	0,97
		10	0,98	0,94	0,98

42



43

44 **Figura 3.** Pseudo-probabilidade (direta) e Curva Característica Operacional do Receptor
 45 (COR, esquerda) da rede neural artificial MLP com melhor desempenho (Cultura,
 46 Período, Densidade e C3/C4) para estimar o controle de plantas daninhas considerando

47 o método não destrutivo. Linha vermelha determina o limite para pseudo-probabilidade
48 (0,5).

49 Todas as redes criadas a partir dos dados não destrutivos foram capazes de
50 aprender e convergir para uma solução com baixo erro durante a fase de treinamento,
51 resultando em altos valores de acurácia e F-score. Esse fato indica que as redes são
52 capazes de determinar com alta precisão o momento de iniciar o controle das plantas
53 daninhas. No entanto, os menores valores para especificidade durante o treinamento
54 mostram menor capacidade das redes em prever corretamente casos de não controle,
55 levando a falsos positivos (WANKHEDE et al., 2017; ALTUNTAŞ et al., 2019). A
56 existência de poucos falsos positivos gerados pelas redes neurais artificiais testadas
57 nesse estudo não representam um problema grave. Na prática, produtores buscam
58 minimizar as perdas causadas pela interferência de plantas daninhas sobre as culturas
59 (COLAS et al., 2020). Conseqüentemente, os falsos positivos não irão permitir essa
60 competição, uma vez que a rede determinará o início do controle mesmo sem existir a
61 necessidade dessa ação.

62 Além do alto desempenho durante a aprendizagem das redes neurais artificiais,
63 as redes treinadas foram capazes de prever novos casos durante a fase de teste com
64 alto grau de acerto. Esse comportamento durante o teste sugere que as redes são
65 generalistas e os resultados não estão viciados apenas aos casos usados durante o
66 treinamento e validação (ZHU et al., 2019). Ainda que um modelo apresente bons
67 resultados no treinamento, a capacidade do modelo em estimar corretamente novas
68 situações é crucial para aplicabilidade prática da rede (KISI; KILIC et al., 2016; ZHU et
69 al., 2019). Geralmente, falsas interpretações durante o teste das redes neurais artificiais
70 se devem ao uso de técnicas que operam o treinamento e teste em um mesmo conjunto
71 de dados, tais como validação cruzada e bootstrap (ÖZESMI et al., 2006). Essa
72 alternativa permite a aplicação de RNAs em conjuntos de dados pequenos, porém o
73 excesso de ajuste gerado pode limitar a capacidade de limitação da rede (ÖZESMI et al.,
74 2006). Esse cenário não foi observado para as redes treinadas e testadas nesse estudo,
75 pois o conjunto de treinamento e teste foram tratados independentemente, com bons
76 resultados para ambas as etapas.

77 Todas as redes foram satisfatórias para determinar o momento de controle de
78 plantas daninhas na cultura do gergelim e melão, independentemente de quantas
79 variáveis de entrada foram usadas. A rede com apenas três variáveis de entrada
80 (Cultura, Período e Densidade) mostrou desempenho muito próximo à rede com todas

81 as variáveis. Todavia, mais neurônios foram necessários na camada oculta (7) para o
 82 bom ajuste do modelo com três entradas comparado à rede com cinco entradas (1)
 83 (Apêndice IV). Isso significa que o menor número de variáveis de entradas não
 84 destrutivas aumentou a complexidade da rede. O uso das cinco entradas permitiu a
 85 classificação dos casos utilizando apenas um hiperplano (um neurônio na camada
 86 oculta), geralmente recorrente nas soluções de problemas simples em aprendizagem de
 87 máquinas (SILVA et al., 2017; ALIBAKSHI, 2018). Apesar do bom resultado para
 88 redes neurais artificiais com cinco entradas, os resultados da tabela 3 indicam melhor
 89 desempenho para rede com quatro entradas (Cultura, Período, Densidade e C3/C4),
 90 exigindo quatro neurônios na camada oculta (Apêndice IV).

91 Os valores de Acurácia e F-score durante o treinamento e validação para as redes
 92 com três, quatro e cinco variáveis de entrada pelo método destrutivo foram superiores a
 93 0,90 em todas classes de perdas aceitáveis (Tabela 4). De maneira similar ao método
 94 não destrutivo, os valores de especificidade apresentaram maior variação, entre 0,61
 95 (menor valor) a 0,96 (maior valor), durante o treinamento, e a rede com quatro entradas
 96 (Cultura, Período, Densidade e C3/C4) apresentou os maiores valores em todas as
 97 classes de perdas aceitáveis (Tabela 4). As redes com três (Cultura, Período, Densidade)
 98 e quatro (Cultura, Período, Densidade e C3/C4) entradas tiveram valores iguais a 1,00
 99 para especificidade na validação em todas as classes de perdas aceitáveis. As redes que
 100 usaram a relação de plantas Mocotiledôneas/Eudicotiledôneas (M/E) como entrada
 101 tiveram menor especificidade (0,5 considerando 2,5% de perdas aceitáveis) durante o
 102 treinamento e validação (Tabela 4).

103

104 **Tabela 4.** Desempenho das redes neurais artificiais MLP nas etapas de treinamento,
 105 validação, e teste para perdas aceitáveis de 2,5, 5 e 10%, considerando diferentes
 106 variáveis de entrada pelo método destrutivo.

Variáveis de entrada	Etapa	Perda (%)	Acurácia	Especificidade	F-score
Cultura, Período, Matéria fresca	Treinamento	2,5	0,93	0,77	0,96
		5	0,90	0,61	0,94
		10	0,96	0,96	0,97
	Validação	2,5	1,00	1,00	1,00
		5	1,00	1,00	1,00
		10	1,00	1,00	1,00
	Teste	2,5	0,94	1,00	0,96
		5	0,94	0,93	0,95

		10	0,98	0,94	0,98
		Perda (%)	Acurácia	Especificidade	F-score
Cultura, Período, Matéria fresca, C3/C4	Treinamento	2,5	0,95	0,89	0,97
		5	0,92	0,89	0,95
		10	0,96	0,96	0,97
	Validação	2,5	1,00	1,00	1,00
		5	1,00	1,00	1,00
		10	1,00	1,00	1,00
	Teste	2,5	0,98	1,00	0,99
		5	0,94	1,00	0,95
		10	0,98	0,96	0,98
		Perda (%)	Acurácia	Especificidade	F-score
Cultura, Período, Matéria fresca, M/E	Treinamento	2,5	0,97	0,77	0,98
		5	0,90	0,89	0,94
		10	0,96	0,96	0,97
	Validação	2,5	0,94	0,50	0,97
		5	1,00	1,00	1,00
		10	1,00	1,00	1,00
	Teste	2,5	0,98	0,95	0,99
		5	0,94	0,93	0,95
		10	0,98	0,94	0,98
		Perda (%)	Acurácia	Especificidade	F-score
Cultura, Período, Matéria fresca, C3/C4, M/E	Treinamento	2,5	0,97	0,77	0,98
		5	0,92	0,89	0,95
		10	0,96	0,96	0,97
	Validação	2,5	0,94	0,50	0,97
		5	1,00	1,00	1,00
		10	1,00	1,00	1,00
	Teste	2,5	0,98	0,95	0,99
		5	0,94	0,93	0,95
		10	0,98	0,94	0,98

107

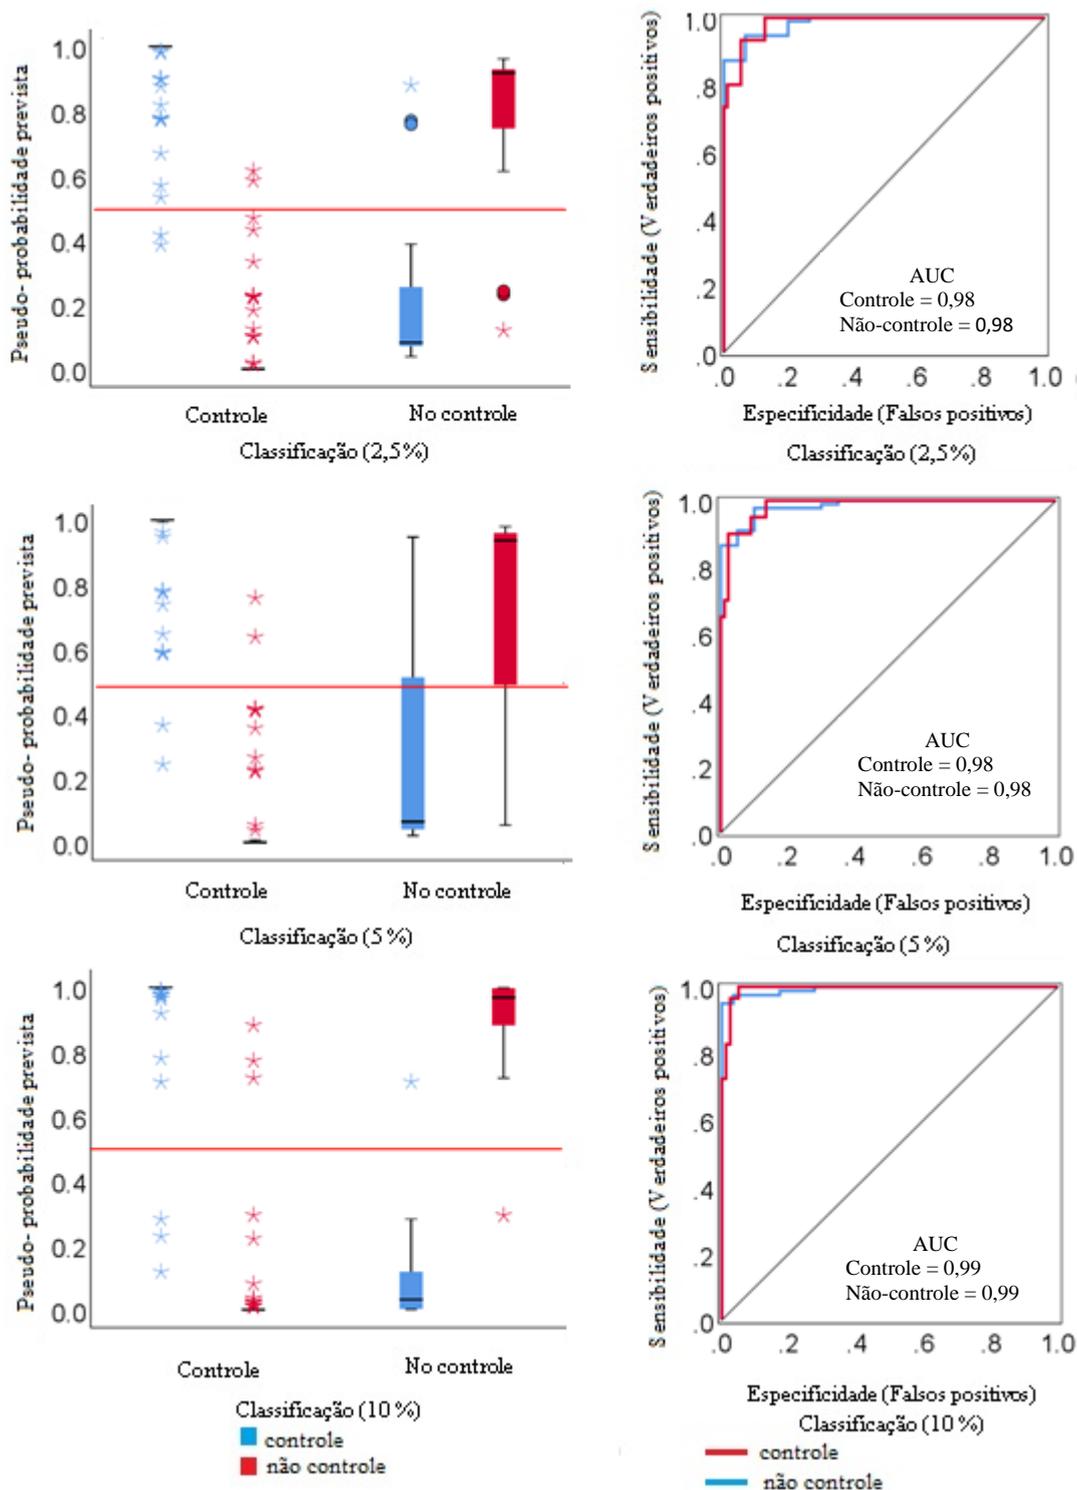
108 De maneira semelhante ao método não destrutivo, as variáveis destrutivas
109 também geraram redes capazes de convergir a uma solução com bom desempenho no
110 treinamento, com alta probabilidade para predição dos verdadeiros casos positivos (F-
111 score superior a 0,90). No entanto, as redes que usaram a relação M/E como entrada
112 demonstraram maior deficiência (baixa Especificidade), durante a validação, para
113 classificar corretamente os casos negativos verdadeiros na classe de 2,5% de perda
114 aceitável. De certo modo, a combinação entre a matéria fresca e a relação mono/dico
115 dificultou o processo de aprendizagem, causando também menores índices de acerto na
116 fase de teste para todas as classes de perdas. Esse comportamento evidencia a
117 importância de selecionar variáveis apropriadas para a construção de RNAs, uma vez

118 que o maior número de entradas nem sempre se reflete no melhor modelo (SILVA et al.,
119 2019). Para situações com grande número de variáveis disponíveis, o pré-
120 processamento das entradas, seja via correlações (SILVA et al., 2019; ABDIPOUR et
121 al., 2019) ou análise de componentes principais (ABDIPOUR et al., 2019), fornecem
122 redes com melhor desempenho.

123 Todas as redes construídas pelo método destrutivo mostraram valores de
124 acurácia, especificidade e F-score superiores a 0,90 durante o teste (Tabela 4). Não
125 houve diferenças para acurácia entre as redes em nenhuma classe de perda. No entanto,
126 redes com quatro e cinco variáveis de entrada tiveram maior valor de F-score
127 comparado à rede com três entradas (Tabela 4). O uso da relação M/E como entrada
128 reduziu a especificidade das redes para a classe de 2,5% de perda aceitável (Tabela 4).
129 A rede com quatro entradas (Cultura, Período, Matéria fresca, C3/C4) obteve os maiores
130 valores de especificidade para todas as classes de perdas aceitáveis, variando entre 0,96
131 e 1,00 (Tabela 4), indicando o melhor desempenho entre as redes neurais artificiais. A
132 alta especificidade dessa rede sugere alto poder para evitar erros de classificação, com
133 poucas pseudo-classificações (apenas 2, 2, e 3 para 2,5, 5 e 10% de perdas aceitáveis,
134 respectivamente) e bons valores para AUC (próximas a 1 para todas classes de perdas
135 aceitáveis), como mostrado na figura 4.

136 De maneira similar às redes neurais artificiais não destrutivas, as redes baseadas
137 em variáveis destrutivas permitiram alta generalização dos casos. Detalhe deve ser dado
138 às redes que utilizaram como entrada a relação M/E, uma vez que a menor
139 especificidade indica maior probabilidade de falsas classificações para casos
140 verdadeiros negativos. O menor desempenho durante o treinamento dessas redes
141 repercutiu na menor capacidade de prever verdadeiros casos negativos na etapa de
142 teste. Consequentemente, redes baseadas na relação M/E tendem a recomendar o
143 controle de plantas daninhas sem a real necessidade, antecipando o início do manejo.
144 Mesmo que esse cenário não seja totalmente desfavorável, um modelo que
145 frequentemente antecipa o controle de plantas daninhas pode elevar os custos finais de
146 produção devido ao maior número de intervenções realizadas ao longo do ciclo das
147 culturas (BERTI et al., 2003; DAMMER, 2016; DAVIS; FRISVOLD, 2017). Por
148 exemplo, o aumento no número de intervenções foi o principal fator que elevou os
149 custos de manejo de plantas daninhas em propriedades agrícolas que usaram o *software*
150 GESTINF para tomada de decisão (BERTI et al., 2003; DAVIS et al., 2013). Esse fato
151 também pode causar maior risco de contaminação ambiental quando frequentes

152 aplicações de herbicidas em pós-emergência são necessárias para controle de plantas
 153 daninhas (BERTI et al., 2003; MAMY et al., 2010; FILLOLS et al., 2020).



158 considerando o método destrutivo. Linha vermelha determina o limite para pseudo-
159 probabilidade (0,5).

160

161 A rede neural artificial com quatro entradas (Cultura, Período, Matéria fresca e
162 C3/C4) teve alta performance para determinar tanto os casos verdadeiros positivos
163 quanto os negativos. Em ambos os métodos, não destrutivo e destrutivo, a relação de
164 plantas C3/C4 melhorou a interpretação dos dados pela rede, elevando os índices de
165 acerto. O índice baseado no ciclo fotossintético das espécies provavelmente permitiu à
166 rede reconhecer um padrão de comportamento da comunidade de plantas daninhas nas
167 áreas cultivadas com o gergelim e melão. O Gergelim possui crescimento ereto e alto
168 porte. Teoricamente, a maior altura e fechamento do dossel do Gergelim podem
169 prejudicar o estabelecimento de plantas daninhas do tipo C4, uma vez que essas
170 espécies são mais sensíveis à ausência de luz (LINS et al., 2019; KARNAS et al., 2019;
171 COLBACH et al., 2019). O melão possui crescimento rasteiro e pequeno porte, porém o
172 uso de mulching também exerce o controle de muitas espécies C4, como
173 frequentemente reportado para outras culturas (THANKAMANI et al., 2016; PRICE et
174 al., 2018; RANAIVOSON et al., 2018, ZHANG et al., 2019). Apesar da alta
175 competitividade de espécies C4 nos períodos iniciais da interferência, plantas daninhas
176 C3 podem ser mais problemáticas para o Gergelim e o Meloeiro ao longo de todo o
177 ciclo, e essa relação provavelmente foi interpretada pela rede ao adicionar a relação de
178 espécies daninhas C3/C4 como uma entrada.

179

180 **3.3 Determinação do controle de plantas daninhas baseados em variáveis mistas** 181 **(não destrutivas + destrutivas)**

182

183 A rede treinada a partir das variáveis não destrutivas e destrutivas mostrou altos
184 valores de acurácia e F-score, superiores a 0,90 para todas as classes de perdas
185 aceitáveis (Tabela 5). Apenas a especificidade para classe de 2,5% de perdas aceitáveis
186 foi inferior a 0,90 durante o treinamento da rede (Tabela 5). A validação e teste da rede
187 também resultaram em valores superiores a 0,90 para todos os índices de desempenho e
188 classes de perdas (Tabela 5).

189 O uso da densidade e matéria fresca como variáveis de entrada aumentou o
190 desempenho da rede, principalmente durante a fase de teste, comparado aos métodos
191 que usaram apenas entradas não destrutivas ou destrutivas.

192 **Tabela 5.** Desempenho da rede neural artificial MLP nas etapas de treinamento,
 193 validação e teste para perdas aceitáveis de 2,5, 5 e 10%, considerando as variáveis de
 194 entrada pelo método não destrutivo e destrutivo.

195

Variáveis de entrada	Etapa	Perda (%)	Acurácia	Especificidade	F-score
Cultura, Período, Densidade, Matéria fresca	Treinamento	2,5	0,97	0,87	0,98
		5	0,93	0,92	0,96
		10	0,96	0,96	0,97
	Validação	2,5	0,94	0,94	0,97
		5	1,00	1,00	1,00
		10	1,00	1,00	1,00
	Teste	2,5	0,98	1,00	0,99
		5	1,00	1,00	1,00
		10	0,98	0,94	0,98

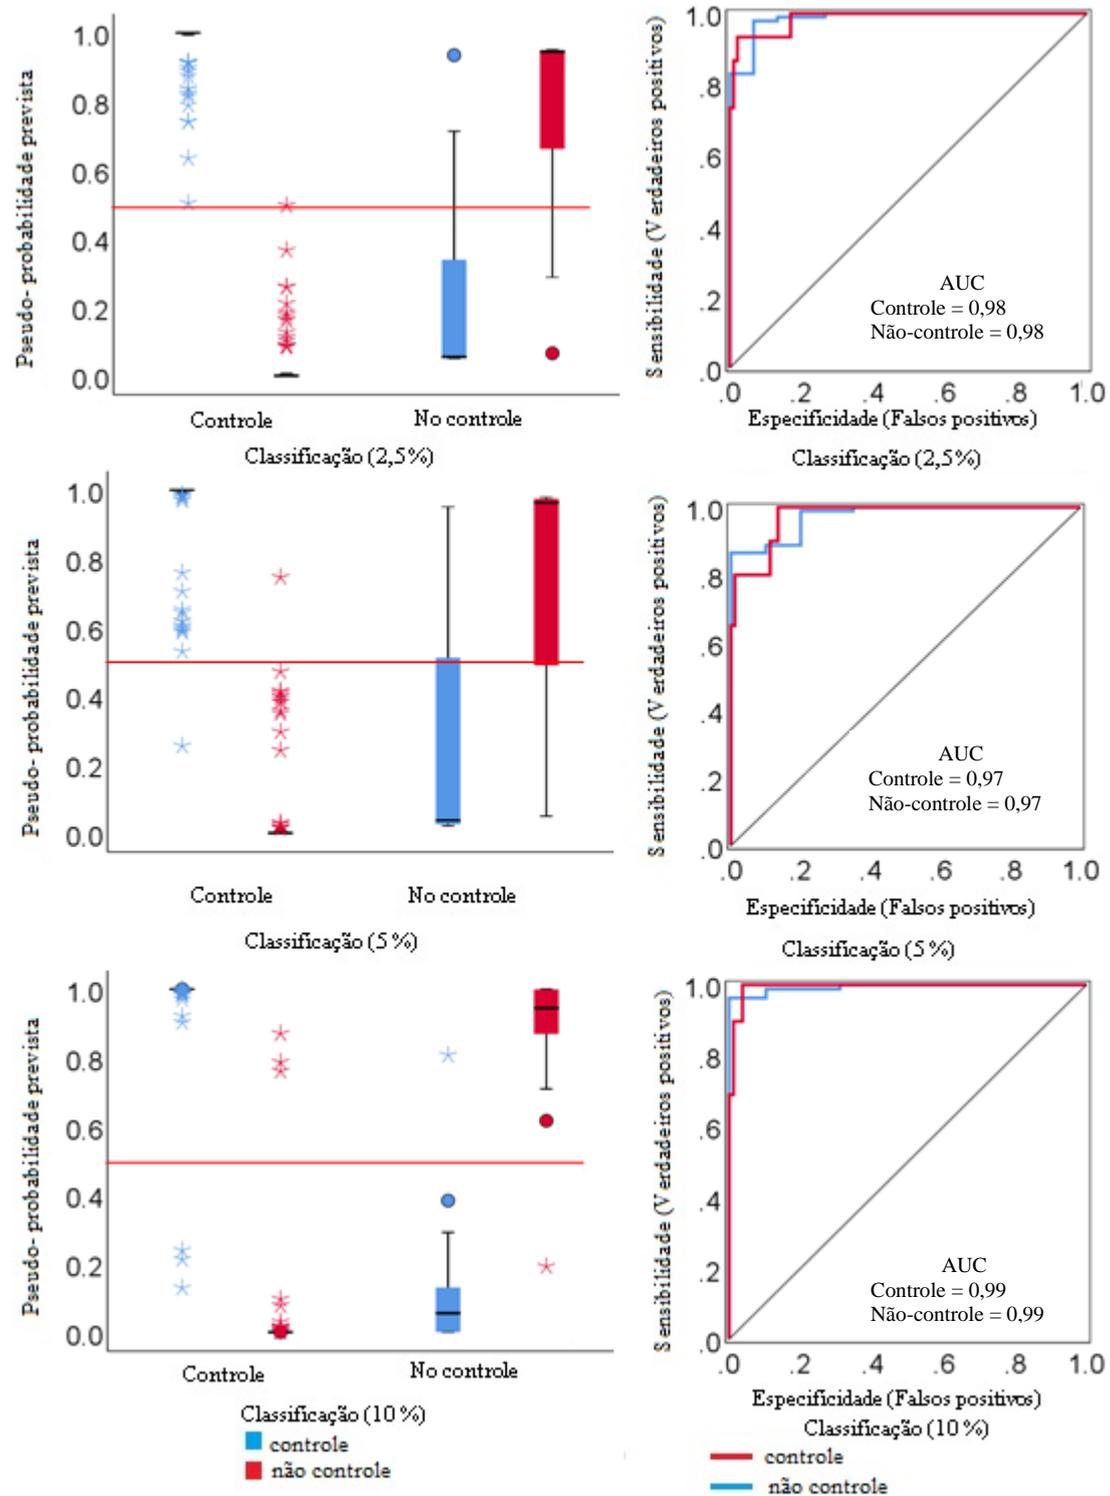
196

197 Além da alta capacidade para determinar os verdadeiros casos positivos
 198 (controle) e negativos (não controle), a rede construída por variáveis mistas permitiu
 199 poucos casos falsamente classificados, com apenas um erro para as classes de 2,5 e 5%
 200 de perdas aceitáveis e nenhum erro para perdas de produção até 10% para uma pseudo-
 201 probabilidade igual a 0,5 % (Figura 5). Além da melhor performance, a rede baseada em
 202 densidade e matéria acumulada de plantas daninhas é mais intuitiva e simples de ser
 203 empregada no campo por diversos produtores devido à facilidade de obter essas
 204 variáveis, evitando possíveis erros de identificação das espécies quanto ao seu ciclo
 205 fotossintético (C3 ou C4) ou classificação botânica (monocotiledôneas e
 206 eudicotiledôneas). Mesmo embasada apenas em simples variáveis, a rede neural
 207 artificial detectou a existência de uma relação complexa e não linear entre as entradas e
 208 o grau de interferência sobre o Gergelim e Meloeiro, requerendo seis neurônios
 209 (Apêndice VI) na camada oculta para o bom desempenho da rede (SILVA et al., 2017).

210

211

212



213

214 **Figura 5.** Pseudo-probabilidade (direta) e Curva Característica Operacional do Receptor
 215 (COR, esquerda) da rede neural artificial MLP selecionada (Cultura, Período,
 216 Densidade, e matéria fresca) para estimar o controle de plantas daninhas considerando o
 217 método não destrutivo e destrutivo.

218

219

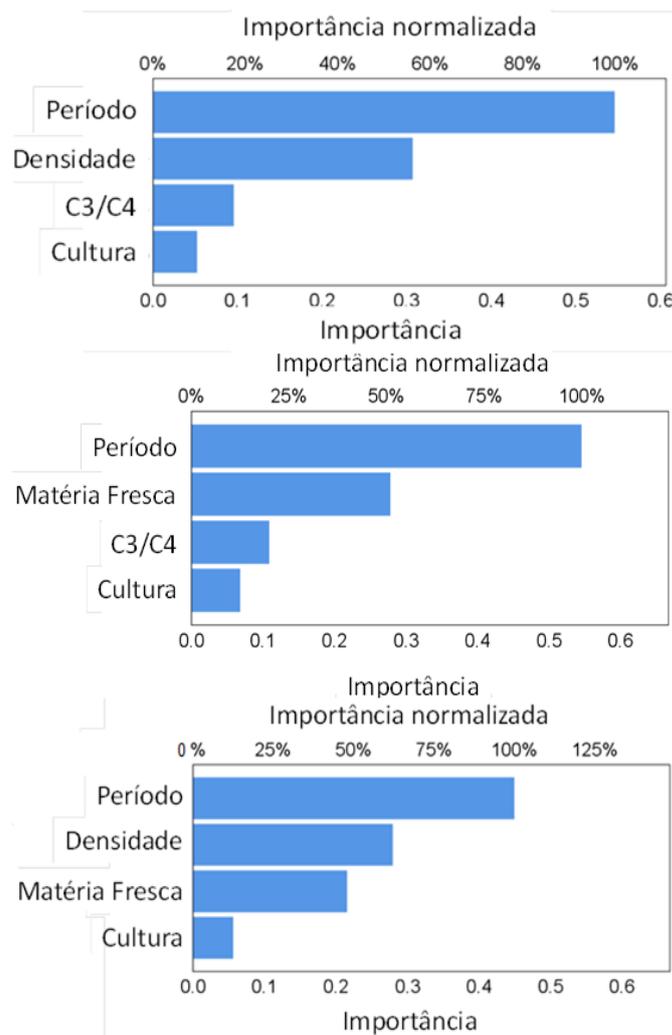
220 Apesar da existência de alta correlação entre as variáveis densidade e matéria
221 fresca de plantas daninhas em alguns estudos (SHAHZAD et al., 2016; JERNIGAN et
222 al., 2017; JIANG et al., 2018; ALONSO-AYUSO et al., 2018), sugerindo uma
223 redundância (aumento da multicolinearidade) para fins de modelagem de dados
224 (SANTOS et al., 2019; CHAGAS et al., 2019; ADHIKARI et al., 2020), elas podem
225 indicar diferentes cenários sobre a comunidade de plantas daninhas quando vinculadas.
226 A densidade é um caminho para elucidar a distribuição das plantas daninhas, tanto nas
227 linhas quanto nas entrelinhas de cultivo; portanto, essa variável pode indiretamente
228 diferenciar o maior ou menor grau de interferência com base na probabilidade das
229 plantas daninhas estarem crescendo sobre a linha de cultivo (WANG et al., 2019;
230 ASAD; BAIS, 2019). Plantas daninhas que crescem sobre a linha de cultivo são mais
231 competitivas, uma vez que o mesmo nicho é explorado pelas raízes das plantas daninhas
232 e culturas (RUBIO et al., 2001; GUNDEL et al., 2014; LU et al., 2020). A alta
233 densidade pode elevar probabilidade de ocorrência de infestantes na linha de cultivo
234 (WANG et al., 2019), resultando em maiores prejuízos ao crescimento e
235 desenvolvimento da cultura (CELETTE et al., 2009; SOUZA et al., 2020). No entanto,
236 além da posição, a taxa de crescimento da comunidade infestante deve ser considerada
237 para inferir sobre o real grau de interferência sobre a cultura, ou seja, a quantidade de
238 recursos que foi limitada pela comunidade de plantas aos cultivos. Essa última condição
239 pode ser interpretada ao avaliar o acúmulo de matéria fresca, explicando a alta
240 performance da rede ao mixar as entradas densidade e matéria fresca para determinar o
241 início da ocorrência da competição.

242

243 **3.4 Análise de sensibilidade das variáveis considerando as melhores rede neurais** 244 **artificiais obtidas através de cada método**

245

246 A análise de sensibilidade das redes com melhores desempenhos para cada
247 método (não destrutivo, destrutivo e misto) revelou a menor importância relativa para a
248 variável cultura (Figura 6). As variáveis densidade, matéria fresca e C3/C4, todas
249 relacionadas à comunidade de plantas daninhas, tiveram maior importância relativa na
250 comparação com a cultura (Figura 6). O período mostrou maior importância relativa
251 comparado às demais variáveis, seguido pela densidade no método não destrutivo e
252 matéria fresca no destrutivo (Figura 6). A importância relativa para densidade e matéria
253 fresca foi equivalente a 60% e 50%, respectivamente, no método misto (Figura 6).



254

255 **Figura 6.** Importância normalizada e absoluta das variáveis de entrada para a rede
 256 neural artificial MLP com melhor desempenho pelos métodos não destrutivo (A),
 257 destrutivo (B) e não destrutivo e destrutivo (C).

258

259 Mesmo usando espécies que foram cultivadas em sistemas extremamente
 260 contrastantes, a importância da variável cultura foi baixa. A influência dessa variável
 261 pode estar sobreposta ao efeito de cada sistema sobre o estabelecimento das plantas
 262 daninhas, definindo o tipo e taxa de crescimento da comunidade na área.
 263 Conseqüentemente, parte dos pesos e da variação causado pela variável cultura pode
 264 estar capturada nas variáveis relacionadas às plantas daninhas, como densidade, matéria
 265 fresca e relação C3/C4, devido à estreita relação entre cultura, sistema de cultivo e
 266 dinâmica populacional de plantas infestantes. O papel das práticas de manejo sobre a
 267 dominância de espécies de plantas daninhas já foi observado em culturas como soja
 268 (SEPAT et al., 2017), cebola (SOUZA et al., 2020), feijão-seca (HILL et al., 2016),

269 milho (VIDOTTO et al., 2016), dentre outras (MASILIONYTE et al., 2017; FORTE et
270 al., 2018; WALLACE et al., 2018). Mesmo com menor importância, alguns aspectos
271 exclusivos às culturas contribuíram para formação das redes neurais artificiais nos
272 métodos não destrutivos ou destrutivos.

273 A forte influência do período nos modelos de redes neurais artificiais reforça a
274 correlação positiva entre o tempo de coexistência e o grau de interferência entre culturas
275 e plantas daninhas. Apesar da maior importância dessa variável, as demais entradas
276 densidade, matéria fresca e relação C3/C4 são necessárias para entender outras relações
277 e dividem 50% da contribuição restante nas redes neurais artificiais criadas pelo método
278 não destrutivo ou destrutivo. Mesmo não considerando a relação C3/C4 no método
279 misto, mesclar a densidade e a matéria fresca acumulada não acrescentou informações
280 redundantes às redes, resultando em alta importância para ambas as variáveis. Caso
281 contrário, a alta correlação entre densidade e matéria fresca eliminaria a importância de
282 alguma dessas variáveis, englobando toda a variação dos dados apenas naquela mais
283 representativa (KOWALSKI; KUSY, 2018). Esse fato reitera o argumento citado
284 anteriormente sobre o papel da densidade e matéria fresca em identificar a distribuição e
285 a taxa de crescimento das plantas, respectivamente, melhorando a modelagem e a
286 capacidade da rede em determinar o grau de interferência de plantas daninhas sobre o
287 Gergelim e o Meloeiro.

288 Independentemente das variáveis de entrada e método usados, a aprendizagem
289 de máquina via redes neurais artificiais pode estimar o grau de interferência das plantas
290 daninhas e os efeitos sobre produtividade das culturas. A rede neural artificial se
291 mostrou uma ferramenta poderosa, pois mesmo baseada em atributos simples, como
292 período de avaliação, densidade e matéria fresca e cultura, foi capaz de prever com
293 alto grau de acerto o momento correto para iniciar o controle de plantas daninhas, para
294 condições de menor e maior perda aceitável. Os resultados obtidos nesse estudo devem
295 encorajar cientistas de plantas daninhas a realizar futuros trabalhos focados em auxiliar
296 o produtor na tomada de decisão. Por exemplo, modelos computacionais capazes de
297 estimar a densidade populacional de plantas daninhas via imagens digitais (SANTOS
298 FERREIRA et al., 2017) podem ser alimentados com informações sobre perdas relativas
299 da cultura, custo de controle e preço do produto colhido, resultando em *softwares* que
300 maximizem os lucros e reduzem as perdas causadas pelas plantas daninhas.

301

302

303 4. CONCLUSÕES

304

305 As redes neurais artificiais são eficientes para determinar o momento ideal para
306 controlar plantas daninhas baseadas na perda relativa do gergelim e melão.

307 Adição da relação C3/C4 – juntamente com o período, densidade ou matéria
308 fresca e cultura – resulta em redes neurais artificiais com melhor desempenho para os
309 métodos exclusivamente não destrutivos e destrutivos.

310 Todavia, a melhor rede neural artificial para estimar o momento de controle de
311 plantas daninhas é baseada na junção de variáveis não destrutivas e destrutivas.

312 O mix de entradas não destrutivas (Densidade) e destrutivas (Matéria Fresca)
313 dispensa outras entradas mais específicas, como relação C3/C4 e M/D.

314 O período é o principal fator para inferir a grau de interferência das plantas
315 daninhas no Gergelim e Meloeiro.

316 A densidade e matéria fresca, apesar de frequentemente correlacionadas, trazem
317 diferentes interpretações sobre a dinâmica populacional de plantas daninhas para a rede
318 neural artificial quando usadas como variáveis de entrada.

319

320

321

322

323

324

325

326

327

328

329

330

331

332

333

334

335

336

337 **REFERÊNCIAS**

338

339 ABDIPOUR, M.; YOUNESSI-HMAZEKHANLU, M.; RAMAZANI, S. H. R.
340 Artificial neural networks and multiple linear regression as potential methods for
341 modeling seed yield of safflower (*Carthamus tinctorius* L.). **Industrial crops and**
342 **products**, v. 12, p. 185-194, 2019.

343

344 ABROUGUI, K.; GABSI, K.; MERCATORIS, B.; KHEMIS, C.; AMAMI, R.;
345 CHEHAIBI, S. Prediction of organic potato yield using tillage systems and soil
346 properties by artificial neural network (ANN) and multiple linear regressions (MLR).
347 **Soil and Tillage Research**, v. 190, p. 202-208, 2019.

348

349 ADHIKARI, A.; REW, L. J.; MAINALI, K. P.; ADHIKARI, S.; MAXWELL, B. D.
350 Future distribution of invasive weed species across the major road network in the state
351 of Montana, USA. **Regional Environmental Change**, v. 20, n. 60, p. 1-14, 2020.

352

353 ALIBAKSHI, A. Strategies to develop robust neural network models: Prediction of
354 flash point as a case study. **Analytica chimica acta**, v. 1026, p. 69-76, 2018.

355

356 ALONSO-AYUSO, M.; GABRIEL, J. L.; GARCÍA-GONZÁLEZ, I.; DEL MONTE, J.
357 P.; QUEMADA, M. Weed density and diversity in a long-term cover crop experiment
358 background. **Crop Protection**, v. 112, p. 103-111, 2018.

359

360 ALTUNTAŞ, Y.; CÖMERT, Z.; KOCAMAZ, A. F. Identification of haploid and
361 diploid maize seeds using convolutional neural networks and a transfer learning
362 approach. **Computers and Electronics in Agriculture**, v. 163, 104874, 2019.

363

364 ALVARES, C. A.; STAPE J. L.; SENTELHAS P. C. Köppen's climate classification
365 map for Brazil. **Meteorologische Zeitschrift, Stuttgart**, v. 22, n. 6, p. 711-728, 2013.

366

367 AMARAL, J. A. B.; SILVA, M. T. Evapotranspiração e coeficiente de cultivo do
368 gergelim por manejo de irrigação. **Revista Brasileira de Oleaginosa e Fibrosa**, v. 12,
369 n. 1, p. 25-33, 2008.

370

371 ASAD, M. H.; BAIS, A. Weed detection in canola fields using maximum likelihood
372 classification and deep convolutional neural network. **Information Processing in**
373 **Agriculture**, 2019.

374

375 BERTI, A.; BRAVIN, F.; ZANIN, G. Application of decision-support software for
376 postemergence weed control. **Weed Science**, v. 51, n. 4, p. 618-627, 2003.

377

378 BERTUCCI, M. B.; JENNINGS, K. M.; MONKS, D. W.; SCHULTHEIS, J. R.;
379 LOUWS, F. J.; JORDAN, D. L.; BROWNIE, C. Critical period for weed control in
380 grafted and nongrafted watermelon grown in plasticulture. **Weed Science**, v. 67, n. 2, p.
381 221-228, 2019.

382

383 CAVALCANTI, F. J. A. **Recomendações de adubação para o estado de**
384 **Pernambuco: 2ª aproximação. 2ª ed. Recife: IPA, 2008.**

385

- 386 CELETTE, F.; FINDELING, A.; GARY, C. Competition for nitrogen in an unfertilized
387 intercropping system: The case of an association of grapevine and grass cover in a
388 Mediterranean climate. **European Journal of Agronomy**, v. 30, n. 1, p. 41-51, 2009.
389
- 390 CHARLES, G. W.; SINDEL, B. M.; COWIE, A. L.; KNOX, O. G. Determining the
391 critical period for grass control in high-yielding cotton using Japanese millet as a mimic
392 weed. **Weed Technology**, v. 34, n. 2, p. 292-300, 2020.
393
- 394 CHAUDHARI, S.; JENNINGS, K. M.; MONKS, D. W.; JORDAN, D. L.; GUNTER,
395 C. C.; MCGOWEN, S. J.; LOUWS, F. J. Critical period for weed control in grafted and
396 nongrafted fresh market tomato. **Weed Science**, v. 64, n. 3, p. 523-530, 2016.
397
- 398 COLAS, F.; CORDEAU, S.; GRANGER, S.; JEUFFROY, M. H.; POINTURIER, O.;
399 QUEYREL, W.; RODRIGUEZ, A.; VILLERD, J.; COLBACH, N. Co-development of
400 a decision support system for integrated weed management: Contribution from future
401 users. **European Journal of Agronomy**, v. 114, 126010, 2020.
402
- 403 CÖMERT, Z.; KOCAMAZ, A. F. Open-access software for analysis of fetal heart rate
404 signals. **Biomedical Signal Processing and Control**, v. 45, p. 98-108, 2018.
405
- 406 CORDEAU, S.; SMITH, R. G.; GALLANDT, E. R.; BROWN, B.; SALON, P.;
407 DITOMMASO, A.; RYAN, M. R. Timing of tillage as a driver of weed communities.
408 **Weed science**, v. 65, n. 4, p. 504-514, 2017.
409
- 410 SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.; LIBONI, L. H. B.; REIS ALVES, S.
411 F. Artificial neural network architectures and training processes. **Artificial neural
412 networks**, p. 21-28, 2017.
413
- 414 DAMMER, K. H. Real-time variable-rate herbicide application for weed control in
415 carrots. **Weed research**, v. 56, n. 3, p. 237-246, 2016.
416
- 417 DARAMOLA, O. S.; ADEYEMI, O. R.; ADIGUN, J. A.; ADEJUYIGBE, C. O. Weed
418 interference and control in soybean, as affected by row spacing, in the transition zone of
419 South West Nigeria. **Journal of Crop Improvement**, v. 34, n. 1, p. 103-121, 2020.
420
- 421 CHAGAS, P. S. F.; FREITAS SOUZA, M.; DOMBROSKI, J. L. D.; OLIVEIRA
422 JUNIOR, R. S.; SOUSA NUNES, G. H.; PEREIRA, G. A. M.; SILVA, D. V.
423 Multivariate analysis reveals significant diuron-related changes in the soil composition
424 of different Brazilian regions. **Scientific reports**, v. 9, n. 1, p. 1-12, 2019.
425
- 426 SANTOS FERREIRA, A.; FREITAS, D. M.; SILVA G. G.; PISTORI, H.; FOLHES,
427 M. T. Weed detection in soybean crops using Conv Nets. **Computers and Electronics
428 in Agriculture**, v. 143, p. 314-324, 2017.
429
- 430 DAVIS, A. M.; THORBURN, P. J.; LEWIS, S. E.; BAINBRIDGE, Z. T.; ATTARD, S.
431 J.; MILLA, R.; BRODIE, J. E. Environmental impacts of irrigated sugarcane
432 production: herbicide run-off dynamics from farms and associated drainage systems.
433 **Agriculture, ecosystems & environment**, v. 180, p. 123-135, 2013.
434

- 435 DAVIS, A. S.; FRISVOLD, G. B. Are herbicides a once in a century method of weed
436 control? **Pest management science**, v. 73, n. 11, p. 2209-2220, 2017.
437
- 438 FREITAS SOUZA, M.; SILVA, T. S.; SANTOS, J. B.; CARNEIRO, G. D. O. P.;
439 REGINALDO, L. T. R. T.; BANDEIRA, J. N.; SANTOS, M. S. PAVÃO, Q. S.;
440 NEGREIROS, M. Z.; SILVA, D. V. Soil water availability alter the weed community
441 and its interference on onion crops. **Scientia Horticulturae**, v. 272, 109573, 2020.
442
- 443 SANTOS, L. O. G.; FREITAS SOUZA, M.; CHAGAS, P. S. F.; TEÓFILO, T. M. S.;
444 FORMIGA, M. A. P.; MEDEIROS, R. C. A.; SILVA, D. V. Multivariate analysis and
445 multiple linear regression as a tool to estimate the behavior of hexazinone in Brazilian
446 soils. **Environmental monitoring and assessment**, v. 191, n. 11, p. 671, 2019.
447
- 448 DYRMANN, M.; KARSTOFT, H.; MIDTIBY, H. S. Plant species classification using
449 deep convolutional neural network. **Biosystems Engineering**, v. 151, p. 72-80, 2016.
450
- 451 EMBRAPA. **Sistema brasileiro de classificação de solos**. Brasília, DF: Embrapa
452 Solos. 2013.
453
- 454 FENG, P.; WANG, B.; LI LIU, D.; YU, Q. Machine learning-based integration of
455 remotely-sensed drought factors can improve the estimation of agricultural drought in
456 South-Eastern Australia. **Agricultural Systems**, v. 173, n. 3, p. 303-316, 2019.
457
- 458 FILGUEIRA, F. A. R. **Novo manual de olericultura: Agrotecnologia moderna na**
459 **produção e comercialização de hortaliças**. Viçosa: UFV, 2002.
460
- 461 FILLOLS, E.; DAVIS, A. M.; LEWIS, S. E.; WARD, A. Combining weed efficacy,
462 economics and environmental considerations for improved herbicide management in the
463 Great Barrier Reef catchment area. **Science of The Total Environment**, v. 720,
464 137481, 2020.
465
- 466 FORTE, C. T.; GALON, L.; BEUTLER, A. N.; REICHERT JR, F. W.; MENEGAT, A.
467 D.; PERIN, G. F.; TIRONI, S. P. Cultivation systems, vegetable soil covers and their
468 influence on the phytosocology of weeds. **Planta Daninha**, v. 36, e018176776, 2018.
469
- 470 GIANESSI, L. P.; REIGNER, N. P. The value of herbicides in US crop production.
471 **Weed Technology**, v. 21, n. 2, p. 559-566, 2007.
472
- 473 GUNDEL, P. E.; PIERIK, R.; MOMMER, L.; BALLARÉ, C. L. Competing neighbors:
474 light perception and root function. **Oecologia**, v. 176, n. 1, p. 1-10, 2014.
475
- 476 HAIDAR, M. A.; SIDAHMED, M. M. Soil solarization and chicken manure for the
477 control of *Orobanche crenata* and other weeds in Lebanon. **Crop Protection**, v. 19, n. 3,
478 p. 169-173, 2000.
479
- 480 HARKER, K. N.; O'DONOVAN, J. T. Recent weed control, weed management, and
481 integrated weed management. **Weed Technology**, v. 27, n. 1, p. 1-11, 2013.
482

- 483 HILL, E. C.; RENNER, K. A.; SPRAGUE, C. L.; DAVIS, A. S. Cover crop impact on
484 weed dynamics in an organic dry bean system. **Weed Science**, v. 64, n. 2, p. 261-275,
485 2016.
- 486
- 487 HUANG, H.; DENG, J.; LAN, Y.; YANG, A.; DENG, X.; ZHANG, L. A fully
488 convolutional network for weed mapping of unmanned aerial vehicle (UAV) imagery.
489 **Plo Sone**, v. 13, n. 4, p. xx-yy, 2018.
- 490
- 491 HUSSAIN, M.; FAROOQ, S.; MERFIELD, C.; JABRAN, K. Mechanical weed control.
492 **In Non-Chemical Weed Control**, p. 133-155, 2018.
- 493
- 494 JABRAN, K.; CHAUHAN, B. S. **Non-chemical weed control**. London: Academic
495 Press, 2018.
- 496
- 497 JERNIGAN, A. B.; CALDWELL, B. A.; CORDEAU, S.; TOMMASO, A.;
498 DRINKWATER, L. E.; MOHLER, C. L.; RYAN, M. R. Weed abundance and
499 community composition following a long-term organic vegetable cropping systems
500 experiment. **Weed Science**, v. 65, n. 5, p. 639-649, 2017.
- 501
- 502 JHA, P.; KUMAR, V.; GODARA, R. K.; CHAUHAN, B. S. Weed management using
503 crop competition in the United States: A review. **Crop Protection**, v. 95, p. 31-37,
504 2017.
- 505
- 506 JIANG, M.; LIU, T.; HUANG, N.; SHEN, X.; SHEN, M.; DAI, Q. Effect of long-term
507 fertilisation on the weed community of a winter wheat field. **Scientific reports**, v. 8, p.
508 1-7, 2018.
- 509
- 510 KARKANIS, A.; LYKAS, C.; LIAVA, V.; BEZOU, A.; PETROPOULOS, S.;
511 TSIROPOULOS, N. Weed interference with peppermint (*Mentha x piperita* L.) and
512 spearmint (*Mentha spicata* L.) crops under different herbicide treatments: effects on
513 biomass and essential oil yield. **Journal of the Science of Food and Agriculture**, v.
514 98, n. 1, p. 43-50, 2018.
- 515
- 516 KARNAS, Z.; ISIK, D.; TURSUN, N.; JABRAN, K. Critical period for weed control in
517 sesame production. **Weed Biology and Management**, v. 19, n. 4, p. 121-128, 2019.
- 518
- 519 KISI, O.; KILIC, Y. An investigation on generalization ability of artificial neural
520 networks and M5 model tree in modeling reference evapotranspiration. **Theoretical
521 and Applied Climatology**, v. 126, n. 3, p. 413-425, 2016.
- 522
- 523 KNEZEVIC, S. Z.; EVANS, S. P.; BLANKENSHIP, E. E.; VAN ACKER, R. C.;
524 LINDQUIST, J. L. Critical period for weed control: the concept and data analysis.
525 **Weed science**, v. 50, n. 6, p.773-786, 2002.
- 526
- 527 KOWALCZYK-JUŚKO, A.; POCHWATKA, P.; ZABOROWICZ, M.; CZEKAŁA,
528 W.; MAZURKIEWICZ, J.; MAZUR, A.; DACH, J. Energy value estimation of silages
529 for substrate in biogas plants using an artificial neural network. **Energy**, v. 202, p. 117-
530 229, 2020.
- 531

- 532 KOWALSKI, P. A.; KUSY, M. Determining significance of input neurons for
533 probabilistic neural network by sensitivity analysis procedure. **Computational**
534 **Intelligence**, v. 34, n. 3, p. 895-916, 2018.
- 535
536 LU, P.; JIANG, B.; WEINER, J. Crop spatial uniformity, yield and weed suppression.
537 **Advances in Agronomy**, v. 161, p. 117-178, 2020.
- 538
539 MAMY, L.; GABRIELLE, B.; BARRIUSO, E. . Comparative environmental impacts of
540 glyphosate and conventional herbicides when used with glyphosate-tolerant and non-
541 tolerant crops. **Environmental Pollution**, v. 158, n. 10, p. 3172-3178, 2010.
- 542
543 MASILIONYTE, L.; MAIKSTENIENE, S.; KRIAUCIUNIENE, Z.; JABLONSKYTE-
544 RASCE, D.; ZOU, L.; SARAUSKIS, E. Effect of cover crops in smothering weeds and
545 volunteer plants in alternative farming systems. **Crop Protection**, v. 91, p. 74-81, 2017.
- 546
547 MERINO, J.; PEDREROS, A.; FISCHER, S.; LÓPEZ, M. D. Critical period of weed
548 interference on total polyphenol content in quinoa. **Chilean journal of agricultural**
549 **research**, v. 79, n. 3, p. 405-414, 2019.
- 550
551 OCHOA-MARTÍNEZ, C. I.; AYALA-APONTE, A. A. Prediction of mass transfer
552 kinetics during osmotic dehydration of apples using neural networks. **Food Science and**
553 **Technology**, v. 40, n. 4, p. 638-645, 2007.
- 554
555 OLSEN, A.; KONOVALOV, D. A.; PHILIPPA, B.; RIDD, P.; WOOD, J. C.; JOHNS,
556 J.; CALVERT, B. Deep Weeds: A multiclass weed species image dataset for deep
557 learning. **Scientific reports**, v. 9, n. 1, p. 1-12, 2019.
- 558
559 ÖZESMI, S. L.; TAN, C. O.; ÖZESMI, U. Methodological issues in building, training,
560 and testing artificial neural networks in ecological applications. **Ecological Modelling**,
561 v. 195, n. 1, p. 83-93, 2006.
- 562
563 PEREIRA, F. A. D. L.; MEDEIROS, J. F. D.; GHEYI, H. R.; DIAS, N. D. S.;
564 PRESTON, W.; VASCONCELOS, C. B. Tolerance of melon cultivars to irrigation
565 water salinity. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 21, n. 12,
566 p. 846-851, 2017.
- 567
568 PICON, A.; ALVAREZ-GILA, A.; SEITZ, M.; ORTIZ-BARREDO, A.;
569 ECHAZARRA, J.; JOHANNES, A. Deep convolutional neural networks for mobile
570 capture device-based crop disease classification in the wild. **Computers and**
571 **Electronics in Agriculture**, v. 161, p. 280-290, 2019.
- 572
573 PRICE, A. J.; WILLIAMS, J. P.; DUZY, L. A.; MCELROY, J. S.; GUERTAL, E. A.;
574 LI, S. Effects of integrated polyethylene and cover crop mulch, conservation tillage, and
575 herbicide application on weed control, yield, and economic returns in watermelon.
576 **Weed Technology**, v. 32, n. 5, p. 623-632, 2018.
- 577
578 RANAIVOSON, L.; NAUDIN, K.; RIPOCHE, A.; RABEHARISOA, L.; CORBEELS,
579 M. Is mulching an efficient way to control weeds? Effects of type and amount of crop
580 residue in rainfed rice based cropping systems in Madagascar. **Field Crops Research**,
581 v. 217, p. 20-31, 2018.

- 582
583 ROSSET, J. D.; GULDEN, R. H. Cultural weed management practices shorten the
584 critical weed-free period for soybean grown in the Northern Great Plains. **Weed**
585 **Science**, v. 68, n. 1, p. 79-91, 2020.
- 586
587 RUBIO, G.; WALK, T.; GE, Z.; YAN, X.; LIAO, H.; LYNCH, J. P. Root gravitropism
588 and below-ground competition among neighbouring plants: a modelling approach.
589 **Annals of Botany**, v. 88, n. 5, p. 929-940, 2001.
- 590
591 SEPAT, S.; THIERFELDER, C.; SHARMA, A. R.; PAVULURI, K.; KUMAR, D.;
592 IQUEBAL, M. A.; VERMA, A. Effects of weed control strategy on weed dynamics,
593 soybean productivity and profitability under conservation agriculture in India. **Field**
594 **Crops Research**, v. 210, p. 61-70, 2017.
- 595
596 SEWSYNKER-SUKAI, Y.; FALOYE, F.; KANA, E. B. G. Artificial neural networks:
597 an efficient tool for modelling and optimization of biofuel production (a mini review).
598 **Biotechnology & Biotechnological Equipment**, v. 31, n. 2, p. 221-235, 2017.
- 599
600 SEYYEDI, S. M.; MOGHADDAM, P. R.; MAHALLATI, M. N. Weed competition
601 periods affect grain yield and nutrient uptake of Black Seed (*Nigella Sativa* L.).
602 **Horticultural Plant Journal**, v. 2, n. 3, p. 172-180, 2016.
- 603
604 SHAHZAD, M.; FAROOQ, M.; JABRAN, K.; HUSSAIN, M. Impact of different crop
605 rotations and tillage systems on weed infestation and productivity of bread wheat. **Crop**
606 **protection**, v. 89, p. 161-169, 2016.
- 607
608 SOLTANI, N.; DILLE, J. A.; BURKE, I. C.; EVERMAN, W. J.; VANGESSEL, M. J.;
609 DAVIS, V. M.; SIKKEMA, P. H. Potential corn yield losses from weeds in North
610 America. **Weed Technology**, v. 30, n. 4, p. 979-984, 2016.
- 611
612 STEPHENSON, D. **Big Data Demystified: How to use big data, data science and AI to**
613 **make better business decisions and gain competitive advantage.** Pearson UK, 2018.
- 614
615 THANKAMANI, C. K.; KANDIANNAN, K.; HAMZA, S.; SAJI, K. V. Effect of
616 mulches on weed suppression and yield of ginger (*Zingiber officinale* Roscoe). **Scientia**
617 **Horticulturae**, v. 207, p. 125-130, 2016.
- 618
619 TURSUN, N.; DATTA, A.; BUDAK, S.; KANTARCI, Z.; KNEZEVIC, S. Z. Row
620 spacing impacts the critical period for weed control in cotton (*Gossypium hirsutum*).
621 **Phytoparasitica**, v. 44, p. 139-149, 2016b.
- 622
623 TURSUN, N.; DATTA, A.; SAKINMAZ, M. S.; KANTARCI, Z.; KNEZEVIC, S. Z.;
624 CHAUHAN, B. S. The critical period for weed control in three corn (*Zea mays* L.)
625 types. **Crop protection**, v. 90, p. 59-65, 2016a.
- 626
627 VIDOTTO, F.; FOGLIATTO, S.; MILAN, M.; FERRERO, A. Weed communities in
628 Italian maize fields as affected by pedo-climatic traits and sowing time. **European**
629 **Journal of Agronomy**, v.74, p. 38-46, 2016.
- 630

631 VITORINO, H. D. S.; SILVA JUNIOR, A. C. D.; GONÇALVES, C. G.; MARTINS,
632 D. Interference of a weed community in the soybean crop in functions of sowing
633 spacing. **Revista Ciência Agronômica**, v. 48, n. 4, p. 605-613, 2017.

634

635 WALLACE, J. M.; KEENE, C. L.; CURRAN, W.; MIRSKY, S.; RYAN, M. R.;
636 VANGESSEL, M. J. Integrated weed management strategies in cover crop-based,
637 organic rotational no-till corn and soybean in the mid-Atlantic region. **Weed Science**, v.
638 66, n. 1, p. 94-108, 2018.

639

640 WANKHEDE, S. S.; ARMSTRONG, L. J. Characterising the impact of drought on
641 Jowar (Sorghum spp) crop yield using bayesian networks. **In International**
642 **Conference on Intelligent Systems Design and Applications**, p. 979-987, 2017.

643

644 YU, J.; SHARPE, S. M.; SCHUMANN, A. W.; BOYD, N. S. Detection of broadleaf
645 weeds growing in turfgrass with convolutional neural networks. **Pest management**
646 **science**, v. 75, n. 8, p. 2211-2218, 2019.

647

648 ZHANG, H.; MILES, C.; GHIMIRE, S.; BENEDICT, C.; ZASADA, I.; DEVETTER,
649 L. Polyethylene and biodegradable plastic mulches improve growth, yield, and weed
650 management in florican red raspberry. **Scientia Horticulturae**, v. 250, p. 371-379,
651 2019.

652

653 ZHU, Z.; PENG, G.; CHEN, Y.; GAO, H. A convolutional neural network based on a
654 capsule network with strong generalization for bearing fault diagnosis.
655 **Neurocomputing**, v. 323, p. 62-75, 2019.

656

657

658

659

660

661

662

663

664

665

666

667

668

669

670

671

672

673 **CONSIDERAÇÕES FINAIS**

674

675 No geral, modelos matemáticos construídos baseados na inteligência artificial,
676 foram capazes de entender melhor a relação entre culturas e plantas daninhas do que os
677 modelos empíricos tradicionais, conforme discutido nesse estudo. Independentemente
678 do sistema de irrigação utilizado, a inserção das variáveis relacionadas à densidade de
679 plantas daninhas como variável não destrutiva e à matéria fresca como variável
680 destrutiva elevou a capacidade preditiva de acertos das redes, indicando melhor precisão
681 para definir o início do controle das plantas daninhas na cultura da cebola.

682 As Redes Neurais Artificiais também foram eficientes em determinar o
683 momento ideal para o controle de plantas daninhas com base na perda relativa da
684 produtividade de gergelim e do meloeiro a níveis de 2, 5 e 10%, principalmente quando
685 os modelos fizeram uso da combinação de variáveis densidade como não destrutiva e a
686 matéria fresca como destrutivas de plantas daninhas. Essa combinação de variáveis não
687 destrutivas e destrutivas dispensa o uso de variáveis mais específicas como a
688 identificação de espécies daninhas quanto ao ciclo fotossintético C4 ou C3 e em
689 monocotiledôneas ou eudicotiledôneas.

690

691

692

693

694

695

696

697

698

699

700

701

702

703

704

APÊNDICE

Apêndice I. Informações das redes neurais artificiais implementadas.

Método	Nome	Treinamento	Teste	Validação	Erro Treinamento	Erro Teste	Erro Validação	Erro das funções	Oculto Ativação	Saida Ativação
Não destrutivo	MLP 2-12-1	0,89	0,88	0,90	116,32	124,17	109,55	SOS	Tanh	Exponential
	MLP 3-20-1	0,98	0,97	0,98	17,92	31,48	30,04	SOS	Logistic	Logistic
	MLP 4-16-1	1,00	0,98	0,98	2,26	20,51	24,09	SOS	Logistic	Tanh
	MLP 5-10-1	1,00	0,98	0,99	1,90	21,05	24,03	SOS	Tanh	Logistic
Destrutivo	MLP 2-15-1	0,90	0,90	0,89	109,25	121,64	119,42	SOS	Tanh	Identity
	MLP 3-18-1	0,99	0,99	0,99	7,00	24,15	18,31	SOS	Tanh	Exponential
	MLP 4-17-1	1,00	0,99	0,99	2,03	17,27	17,47	SOS	Logistic	Tanh
	MLP 5-18-1	1,00	1,00	0,99	0,31	16,24	15,00	SOS	Logistic	Tanh

Apêndice II. Observações geradas para os modelos de redes neurais para os diferentes métodos.

Conj. de dados	Sis.	Ano	Não destrutivo e destrutivo		Não destrutivo			Destrutivo		
			Per.	PR (%)	Dens. (p/m ²)	C4/C3	M/E	C4/C3	M/E	Mat. fresca (g m ²)
Trein.	Gotej.	2016	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Trein.	Gotej.	2016	12,00	100,00	127,12	0,48	0,20	0,45	0,12	5,15
Trein.	Gotej.	2016	24,00	97,78	155,00	0,68	0,00	0,63	0,00	84,51
Trein.	Gotej.	2016	36,00	85,45	178,00	0,92	0,00	0,85	0,00	154,40
Trein.	Gotej.	2016	48,00	76,19	235,20	0,73	0,00	0,58	0,00	218,30
Trein.	Gotej.	2016	60,00	67,16	140,00	0,86	0,00	0,86	0,00	245,08
Trein.	Gotej.	2016	120,00	30,33	198,00	0,72	0,00	0,62	0,00	875,81
Trein.	Gotej.	2017	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Trein.	Gotej.	2017	12,00	94,14	880,00	0,18	0,14	0,18	0,14	12,00
Trein.	Gotej.	2017	24,00	89,38	1574,72	0,11	0,05	0,11	0,05	197,60
Trein.	Gotej.	2017	36,00	70,53	1284,64	0,37	0,27	0,35	0,26	355,60
Trein.	Gotej.	2017	48,00	57,53	1781,92	0,48	0,24	0,47	0,23	851,20
Trein.	Gotej.	2017	60,00	50,06	1670,00	0,66	0,59	0,66	0,59	941,93
Trein.	Gotej.	2017	120,00	18,69	1200,00	0,47	0,40	0,47	0,40	1908,40
Trein.	Gotej.	2018	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Trein.	Gotej.	2018	12,00	98,24	8980,00	0,86	0,44	0,86	0,44	1316,13
Trein.	Gotej.	2018	24,00	62,47	10348,13	0,78	0,55	0,68	0,55	1588,78
Trein.	Gotej.	2018	36,00	20,77	4135,90	0,75	0,52	0,65	0,52	1731,26
Trein.	Gotej.	2018	48,00	3,32	3770,77	0,81	0,50	0,85	0,53	1989,21
Trein.	Gotej.	2018	60,00	3,38	2893,85	0,95	0,95	1,00	1,00	3993,33
Trein.	Gotej.	2018	120,00	0,20	110,77	0,95	0,95	1,00	1,00	2467,23
Teste	Gotej.	2016	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Teste	Gotej.	2016	12,00	99,51	121,07	0,45	0,12	0,48	0,20	0,00
Teste	Gotej.	2016	24,00	100,00	176,00	0,73	0,00	0,68	0,00	0,00
Teste	Gotej.	2016	36,00	90,89	186,90	0,99	0,00	0,86	0,00	0,00
Teste	Gotej.	2016	48,00	67,81	219,52	0,64	0,00	0,63	0,00	0,00
Teste	Gotej.	2016	60,00	68,16	147,00	0,92	0,00	0,85	0,00	0,00
Teste	Gotej.	2016	120,00	31,93	207,90	0,77	0,00	0,67	0,00	0,00
Teste	Gotej.	2017	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Teste	Gotej.	2017	12,00	100,00	911,68	0,19	0,14	0,19	0,14	0,00
Teste	Gotej.	2017	24,00	82,75	1520,00	0,11	0,05	0,11	0,05	0,00
Teste	Gotej.	2017	36,00	64,20	1240,00	0,35	0,26	0,37	0,27	0,00
Teste	Gotej.	2017	48,00	55,87	1720,00	0,47	0,23	0,48	0,24	0,00
Teste	Gotej.	2017	60,00	50,50	1730,12	0,69	0,61	0,69	0,61	0,00
Teste	Gotej.	2017	120,00	17,74	1118,88	0,44	0,37	0,48	0,41	0,00
Teste	Gotej.	2018	0,00	95,03	0,00	0,00	0,00	0,00	0,00	0,00
Teste	Gotej.	2018	12,00	90,44	8082,00	0,82	0,41	0,89	0,45	0,00
Teste	Gotej.	2018	24,00	69,10	10658,57	0,80	0,57	0,80	0,57	0,00

Teste	Gotej.	2018	36,00	14,44	3722,31	0,71	0,50	0,68	0,54	0,00
Teste	Gotej.	2018	48,00	6,63	4315,44	0,88	0,55	0,88	0,55	0,00
Teste	Gotej.	2018	60,00	4,25	3311,85	0,95	0,69	0,86	0,69	0,00
Teste	Gotej.	2018	120,00	0,71	123,08	1,00	1,00	1,00	1,00	0,00
Valid.	Gotej.	2016	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Valid.	Gotej.	2016	12,00	97,29	118,65	0,42	0,00	0,42	0,00	0,00
Valid.	Gotej.	2016	24,00	100,00	184,80	0,78	0,00	0,68	0,00	0,00
Valid.	Gotej.	2016	36,00	80,01	174,44	0,86	0,00	0,86	0,00	0,00
Valid.	Gotej.	2016	48,00	72,00	224,00	0,58	0,00	0,64	0,00	0,00
Valid.	Gotej.	2016	60,00	66,16	120,00	0,80	0,00	0,70	0,00	0,00
Valid.	Gotej.	2016	120,00	28,73	180,00	0,67	0,00	0,67	0,00	0,00
Valid.	Gotej.	2017	0,00	95,03	0,00	0,00	0,00	0,00	0,00	0,00
Valid.	Gotej.	2017	12,00	86,34	820,51	0,17	0,13	0,17	0,13	0,00
Valid.	Gotej.	2017	24,00	76,11	1417,25	0,10	0,05	0,10	0,05	0,00
Valid.	Gotej.	2017	36,00	57,86	1156,18	0,33	0,24	0,33	0,24	0,00
Valid.	Gotej.	2017	48,00	54,22	1603,73	0,43	0,22	0,43	0,22	0,00
Valid.	Gotej.	2017	60,00	49,62	1557,11	0,62	0,55	0,62	0,55	0,00
Valid.	Gotej.	2017	120,00	19,63	1243,20	0,48	0,41	0,44	0,37	0,00
Valid.	Gotej.	2018	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Valid.	Gotej.	2018	12,00	100,00	9249,40	0,89	0,45	0,82	0,41	0,00
Valid.	Gotej.	2018	24,00	55,84	9313,31	0,74	0,52	0,64	0,52	0,00
Valid.	Gotej.	2018	36,00	27,11	4259,97	0,78	0,54	0,61	0,50	0,00
Valid.	Gotej.	2018	48,00	4,97	4189,74	0,85	0,53	0,81	0,50	0,00
Valid.	Gotej.	2018	60,00	3,81	3215,38	1,00	1,00	0,86	0,86	0,00
Valid.	Gotej.	2018	120,00	1,65	126,77	1,00	1,00	0,86	0,86	0,00
Trein.	Micro	2016	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Trein.	Micro	2016	12,00	85,83	103,88	0,52	0,00	0,49	0,00	4,31
Trein.	Micro	2016	24,00	84,73	59,36	0,38	0,00	0,36	0,00	51,68
Trein.	Micro	2016	36,00	60,43	112,00	0,57	0,00	0,57	0,00	232,04
Trein.	Micro	2016	48,00	36,42	88,00	0,45	0,05	0,45	0,05	662,35
Trein.	Micro	2016	60,00	36,95	68,00	0,29	0,00	0,29	0,00	567,67
Trein.	Micro	2016	120,00	9,16	93,28	0,58	0,00	0,55	0,00	1439,36
Trein.	Micro	2017	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Trein.	Micro	2017	12,00	98,55	710,00	0,14	0,06	0,14	0,06	10,86
Trein.	Micro	2017	24,00	70,91	981,15	0,35	0,13	0,33	0,13	89,55
Trein.	Micro	2017	36,00	72,80	713,33	0,24	0,06	0,24	0,06	302,88
Trein.	Micro	2017	48,00	53,06	806,72	0,24	0,11	0,23	0,10	748,34
Trein.	Micro	2017	60,00	42,06	1005,33	0,51	0,40	0,51	0,40	2462,57
Trein.	Micro	2017	120,00	13,34	971,94	0,36	0,32	0,35	0,30	2762,13
Trein.	Micro	2018	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Trein.	Micro	2018	12,00	100,00	8176,62	0,95	0,18	0,85	0,17	382,88
Trein.	Micro	2018	24,00	93,83	8564,10	0,94	0,18	0,85	0,18	596,51
Trein.	Micro	2018	36,00	81,03	1933,33	0,87	0,36	0,87	0,36	740,86
Trein.	Micro	2018	48,00	67,85	1521,23	0,89	0,24	0,87	0,23	2078,87

Trein.	Micro	2018	60,00	27,33	1851,36	0,86	0,75	0,83	0,63	3525,79
Trein.	Micro	2018	120,00	3,31	251,28	0,51	0,51	0,51	0,51	2526,36
Teste	Micro	2016	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Teste	Micro	2016	12,00	83,61	98,00	0,49	0,00	0,52	0,00	0,00
Teste	Micro	2016	24,00	80,30	52,08	0,33	0,00	0,38	0,00	0,00
Teste	Micro	2016	36,00	65,87	118,72	0,61	0,05	0,61	0,05	0,00
Teste	Micro	2016	48,00	32,23	81,84	0,42	0,00	0,48	0,00	0,00
Teste	Micro	2016	60,00	54,15	72,08	0,31	0,00	0,31	0,00	0,00
Teste	Micro	2016	120,00	5,96	81,84	0,51	0,00	0,58	0,00	0,00
Teste	Micro	2017	0,00	97,78	0,00	0,00	0,00	0,00	0,00	0,00
Teste	Micro	2017	12,00	100,00	742,66	0,15	0,06	0,15	0,06	0,00
Teste	Micro	2017	24,00	68,70	938,00	0,33	0,13	0,35	0,13	0,00
Teste	Micro	2017	36,00	78,25	746,15	0,25	0,06	0,25	0,06	0,00
Teste	Micro	2017	48,00	48,86	771,24	0,23	0,10	0,24	0,11	0,00
Teste	Micro	2017	60,00	49,06	1051,58	0,53	0,42	0,53	0,42	0,00
Teste	Micro	2017	120,00	11,74	929,20	0,35	0,30	0,36	0,32	0,00
Teste	Micro	2018	0,00	97,78	0,00	0,00	0,00	0,00	0,00	0,00
Teste	Micro	2018	12,00	96,21	7236,30	0,84	0,16	0,85	0,18	0,00
Teste	Micro	2018	24,00	96,05	8821,03	0,96	0,18	0,86	0,18	0,00
Teste	Micro	2018	36,00	86,47	1991,33	0,90	0,37	0,90	0,37	0,00
Teste	Micro	2018	48,00	59,46	1346,29	0,79	0,21	0,89	0,24	0,00
Teste	Micro	2018	60,00	25,33	1797,44	0,83	0,73	0,86	0,65	0,00
Teste	Micro	2018	120,00	4,91	258,82	0,53	0,53	0,53	0,53	0,00
Valid.	Micro	2016	0,00	97,78	0,00	0,00	0,00	0,00	0,00	0,00
Valid.	Micro	2016	12,00	81,40	91,14	0,46	0,01	0,46	0,01	0,00
Valid.	Micro	2016	24,00	82,51	56,00	0,36	0,00	0,33	0,00	0,00
Valid.	Micro	2016	36,00	54,99	104,16	0,53	0,00	0,53	0,00	0,00
Valid.	Micro	2016	48,00	40,62	93,28	0,48	0,00	0,42	0,00	0,00
Valid.	Micro	2016	60,00	19,74	63,24	0,27	0,00	0,27	0,00	0,00
Valid.	Micro	2016	120,00	7,56	88,00	0,55	0,00	0,51	0,00	0,00
Valid.	Micro	2017	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Valid.	Micro	2017	12,00	96,33	660,97	0,13	0,05	0,13	0,05	0,00
Valid.	Micro	2017	24,00	66,48	873,22	0,31	0,12	0,31	0,12	0,00
Valid.	Micro	2017	36,00	67,36	664,07	0,22	0,05	0,22	0,05	0,00
Valid.	Micro	2017	48,00	44,67	717,98	0,21	0,10	0,21	0,10	0,00
Valid.	Micro	2017	60,00	35,06	935,91	0,47	0,37	0,47	0,37	0,00
Valid.	Micro	2017	120,00	10,14	865,03	0,32	0,28	0,32	0,28	0,00
Valid.	Micro	2018	0,00	100,00	0,00	0,00	0,00	0,00	0,00	0,00
Valid.	Micro	2018	12,00	98,42	7938,46	0,92	0,17	0,84	0,16	0,00
Valid.	Micro	2018	24,00	91,62	7806,61	0,85	0,16	0,85	0,16	0,00
Valid.	Micro	2018	36,00	75,59	1762,33	0,80	0,32	0,70	0,32	0,00
Valid.	Micro	2018	48,00	63,66	1476,92	0,87	0,23	0,69	0,21	0,00
Valid.	Micro	2018	60,00	23,33	1638,45	0,76	0,66	0,66	0,66	0,00
Valid.	Micro	2018	120,00	1,71	229,06	0,47	0,47	0,47	0,47	0,00

Trein. = treinamento; Valid. = validação; Sist. = sistemas; Per. = períodos; Micro = microaspersão; Got. = gotejamento; Dens. = densidade de plantas daninhas; PR= produtividade relativa; C4/C3 = relação entre espécies C4/C3; M/E= relação entre espécies monocotiledôneas e eudicotiledôneas; Mat. Fresca = matéria fresca de planta.

Apêndice III. Parâmetros dos modelos sigmoidais log-logístico, Weibull tipo 1 e Weibull tipo 2 para estimar o rendimento relativo do bulbo no sistema de gotejamento e microaspersão.

Parâmetros	Sistema	*Modelo Log-logístico		Modelo Weibull-1		Modelo Weibull-2	
		Estimativa	Std. Error	Estimativa	Std. Error	Estimativa	Std. Error
Slope	Gotejo	1,59	0,52	1,26	0,35	1,26	0,35
Limite mínimo	Gotejo	-0,05	24,43	10,35	17,19	10,35	17,19
Limite máximo	Gotejo	100,62	5,24	100,93	5,29	100,93	5,29
ED50	Gotejo	48,45	18,1	58,36	19,25	58,36	19,25
	R ²	0,64		0,63		0,64	
	MAE	17,09		18,1		19,02	
	RSME	23		24,56		22,81	
	AIC	671,98*		672,51		672,01	
Slope	Microaspersão	2,31	1,01	1,98	0,67	1,98	0,67
Limite mínimo	Microaspersão	-7,84	22,09	5,7	8,78	5,7	8,78
Limite máximo	Microaspersão	96,68	5,84	97,1	5,68	97,1	5,68
ED50	Microaspersão	55,32	11,91	59,53	7,56	59,53	7,56
	R ²	0,67		0,61		0,62	
	MAE	16,09		18,4		18,12	
	RSME	21,63		25,56		26,01	
	AIC	670,11*		673,53		673,98	

*Melhores modelos segundo teste akaike (AIC).

Apêndice IV. Informações gerais das redes neurais artificiais MLP considerando as diferentes variáveis de entrada pelo método não destrutivo.

		Informação das redes				
		Fatores	Cultura Período	Cultura Período	Cultura Período	Cultura Período
			Densidade	Densidade	Densidade	Densidade
Não destrutivo	Camada de entrada	Covariáveis	C3/C4 Monocotiledôneas /eudicotiledônneas	C3/C4	Monocotiledôneas /eudicotiledônneas	
		Número de unidades ^a	8	7	7	6
		Método de padronização	Normalização	Normalização	Normalização	Normalização
		Número de camadas ocultas	1	1	1	1
	Camada oculta	Número de neurônios ^a	1	4	5	7
		Função de ativação	Sigmoide	Sigmoide	Sigmoide	Sigmoide
			Perda aceitável (2,5%)	Perda aceitável (2,5%)	Perda aceitável (2,5%)	Perda aceitável (2,5%)
		Variáveis dependentes	Perda aceitável (5%)	Perda aceitável (5%)	Perda aceitável (5%)	Perda aceitável (5%)
	Camada de saída		Perda aceitável (10%)	Perda aceitável (10%)	Perda aceitável (10%)	Perda aceitável (10%)
		Número de unidades	6	6	6	6
	Função de ativação	Sigmoide	Sigmoide	Sigmoide	Sigmoide	
	Função de erro	Cross-entropy	Cross-entropy	Cross-entropy	Cross-entropy	

^aExcluindo o bias.

Apêndice V. Informações gerais das redes neurais artificiais MLP considerando as diferentes variáveis de entrada pelo método destrutivo.

		Informação das redes				
Fatores		Cultura Período	Cultura Período	Cultura Período	Cultura Período	
		Matéria fresca	Matéria fresca	Matéria fresca	Matéria fresca	
Destrutivo	Camada de entrada	Covariáveis C3/C4	C3/C4	Monocotiledôneas /eudicotiledôneas		
		Monocotiledôneas /eudicotiledôneas				
		Número de unidades ^a	8	7	7	6
		Método de padronização	Normalização	Normalização	Normalização	Normalização
		Número de camadas ocultas	1	1	1	1
	Camada oculta	Número de neurônios ^{1a}	4	3	4	3
		Função de ativação	Sigmoide	Sigmoide	Sigmoide	Sigmoide
			Perda aceitável (2,5%)	Perda aceitável (2,5%)	Perda aceitável (2,5%)	Perda aceitável (2,5%)
		Variáveis dependentes	Perda aceitável (5%)	Perda aceitável (5%)	Perda aceitável (5%)	Perda aceitável (5%)
	Camada de saída		Perda aceitável (10%)	Perda aceitável (10%)	Perda aceitável (10%)	Perda aceitável (10%)
		Número de unidades	6	6	6	6
		Função de ativação	Sigmoide	Sigmoide	Sigmoide	Sigmoide
	Função de erro	Cross-entropy	Cross-entropy	Cross-entropy	Cross-entropy	

^aExcluindo o bias.

Apêndice VI. Informações gerais das redes neurais artificiais MLP considerando as diferentes variáveis de entrada pelos métodos não destrutivo e destrutivo.

Informação das redes			
	Fatores	Cultura Período	
		Matéria fresca	
	Covariáveis	Densidade	
Não destrutivo e destrutivo	Camada de entrada		
		Número de unidades ^a	7
		Método de padronização	Normalização
		Número de camadas ocultas	1
	Camada oculta	Número de neurônios ¹ ^a	6
		Função de ativação	Sigmoide
			Perda aceitável (2,5%)
		Variáveis dependentes	Perda aceitável (5%)
	Camada de saída		Perda aceitável (10%)
		Número de unidades	6
	Função de ativação	Sigmoide	
	Função de erro	Cross-entropy	

^aExcluindo o bias.

Apêndice VII. Matriz de confusão para as redes neurais artificiais MLP nas etapas de treinamento, validação e teste para perdas aceitáveis de 2,5, 5 e 10%, considerando diferentes variáveis de entrada pelo método não destrutivo.

		Perda (2,5%)		Perda (5%)		Perda (10%)	
		Cultura, Período, Densidade, C3/C4, Monocotiledôneas/Eudicotiledôneas					
Etapa	Observado	Estimado		Estimado		Estimado	
		Controle	Sem Controle	Controle	Sem Controle	Controle	Sem Controle
Treinamento	Controle	76	2	69	4	62	3
	Sem Controle	2	11	5	13	2	24

Validação	Controle	16	0	16	0	15	0
	Sem Controle	0	2	0	2	0	3
Teste	Controle	34	1	31	2	29	0
	Sem Controle	0	12	0	14	1	17
Cultura, Período, Densidade, C3/C4							
Etapa	Observado	Estimado		Estimado		Estimado	
		Controle	Sem Controle	Controle	Sem Controle	Controle	Sem Controle
Treinamento	Controle	76	2	72	1	62	3
	Sem Controle	3	10	6	12	1	25
Validação	Controle	16	0	16	0	15	0
	Sem Controle	0	2	0	2	0	3
Teste	Controle	34	1	33	0	29	0
	Sem Controle	0	12	0	14	1	17
Cultura, Período, Densidade, Monocotiledôneas/Eudicotiledôneas							
Etapa	Observado	Estimado		Estimado		Estimado	
		Controle	Sem Controle	Controle	Sem Controle	Controle	Sem Controle
Treinamento	Controle	76	2	68	5	62	3
	Sem Controle	3	10	2	16	2	24
Validação	Controle	16	0	16	0	15	0
	Sem Controle	0	2	0	2	0	3
Teste	Controle	33	2	30	3	29	0
	Sem Controle	0	12	0	14	1	17
Cultura, Período, Densidade							
Etapa	Observado	Estimado		Estimado		Estimado	
		Controle	Sem Controle	Controle	Sem Controle	Controle	Sem Controle
Treinamento	Controle	76	2	68	5	63	2
	Sem Controle	3	10	2	16	3	23
Validação	Controle	16	0	16	0	15	0
	Sem Controle	0	2	0	2	0	3
Teste	Controle	33	2	30	3	29	0
	Sem Controle	0	12	0	14	1	17

Apêndice VIII. Matriz de confusão para as redes neurais artificiais MLP nas etapas de treinamento, validação e teste para perdas aceitáveis de 2,5, 5 e 10%, considerando diferentes variáveis de entrada pelo método destrutivo.

		Perda (2,5%)		Perda (5%)		Perda (10%)	
		Cultura, Período, Densidade, C3/C4, monocotiledôneas/eudicotiledôneas					
Etapa	Observado	Estimado		Estimado		Estimado	
		Controle	Sem Controle	Controle	Sem Controle	Controle	Sem Controle
Treinamento	Controle	78	0	68	5	62	3
	Sem Controle	3	10	2	16	1	25
Validação	Controle	16	0	16	0	15	0
	Sem Controle	1	1	0	2	0	3
Teste	Controle	34	1	30	3	29	0
	Sem Controle	0	12	0	14	1	17
		Cultura, Período, Densidade, C3/C4					
Etapa	Observado	Estimado		Estimado		Estimado	
		Controle	Sem Controle	Controle	Sem Controle	Controle	Sem Controle
Treinamento	Controle	76	2	71	2	62	3
	Sem Controle	3	10	5	13	1	25
Validação	Controle	16	0	16	0	15	0
	Sem Controle	0	2	0	2	0	3
Teste	Controle	34	1	30	3	29	0
	Sem Controle	0	12	0	14	1	17
		Cultura, Período, Densidade, Mono/dico					
Etapa	Observado	Estimado		Estimado		Estimado	
		Controle	Sem Controle	Controle	Sem Controle	Controle	Sem Controle
Treinamento	Controle	78	0	66	7	62	3
	Sem Controle	3	10	2	16	1	25
Validação	Controle	16	0	16	0	15	0
	Sem Controle	1	1	0	2	0	3
Teste	Controle	34	1	30	3	29	0
	Sem Controle	0	12	0	14	1	17
		Cultura, Período, Densidade					
Etapa	Observado	Estimado		Estimado		Estimado	
		Controle	Sem Controle	Controle	Sem Controle	Controle	Sem Controle
Treinamento	Controle	75	3	71	2	62	3
	Sem Controle	3	10	7	11	1	25
Validação	Controle	16	0	16	0	15	0
	Sem Controle	0	2	0	2	0	3
Teste	Controle	32	3	31	2	29	0
	Sem Controle	0	12	1	13	1	17

Apêndice IX. Matriz de confusão para as redes neurais artificiais MLP nas etapas de treinamento, validação e teste para perdas aceitáveis de 2,5, 5 e 10%, considerando diferentes variáveis de entrada pelo método não destrutivo e destrutivo.

		Perda (2,5%)		Perda (5%)		Perda (10%)	
		Cultura, Período, Densidade, C3/C4, Mono/dico					
Etapa	Observado	Estimado		Estimado		Estimado	
		Controle	Sem Controle	Controle	Sem Controle	Controle	Sem Controle
Treinamento	Controle	78	0	72	1	62	3
	Sem Controle	3	10	5	13	1	25
Validação	Controle	16	0	16	0	15	0
	Sem Controle	1	1	0	2	0	3
Teste	Controle	34	1	33	0	29	0
	Sem Controle	0	12	0	14	1	17