

# Redes Neurais Artificiais na Previsibilidade da Produtividade de Grãos da Aveia pelo uso do Nitrogênio e Condições do Ciclo de Desenvolvimento da Cultura

Juliana Aozane da Rosa,<sup>1</sup> Rubia Diana Mantai,<sup>2</sup> Cibele Luisa Peter,<sup>3</sup> Natiane Carolina Ferrari Basso,<sup>4</sup> Júlia Sarturi Jung,<sup>5</sup> Willyan Júnior Adorian Bandeira,<sup>6</sup> Ivan Ricardo Carvalho,<sup>7</sup> José Antonio Gonzalez da Silva<sup>8</sup>  
UNIJUÍ, IJUÍ, RS

**Resumo.** O uso da inteligência artificial (IA), com os modelos de simulação e otimização por redes neurais artificiais (RNAs), tem sido aplicado com êxito em diversas pesquisas ligadas a processos de biosistemas. A cultura da aveia branca é fortemente dependente do nitrogênio para garantir produtividade de grãos. O objetivo do trabalho é desenvolver um sistema adaptativo de inteligência artificial por redes neurais para a previsibilidade de produtividade de grãos de aveia pela produtividade de biomassa e elementos meteorológicos ao longo do ciclo do desenvolvimento, considerando o manejo de uso do nitrogênio em sistemas de sucessão soja/aveia e milho/aveia. O delineamento experimental foi de blocos casualizados com 4 repetições, seguindo um esquema fatorial 4 x 2, com quatro doses de nitrogênio ( $0 \text{ kg ha}^{-1}$ ,  $30 \text{ kg ha}^{-1}$ ,  $60 \text{ kg ha}^{-1}$  e  $120 \text{ kg ha}^{-1}$ ) e duas cultivares (Barbarasul e Brisasul), no sistema de cultivo soja/aveia e milho/aveia nos anos agrícolas de 2011 a 2016. No desenvolvimento dos modelos de simulação via RNA foi utilizado o toolbox neural network, do software Matlab. As redes neurais artificiais se apresentam como uma ferramenta de grande contribuição ao desenvolvimento de modelos de previsibilidade voltados a produtividade de grãos, sendo capazes que estimar com alta precisão as produtividades e a qualidade nutricional relacionadas com um grande número de variáveis.

**Palavras-chave.** *Avena sativa L.*, modelagem matemática, simulação, nitrogênio

## 1 Introdução

A formulação de modelos matemáticos voltados à previsibilidade e otimização da produtividade e manejos de culturas agrícolas é difícil e limitada, devido à complexidade e a não linearidade dos dados relacionados a eles. O uso da inteligência artificial (IA), tem sido aplicada com êxito em diversas pesquisas ligadas a processos de biosistemas, com destaque para os modelos de simulação e otimização por redes neurais artificiais (RNAs) [7, 15]. As RNAs são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes, adquirem conhecimento através da experiência e o tornam disponíveis para uso. Assim, uma RNA é capaz de reconhecer padrões, ou seja, possui a capacidade de aprender por meio de exemplos e de generalizar

---

<sup>1</sup>juaozane@gmail.com

<sup>2</sup>rdmantai@yahoo.com.br

<sup>3</sup>cibele.peter@sou.unijui.edu.br

<sup>4</sup>natiane.basso@sou.unijui.edu.br

<sup>5</sup>julia.jung@sou.unijui.edu.br

<sup>6</sup>willyan.bandeira@sou.unijui.edu.br

<sup>7</sup>ivan.carvalho@unijui.edu.br

<sup>8</sup>jose.gonzales@unijui.edu.br

as informações aprendidas, gerando modelos não lineares, o que torna a sua aplicação fundamental e eficiente para simulação da produtividade de diversas culturas [12, 13].

A aveia branca é um cereal que apresenta elevada produtividade de grãos, com destaque entre os demais cereais em virtude de sua qualidade nutricional com fibras e proteínas [10, 14]. A sua produtividade é dependente das condições meteorológicas e do fornecimento de adubação através do nitrogênio, sendo o nutriente essencial para o desenvolvimento da planta, com efeitos na elaboração da biomassa e produtividade de grãos [4, 9]. A eficiência do nitrogênio é influenciada pelas condições meteorológicas, uma vez que se for aplicado com temperatura do ar elevada, com baixa umidade do solo ou elevada precipitação pluviométrica, comumente ocasionam perdas do nutriente, gerando sérios prejuízos econômicos e poluição ambiental [10, 11]. Neste sentido, análises que consideram o uso da adubação nitrogenada junto aos elementos meteorológicos diretamente ligados aos processos biológicos são fundamentais para a adoção de tecnologias que promovam uma agricultura mais sustentável [4, 14].

A capacidade de ajuste de padrões de informação em condições reais via redes neurais artificiais pode representar uma configuração que permite simular a produtividade e grãos de aveia ao longo do ciclo de desenvolvimento. Portanto, o objetivo do trabalho é desenvolver um sistema adaptativo de inteligência artificial por redes neurais para a previsibilidade de produtividade de grãos de aveia pela produtividade de biomassa e elementos meteorológicos ao longo do ciclo do desenvolvimento, considerando o manejo de uso do nitrogênio em sistemas de sucessão soja/aveia e milho/aveia.

## 2 Materiais e Métodos

O experimento foi conduzido a campo nos anos agrícolas de 2011 a 2016, em Augusto Pestana, RS, Brasil. O delineamento experimental foi o de blocos casualizados com quatro repetições, seguindo um esquema fatorial  $4 \times 2$ , para doses de nitrogênio (0, 30, 60 e 120 kg  $ha^{-1}$ ) e cultivares de aveia (Barbarasul e Brisasul) no sistema de sucessão soja/aveia e milho/aveia. A adubação nitrogenada ocorreu em uma única aplicação em  $V_3/V_4$  estágio fenológico de terceira e quarta folha expandida. Em cada sistema de cultivo, dois experimentos foram conduzidos, um para quantificar a taxa de produção de biomassa total acumulada a cada 30 dias até o ponto de maturidade fisiológica e, o outro, para a colheita no final do ciclo visando exclusivamente a estimativa da produtividade de grãos. No experimento da produtividade de biomassa total ao longo do desenvolvimento das plantas, a colheita do material vegetal foi realizada rente ao solo, a partir da coleta de um metro linear das três linhas centrais de cada parcela, no período de 30, 60, 90 e 120 dias após a emergência, totalizando quatro cortes. Após, as amostras com a biomassa verde foram direcionadas a estufa de ar forçado a temperatura de 65 °C até atingir peso constante, para a estimativa da matéria seca total, convertida em kg  $ha^{-1}$ . A produtividade de grãos foi obtida pelo corte das três linhas centrais de cada parcela, quando as plantas atingiram a maturidade fisiológica, com umidade de grãos próxima a 22%. As amostras coletadas foram trilhadas em colheitadeira estacionária e direcionadas ao laboratório para correção da umidade de grãos para 13% e estimativa da produtividade de grãos em kg  $ha^{-1}$ . Os dados meteorológicos de temperatura do ar e precipitação pluviométrica para análise dos anos agrícolas foram obtidos pela estação total automática instalada a 200 metros do experimento

Foram analisadas como possíveis variáveis de entrada a produtividade de biomassa, dia do ciclo, temperatura mínima, média e máxima, soma térmica, precipitação pluviométrica, dose de nitrogênio e categoria de ano agrícola, e como variáveis de saída a produtividade de grãos. A metodologia de Stepwise foi utilizada para selecionar as variáveis independentes que influenciam na variável dependente, sendo estas usadas como variáveis de entrada RNA. No desenvolvimento dos modelos de simulação via RNA foi utilizado o toolbox neural network, disponibilizado no software Matlab. A arquitetura escolhida foi a Perceptron de múltiplas camadas, sendo composta

por uma camada de entrada com sete neurônios, uma camada escondida com quinze neurônios e uma camada de saída com um neurônio. Para a função de ativação dos neurônios, foi definido a função tan-sigmóide (tansig), e o treinamento da rede foi realizado pelo algoritmo backpropagation com o método LevenbergMarquardt.

A rede de múltiplas camadas consiste em um modelo sem realimentação formado por camadas de neurônios. Cada neurônio possui uma função de ativação não-linear continuamente diferenciável. A Figura 1 ilustra uma rede feedforward de camadas múltiplas formada por uma camada de entrada composta de  $n$  sinais, duas camadas neurais escondidas constituídas respectivamente de  $n_1$  e  $n_2$  neurônios e, finalmente, uma camada neural de saída composta de  $m$  neurônios representando os respectivos valores de saída da aplicação [6].

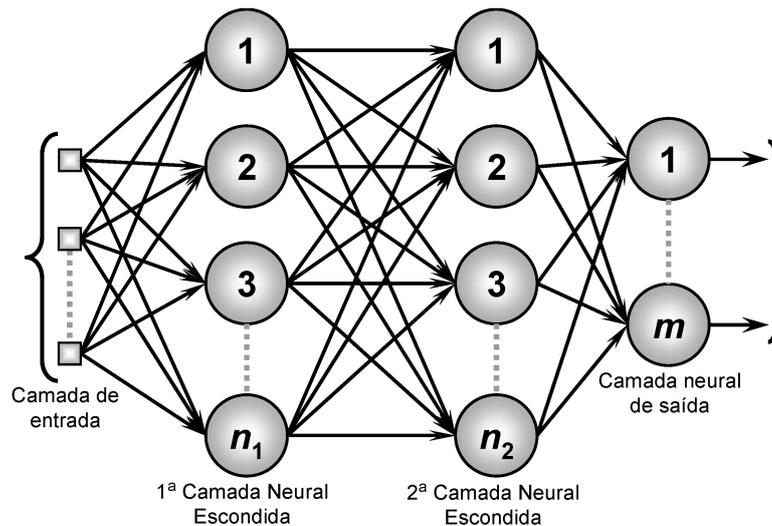


Figura 1: Exemplo de rede de camadas múltiplas.[6]

O algoritmo de aprendizado aplicado no decorrer do processo de treinamento das redes Perceptron multicamadas (PMC) é denominado backpropagation ou algoritmo de retropropagação do erro. O algoritmo mais popular das redes neurais artificiais é o de retropropagação do erro (error back-propagation), cuja fundamentação é corrigir os erros conforme a regra de aprendizagem. A maioria dos métodos de aprendizado para redes neurais artificiais utiliza variações deste algoritmo [5]. Este algoritmo propõe uma forma de definir o erro dos nodos das camadas intermediárias, possibilitando o ajuste de seus pesos. Os ajustes dos pesos são realizados utilizando-se o método do gradiente. Os dados amostrais da RNA foram padronizados pelo processo de normalização dos dados, através da equação,

$$p_n = \frac{2(p_o - p_{min})}{p_{max} - p_{min}} - 1 \tag{1}$$

sendo,  $p_n$  valor normalizado;  $p_o$  o valor observado da amostra;  $p_{min}$  o menor valor observado da amostra;  $p_{max}$  é o maior valor observado da amostra. Esta normalização dos dados se fez necessário devido ao fato que a função de ativação definida para o neurônio na camada de saída fornece valores nesse intervalo. Os dados amostrais (entrada e saída) foram divididos aleatoriamente em 70% para o treinamento, 15% para testes e 15% para validação.

Para simulação das variáveis de interesse pela RNA, foram utilizados no modelo os valores médios da produtividade de biomassa a cada 30 dias do ciclo e os valores médios dos dados me-

teorológicos ocorridos por categoria de ano agrícola para cada dose de nitrogênio e sistema de sucessão. A verificação da eficiência no modelo RNA deu-se através do desvio padrão dos dados observados e através do erro absoluto entre o valor observado em campo e o valor simulado pelo modelo RNA.

### 3 Resultados e Discussão

A Tabela 1 apresenta os valores médios de temperatura, soma térmica e precipitação pluviométrica a cada 30 dias do ciclo de desenvolvimento da aveia por categoria de ano agrícola. Destaca-se que anos favoráveis à produtividade de grãos de aveia mostram, em geral, as menores médias de temperatura e soma térmica, seguidos pelo maiores acumulados de precipitação pluviométrica até o momento de enchimento de grãos. Estes eventos favorecem a manutenção de afilhos férteis e a qualidade da produtividade dos grãos. Anos desfavoráveis ao cultivo são marcados pelas mais elevadas somas térmica durante todo o ciclo de desenvolvimento da cultura, aliado a elevada precipitação pluviométrica durante a fase que se aproxima da maturação fisiológica dos grãos. As elevadas temperaturas podem ter afetado a eficiência do nitrogênio dado pela volatilização da amônia, assim como o grande volume de chuvas ter contribuído para a perda de qualidade do grão e atraso na colheita com maior exposição do produto no ambiente. Os anos classificados como intermediários ao cultivo apresentaram temperaturas amenas até o início da alongação, a partir daí com temperaturas elevadas, em contrapartida aos menores acumulados de chuva.

Tabela 1: Valores médios da temperatura, soma térmica e precipitação pluviométrica do ciclo de cultivo da aveia por categoria de ano agrícola.

Dia do ciclo	Ano	Temperatura Média (°C)			$\sum ST$ (graus $dia^{-1}$ )	$\sum PP$ (mm)
		$\bar{T}_{min}$	$\bar{T}_{med}$	$\bar{T}_{max}$		
30	2011+2013 (AF)	9,0	13,9	18,8	296	225
	2012+2014 (AD)	11,6	16,6	21,6	378	203
	2015+2016 (AI)	9,4	15,5	21,5	343	148
60	2011+2013 (AF)	7,9	14,2	20,5	602	357
	2012+2014 (AD)	9,3	15,8	22,2	731	309
	2015+2016 (AI)	9,8	15,6	21,4	691	287
90	2011+2013 (AF)	8,6	15,3	21,9	939	464
	2012+2014 (AD)	11,4	17,3	23,1	1127	455
	2015+2016 (AI)	11,9	17,9	24,0	1108	416
120	2011+2013 (AF)	11,5	18,4	25,2	1489	639
	2012+2014 (AD)	13,9	18,7	23,3	1673	772
	2015+2016 (AI)	13,1	18,6	24,1	1632	639

AF= ano favorável; AD= ano desfavorável; AI= ano intermediário;  $\bar{T}_{min}$  = temperatura média mínima;  $\bar{T}_{med}$  = temperatura média;  $\bar{T}_{max}$  = temperatura média máxima;  $\sum ST$  = soma térmica;  $\sum PP$  = precipitação pluviométrica.

Para uma análise generalizada da produtividade e qualidade da aveia, a Tabela 2 apresenta os valores médios da produtividade biológica acumulada a cada 30 dias do ciclo e a produtividade de grãos da aveia, informações apresentadas por dose de nitrogênio e categoria de ano agrícola em distintos sistemas de sucessão. A partir dos 30 dias após a emergência o aumento da dose de nitrogênio tende incrementar a produtividade biológica independente da categoria de ano e sistema de sucessão. Em geral, a produtividade de grãos é beneficiada pelo fornecimento do nutriente, porém tende a atingir uma estabilidade a partir da dose 60 kg  $ha^{-1}$  de nitrogênio. Em anos favoráveis à produtividade de grãos, não acompanham a maior produtividade biológica. A categoria de ano desfavorável no sistema soja/aveia, é marcada pela reduzida produtividade de grãos e

biomassa. Em ano intermediário à produtividade de grãos, destaca-se a elevada produtividade biológica.

Tabela 2: Valores médios da produtividade biológica, produtividade de grãos por categoria de ano e doses de adubação nitrogenada.

Categoria de ano	Dose N (kg ha <sup>-1</sup> )	Biomassa (dias do ciclo)				PG (kg ha <sup>-1</sup> )
		30	60	90	120	
Sistema Soja/Aveia						
2011+2013 (AF)	0	517	1348	4529	9816	3013
	30	515	1446	6205	10731	3708
	60	571	1510	6168	11579	4149
	120	557	1596	6394	12241	3966
2012+2014 (AD)	0	284	1395	6205	6268	1695
	30	305	1908	6443	6747	2247
	60	319	1912	6762	6937	2589
	120	345	2310	8711	9357	2588
2015+2016 (AI)	0	209	1401	6595	9291	2604
	30	226	2108	7854	11293	3320
	60	251	2477	8661	12085	3855
	120	280	2826	10405	13969	3794
Sistema Milho/Aveia						
2011+2013 (AF)	0	463	629	1955	5957	2028
	30	479	1114	3016	7304	3050
	60	489	2155	4223	8731	3620
	120	496	3392	6369	9673	4084
2012+2014 (AD)	0	168	915	3160	4564	1167
	30	194	1208	5319	6187	1762
	60	207	1244	5880	6944	2163
	120	219	1231	6938	7998	2406
2015+2016 (AI)	0	191	631	3182	7144	1688
	30	226	1493	6245	9654	2575
	60	222	2132	6785	11061	3269
	120	238	2458	9677	13603	3495

AF= ano favorável; AD= ano desfavorável; AI= ano intermediário; = produtividade média de grãos.

Com intuito de qualificar a simulação das variáveis de produtividade da aveia pela inteligência artificial e diminuir o esforço computacional, foram selecionadas as variáveis à programação da rede neural, determinadas pela técnica Stepwise. As variáveis indicadas ao modelo foram a categoria de ano agrícola, a dose de nitrogênio (kg ha<sup>-1</sup>), o dia do ciclo, a produtividade de biomassa (kg ha<sup>-1</sup>), a temperatura máxima (°C), a soma térmica (°C) e a precipitação pluviométrica (mm).

A partir dos dados reais das variáveis explicativas selecionadas para determinação das variáveis respostas, a Tabela 3 apresenta o resultado de implementação da rede neural através do número de iterações e valores de erro do quadrado médio e correlações entre os resultados reais e simulados dos valores selecionados para treinamento e validação. Destaca-se que a arquitetura da rede neural treinada foi composta de 6 neurônios de entrada, 13 neurônios na camada escondida e 1 neurônio de saída, independente do sistema de cultivo. A arquitetura escolhida se mostra ajustada para simulação das variáveis produtividade de grãos, mostrando fortes correlações na fase de treinamento e validação do modelo, inclusive, com baixo erro médio relativo.

O aumento do uso das redes neurais está diretamente relacionado com a sua alta versatilidade, pois existem aplicações para as mais diversas áreas, e que tem se apresentado como uma

Tabela 3: Valores adimensionais de erro quadrático médio, para dados de treinamento, erro relativo médio para dados de validação, e correção entre os resultados obtidos e observados na arquitetura treinada (7 NE – 15 NCE – 1 NS)

Variáveis	IT	EQM (treinamento)	$r_{xy}$ (treinamento)	ERM (validação)	$r_{xy}$ (validação)
Sistema Soja/Aveia					
PG	12	0,004114	0,96	0,004348	0,96
Sistema Milho/Aveia					
PG	12	0,002911	0,98	0,003455	0,96

NE= número de neurônios de entrada; NCE= número de neurônios da camada escondida; NS= número de neurônios de saída; IT= número de iterações; EQM= erro quadrado médio; ERM= erro médio relativo; rxy = correlação entre os resultados; PG= produtividade de grãos (kg ha<sup>-1</sup>).

tecnologia bastante promissora para o desenvolvimento de aplicações agrícolas [2, 8]. Em trigo, foi desenvolvido um modelo via rede neural para estimar a produtividade, comparando com modelos de regressão linear simples e, obtendo melhor resultado pela rede neural [3]. Em aveia as redes neurais foram utilizadas para simulação da produtividade de grãos em diferentes cultivares, considerando como variável de entrada a densidade de semeadura [7]. Em soja foi utilizado um modelo via rede neural para realizar previsões de safras agrícolas, em que o modelo proposto atendeu as expectativas, com erros mínimos [1].

## 4 Conclusões

O uso de variáveis que consideram o manejo de adubação nitrogenada, as condições meteorológicas de temperatura e precipitação pluviométrica, junto a produtividade biológica nos estádios de desenvolvimento da aveia, se mostram apropriadas na geração de um sistema adaptativo à previsibilidade da produtividade e de grãos. As redes neurais artificiais se apresentam como uma ferramenta de grande contribuição ao desenvolvimento de modelos de previsibilidade voltados a produtividade de grãos, sendo capazes que estimar com alta precisão as produtividades e a qualidade nutricional relacionadas com um grande número de variáveis.

## Referências

- [1] E. R. Abraham et al. “Estimativa da produção da soja brasileira utilizando redes neurais artificiais”. Em: **Agrarian** 12.44 (), pp. 261–271. DOI: <https://doi.org/10.30612/agrarian.v12i44.9209>.
- [2] N. Abrishami, A. R. Sepaskhah e M. H. Shahrokhnia. “Estimating wheat and maize daily evapotranspiration using artificial neural network”. Em: **Theoretical and Applied Climatology** 135.3 (2019), pp. 945–958. DOI: <https://doi.org/10.1007/s00704-018-2418-4>.
- [3] R. Alvarez e H. S. Steinbach. “Modeling apparent nitrogen mineralization under field conditions using regressions and artificial neural networks”. Em: **Agronomy journal** 103.4 (2011), pp. 1159–1168. DOI: <https://doi.org/10.2134/agronj2010.0254>.
- [4] E. G. Arenhardt et al. “The nitrogen supply in wheat cultivation dependent on weather conditions and succession system in southern Brazil”. Em: **African Journal of Agricultural Research** 10.48 (2015), pp. 4322–4330. DOI: <https://doi.org/10.5897/AJAR2015.10038>.
- [5] A. de P. Braga. **Redes neurais artificiais: teoria e aplicações**. 1a. ed. Rio de Janeiro: LTC, 2000.

- [6] I. N. Da Silva, D. H. Spatti e R. A. Flauzino. “Redes neurais artificiais para engenharia e ciências aplicadas-curso prático”. Em: **São Paulo: Artliber** (2010).
- [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] L. Fleck et al. “Redes neurais artificiais: Princípios básicos”. Em: **Revista Eletrônica Científica Inovação e Tecnologia** 1.13 (2016), pp. 47–57.
- [9] A. R. Kraisig et al. “Time of nitrogen supply in yield, industrial and chemical quality of oat grains”. Em: **Revista Brasileira de Engenharia Agrícola e Ambiental** 24 (2020), pp. 700–706. DOI: <https://doi.org/10.1590/1807-1929/agriambi.v24n10p700-706>.
- [10] R. D. Mantai et al. “Contribution of nitrogen on industrial quality of oat grain components and the dynamics of relations with yield”. Em: **Australian Journal of Crop Science** 15 (2021). DOI: [10.21475/ajcs.21.15.03.p2592](https://doi.org/10.21475/ajcs.21.15.03.p2592).
- [11] A. Marolli et al. “A simulação da biomassa de aveia por elementos climáticos, nitrogênio e regulador de crescimento”. Em: **Arquivo Brasileiro de Medicina Veterinária e Zootecnia** 70 (2018), pp. 535–544. DOI: <https://doi.org/10.1590/1678-4162-9504>.
- [12] M. A. R. Schmidt e G. R. Barbosa. “Uso de redes neurais artificiais na ponderação inicial da técnica AHP em análises de vulnerabilidade de bacias hidrográficas”. Em: **Boletim de Ciências Geodésicas** 22 (2016), pp. 511–525. DOI: <https://doi.org/10.1590/S1982-21702016000300029>.
- [13] 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.v8i4.17711e>.
- [14] J. A. G. da Silva et al. “Nitrogen efficiency in oats on grain yield with stability”. Em: **Revista Brasileira de Engenharia Agrícola e Ambiental** 20 (2016), pp. 1095–1100. DOI: <https://doi.org/10.1590/1807-1929/agriambi.v20n12p1095-1100>.
- [15] 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>.