

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

MODELAGEM MATEMÁTICA POR REDE NEURAL ARTIFICIAL NA PROPOSTA DE SIMULAÇÃO DA PRODUTIVIDADE DE GRÃOS DE AVEIA NO SISTEMA DE SUCESSÃO MILHO/AVEIA EM CONDIÇÕES REAIS DE CULTIVO¹

Eldair F. Dornelles², Osmar Bruneslau Scremin³, Ana Paula Brezolin⁴, Ari Higino Scremin⁵, Rafael Z. Frantz⁶, José Antonio Gonzalez Da Silva⁷.

¹ Parte dos resultados de pesquisa desenvolvida pelo DEAg/UNIJUÍ

² Mestrando 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 Doutorando em Modelagem Matemática do Departamento de Ciências Exatas e Engenharias da 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 Professor 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

A aveia branca tem assumido um papel importante nos sistemas de cultivo em estação fria (CONAB, 2016). Por ser uma cultura de múltiplos propósitos é uma excelente alternativa de exploração agrícola em relação ao trigo. O cultivo deste cereal possui distintas finalidades, tais como: alimentação humana e animal, rotação de culturas e cobertura de solo. Com o aumento das áreas destinadas ao cultivo deste cereal, passou a existir um interesse maior por cultivares que possam proporcionar melhor qualidade e elevada produção. Para que tal objetivo seja alcançado, é necessário realizar estudos sobre as características fisiológicas desta planta, analisar seu processo de desenvolvimento e como a mesma reage aos diversos estímulos ambientais e ao uso de fertilizantes (MANTAI et al., 2015).

Na agricultura é de suma importância o uso de técnicas modernas de produção e de administração das propriedades para auxiliar na tomada de decisões. Neste cenário, o uso de redes neurais artificiais, pode permitir correlacionar as variáveis que interferem na produtividade (ARRUDA et al., 2013), possibilitando o desenvolvimento de modelos de simulação que auxiliem na tomada de decisões quanto ao manejo. O objetivo do trabalho foi avaliar o desenvolvimento da aveia pelo uso do nitrogênio nos diferentes estádios de desenvolvimento da espécie, através da análise dos índices de biomassa, temperatura máxima acumulada e precipitação pluviométrica acumulada, na implementação de um modelo de simulação da produtividade de grãos utilizando Rede Neural Artificial (RNA).

Material e métodos

Modalidade do trabalho: Relatório técnico-científico

Evento: XXI Jornada de Pesquisa

O trabalho foi desenvolvido nas safras de 2014 e 2015, da cultivar de aveia branca URS-Corona, no sistema de cultivo milho/aveia, no município de Augusto Pestana, RS. Para os experimentos foram definidos blocos ao acaso com quatro repetições, utilizando um esquema unifatorial para as doses de Nitrogênio de 0, 30, 60 e 120 kg/ha. Cada bloco foi definido com 5 linhas de 5 metros de comprimento, e com espaçamento de 18 cm. Os experimentos foram divididos em duas etapas. A primeira etapa teve por objetivo quantificar a produtividade de biomassa, realizando a colheita parcial de cada bloco a cada 30 dias de desenvolvimento da espécie. A segunda etapa, consistiu em realizar a estimativa da produtividade de grãos para a colheita ao final do ciclo, com base nos dados obtidos na primeira etapa. A colheita parcial realizada ao longo do desenvolvimento das plantas (30, 60, 90 e 120 dias após a emergência), consistiu na coleta de um metro linear das três linhas centrais de cada bloco, com corte rente ao solo. As amostras coletadas eram encaminhadas para uma estufa de ar forçado com temperatura definida em 65°C, até atingir um peso constante. Na sequência estimava-se a matéria seca total convertida em kg/ha. Na etapa da estimativa da produtividade de grãos, a colheita foi realizada de forma manual, sendo aproveitado apenas as três linhas centrais de cada parcela, na sequência, foram trilhadas com colheitadeira estacionária e encaminhada ao laboratório para realizar a correção da umidade de grãos à 13%. Após obter os dados experimentais referente as safras 2014 e 2015, iniciou-se o desenvolvimento da RNA, para previsibilidade de produtividade de grãos da aveia. Para tal foi utilizado a ferramenta Neural Network Toolbox do software Matlab.

Foram definidas 5 diferentes estruturas de RNAs, todas compostas com apenas uma camada intermediária, 5 neurônios na camada de entrada, e 1 neurônio da camada de saída, variando apenas a quantidade de neurônios da camada intermediária, iniciando com 5 neurônios e incrementando 5 neurônios a cada nova estrutura. Para representação da rede é utilizado neste trabalho a notação "NE-NCE-NS", onde NE é número de neurônio na camada de entrada, NCE é o número de neurônios na camada escondida, e NS é o número de neurônios da camada de saída. O treinamento da RNA foi realizado através do algoritmo backpropagation utilizando a função Levenberg-Marquadt (trainlm), e a função de ativação tan-sigmóide (tan-sig) para todas as camadas. Para as variáveis de entradas das RNAs foram utilizadas as doses de nitrogênio (30, 60, 120 kg/ha), os estádios de desenvolvimento (30, 60, 90 e 120 dias), a produtividade biológica em cada estágio, precipitação pluviométrica acumulada e temperatura média acumulada. Na Figura 1 são apresentados as informações referente a precipitação pluviométrica e temperatura máxima ocorrida durante o ciclo da aveia nos anos 2014 e 2015.

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




Figura 1. Precipitação pluviométrica e temperatura máxima no ciclo da aveia.

A variável definida para a saída da estrutura da RNA foi a produtividade de grãos de cada ano de cultivo. Os dados de saída da rede neural foram padronizados para o intervalo de -1 a 1, pelo processo de normalização dos dados, expresso pela seguinte equação: $pn = [2(p - \min p) / (\max p - \min p)] - 1$, 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.

Para os treinamentos das RNAs, os valores da produtividade de grãos de aveia, obtidos nos anos de 2014 e 2015 (128 amostras), foram divididos aleatoriamente, 70% dos dados foram destinados para o treinamento, 15% para testes e 15% para validação. Tendo em vista que os parâmetros iniciais gerados para a rede neural são aleatórios, e que tais parâmetros podem influenciar no resultado final, foram realizados 10 treinamentos para cada estrutura. Na sequência, foi realizada a validação para o efeito cumulativo dos anos, onde foi obtido resultados dentro do intervalo de confiança, a 5% de probabilidade de erro.

Discussão dos resultados

Modalidade do trabalho: Relatório técnico-científico

Evento: XXI Jornada de Pesquisa

Para avaliar a eficiência das arquiteturas das RNAs, observou-se os valores adimensionais de erro quadrático médio, erro relativo e a variância. Na Tabela 1, são apresentados os valores obtidos no processo de testes e validação das arquiteturas treinadas para os dados experimentais das safras de 2014 e 2015 no sistema de sucessão milho/aveia.

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

Arquitetura NE->NCE->NS	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
5-5-1	6.31E-3	4.77E-3	7.77E-3
5-10-1	6.75E-3	8.44E-3	6.37E-3
5-15-1	5.89E-3	5.69E-3	7.78E-3
5-20-1	6.39E-3	1.78E-2	8.32E-3
5-25-1	3.42E-3	9.62E-3	1.68E-2

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

Observa-se que a rede 5-25-1 apresentou menor erro quadrático médio, porém obteve a maior variância de validação. Segundo 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) e de menor erro de relativo médio de validação. Seguindo este conceito escolheu-se a estrutura 5-15-1, por apresentar erro quadrático médio menor que as demais estruturas e por possuir erro relativo médio menor. Na Figura 2, são 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 milho/aveia.

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




Figura 2. Coeficientes de determinação do treinamento, teste, validação e de todos (treinamento, teste, validação) das redes neurais artificiais na arquitetura 5-15-1 para o sistema milho/aveia.

Através da análise da Figura 1 é possível 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. Uma das principais características das RNAs é a capacidade de aprender através de um conjunto reduzido de exemplos e, posteriormente generalizar essas informações (WASSERMAN, 1989). Tal capacidade é uma demonstração que as RNAs vão além do que simplesmente relações de entrada e saída (SOARES, 2014). Na simulação para o sistema milho/aveia desenvolvido neste trabalho as simulações ficaram dentro do intervalo de confiança, conforme observa-se na Tabela 2.

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

Tabela 2. Comparação dos valores de produtividade de grãos de aveia obtidos na validação da RNA de arquitetura 5-15-1 no experimento a campo no sistema milho/aveia.

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 de Confiança
0	30	2015	324	337	18.4	1458	L _i =1240
		2014	195	112	21.3		
	60	2015	854	480	20.0	1524	$\bar{X}$ =1551
		2014	1029	307	23.0		
	90	2015	4370	565	20.2	1522	L _s =1818
		2014	4462	548	23.1		
	120	2015	7524	785	20.7	1517	
		2014	4657	813	24.7		
30	30	2015	326	337	18.4	2384	L _i =2163
		2014	230	112	21.3		
	60	2015	1484	480	20.0	2430	$\bar{X}$ =2476
		2014	1305	307	23.0		
	90	2015	4991	565	20.2	2431	L _s =2745
		2014	6564	548	23.1		
	120	2015	9515	785	20.7	2584	
		2014	8490	813	24.7		
60	30	2015	294	337	18.4	2840	L _i =2451
		2014	268	112	21.3		
	60	2015	1857	480	20.0	2897	$\bar{X}$ =2902
		2014	1968	307	23.0		
	90	2015	5587	565	20.2	2852	L _s =3289
		2014	7845	548	23.1		
	120	2015	10628	785	20.7	3030	
		2014	10282	813	24.7		
120	30	2015	272	337	18.4	3032	L _i =2778
		2014	300	112	21.3		
	60	2015	2668	480	20.0	3126	$\bar{X}$ =3094
		2014	2685	307	23.0		
	90	2015	6353	565	20.2	2997	L _s =3364
		2014	9803	548	23.1		
	120	2015	12111	785	20.7	3181	
		2014	11179	813	24.7		

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

Conclusão

O uso de redes neurais artificiais permitem a previsibilidade da produtividade de grãos de aveia considerando a análise de biomassa dos diferentes estádios de desenvolvimento da espécie pelo uso

Modalidade do trabalho: Relatório técnico-científico

Evento: XXI Jornada de Pesquisa

do N-fertilizante considerando a temperatura máxima e precipitação pluviométrica acumulada. Desta forma pode servir como uma nova ferramenta de auxílio a simulações de produtividade considerando condições reais de cultivo.

Palavras-chave

Biomassa, nitrogênio, inteligência artificial, temperatura máxima, precipitação pluviométrica.

Agradecimentos

À CAPES, 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

ARRUDA, Gustavo Pais de, DEMATTÊ, José Alexandre M., CHAGAS, César da Silva. 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.

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.

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

SOARES, Fátima Cibele et al. Redes neurais artificiais na estimativa da retenção de água do solo. Ciência Rural, Santa Maria, v.44, n.2, p.293-300, fev, 2014.

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.