

**Modalidade do trabalho:** Relatório técnico-científico  
**Evento:** XXI Jornada de Pesquisa

## **REDE NEURAL ARTIFICIAL NA SIMULAÇÃO DA PRODUTIVIDADE DE GRÃOS DE TRIGO NO SUL DO BRASIL PELAS CONDIÇÕES DE DESENVOLVIMENTO DA ESPÉCIE COM ELEMENTOS METEOROLÓGICOS<sup>1</sup>**

**Ângela Teresinha Woschinski De Mamann<sup>2</sup>, Anderson Marolli<sup>3</sup>, Osmar Brunelau Scremin<sup>4</sup>, Ana Paula Brezolin<sup>5</sup>, Douglas César Reginatto<sup>6</sup>, José Antonio Gonzalez Da Silva<sup>7</sup>.**

<sup>1</sup> Parte dos resultados de pesquisa desenvolvida pelo DEAg/UNIJUÍ

<sup>2</sup> Docente IFRS e Mestre em Modelagem Matemática pela Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ, angela.mamann@ibiruba.ifrs.edu.br

<sup>3</sup> Doutorando em Modelagem Matemática do Departamento de Ciências Exatas e Engenharias da Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ, marollia@yahoo.com.br

<sup>4</sup> Doutorando em Modelagem Matemática do Departamento de Ciências Exatas e Engenharias da Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ, osmarscremin@hotmail.com

<sup>5</sup> Doutoranda em Modelagem Matemática do Departamento de Ciências Exatas e Engenharias da Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ, anabrezolin@hotmail.com

<sup>6</sup> Mestrando em Modelagem Matemática do Departamento de Ciências Exatas e Engenharias da Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ, reginattodouglas@gmail.com

<sup>7</sup> Professor do Departamento de Estudos Agrários, Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ, jagsfaem@yahoo.com.br

### Introdução

O trigo, de acordo com a FAO (Food and Agriculture Organization), é a segunda cultura de grãos mais produzida no mundo (Miloca et al., 2007, MAPA, 2015). Contudo, por ser uma cultura de inverno, sua produção concentra-se, principalmente na região do Sul do Brasil que apresenta clima ameno e temperaturas baixas (Pereira et al., 2015). Além disso, para garantir alta produtividade e qualidade dos grãos de trigo, é essencial o uso do nitrogênio (Teixeira Filho et al., 2011; Prando, 2013), porém o fornecimento de nitrogênio depende, dentre outros fatores, da umidade, aeração e temperatura que interagem entre si nos sistemas de cultivo (Rocha et al., 2008; Silva et al., 2015). Dessa forma, o nutriente evidencia grande complexidade de ação sobre o ambiente (Teixeira Filho et al., 2011). Neste contexto, as redes neurais artificiais que são modelos computacionais que aprendem pela experiência (Wasserman, 1989; Bucene & Rodrigues, 2004), podem generalizar informações e dar respostas coerentes para dados não conhecidos (Soares, 2015), assim, dados coletados em campo, tais como condições e medidas topográficas, parâmetros edáficos, valores de fitomassa, estágio de desenvolvimento de culturas agrícolas etc., podem ser utilizados como fonte de definição e de contexto de determinado alvo, importante na tarefa de memorização de característica temática (Venturieri & Santos, 1998; Depiné et al., 2013).

O objetivo do trabalho é buscar a previsibilidade da produtividade de grãos do trigo com base no modelo de Redes Neurais Artificiais (RNAs), utilizando-se do Perceptron Múltiplas Camadas com o algoritmo de treinamento backpropagation. Desta forma, obter o número ótimo de neurônios na camada escondida que permitam simular a produtividade de grãos de trigo na combinação do uso do nitrogênio com a produtividade biológica nos estádios de desenvolvimento com o somatório da precipitação pluviométrica e temperatura média máxima.

**Modalidade do trabalho:** Relatório técnico-científico

**Evento:** XXI Jornada de Pesquisa

### Metodologia

O trabalho foi desenvolvido a campo, nos anos agrícolas de 2014 e 2015, no município de Augusto Pestana, RS. O delineamento experimental foi o de blocos casualizados com quatro repetições, seguindo um esquema unifatorial com 4 doses de N-fertilizante (fonte ureia) nos níveis 0, 30, 60 e 120 kg/ha (aplicado em cobertura no estágio de terceira folha expandida), no sistema de cultivo soja/trigo empregando a cultivar de trigo TEC 10. A colheita para a estimativa da produtividade de grãos ocorreu de forma manual pelo corte das três linhas centrais de cada parcela. Após, as plantas foram trilhadas com colheitadeira estacionária e direcionadas ao laboratório para correção da umidade de grãos a 13% e pesagem para estimativa da produtividade. Os dados climáticos foram obtidos através da estação meteorológica do IRDer, situada próxima a área experimental.

Para o desenvolvimento das Redes Neurais Artificiais (RNAs) multicamadas na previsibilidade de grãos de trigo foi utilizado o Neural Network Toolbox do software Matlab. As redes foram treinadas com o algoritmo backpropagation e a função de treinamento Levenberg-Merquadt (trainlm). Para a ativação da camada de entrada, camada escondida e camada de saída foi usada a função tan-sigmoide. Para a arquitetura da RNA, os dados amostrais foram divididos aleatoriamente em 70% para o treinamento (banco de dados com 128 amostras), 15% para teste e 15% para validação. Foram treinadas 10 redes com 3 camadas (camada de entrada, camada escondida e camada de saída). A camada de entrada foi composta de 5 neurônios, a camada escondida de 5 a 10 neurônios, fazendo-se incremento de 1 em 1 e a camada de saída com 1 neurônio. As variáveis de entrada utilizadas pela rede neural artificial formam: doses de N-fertilizante (0, 30, 60 e 120 kg/ha), estádios de desenvolvimento do trigo (30, 60, 90 e 120 dias), produtividade biológica a cada estágio, precipitação pluviométrica acumulada a cada estágio e temperatura média máxima acumulada a cada estágio e a variável de saída foi à produtividade de grãos de trigo.

### Resultados e discussão

Na tabela 1, estão apresentados os valores de erro quadrático médio, erro relativo médio e variância, observados durante o processo de testes e validação das arquiteturas testadas para o sistema soja/trigo. Para a escolha da arquitetura no sistema soja/trigo, observou-se que a rede 5-6-1 apresentava menor erro quadrático médio. Entretanto, nota-se que a variância no processo de validação está acima das arquiteturas 5-7-1, 5-8-1 e 5-10-1, significando que o erro no processo de treinamento diminui, porém, na validação esta redução não ocorre. Seguindo a interpretação de Soares et al. (2015) que estudou a predição de produtividade de milho por rede neural artificial, a arquitetura escolhida foi aquela que apresenta relação entre o número amostras de treinamento e o número de conexões escondidas superior a dois, conforme indicado por Masters (1993) de menor erro relativo médio de validação. Portanto, para o sistema soja/trigo, a arquitetura escolhida foi 5-8-1 (Tabela 1).

Tabela 1. Valores adimensionais de erro quadrático médio, para dados de treinamento, erro relativo médio e variância para dados de validação, nas arquiteturas treinadas.

**Modalidade do trabalho:** Relatório técnico-científico  
**Evento:** XXI Jornada de Pesquisa

Arquitetura NE-NCE-NS	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
5-5-1	1.65E-2	3.12E-2	2.06E-2
5-6-1	5.51E-3	7.76E-2	1.82E-2
5-7-1	9.16E-3	2.41E-2	1.70E-2
5-8-1	1.52E-2	1.50E-2	1.80E-2
5-9-1	8.81E-3	2.44E-2	1.96E-2
5-10-1	9.57E-3	2.50E-2	1.75E-2

NE= número de variáveis de entrada; NCE= número de neurônios da camada escondida; NS= número de neurônios da camada de saída

Na definição da arquitetura da rede, na figura 1, estão apresentados os coeficientes de determinação do treinamento (70% dos dados), validação (15% dos dados), teste (15% dos dados) da rede e total (100% dos dados). Portanto, permitindo confirmar a confiabilidade da rede em gerar o algoritmo que dimensiona o comportamento dos dados reais obtidos com valores de coeficiente de determinação próximos a 1 (Figura 1).

**Modalidade do trabalho:** Relatório técnico-científico  
**Evento:** XXI Jornada de Pesquisa

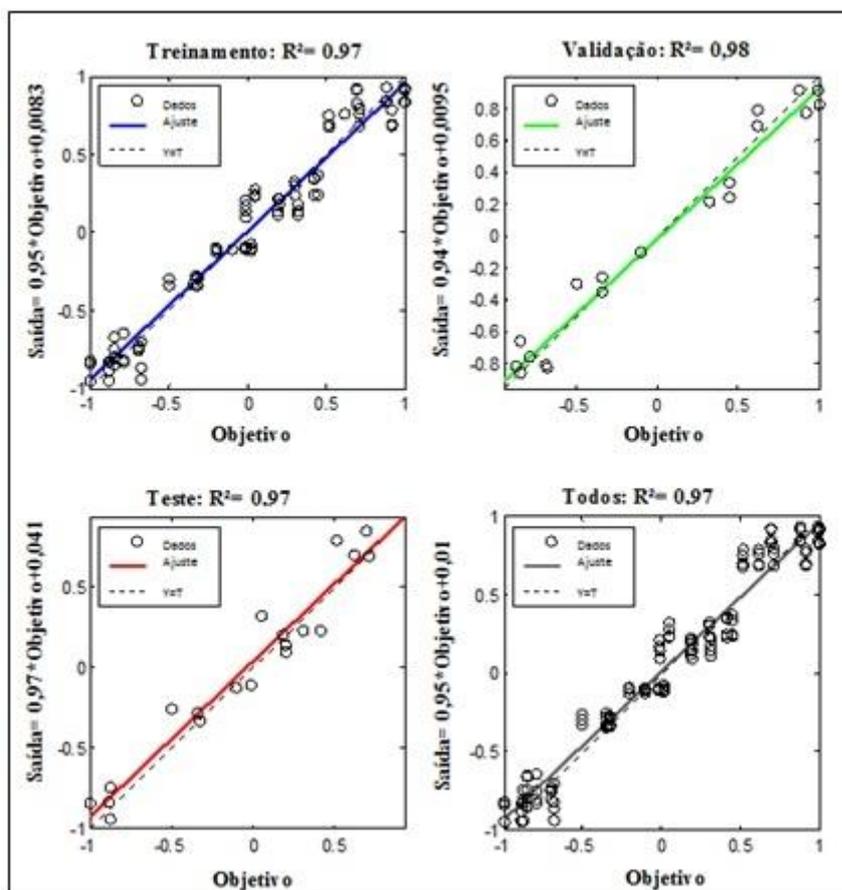


Figura 1. Coeficientes de determinação do treinamento, teste, validação e todos (treinamento, teste, validação) das redes neurais artificiais de arquitetura 5-8-1

As redes neurais artificiais (RNA) são indicadas para tratar de sistemas complexos (Vieira et al.; 2009; Jana et al., 2012; Jana & Mohanty, 2012; Soares et al., 2015). Estas redes são modelos computacionais inspirados no sistema nervoso biológico, ou seja, aprendem pela experiência, generalizam exemplos através de outros e abstraem características (Wasserman, 1989; Bucene & Rodrigues, 2004). As RNA e a lógica fuzzy são técnicas de processamento de dados utilizadas para elaborar modelos de predição em sistemas complexos e estimar parâmetros desejados, sendo amplamente explorado na agricultura (Huang et al., 2010; Silva et al., 2014). Existem as redes neurais de camadas simples, constituídas por um grupo de neurônios arranjados em apenas uma camada, e as redes multicamadas, formadas pela combinação de várias redes de camada simples (Venturieri & Santos, 1998). Para verificar o desempenho da rede neural artificial de arquitetura 5-8-1 do sistema soja/trigo (Tabela 2), os valores médios estimados pelas redes foram comparados com os valores da produtividade de grãos obtidos no efeito cumulativo dos anos (2014+2015).

Tabela 2. Comparação dos valores de produtividade de grãos de trigo obtidos na validação da RNA de arquitetura 5-8-1 e no experimento a campo no sistema soja/trigo.

**Modalidade do trabalho: Relatório técnico-científico**  
**Evento: XXI Jornada de Pesquisa**

N (kg ha <sup>-1</sup> )	Estádio (dias)	Ano	PB (kg ha <sup>-1</sup> )	$\Sigma_{Prec}$ (mm)	$\bar{X}_{TMax}$ (°C)	(2014+2015)		
						PG <sub>Simulado</sub>	IC	
0	30	2015	170	308	18.1	1421	L <sub>i</sub> =1286 $\bar{X}$ = 1381 L <sub>s</sub> = 1463	
		2014	368	112	21.3			
	60	2015	1090	437	20.3	1391		
		2014	1962	307	23			
	90	2015	5532	570	20.4	1434		
		2014	6546	548	23.1			
	120	2015	6340	736	21	1372		
		2014	6765	813	24.7			
	30	30	2015	202	308	18.1		2358
			2014	335	112	21.3		
60		2015	1654	437	20.3	2245	L <sub>i</sub> =1815 $\bar{X}$ = 2167 L <sub>s</sub> = 2470	
		2014	2880	307	23			
90		2015	7838	570	20.4	2263		
		2014	7785	548	23.1			
120		2015	8071	736	21	2283		
		2014	7818	813	24.7			
60		30	2015	188	308	18.1		2724
			2014	328	112	21.3		
	60	2015	1813	437	20.3	2559		L <sub>i</sub> =2116 $\bar{X}$ = 2507 L <sub>s</sub> = 2843
		2014	3043	307	23			
	90	2015	7445	570	20.4	2550		
		2014	7742	548	23.1			
	120	2015	8844	736	21	2604		
		2014	8474	813	24.7			
	120	30	2015	201	308	18.1	2801	
			2014	359	112	21.3		
60		2015	1804	437	20.3	2766	L <sub>i</sub> =2360 $\bar{X}$ = 2728 L <sub>s</sub> = 3045	
		2014	3630	307	23			
90		2015	9117	570	20.4	2780		
		2014	8964	548	23.1			
120		2015	10533	736	21	2843		
		2014	10860	813	24.7			

N= nitrogênio; PB= produtividade biológica;  $\Sigma_{Prec}$ = somatório da precipitação;  $\bar{X}_{TMax}$ = média da temperatura máxima; IC= intervalo de confiança (kg ha<sup>-1</sup>); PG= produtividade de grãos (kg ha<sup>-1</sup>); L<sub>i</sub>= limite inferior;  $\bar{X}$ = média; L<sub>s</sub>= limite superior

**Modalidade do trabalho:** Relatório técnico-científico

**Evento:** XXI Jornada de Pesquisa

As simulações tinham como valores de entrada da rede neural artificial, as doses de N-fertilizante, os estádios de desenvolvimento do trigo, a média da produtividade biológica dos estádios, a média da precipitação acumulada dos estádios e a média da temperatura máxima acumulada dos estádios. Na tabela 2, a simulação mostrou alta capacidade preditiva para a produtividade de grãos de trigo, sendo que os valores simulados pela rede neural artificial ficaram dentro do intervalo de confiança, do efeito cumulativo dos anos de 2014 e 2015.

Estes resultados mostram que o uso da rede possibilita a previsibilidade da produtividade de grãos em qualquer estádio de desenvolvimento do trigo e em qualquer condição de uso do N-fertilizante, tornando-se uma ferramenta de auxílio na tomada de decisões, quanto ao manejo da cultura.

Oliveira et al. (2013), fez uso de redes neurais artificiais em estudo de bananeira (*musa acuminata colla*) e Arruda et al. (2013), utilizou as RNAs na obtenção de um mapa digital de solos. Valverde et al. (2014), usaram redes neurais e lógica fuzzy para fazer a previsão de precipitação diária sobre o estado de São Paulo, avaliando esses métodos como úteis, evitando desastres e salvando vidas. Soares et al. (2015) estudando a produtividade da cultura de milho por RNA, observou que não houve diferença entre os valores da produção de grãos estimados e observados.

#### Conclusões

A Rede Neural Artificial do tipo Perceptron de Múltiplas Camadas, com o algoritmo de aprendizagem backpropagation e função de treinamento Levenberg-Marquadt, se mostra eficiente na previsibilidade da produtividade de grãos de trigo, em qualquer estádio de desenvolvimento e condições agroclimáticas reais e evidencia que 8 é o número ótimo de neurônios na camada escondida da rede. Dessa forma, a RNA é mais um modelo para ser utilizado nas simulações de produtividade agrícola.

#### Palavras-chave

Nitrogênio; previsibilidade; treinamento

#### Agradecimentos

Ao CNPq, FAPERGS, UNIJUÍ e ao IFRS pelo aporte dos recursos destinados ao desenvolvimento deste estudo e pelas bolsas de estudo e pesquisa.

#### Referências Bibliográficas

ARRUDA, G. P.; DEMATTÊ, J. A. M.; CHAGAS, C. S.. Digital soil mapping by artificial neural networks based on soil-landscape relationships. *Revista Brasileira de Ciência do Solo*, v. 37, n. 2, p. 327-338, 2013.

BUCENE, L.C.; RODRIGUES, L. H. A.. Utilização de redes neurais artificiais para avaliação de produtividade do solo, visando classificação de terras para irrigação. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.8, n.2/3, p.326-329, 2004.

DEPINÉ, M., FRIMMEL, H. E., EMSBO, P., KOENIG, A. E., & KERN, M. Trace element distribution in uraninite from Mesoarchean Witwatersrand conglomerates (South Africa) supports placer model and magmatogenic source. *Mineralium Deposita*, v. 48, n.4, p.423-435, 2013.

HUANG, Y.; LAN, Y.; THOMSON S. J.; FANG A.; HOFFMANN W. C.; LACEY, R. E.. Development of soft computing and applications in agricultural and biological engineering. *Computers and Eletronics in Agriculture*, v.71, p.107-127, 2010.

**Modalidade do trabalho:** Relatório técnico-científico

**Evento:** XXI Jornada de Pesquisa

JANA, R. B.; MOHANTY, B. P.; SHENG, Z. Upscaling soil hydraulic parameters in the Picacho Mountain region using Bayesian Neural Networks. *Transactions of the ASABE*, v.55, n.2, p.463-473, 2012.

JANA, R.B.; MOHANTY, B.P. A comparative study of multiple approaches to soil hydraulic parameter scaling applied at the hillslope scale. *Water Resources Research*, v.48, p.1-16, 2012.

MAPA, Ministério da Agricultura, Pecuária e Abastecimento. Disponível em: <<http://www.agricultura.gov.br/vegetal/culturas/trigo>>. Acesso em: 01/03/2015.

MASTERS, T. Practical neural network recipes in C++. Academic, p. 493, 1993.

MILOCA, S.A.; CHAVES NETO, A.; VOLPI, N. M. P.; CONEJO, P. D. Relação entre variáveis meteorológicas e a qualidade industrial do trigo. *Ciência Rural*, v.37, n.1, p. 31-37, 2007.

OLIVEIRA, A. C. L. et al.. Utilização da modelagem matemática (redes neurais artificiais) na classificação de autotetraploides de bananeira (*Musa acuminata* COLLA). *Bioscience Journal*, v.29, n. 3, p. 617-622, 2013.

PEREIRA, M. W. G.; DE ARÊDES, A. F.; TEIXEIRA, E. C.. Avaliação econômica do cultivo de trigo dos Estados do Rio Grande do Sul e Paraná. *Revista de Economia e Agronegócio-REA*, v. 5, n. 4, 2015.

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

ROCHA, F. A.; MARTINEZ, M. A.; MATOS, A. T.; CANTARUTTI, R. B.; SILVA, J. O. Modelo numérico do transporte de nitrogênio no solo. Parte II: Reações biológicas durante a lixiviação. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.12, p.54-61, 2008.

SILVA, A.A.V.; SILVA, I.A.F.; TEIXEIRA FILHO, M.C.M.; BUZZETTI, S.; TEIXEIRA, M.C.M.. Estimativa da produtividade de trigo em função da adubação nitrogenada utilizando modelagem neuro fuzzy. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.18, n.2, p.180-187, 2014.

SILVA, J. A. G.; ARENHARD, E. G.; KRÜGERS, C. A. M. B.; LUCCHESI, O. A.; METZ, M.; MAROLLI, A. A expressão dos componentes de produtividade do trigo pela classe tecnológica e aproveitamento do nitrogênio. *Agriambi*, v.19, p.27-33, 2015.

SOARES, F.C.; ROBAINA, A. D.; PEITER, M. X.; RUSSI, J. L.. Predição da produtividade da cultura do milho utilizando rede neural artificial. *Ciência Rural*, v. 45, n. 11, p. 1987-1993, 2015.

TEIXEIRA FILHO, M. C. M., BUZZETTI, S., ANDREOTTI, M., ARF, O., & BENETT, C. G. S.. Doses, fontes e épocas de aplicação de nitrogênio em trigo irrigado em plantio direto. *Pesquisa Agropecuária Brasileira*, v.45, n.8, p. 797-804, 2011.

VALVERDE, M.C.; ARAUJO, E. ; VELHO, H. C.. Neural network and fuzzy logic statistical downscaling of atmospheric circulation-type specific weather pattern for rainfall forecasting. *Applied Soft Computing*, v.22, p. 681-694, 2014.

VENTURIERI, A.; SANTOS, J.R. Técnicas de classificação de imagens para análise de cobertura vegetal. In: Assad, E. D; Sano, E.E. Sistema de informações geográficas. Aplicações na agricultura. 2 ed., Brasília: Embrapa – SPI/ Embrapa – CPAC, p.351-371, 1998.

VIEIRA, T.G.C. et al. Mapeamento de áreas cafeeiras utilizando redes neurais artificiais: estudo de caso na região de Três Pontas, Minas Gerais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14, 2009, Natal, RN. Anais... Natal: INPE, p. 7947-7954, 2009.

**Modalidade do trabalho:** Relatório técnico-científico  
**Evento:** XXI Jornada de Pesquisa

WASSERMAN, P.D. Neural computing: theory and practice. New York: van Nostrand Reinhold. 1989.