

Modalidade do trabalho: Relatório técnico-científico
Evento: XVII Jornada de Extensão

MODELAGEM MATEMÁTICA POR REDE NEURAL ARTIFICIAL NA SIMULAÇÃO DA PRODUTIVIDADE DE GRÃOS DE AVEIA BRASILEIRA NO APROVEITAMENTO DO NITROGÊNIO NO SISTEMA SOJA/AVEIA¹

Osmar Brunelau Scremin², Rubia Diana Mantai³, Angela Teresinha Woschinski De Mammann⁴, Ari Higino Scremin⁵, Douglas César Reginatto⁶, José Antonio Gonzalez Da Silva⁷.

¹ Projeto de Pesquisa realizado no curso de Mestrado em Modelagem Matemática da Unijuí

² Doutorando em Modelagem Matemática do Departamento de Ciências Exatas e Engenharias da Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ.

³ Doutorando em Modelagem Matemática do Departamento de Ciências Exatas e Engenharias da Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ.

⁴ Mestre em Modelagem Matemática pela Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ.

⁵ Mestrando em Modelagem Matemática do Departamento de Ciências Exatas e Engenharias da Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ.

⁶ Mestrando em Modelagem Matemática do Departamento de Ciências Exatas e Engenharias da Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ.

⁷ Professor do Departamento de Estudos Agrários, Universidade Regional do Noroeste do Estado do Rio Grande do Sul/UNIJUÍ.

INTRODUÇÃO

Por ser uma cultura de múltiplos propósitos a aveia branca (*Avena sativa* L.) tem assumido nos últimos anos um papel importante nos sistemas de cultivo na estação fria do ano (HARTWIG et al., 2007; CONAB, 2016). Entretanto, é cada vez maior a demanda por cultivares altamente produtivas, de elevada qualidade e eficientes em resposta à melhoria de estímulos ambientais e ao uso de fertilizantes (HAWERROTH et al., 2013; MANTAI et al., 2015). Neste contexto, as simulações durante os estádios de desenvolvimento da cultura são de suma importância à aplicação do N-fertilizante e a tomada de decisões quanto ao manejo da cultura.

As condições climáticas também são fatores que interferem diretamente na expressão dos caracteres de produtividade (BENIN ET AL., 2013). Seu emprego nos sistemas de simulações tem se tornado uma ferramenta importante no entendimento do desenvolvimento de novas tecnologias de cultivo. Desta forma, o uso de modelos matemáticos como as redes neurais artificiais permite correlacionar às interferências climáticas ao manejo da cultura (DE ARRUDA et al., 2013). Assim, dados climáticos e de manejo podem ser utilizados como fonte de definição e de contexto de determinado alvo, importante na tarefa de memorização de característica temática (VENTURIERI & SANTOS, 1998; BUCENE & RODRIGUES, 2004). O conhecimento de uso de redes neurais artificiais pode representar uma nova possibilidade de simulações voltada a produtividade de grãos das culturas no Brasil em condições reais de cultivo. Portanto, o objetivo do trabalho é validar a possibilidade de uso de redes neurais artificiais como suporte de simulações de processos biológicos em aveia pela

Modalidade do trabalho: Relatório técnico-científico
Evento: XVII Jornada de Extensão

análise da biomassa nos estádios de desenvolvimento da cultura junto às condições meteorológicas de temperatura máxima e precipitação pluviométrica com diferentes doses de nitrogênio no sistema soja/aveia.

MATERIAL E MÉTODOS

Os estudos foram realizados nas safras agrícolas de 2014 e 2015, na condição de cultivo soja/aveia, no município de Augusto Pestana, RS. Foram conduzidos dois experimentos, um para quantificar a taxa de produtividade de biomassa pelos cortes realizados a cada 30 dias até o ponto de colheita e o outro para a colheita no final do ciclo, visando exclusivamente à estimativa da produtividade de grãos. Na semeadura, foi utilizada semeadora-adubadora na composição da parcela com 5 linhas de 5 m de comprimento e espaçamento entre linhas de 0,18 m, formando a unidade experimental de 4,5 m². O delineamento experimental foi de blocos ao acaso com quatro repetições, seguindo um esquema unifatorial para as doses de Nitrogênio nos níveis 0, 30, 60 e 120 kg/ha (fonte ureia), com o uso da cultivar de aveia branca URS-Corona. A colheita para a estimativa da produtividade de grãos ocorreu de forma manual pelo corte das três linhas centrais de cada parcela, que foram trilhadas com colheitadeira estacionária e direcionadas ao laboratório para correção da umidade de grãos a 13% e pesagem para estimativa da produtividade. No experimento visando quantificar a 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, nos estádios de 30, 60, 90 e 120 dias após a emergência, totalizando quatro cortes. As amostras com a biomassa verde foram direcionadas à estufa de ar forçado na temperatura de 65 °C, até atingir peso constante. Após, foram pesadas em balança de precisão e com posterior estimativa da matéria seca total convertida em kg/ha. Os dados climáticos foram obtidos através da estação meteorológica do IRDeR (Instituto Regional de Desenvolvimento e Extensão Rural), próxima aos experimentos.

Para o desenvolvimento da Rede Neural Artificial (RNA) multicamadas na previsibilidade de produtividade de grãos de aveia foi utilizado o Neural Network Toolbox do software Matlab. As RNAs foram treinadas com o algoritmo backpropagation e função de treinamento Levenberg-Marquadt (trainlm). Para a ativação da camada de entrada, camada escondida e camada de saída foram usadas a função tan-sigmóide (tansig). Para cada arquitetura da RNA, os dados amostrais foram divididos aleatoriamente em 70% para o treinamento (banco de dados com 128 amostras), 15% para testes e 15% para validação.

Em decorrência de que os parâmetros são gerados aleatoriamente no início do treinamento, e que esses resultados iniciais podem influenciar no resultado final da RNA, esta foi treinada 10 vezes para cada estrutura, com 3 camadas (Camada de entrada, camada escondida e camada de saída). As camadas de entrada foi composta de 5 neurônios, 5 a 25 a camada escondida, fazendo incremento de 5 em 5, e a camada de saída com 1 neurônio. Para representar a arquitetura da rede foi utilizada a notação "NE-NCE-NS", onde NE é o número de neurônios da camada de entrada da rede, NCE é o número de neurônios da camada escondida e NS é o número de neurônios da camada de saída. Em

Modalidade do trabalho: Relatório técnico-científico
Evento: XVII Jornada de Extensão

cada treinamento foram realizadas inúmeras interações, até que o erro médio quadrático entre a saída desejada e calculada fosse minimizado.

Para o treinamento e validação das RNAs, foram utilizados os valores da produtividade de grãos de aveia, obtidos nos anos de 2014 e 2015, no experimento a campo. O processo de treinamento foi concluído quando a diferença entre os valores médios da produtividade de grãos do efeito cumulativo dos anos obtidos a campo e os simulados pelas RNAs foi o menor possível. Na sequência, foi feita a validação para o efeito cumulativo dos anos, sendo que as saídas ficaram dentro do intervalo de confiança, a 5% de probabilidade de erro.

As variáveis de entrada utilizadas pela rede neural artificial foram: doses de N-fertilizante (0, 30, 60 e 120 kg/ha), estádios de desenvolvimento da aveia (30, 60, 90 e 120 dias), produtividade biológica a cada estágio, precipitação pluviométrica acumulada a cada estágio e temperatura média acumulada a cada estágio. A variável de saída foi a produtividade de grãos de aveia de cada ano de cultivo no sistema soja/aveia. Os dados de saída de rede neural foram padronizados para o intervalo de -1 a 1, pelo processo de normalização dos dados, expresso pela seguinte equação: $pn = \frac{2 \cdot (p - \min(p))}{\max(p) - \min(p)} - 1$, em que: pn é o valor normalizado, adimensional; p é o valor de produtividade de grãos observado; min(p) é o mínimo valor de produtividade de grãos da amostra; e max(p) o valor máximo de produtividade de grãos da amostra.

DISCUSSÃO DOS RESULTADOS

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 de sucessão soja/aveia.

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

Arquitetura NE->NCE->NS	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
5-5-1	5.54E-3	1.01E-2	7.82E-3
5-10-1	5.51E-3	7.76E-3	1.42E-2
5-15-1	5.83E-3	6.29E-3	2.32E-2
5-20-1	5.64E-3	7.85E-3	2.32E-2
5-25-1	6.81E-3	1.44E-2	1.96E-2

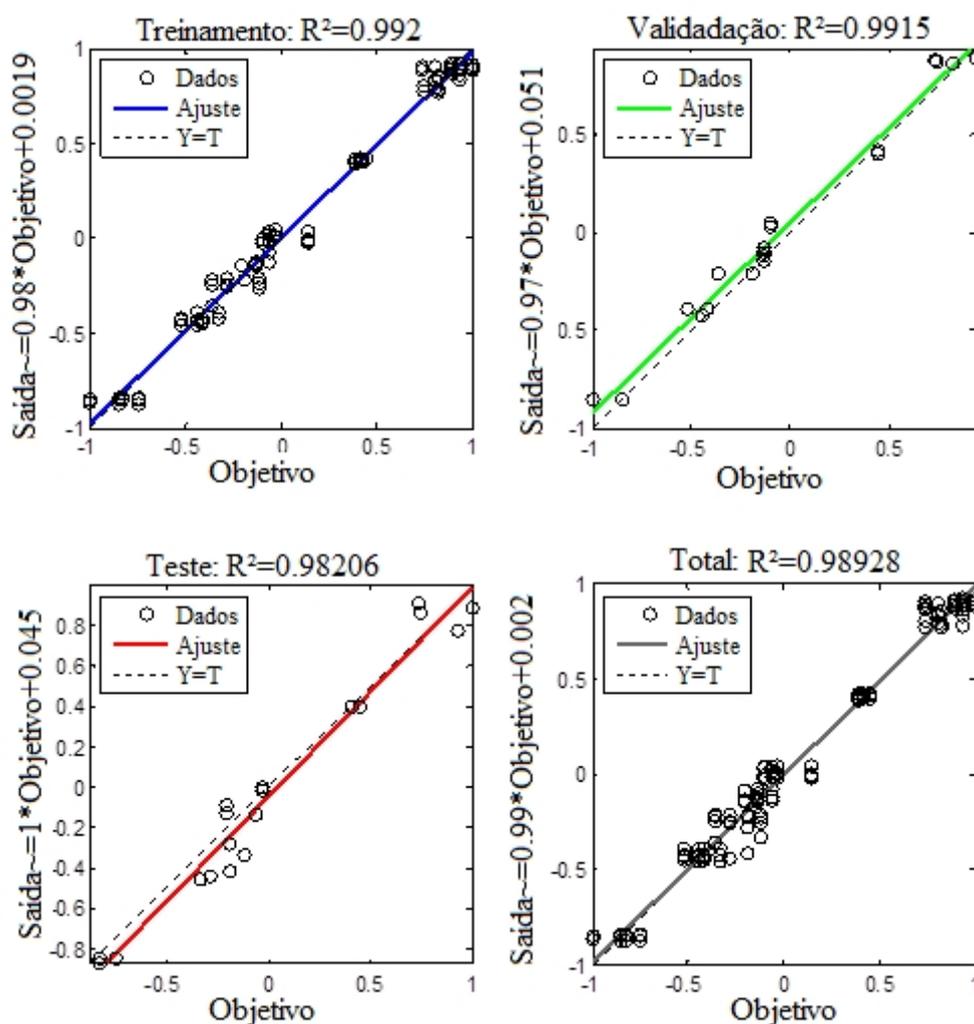
NE= Número de neurônios da camada de entrada; NCE= Número de neurônios da camada escondida; NS= Número de neurônios da camada de saída.

Para a escolha da arquitetura ideal observou-se que a rede 5-10-1 apresentava menor erro quadrático médio. Entretanto, nota-se que a variância no processo de validação está acima da arquitetura 5-5-1, significando que o erro no processo de treinamento diminuiu, porém, na validação 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 a que apresentou relação entre o número

Modalidade do trabalho: Relatório técnico-científico
Evento: XVII Jornada de Extensão

amostras de treinamento e o número de conexões escondidas superior a dois, conforme indicado por Masters (1993) e de menor erro de relativo médio de validação. Portanto, a arquitetura escolhida foi a 5-10-1 (Tabela 1). De Oliveira et al. (2013), fez uso da estrutura 4-3-2 na simulação por redes neurais artificiais na classificação de autotetraploides de bananeira (*musa acuminata colla*), com o algoritmo de treinamento backpropagation. Chagas et al. (2009), trabalhando com a classificação dos níveis de degradação de pastagens na zona da mata mineira por meio de RNA, constatou que a rede é um classificador viável para este fim, principalmente em grandes áreas.

Na definição da escolha da arquitetura da rede, na Figura 1, estão apresentados os coeficientes de determinação, do Treinamento (70% dos dados), da Validação (15% dos dados), do Teste da Rede (15% dos dados) e Total (100% dos dados) do sistema soja/aveia. Portanto, permitindo confirmar 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: XVII Jornada de Extensão

Figura 1. Coeficientes de determinação do Treinamento, Teste, Validação e Todos (Treinamento, Teste, Validação) das redes neurais artificiais para a arquitetura 5-10-1.

Para verificar o desempenho da rede neural artificial de arquitetura 5-10-1 (Tabela 1), foi simulada a produtividade de grãos (Tabela 2) pelos valores médios observados no efeito cumulativo dos anos (2014+2015) para as variáveis de entrada "doses de N-fertilizante", "estádios de desenvolvimento da aveia", "média da produtividade biológica dos estádios", "média da precipitação acumulada dos estádios" e "média da temperatura máxima acumulada dos estádios" (Figura 2).



Modalidade do trabalho: Relatório técnico-científico
Evento: XVII Jornada de Extensão

Tabela 2. Comparação dos valores de produtividade de grãos de aveia obtidos na validação da RNA de arquitetura 5-10-1.

N (kg ha ⁻¹)	Estádio (dias)	Ano	PB (kg ha ⁻¹)	Σ_{Prec} (mm)	\bar{X}_{TMax} (°C)	PG (kg ha ⁻¹) (2014+2015)			
						Simulação/RNA	Intervalo Confiança		
0	30	2015	288	337	18.4	2322	$L_i = 1987$		
		2014	345	112	21.3				
	60	2015	1317	480	20.0	2260		$X = 2220$	
		2014	1430	307	23.0				
	90	2015	4117	565	20.2	2320		$L_s = 2420$	
		2014	4594	548	23.1				
	120	2015	9919	785	20.7	2215			
		2014	5044	813	24.7				
	30	30	2015	327	337	18.4	3179		$L_i = 2750$
			2014	370	112	21.3			
		60	2015	2188	480	20.0	3188	$X = 3035$	
			2014	1722	307	23.0			
90		2015	5059	565	20.2	3183	$L_s = 3278$		
		2014	8266	548	23.1				
120		2015	11972	785	20.7	3059			
		2014	8857	813	24.7				
60		30	2015	320	337	18.4		3444	$L_i = 2872$
			2014	359	112	21.3			
		60	2015	2250	480	20.0	3481	$X = 3342$	
			2014	3131	307	23.0			
	90	2015	8611	565	20.2	3485	$L_s = 3745$		
		2014	9681	548	23.1				
	120	2015	12051	785	20.7	3452			
		2014	11012	813	24.7				
	120	30	2015	304	337	18.4		3171	$L_i = 3061$
			2014	369	112	21.3			
		60	2015	3234	480	20.0	3244	$X = 3192$	
			2014	3398	307	23.0			
90		2015	9531	565	20.2	3161	$L_s = 3663$		
		2014	11295	548	23.1				
120		2015	14864	785	20.7	3159			
		2014	11939	813	24.7				

N= nitrogênio; Ms= massa seca; Σ_{Prec} = somatório da precipitação; \bar{X}_{TMax} = média da temperatura máxima; PG= produtividade de grãos; PB= produtividade biológica; RNA= rede neural artificial; L_i = limite inferior; X = média; L_s = limite superior.

Modalidade do trabalho: Relatório técnico-científico
Evento: XVII Jornada de Extensão

Na Tabela 2, a simulação mostrou alta capacidade preditiva para a produtividade de grãos de aveia, sendo que os valores simulados pela rede neural artificial ficaram dentro do intervalo de confiança, do efeito cumulativo dos anos, 2014 e 2015. A capacidade de aprender através de exemplos e de generalizar a informação aprendida é o atrativo principal da solução de problemas através de RNAs (WASSERMAN, 1989; SOARES, 2014).

Os resultados mostram que o uso da rede possibilita a previsibilidade da produtividade de grãos em qualquer estágio de desenvolvimento da aveia, em qualquer condição de uso do N-fertilizante, tornando-se uma ferramenta de auxílio na tomada de decisões, quanto ao manejo da cultura. Da Costa Leite et al. (2015), na análise econômica do feijoeiro em diferentes épocas e doses de aplicação de nitrogênio, verificou que o menor risco apresentado foi para a época de aplicação antes da semeadura e o maior risco para a época antes+cobertura do N-fertilizante.

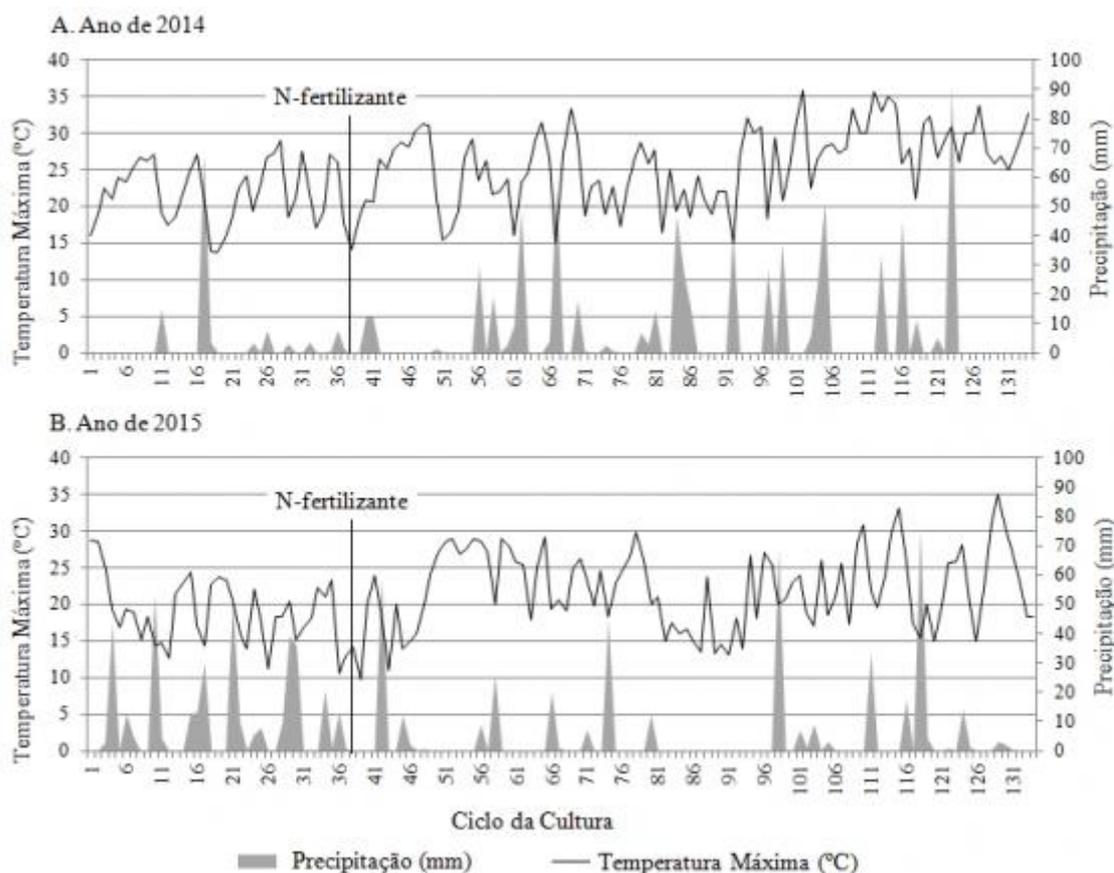


Figura 2. Precipitação pluviométrica e temperatura máxima no ciclo da aveia.

CONCLUSÃO

As redes neurais artificiais do tipo Perceptron de Múltiplas Camadas, com o algoritmo de aprendizagem backpropagation e função de treinamento Levenberg-Marquadt, se mostraram

Modalidade do trabalho: Relatório técnico-científico
Evento: XVII Jornada de Extensão

eficientes na previsibilidade da produtividade de grãos em qualquer estágio de desenvolvimento da aveia, independente da condição de uso do nitrogênio junto as condições de temperatura máxima e precipitação. Assim, vindo a somar-se com os modelos convencionais de simulação, tornando-se uma ferramenta de auxílio na tomada de decisões, quanto ao manejo da cultura da aveia.

PALAVRAS-CHAVE: Avena sativa, novas tecnologias, inteligência artificial,

AGRADECIMENTOS

Ao CNPq, FAPERGS e à UNIJUI pelo aporte dos recursos destinados ao desenvolvimento deste estudo e pelas bolsas de Iniciação Científica e de Apoio Técnico, de Pós-graduação e de Produtividade em Pesquisa.

REFERÊNCIAS

- BENIN, Giovani et al. Precisão experimental de ensaios de trigo em regiões homogêneas de adaptação. *Pesquisa Agropecuária Brasileira*, v. 48, n. 4, p. 365-372, 2013.
- BUCENE, Luciana C.; RODRIGUES, Luiz HA. 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.
- CHAGAS. "Digital soil mapping by artificial neural networks based on soil-landscape relationships." *Revista Brasileira de Ciência do Solo*. V. 37.2, P.327-338, 2013.
- CONAB – Companhia Nacional de Abastecimento. Brasil Grãos. Disponível em: <<http://www.conab.gov.br/detalhe.php?c=5031>>. Acesso em: 27/06/2016.
- DA COSTA LEITE, Rafael; LAMPERT, Vinicius Nascimento; SOUZA, João Paulo. ANÁLISE ECONÔMICA DO FEIJOEIRO EM DIFERENTES ÉPOCAS E DOSES DE APLICAÇÃO DE NITROGÊNIO SOB CONDIÇÕES DE RISCO E INCERTEZA. *ANAIS DO ENIC*, v. 1, n. 4, 2015.
- DE ARRUDA, Gustavo Pais; DEMATTÊ, José Alexandre M.; DA SILVA CHAGAS, César. Mapeamento digital de solos por redes neurais artificiais com base na relação solo-paisagem. *Revista Brasileira de Ciência do Solo*, v. 37, n. 2, p. 327-338, 2013.
- DE OLIVEIRA, Ana Catarina Lima et al. Utilização da modelagem matemática (redes neurais artificiais) na classificação de autotetraploides de bananeira (*Musa acuminata* Colla)= Use of mathematical modeling (artificial neural networks) in classification of banana autotetraploid.. *Bioscience Journal*, v. 29, n. 3, 2013.
- HARTWIG, Irineu et al. Variabilidade fenotípica de caracteres adaptativos da aveia branca (*Avena sativa* L.) em cruzamentos dialélicos. *Ciência Rural*, vol.37, n.2, p.337-345, 2007.
- HAWERROTH, Maraisa Crestani et al. Adaptability and stability of white oat cultivars in relation to chemical composition of the caryopsis. *Pesquisa Agropecuária Brasileira*, v. 48, n. 1, p. 42-50, 2013
- MANTAI, R.D.; SILVA, J.A.G.; SAUSEN, A.T.Z.R.; COSTA, J.S.; FERNANDES, S.B.; UBESSI, C.A. Eficiência na produção de biomassa e grãos de aveia pelo uso do nitrogênio. *Revista Brasileira de Engenharia Agrícola e Ambiental*. v. 19, n. 4, p. 343-349, 2015.
- MASTERS, T. Practical neural network recipes in C + +. San Diego: Academic, 1993. 493 p.

Modalidade do trabalho: Relatório técnico-científico
Evento: XVII Jornada de Extensão

SOARES, Fátima Cibele et al. Predição da produtividade da cultura do milho utilizando rede neural artificial. *Ciência Rural*, v. 45, n. 11, p. 1987-1993, 2015.

VENTURIERI, Adriano; SANTOS, JR dos. Técnicas de classificação de imagens para análise de cobertura vegetal. *Sistemas de informações geográficas: aplicações na agricultura*, v. 2, p. 351-371, 1998.

WASSERMAN, Philip D. *Neural computing*. Van Nostrand Reinhold, New York, 1989.