

5.01.99 - Agronomia

INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DA PRODUTIVIDADE DE GRÃOS DE TRIGO PELA DOSE DE FORNECIMENTO DE NITROGÊNIO COM INDICADORES BIOLÓGICOS E AMBIENTAIS

Cláudia Vanessa Argenta^{1*}, Natiane Carolina Ferrari Basso², Felipe Uhde Porazzi³, Jean Vitor Tisott⁴, Crísthian Milbradt Babeski⁵, José Antonio Gonzalez da Silva⁶

1. Estudante de Agronomia da Universidade Regional do Noroeste do Estado do Rio Grande do Sul
2. Estudante da Faculdade de Agronomia da UNIJUÍ
3. Estudante da Faculdade de Agronomia da UNIJUÍ
4. Estudante da Faculdade de Agronomia da UNIJUÍ
5. Estudante da Faculdade de Agronomia da UNIJUÍ
6. Professor/orientador da Faculdade de Agronomia da UNIJUÍ

Resumo

O objetivo do estudo é adequar uma arquitetura de rede neural capaz de prever a produtividade de grãos de trigo ao longo do ciclo de seu desenvolvimento envolvendo o nitrogênio e os indicadores biológicos e ambientais. O experimento foi conduzido nos sistemas soja/trigo e milho/trigo, com delineamento de blocos casualizados com oito repetições (produtividade de grãos e biomassa) para quatro doses de N-fertilizante (fonte ureia) nos níveis 0, 30, 60 e 120 kg ha⁻¹. Para este estudo, foram utilizadas redes neurais artificiais (RNAs) denominadas Percéptrons de Múltiplas Camadas (MLP), proposta por Frank Rosenblatt (1958). A partir dos resultados obtidos neste estudo, verificou-se que através das RNAs foi possível chegar a uma simulação da produtividade de grãos de trigo muito próxima a obtida, envolvendo a dose de nitrogênio em cobertura e a não linearidade da temperatura máxima do ar e precipitação pluviométrica com informações de biomassa obtidas durante o ciclo de cultivo.

Palavras-chave: Rede neural; Otimização; Sustentabilidade.

Apoio financeiro: UNIJUÍ

Trabalho selecionado para a JNIC: UNIJUÍ

Introdução

O trigo (*Triticum aestivum* L.) é um dos principais cereais produzidos mundialmente e mostra necessidade de desenvolvimento de pesquisas que intensifiquem uma produção mais sustentável (FAO, 2018). Para garantir produtividade satisfatória, o nitrogênio é o elemento mais essencial a esta cultura (PRANDO, et al., 2013). Porém o manejo desse nutriente é complexo, por possuir altos índices de perdas, por lixiviação e volatilização, aumentando os custos de produção e gerando poluição ambiental (CAMPONOGARA et al.; 2016; MAMANN et al., 2019). Destaca-se, que os elementos meteorológicos precipitação pluviométrica e temperatura do ar estão diretamente ligados ao aproveitamento ou perdas do nitrogênio pela planta, como também os mais relacionados à expressão da produtividade do trigo (SANTI et al., 2018; MAMANN et al., 2019). Nesta perspectiva, o emprego de algoritmos computacionais via redes neurais artificiais, pode representar uma ferramenta promissora para agregar informações de manejo do nitrogênio com variáveis biológicas e ambientais na simulação da produtividade buscando manejos mais sustentáveis. O objetivo do estudo é adequar uma arquitetura de rede neural capaz de prever a produtividade de grãos de trigo ao longo do ciclo de desenvolvimento, envolvendo o nitrogênio e a não linearidade da temperatura máxima do ar e precipitação pluviométrica, considerando os principais sistemas de sucessão no cultivo de trigo e otimizando sua produção.

Metodologia

O trabalho foi desenvolvido a campo nos anos agrícolas de 2017 e 2018 no município de Augusto Pestana, RS, Brasil. Na semeadura, foi utilizada semeadora-adubadora na composição da parcela com 5 linhas de 5 m de comprimento e espaçamento entre linhas de 0,20 m, a densidade populacional utilizada foi de 400 sementes viáveis por metro quadrado. O experimento foi conduzido nos sistemas soja/trigo e milho/trigo, sendo que em cada condição de cultivo, dois experimentos foram conduzidos, um para quantificar produtividade de biomassa pelos cortes realizados a cada 30 dias até maturidade fisiológica e, o outro, à estimativa da produtividade de grãos, obtida pelo corte de três linhas centrais de cada parcela. Portanto, nos quatro experimentos, o delineamento foi o de blocos casualizados com oito repetições para quatro doses de N-fertilizante (fonte ureia) nos níveis 0, 30, 60 e 120 kg ha⁻¹, com o uso da cultivar de trigo de reconhecido uso de cultivo. Para este estudo, foram utilizadas redes neurais artificiais denominadas Percéptrons de Múltiplas Camadas (MLP), proposta por Frank Rosenblatt (1958). Estas redes foram treinadas com o algoritmo backpropagation em conjunto com o algoritmo de otimização Levenberg-Merquadt (LM), com capacidade de tratar dados não linearmente separáveis, apresentando uma camada de entrada, uma camada intermediária (pelo menos) e uma camada de saída (GONÇALVES et al., 2010). As variáveis de entrada utilizadas pela rede neural artificial

foram: doses de N-fertilizante, estádios de desenvolvimento (30, 60, 90 e 120 dias), produtividade de biomassa (em cada estágio de desenvolvimento), precipitação pluviométrica acumulada e temperatura máxima média do ar em cada estágio mencionado. A variável de saída foi à produtividade de grãos, considerando os principais sistemas de sucessão.

Resultados e Discussão

Na Tabela 1, de modo geral, independente do sistema de cultivo e doses de N-fertilizante, o ano de 2017 mostrou valores absolutos de produtividade de biomassa superior a 2018, até o estágio de 60 dias após a emergência. Embora a média da temperatura máxima tenha sido menor em 2018, o que deveria favorecer a cultura, a menor produtividade obtida pode ser explicada pelo grande volume de chuvas, ocasionando extensos períodos de menor luminosidade, limitando a eficiência de fotossíntese à elaboração de biomassa.

Tabela 1. Dados meteorológicos e produtividade de biomassa nos estádios da cultura nas condições de uso do nitrogênio.

Estádio (dias)	Ano	Σ_{Prec}	\bar{X}_{TMax}	Soja/trigo		Milho/trigo	
				PB (kg ha ⁻¹)		PB (kg ha ⁻¹)	
0 kg ha ⁻¹ de N							
30	2017	112	21,3	368		236	
	2018	308	18,1	170		130	
60	2017	307	23	1962		858	
	2018	437	20,3	1090		557	
90	2017	548	23,1	6546		3685	
	2018	570	20,4	5532		2855	
120	2017	813	24,7	6765		4651	
	2018	736	21	6340		5402	
30 kg ha ⁻¹ de N							
30	2017	112	21,3	335		242	
	2018	308	18,1	202		111	
60	2017	307	23	2880		1036	
	2018	437	20,3	1654		665	
90	2017	548	23,1	7785		4979	
	2018	570	20,4	7838		4019	
120	2017	813	24,7	7818		5666	
	2018	736	21	8071		7535	
60 kg ha ⁻¹ de N							
30	2017	112	21,3	328		221	
	2018	308	18,1	188		116	
60	2017	307	23	3043		1854	
	2018	437	20,3	1813		1234	
90	2017	548	23,1	7742		5809	
	2018	570	20,4	7445		6380	
120	2017	813	24,7	8474		5859	
	2018	736	21	8844		8685	
120 kg ha ⁻¹ de N							
30	2017	112	21,3	359		244	
	2018	308	18,1	201		110	
60	2017	307	23	3630		1967	
	2018	437	20,3	1804		1521	
90	2017	548	23,1	8964		7321	
	2018	570	20,4	9117		7750	
120	2017	813	24,7	10860		7520	
	2018	736	21	10533		11033	

N - Nitrogênio; PB - Produtividade de biomassa; Σ_{Prec} - Somatório da precipitação; \bar{X}_{TMax} - Média da temperatura máxima; \bar{X} - Média

Destaca-se que estas informações (Tabela 1) que envolvem a complexidade de variáveis biológicas e ambientais e de efeitos lineares e não lineares durante o cultivo serão utilizadas no treinamento da rede neural artificial na proposta de simulação da produtividade de grãos de trigo durante o ciclo de desenvolvimento

Desta forma, a Figura 1 apresenta os coeficientes de determinação próximos a um, nos processos de treinamento, teste e validação, o que permite confirmar a confiabilidade da rede neural artificial em gerar o algoritmo que dimensiona o comportamento dos dados reais obtidos e generaliza o aprendizado para a simulação da produtividade de grãos de trigo, considerando a inclusão de variáveis biológicas e ambientais no processo computacional.

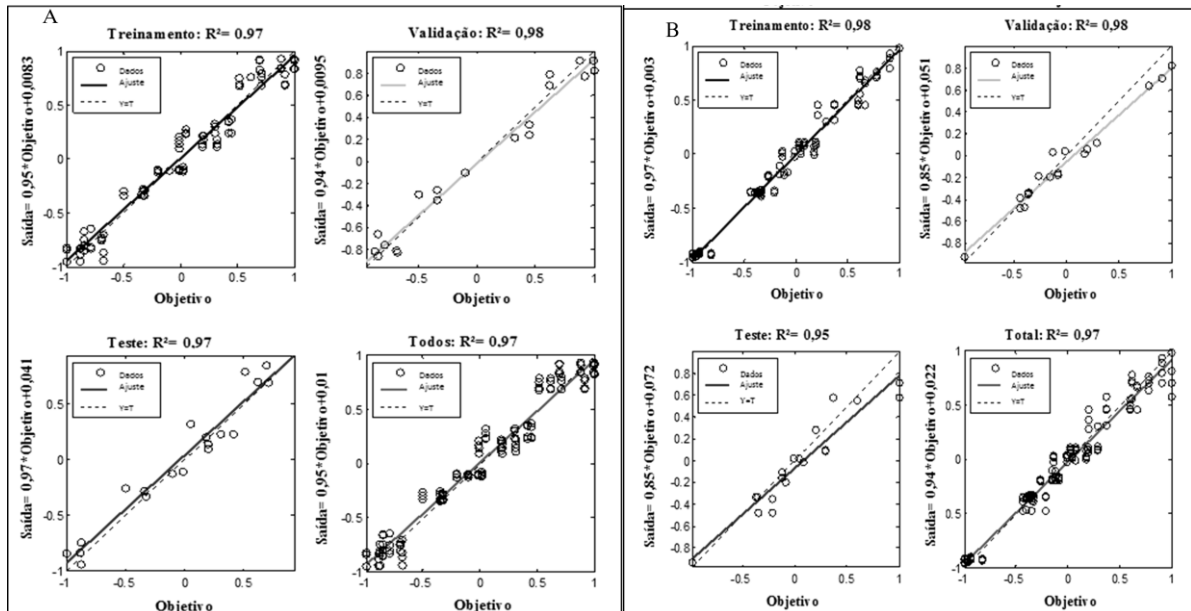


Figura 1. Coeficientes de determinação do treinamento, teste, validação e todos (treinamento, teste, validação) das redes neurais artificiais. (A) Arquitetura 5-8-1 para o sistema soja/trigo; (B) Arquitetura 5-7-1 para o sistema milho/trigo

Na Tabela 2, está apresentada a comparação das médias da produtividade de grãos de trigo observadas e simuladas via rede neural para cada sistema de cultivo. Destaca-se que a produtividade de grãos observada foi incrementada pelo aumento das doses de nitrogênio, evidenciando um comportamento de tendência quadrática. Este mesmo comportamento também foi reconhecido pela rede neural artificial desde a simulação no estágio de trinta dias após a emergência, independente do sistema de sucessão. Como exemplo, no sistema soja/trigo, destaca-se a condição 120 kg ha⁻¹ de nitrogênio, com média de produtividade de grãos de trigo de 2728 kg ha⁻¹, sendo que a simulação via rede neural mostrou no estágio de trinta dias após a emergência uma média produtividade de 2801 kg ha⁻¹. Estes resultados se diferem (EA) em apenas 73 kg ha⁻¹ de grãos, o que confirma a alta capacidade preditiva da rede neural. Além disso, destaca-se, que o maior erro absoluto, ficou abaixo de 200 kg ha⁻¹ de grãos de trigo, fato que reporta a validação das redes neurais artificiais na previsibilidade da produtividade de grãos de trigo.

Tabela 2. RNA na simulação da produtividade de grãos de trigo em distintos estádios da cultura nas condições de uso do nitrogênio

N (kg ha ⁻¹)	Estádio (Dias)	Sistema soja/trigo			Sistema milho/trigo		
		PGs	\bar{X}_{PGo}	EA	PGs	\bar{X}_{PGo}	EA
(2017+2018)							
0	30	1421		40	959		79
	60	1391	1381	10	860	880	20
	90	1434		53	957		77
	120	1372		9	916		36
<hr/>							
30	30	2358		191	1439		29
	60	2245	2167	78	1450	1468	18
	90	2263		96	1450		18
	120	2283		116	1381		87
<hr/>							
60	30	2724		182	1740		24
	60	2559	2542	17	1765	1716	49
	90	2550		8	1791		75
	120	2604		62	1626		90
<hr/>							
120	30	2801		73	2126		178
	60	2766	2728	38	2102	1948	154
	90	2780		52	1890		58
	120	2843		115	1769		179
<hr/>							

N- Nitrogênio; PGs - Produtividade de grãos simulada (kg ha⁻¹); \bar{X}_{PGo} - Média da produtividade de grãos observada (kg ha⁻¹); EA - Erro absoluto (kg ha⁻¹); \bar{X} - Média (kg ha⁻¹); Médias seguidas pelas mesmas letras compara doses de nitrogênio constituindo grupo estatisticamente homogêneo pelo modelo Skott-Knott a 0.05 de probabilidade de erro.

Já na Figura 2 independente do sistema de cultivo, evidencia comportamento quadrático para a produtividade de grãos de trigo observada a campo e simulada via RNA. Frente ao comportamento quadrático é possível determinar que no sistema de cultivo soja/trigo, a máxima eficiência técnica é de 100 kg ha⁻¹ e 93 kg ha⁻¹ de nitrogênio, considerando a equação de regressão para a produtividade de grãos observada e simulada pelas redes neurais artificiais, respectivamente. No sistema milho/trigo, a máxima eficiência técnica, é de 111 kg ha⁻¹ e 113 kg ha⁻¹ de nitrogênio para a produtividade observada e simulada, respectivamente. Estes

resultados se mostram similares na comparação entre o observado e o simulado em cada sistema de cultivo. Frente a isso, é possível validar o uso de redes neurais na previsibilidade da produtividade de grãos em qualquer estágio de desenvolvimento do trigo, em diferentes condições de uso do nitrogênio nos distintos sistemas de sucessão, considerando a não linearidade da temperatura máxima do ar e precipitação pluviométrica com informações de biomassa obtidas durante o ciclo de cultivo.




Figura 2. Comportamento da produtividade de grãos observada e simulada por redes RNA. PGo - Produtividade de grãos observado (kg ha⁻¹); PGs - Produtividade de grãos simulado (kg ha⁻¹); R² - Coeficiente de determinação; (A) – Sistema soja/trigo; (B) Sistema milho/trigo.

As RNAs permitem a modelagem de sistemas complexos nos quais apresentam propriedades como capacidade de aproximação de funções, suporte a múltiplas variáveis lineares e não-lineares com interações desconhecidas e boa capacidade de generalização. Estes modelos são capazes de processar rapidamente uma grande quantidade de dados e de reconhecer padrões com base em sua autoaprendizagem (TEODORO et al., 2015).

Conclusões

A rede neural artificial do tipo percéptron de múltiplas camadas, com o algoritmo de aprendizagem backpropagation com a arquitetura de rede 5-8-1 e 5-7-1 nos sistemas soja/trigo e milho/trigo, respectivamente, é capaz de simular a produtividade de grãos de trigo envolvendo a dose de nitrogênio em cobertura e a não linearidade da temperatura máxima do ar e precipitação pluviométrica com informações de biomassa obtidas durante o ciclo de cultivo.

Referências bibliográficas

CAMPONOGARA, A.S.; OLIVEIRA, G. A.; GEORGIN, J; ROSA, A. L. D. Avaliação dos Componentes de Rendimento do Trigo quando Submetido a Diferentes Fontes de Nitrogênio. **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental**. Santa Maria, v. 20, n. 1, jan.-abr. 2016, p. 524-532.

FAO. World cereal production forecast raised slightly from July but still down sharply from last year; stocks lowered further. 2018. Available at: <Available at: <http://www.fao.org/worldfoodsituation/csdb/en> >. Acesso em julho de 2020.

GONÇALVES, R. M.; COELHO, L. S.; KRUEGER, C. P.; HECK, B. Modelagem preditiva de linha de costa utilizando redes neurais artificiais. **Bol. Ciênc. Geod., sec. Artigos, Curitiba**, v. 16, no 3, p.420-444, jul-set, 2010.

MAMANN, A. T.; SILVA, J. A. G.; BINELLO, M. O.; SCREMIN, O. B.; KRAISIG, A. R.; CARVALHO, I.R.; PEREIRA, L. M.; BERLEZI, J. D.; BERLEZI, J. D.; ARGENTA, C. V. Artificial intelligence simulating grain productivity during the wheat development considering biological and environmental indicators. **Journal of agricultural studies**, 2019.

PRANDO, A. M.; ZUCARELI, C.; FRONZA, V.; OLIVEIRA, F. A.; JÚNIOR, A. O. Características produtivas do trigo em função de fontes e doses de nitrogênio. **Pesquisa Agropecuária Tropical**, v.43, p.34-41, 2013.

SANTI, A.; VICARI, M. B.; PANDOLFO, C.; DALMAGO, G. A.; Massignam, A. M.; Pasinato, A. Impacto de cenários futuros de clima no zoneamento agroclimático do trigo na região Sul do Brasil. **Revista da Sociedade Brasileira de Agrometeorologia**, v.25, p.303-311, 2018.

TEODORO, P. E., BARROSO, L. M. A., NASCIMENTO, M., TORRES, F. E., SAGRILLO, E., dos Santos, A., & Ribeiro, L. P. (2015). Redes neurais artificiais para identificar genótipos de feijão-caupisemiprostrado com alta adaptabilidade e estabilidade fenotípicas. **Pesquisa Agropecuária Brasileira**, 50(11), 1054-1060.