

Simulação do Progresso de doenças Foliares da Aveia por Redes Neurais Artificiais à Redução de Uso de Agrotóxicos

Cibele L. Peter ¹, Odenis Alessi², Juliana A. da Rosa ³, Natiane C. F. Basso⁴, Cristhian M. Babeski ⁵, Márcia S. Jung ⁶, Ivan R. Carvalho ⁷, José A. G. da Silva ⁸,
UNIJUI, Ijuí, RS

Resumo. Uma ferramenta que possui aplicabilidade em diversas áreas e representa uma possibilidade eficiente de simulação e otimização é a modelagem computacional. As redes neurais artificiais podem contribuir na simulação eficiente do progresso de doenças foliares da aveia e contribuir em estratégias à redução de uso de agrotóxicos na aveia direcionada a alimentação humana. O objetivo do estudo é simular por redes neurais artificiais o progresso de doenças foliares de aveia envolvendo o ciclo de desenvolvimento, variáveis meteorológicas e o número de aplicações de fungicida. O delineamento experimental foi de blocos casualizados em esquema fatorial 3 x 5 para 3 cultivares de aveia branca e 5 condições de aplicação de fungicida, respectivamente, com três repetições. As redes neurais artificiais mostraram alta capacidade de aprendizado na expressão da área foliar necrosada e simulam com eficiência o progresso das doenças foliares ao longo do ciclo da aveia, oportunizando direcionar manejos que reduzam o uso do agrotóxico fungicida na garantia de produtividade com segurança alimentar.

Palavras-chave. *Avena sativa* L., segurança alimentar, modelagem, inteligência artificial

1 Introdução

Uma ferramenta que tem auxiliado e qualificado o estudo em sistemas agrícolas é a modelagem computacional, oportunizando previsões e a resolução de problemas de alta complexidade [16, 22]. Nesta linha, a inteligência artificial, vem se mostrando como uma possibilidade eficiente na elaboração de modelos de simulação e otimização [7, 23]. As redes neurais artificiais (RNAs) representam um modelo baseado no funcionamento dos neurônios do cérebro humano. Possuem a capacidade de adquirir conhecimento através do reconhecimento de padrões e por meio de exemplos aprende e generaliza a informação gerando um modelo não-linear [10, 13]. O emprego de modelos via redes neurais artificiais, vem sendo muito acessado na agricultura, com o intuito de auxiliar na resolução de diversos problemas, sejam tecnológicos e gerenciais, principalmente na predição das produtividades a partir de diferentes cenários [6, 17].

Uma cultura de inverno de grande destaque no sul do Brasil é a aveia branca (*Avena sativa* L.) Um cereal de importante valor a alimentação em virtude de suas características nutracêuticas [1, 21]. Durante seu cultivo, a aveia está sujeita ao aparecimento de doenças foliares, principalmente

¹cibele.peter@sou.unijui.edu.br

²odenis.alessi@sou.unijui.edu.br

³juliana.aozane@sou.unijui.edu.br

⁴natiane.basso@sou.unijui.edu.br

⁵cristhian.babeski@sou.unijui.edu.br

⁶marcia.jung@sou.unijui.edu.br

⁷ivan.carvalho@unijui.edu.br

⁸jose.gonzales@unijui.edu.br

causada por fungos. Estas interferem no desenvolvimento da cultura, afetando a produtividade e a qualidade de grãos [15, 18]. Em virtude do acelerado progresso dos patógenos, as doenças foliares não são satisfatoriamente controladas pela resistência genética, sendo a utilização de fungicida a forma mais eficaz [3, 9]. No cultivo da aveia, a variação das condições meteorológicas e o manejo do fungicida são fatores que afetam o desenvolvimento das principais doenças foliares e o rendimento da cultura [5]. As redes neurais artificiais podem contribuir na simulação eficiente do progresso de doenças foliares da aveia e contribuir em estratégias à redução de uso de agrotóxicos na aveia direcionada a alimentação humana. O objetivo do estudo é simular por redes neurais artificiais o progresso de doenças foliares de aveia envolvendo o ciclo de desenvolvimento, variáveis meteorológicas e o número de aplicações de fungicida.

2 Materiais e Métodos

O estudo foi desenvolvido a campo, nos anos de 2015 a 2020, na área experimental do Instituto Regional de Desenvolvimento Rural (IRDeR) em Augusto Pestana, RS, Brasil. O delineamento experimental foi o de blocos casualizados, seguindo um esquema fatorial 3×5 , para 3 cultivares de aveia branca e 5 condições de aplicação de fungicida, respectivamente, com três repetições. As cultivares de aveia branca utilizadas foram: URS Altiva, URS Fapa Slava e URS Taura. As condições de uso do fungicida foram acumulativas a cada 15 dias, utilizando o princípio ativo tebuconazole. Portanto, as condições foram: sem aplicação de fungicida; uma aplicação aos 60 Dias Após Emergência (DAE); duas aplicações aos 60 e 75 DAE; três aplicações, aos 60, 75, 90 DAE e; quatro aplicações, aos 60, 75, 90 e 105 DAE. A unidade experimental (parcela) foi constituída de 5 linhas de 5 metros (m) de comprimento e espaçamento entre linhas de 0,2 m para compor uma área de 5 m^2 , portanto, um experimento a campo com 45 parcelas.

Em cada parcela foram coletadas três plantas de forma aleatória e de cada planta retirada as três folhas superiores. Este procedimento foi realizado aos 60, 75, 90, 105 e 120 dias após a emergência das plantas para análise da área foliar necrosada nas cultivares. Para esta determinação, as folhas foram digitalizadas, com as imagens analisadas pelo leitor de área foliar e o software WinDIAS (Copyright 2012, Delta-T Devices Limited) na determinação da necrose pela doença sobre a área foliar total. As variáveis meteorológicas foram obtidas a partir da estação automática instalada à 200 metros da implantação do experimento. Foram consideradas neste estudo, as variáveis selecionadas pela técnica Stepwise, indicando as mais promissoras para o processo de simulação. Portanto, foram indicadas as variáveis temperatura mínima do ar ($^{\circ}\text{C}$) e temperatura máxima ($^{\circ}\text{C}$) e umidade relativa do ar mínima (%) e umidade relativa máxima (%), obtidas em períodos quinzenais, anteriores a cada estágio de avaliação da área foliar necrosada realizada ao 60, 75, 90, 105 e 120 DAE. O modelo de seleção de variáveis também considerou a necessidade de inclusão na simulação, os dias do ciclo de desenvolvimento e as condições de aplicação de fungicida.

Foi implementada uma RNA do tipo feedforward, a Percéptrons de múltiplas camadas em que sua estrutura foi constituída por três camadas, sendo a camada de entrada, oculta e de saída. A camada de entrada possui a quantidade de neurônios igual a quantidade de variáveis selecionadas pela técnica stepwise. A camada de saída possui um neurônio, considerando a área foliar necrosada como dado de saída. Para a definição do número de neurônios da camada oculta, foi considerada a metodologia sugerida por Hecht-Nielsen (1989) [11] que determina que o número de neurônios da camada escondida será igual ao dobro do número de neurônios da camada de entrada mais um. A função de ativação utilizada foi a tangente hiperbólica. Para o treinamento da RNA foi utilizado o algoritmo de otimização Levenberg-Marquardt backpropagation através da ferramenta Neural Network Start do software Matlab. Para o treinamento da RNA, os dados amostrais foram normalizados utilizando a seguinte equação:

$$N = \frac{2(p - p_{min})}{p_{max} - p_{min}} - 1 \tag{1}$$

em que, N é o valor normalizado dimensional, p é o valor a ser normalizado, p_{min} é o menor valor da amostra e p_{max} é o maior valor amostra. Esta normalização dos dados é necessária devido ao fato de que a função de ativação definida se utiliza de valores no intervalo de -1 a 1. Após a normalização, os dados amostrais foram divididos aleatoriamente em 70% para o treinamento, 15% para teste e 15% para validação.

Após o treinamento, o modelo de RNA obtido foi validado a partir do cálculo do erro absoluto, dado pela diferença entre os dados simulados e os observados de área foliar necrosada em todas as condições de uso de fungicida e em todos os anos agrícolas nos momentos de 90 DAE e 105 DAE. Estes momentos foram utilizados considerando os resultados obtidos por Alessi (2022) [2] que identificou que 90 e 105 DAE são os mais adequados para a análise da variabilidade genética de resistência aos fungos causadores das principais doenças foliares da aveia.

3 Resultados e Discussões

A tabela 1, apresenta os dados coletados das variáveis meteorológicas para a composição do modelo de simulação via RNA.

Tabela 1: Variáveis meteorológicas em períodos quinzenais do ciclo de cultivo da aveia.

Ano	DAE	Variáveis Meteorológicas			
		T_{min}	T_{max}	U_{min}	U_{max}
2015	60	6,4	29	52	94
	75	12,7	30	41	74
	90	4,7	29	39	91
	105	2,6	30	43	90
	120	6,1	32	42	67
2016	60	2,4	28	41	90
	75	-0,3	31	33	90
	90	5,0	32	40	90
	105	2,3	32	22	89
	120	4,4	30	28	87
2017	60	0,2	32	40	84
	75	9,4	33	36	84
	90	12,5	34	35	92
	105	1,3	30	34	85
	120	5,1	34	32	89
2018	60	-0,2	27	38	88
	75	-1,5	27	26	73
	90	5,3	29	31	82
	105	9,7	32	34	86
	120	12,1	32	24	82
2019	60	-1,3	28	31	83
	75	3,8	33	31	79
	90	1,7	34	33	75
	105	4,4	33	20	79
	120	11,1	36	23	77
2020	60	-2,4	30	33	82
	75	3,6	33	42	85
	90	2,7	33	35	89
	105	6,9	38	24	76
	120	6,8	36	23	82

T_{min} : temperatura mínima (°C); T_{max} : temperatura máxima (°C); U_{min} : umidade mínima (%); U_{max} : umidade máxima (%); DAE: dias após emergência; 60, 75, 90, 105, 120: representam os dias entre a emergência da planta até o momento de avaliação da área foliar necrosada.

A Tabela 2, apresenta a progressão da área foliar necrosada avaliada a partir dos 60 dias após a emergência do ciclo de cultivo da aveia nas condições de uso de fungicida.

Tabela 2: Área foliar necrosada a partir dos 60 dias após a emergência do ciclo de cultivo da aveia nas condições de uso de fungicida.

Condição	Área foliar necrosada (%)				
Fungicida	60	75	90	105	120
2015					
SF	0	17	55	70	100
CF1	0	4	24	34	100
CF2	0	4	11	16	100
CF3	0	4	11	12	100
CF4	0	4	11	12	100
2016					
SF	0	1	8	17	42
CF1	0	0	3	6	19
CF2	0	0	2	5	12
CF3	0	0	2	4	4
CF4	0	0	2	4	4
2017					
SF	2	5	34	99	100
CF1	2	3	24	66	100
CF2	2	3	17	61	100
CF3	2	3	17	58	100
CF4	2	3	17	58	100
2018					
SF	1	3	54	100	100
CF1	1	2	13	99	100
CF2	1	2	6	83	100
CF3	1	2	6	80	100
CF4	1	2	6	80	100
2019					
SF	1	7	55	99	100
CF1	1	6	19	93	100
CF2	1	6	12	63	100
CF3	1	6	12	56	100
CF4	1	6	12	56	100
2020					
SF	1	4	21	95	100
CF1	1	1	14	94	100
CF2	1	1	12	91	100
CF3	1	1	12	89	100
CF4	1	1	12	89	100

60, 75, 90, 105, 120: representam os dias da emergência ao momento de avaliação da área foliar necrosada em cultivares de aveia; SF: sem uso de fungicida; CF1: uma aplicação de fungicida aos 60 DAE; CF2: duas aplicações de fungicida aos 60 e 75 DAE; CF3: três aplicações de fungicida aos 60, 75 e 90 DAE; CF4: quatro aplicações de fungicida aos 60, 75, 90 e 105 DAE.

Na tabela 2, observa-se que a área foliar necrosada diminui conforme o número de aplicações de fungicida aumenta. Entretanto, a partir da terceira aplicação não há uma redução expressiva da necrose foliar, inclusive não apresentando nenhuma alteração para a quarta aplicação. Para os anos de 2015, 2017, 2018, 2019 e 2020, é observado o comprometimento total da área foliar necrosada aos 120 dias após a emergência, independente da condição de uso de fungicida. Para o ano de 2016, esta condição não é observada devido o forte controle natural das doenças foliares.

A RNA obtida possui seis neurônios na camada de entrada, um neurônio na camada de saída e treze neurônios na camada escondida. Após o seu treinamento obteve-se os valores de 0,0120, 0,0108 e 0,0111 de erro quadrático médio para o treino, validação e teste, juntamente com os valores de 0,99 de coeficiente de determinação para o treino, validação e teste, indicando um bom ajuste do modelo aos dados. Estes resultados dão indícios da grande capacidade de reconhecimento da

rede implementada. Na Tabela 3, são apresentados os valores da área foliar necrosada observada e simulada por RNA, juntamente com os valores de erro absoluto médios obtidos para cada ano e momento de avaliação.

Tabela 3: Área foliar necrosada observada e simulada por RNA e valor de erro absoluto médio por ano agrícola.

Ano	AFN_O					AFN_{RNA}					$EA_{médio}$
	SF	CF1	CF2	CF3	CF4	SF	CF1	CF2	CF3	CF4	
90 DAE											
2015	55	24	11	11	11	52	29	13	11	10	2,2
2016	8	3	2	2	2	7	1	2	2	1	0,8
2017	34	24	17	17	17	43	25	18	18	17	2,4
2018	54	13	6	6	6	50	18	4	6	7	2,4
2019	55	19	12	12	12	62	27	13	12	11	3,4
2020	21	14	12	12	12	26	12	11	11	10	2,2
105 DAE											
2015	70	34	16	12	12	80	36	20	13	9	4,0
2016	17	6	5	4	4	16	7	5	3	4	0,6
2017	99	66	61	58	58	92	65	56	54	50	5,0
2018	100	99	83	80	80	103	95	87	82	79	2,8
2019	99	93	63	56	56	101	84	66	58	58	3,6
2020	95	94	91	89	89	96	93	90	88	87	1,2

AFN_O : área foliar necrosada observada (%); AFN_{RNA} : área foliar necrosada simulada por RNA (%); $EA_{médio}$: erro absoluto médio (%); RNA: rede neural artificial; SF: sem uso de fungicida; CF1: uma aplicação de fungicida aos 60 DAE; CF2: duas aplicações de fungicida aos 60 e 75 DAE; CF3: três aplicações de fungicida aos 60, 75 e 90 DAE; CF4: quatro aplicações de fungicida aos 60, 75, 90 e 105 DAE.

Na tabela 3, se pode usar como exemplo, os resultados do ano 2016, em que os valores observados de área foliar necrosada foram de 8, 3, 2, 2 e 2% aos 90 DAE nas condições de ausência, uma, duas, três e quatro aplicações de fungicida, respectivamente. Na simulação são encontrados os valores de 7, 1, 2, 2 e 1 % de área foliar necrosada nas mesmas condições de aplicação sequencial, totalizando um erro absoluto médio de apenas 0,8%. Cenário semelhante é verificado também para os demais anos na avaliação aos 90 DAE. Além disso, a simulação realizada nos diferentes cenários para a avaliação aos 105 DAE, também se traduz em reduzidos erros entre valores observados e simulados de área foliar necrosada, confirmando a qualidade da rede neural implementada.

Dentro deste contexto, o presente trabalho se articula a outros estudos que verificam a eficiência das redes neurais artificiais na simulação e previsão, especialmente na área de biosistemas. [14, 16]. Junior, Santos e Sáfiadi (2019) [12] realizaram eficiente classificação de imagens radiografadas de sementes de girassol através das redes neurais artificiais. Alves et al. (2019) [4] identificaram cultivares de soja com estabilidade e previsibilidade de comportamento de produtividade por redes neurais artificiais. Scremin et al. (2020) [20] e da Rosa et al. (2022) [19], desenvolveram um modelo eficiente via redes neurais artificiais para prever a produtividade de grãos de aveia pela biomassa ao longo do ciclo, a dose de nitrogênio e variáveis meteorológicas. Dornelles et al. (2023) [8] também relatam a importância de simulação das doenças de aveia, reconhecendo uma alternativa para simulação de cenários para validação de manejos mais sustentáveis. Nesta perspectiva, as redes neurais artificiais se apresentam como uma tecnologia bastante promissora para o desenvolvimento de aplicações na agricultura, permitindo a simulação e previsão de cenários com alta precisão.

4 Considerações Finais

Nesta pesquisa foi mostrado que redes neurais artificiais apresentam alta capacidade de aprendizado na expressão da área foliar necrosada envolvendo as variáveis temperatura do ar mínima e máxima, umidade relativa do ar mínima e máxima, juntamente a aplicação sequencial de fungicida e os dias do ciclo de desenvolvimento da aveia.

As redes neurais artificiais simulam com eficiência o progresso da área foliar necrosada ao longo do ciclo, oportunizando direcionar manejos que reduzam o uso do agrotóxico fungicida na garantia de produtividade com segurança alimentar.

Agradecimentos

Ao CNPq, à CAPES, à FAPERGS e à UNIJUÍ pelos recursos financeiros, estrutura física e materiais necessários para a realização da pesquisa.

Referências

- [1] O. Acar et al. “Comparison of short and long milling flows on yield and physicochemical properties of brans from biofortified and nonbiofortified hull-less oats”. Em: **Cereal Chemistry** 97.4 (2020), pp. 859–867. DOI: <https://doi.org/10.1002/cche.10308>.
- [2] O. Alessi. “Modelagem do progresso de doenças foliares e produtividade em cultivares de aveia à redução no uso de fungicida”. Tese de doutorado. UNIJUÍ, 2022.
- [3] O. Alessi et al. “Aplicação de Modelos de Regressão e de Adaptabilidade e Estabilidade na Identificação de Cultivares de Aveia Branca com Maior Resistência Genética a Doenças Foliares”. Em: **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics** 6.2 (2018).
- [4] G. F. Alves et al. “Stability of the hypocotyl length of soybean cultivars using neural networks and traditional methods”. Em: **Ciência Rural** 49 (2019). DOI: <https://doi.org/10.1590/0103-8478cr20180300>.
- [5] N. R. Bhardwaj, D. K. Banyal e A. K. Roy. “Prediction model for assessing powdery mildew disease in common Oat (*Avena sativa* L.)” Em: **Crop Protection** 146 (2021). DOI: <https://doi.org/10.1016/j.cropro.2021.105677>.
- [6] L. V.a da Conceição et al. “Predição de produtividade do mamoeiro (*Carica Papaya* L.) por Redes Neurais Artificiais”. Em: **Research, Society and Development** 10.12 (2021). DOI: <https://doi.org/10.33448/rsd-v10i12.20692>.
- [7] E. F. Dornelles et al. “Artificial intelligence in seeding density optimization and yield simulation for oat”. Em: **Revista Brasileira de Engenharia Agrícola e Ambiental** 22 (2018), pp. 183–188. DOI: <https://doi.org/10.1590/1807-1929/agriambi.v22n3p183-188>.
- [8] E. F. Dornelles et al. “Artificial Intelligence in the Simulation of Fungicide Management Scenarios for Satisfactory Yield and Food Safety in oat Crops”. Em: **Revista de Gestão Social e Ambiental-RGSA** 17.1 (2023).
- [9] E. F. Dornelles et al. “The efficiency of Brazilian oat cultivars in reducing fungicide use for greater environmental quality and food safety”. Em: **Australian Journal of Crop Science** 15.7 (2021), pp. 1058–1065. DOI: [10.21475/ajcs.21.15.07.p3175](https://doi.org/10.21475/ajcs.21.15.07.p3175).
- [10] L. Fleck et al. “Redes neurais artificiais: Princípios básicos”. Em: **Revista Eletrônica Científica Inovação e Tecnologia** 1.13 (2016), pp. 47–57.
- [11] R. Hecht-Nielsen. “Theory of the backpropagation neural network”. Em: **Neural networks for perception**. 1992, pp. 65–93. DOI: <https://doi.org/10.1016/B978-0-12-741252-8.50010-8>.
- [12] A. M. Magalhães Junior, P. R. Santos e T. Sáfadi. “Utilização de Redes Neurais Artificiais na classificação de danos em sementes de girassol”. Em: **Sigmae** 8.2 (2019), pp. 564–575.

- [13] A. T. W de Mamann et al. “Artificial intelligence simulating grain productivity during the wheat development considering biological and environmental indicators”. Em: **Journal of Agricultural Studies** 7.3 (2019), p. 197.
- [14] V. P. Martins et al. “Modelagem técnica-comercial de peças automotivas com rede neural artificial”. Em: **Brazilian Journal of Business** 3.1 (2021), pp. 413–427.
- [15] J. M. Nerbass Junior et al. “Controle de doenças foliares na aveia branca e danos na produção em resposta à dose e ao número de aplicações de fungicida”. Em: **Revista de Ciências Agroveterinárias** 7.2 (2014), pp. 127–134.
- [16] A. B. Neto et al. “Interface gráfica via redes neurais artificiais: um estudo de caso na estimativa da produção de capim marandu em sistemas integrados”. Em: **Revista Brasileira de Engenharia de Biosistemas** 15 (2021).
- [17] P. A. Paul e G. P. Munkvold. “Regression and artificial neural network modeling for the prediction of gray leaf spot of maize”. Em: **Phytopathology** 95.4 (2005), pp. 388–396. DOI: <https://doi.org/10.1094/PHYTO-95-0388>.
- [18] L. M. Pereira et al. “A utilização de fungicida no cultivo de aveia: uma revisão integrativa da literatura”. Em: **Research, Society and Development** 9.8 (2020).
- [19] J. A. da Rosa et al. “Redes Neurais Artificiais na Previsibilidade da Produtividade de Grãos da Aveia pelo uso do Nitrogênio e Condições do Ciclo de Desenvolvimento da Cultura”. Em: **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics** 9.1 (2022). DOI: <https://doi.org/10.5540/03.2022.009.01.0296>.
- [20] O. B. Scremin et al. “Artificial intelligence by artificial neural networks to simulate oat (*Avena sativa* L.) grain yield through the growing cycle”. Em: **Journal of Agricultural Studies** 4 (2020), pp. 610–628. DOI: <https://doi.org/10.5296/jas.v8i4.17711>.
- [21] A. H. Scremin et al. “Aptitude of Brazilian oat cultivars for reduced fungicide use while maintaining satisfactory productivity”. Em: **Genetics and molecular research** 22 (2023). DOI: <http://dx.doi.org/10.4238/gmr19034>.
- [22] F. C. Soares et al. “Predição da produtividade da cultura do milho utilizando rede neural artificial”. Em: **Ciência Rural** 45 (2015), pp. 1987–1993. DOI: <https://doi.org/10.1590/0103-8478cr20141524>.
- [23] J. Wolfrann et al. “Simulação da irrigação por aspersão utilizando redes neurais artificiais treinadas com e sem termo momentum”. Em: **Revista de Computação Aplicada ao Agronegócio** 1.2 (2019), pp. 44–55.