



Revista Agrarian

ISSN: 1984-2538

Estimativa da produção da soja brasileira utilizando redes neurais artificiais

Prediction of Brazilian soybean production using artificial neural network

Emerson Rodolfo Abraham¹, João Gilberto Mendes Dos Reis¹, Rodrigo Carlo Tolo¹, Aginaldo Eduardo de Souza¹, Adriane Paulieli Colosetti¹

¹ Universidade Paulista, Programa de Pós-Graduação em Engenharia de Produção, Grupo de Pesquisa em Redes de Suprimentos. Rua Dr. Bacelar, 1212 – Vila Clementino. CEP: 04026-002 – São Paulo/SP. E-mail: emerson_abraham@yahoo.com.br

Recebido em: 27/12/2018

Aceito em: 15/05/2019

Resumo: Brasil e Estados Unidos foram responsáveis por dois terços da produção mundial da soja durante a safra de 2016/17, equivalente a cerca de 348,1 milhões de toneladas. A soja é o principal produto na corrente de comércio brasileira, visto que sua participação na balança comercial foi de 33%, com o volume exportado de 68 milhões de toneladas, equivalente a US\$ 25,7 bilhões. Assim, faz-se necessário analisar e estimar a relação entre área plantada, produtividade e produção, visando tomadas de decisões que possam afetar o suprimento interno e externo desse cereal. Nesse contexto, propõe-se nesse trabalho, uma rede neural artificial para estimar a produção futura da soja brasileira. Utilizou-se o software Matlab R2017b e a Neural Network tool box para elaboração, treinamento, validação e testes da rede. Os dados foram coletados das séries históricas de 41 anos de área plantada, produtividade e produção, fornecidas pela Companhia Nacional de Abastecimento. Os resultados apontaram uma produção de 108,1 milhões de toneladas, para a safra 2017/2018, ou seja, uma pequena queda de 5% em relação à safra 2016/17 que foi de 114,1 milhões de toneladas.

Palavras-chave: agronegócio, previsões em series temporais, sistemas inteligentes,

Abstract: Brazil and the United States accounted for two-thirds of world soybean production during the 2016/17 crop, equivalent to about 348.1 million tonnes. Soybeans are the main product in the Brazilian trade chain, since its share in the trade balance was 33%, with the volume exported of 68 million tons, equivalent to US\$ 25.7 billion. Thus, it is necessary to analyze and estimate the relationship between harvested area, yield and production, aiming at decisions that may affect the internal and external supply of this cereal. In this context, we propose an artificial neural network to estimate the future production of Brazilian soybean. The software Matlab R2017b and the Neural Network tool box were used for the elaboration, training, validation and testing of the network. The data were collected from the historical series of 41 years of harvested area, yield and production, provided by Companhia Nacional de Abastecimento. The results showed a production of 108.1 million tons, for the 2017/2018 harvest, a small decrease of 5% compared to the 2016/17 harvest of 114.1 million tons.

Keywords: agribusiness, time series forecasts, intelligent systems

Introdução

A produção mundial de grãos de soja durante a safra de 2016/17 foi de 348,1 milhões de toneladas (USDA, 2018).

Nesse período, o Brasil teve uma produção de 114,1 milhões de toneladas em uma área plantada de 33,9 milhões de hectares e produtividade de 3,4 ton ha⁻¹ (Conab, 2018).

O maior produtor mundial tem sido os Estados Unidos com 116,9 milhões de toneladas, juntos esses dois países provem aproximadamente dois terços da produção mundial de soja (USDA, 2018).

Durante a safra de 2016/17, as regiões Centro-Oeste e Sul do Brasil foram as maiores produtoras, tendo gerado 50,1 e 40,5 milhões de toneladas, respectivamente (Conab, 2018). A



Figura 1 demonstra a produção das cinco regiões brasileiras.

Na região Centro-Oeste, somente o estado do Mato Grosso (maior produtor nacional), produziu 30,5 milhões de toneladas em uma área plantada de 9,3 milhões de hectares e uma produtividade de 3,3 ton ha⁻¹. Na região Sul o estado do Paraná produziu 19,5 milhões de toneladas em uma área plantada de 5,2 milhões de hectares e produtividade de 3,7 ton ha⁻¹; e o estado do Rio Grande do Sul produziu 18,7 milhões de toneladas em uma área plantada de 5,5 milhões de hectares com produtividade de 3,3 ton ha⁻¹ (CONAB, 2018).

O agronegócio tem tido fundamental importância na economia brasileira. No acumulado do ano de 2017 o setor foi responsável por 44,1% das vendas no exterior, as transações de exportações do agronegócio

somaram US\$ 96 bilhões (Deagro, 2018).

Dados do Instituto Brasileiro de Geografia e Estatística – IBGE, revelam um crescimento no segmento de 13% em relação a 2016. Os grãos foram os principais responsáveis pelo desempenho do setor (IBGE, 2018).

A soja é o principal produto na corrente de comércio, visto que sua participação na balança comercial foi de 33%, com o volume exportado de 68 milhões de toneladas, equivalente a US\$ 25,7 bilhões, atingindo recorde absoluto de vendas no mercado internacional. A China é o principal mercado da soja brasileira, representando 76,4% de todo volume do agronegócio exportado àquele país, totalizando US\$ 21,3 bilhões (DEAGRO, 2018; MDIC, 2018).

Produção da soja por regiões 2016/17
(milhões de toneladas)

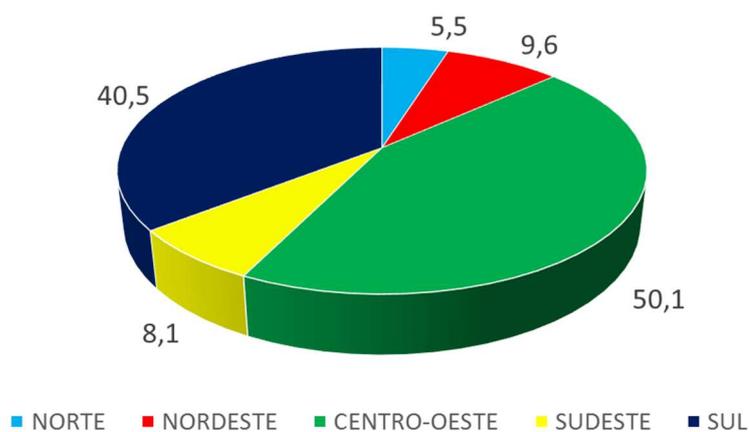


Figura 1. Produção das regiões. Fonte: os autores; dados extraídos de Conab (2018)

Nesse contexto, torna-se importante analisar e estimar a relação entre área plantada, produtividade e produção, visando tomadas de decisões que possam afetar o suprimento interno e externo desse cereal. A Figura 2, demonstra um comparativo entre a área plantada no Brasil e no Mundo nos últimos 41 anos.

A área plantada no mundo era de 42,1 milhões de hectares em 1976/77, desde então,

houve um aumento significativo, alcançando o número de 119 milhões de hectares em 2016/17. Nesse mesmo período, a área plantada brasileira era de aproximadamente 6,9 milhões de hectares, passando para cerca de 33,9 milhões em 2016/17.

A seguir, a Figura 3 apresenta um comparativo entre a produtividade no Brasil e no Mundo nos últimos 41 anos.

Área plantada da soja (1976/77 - 2016/17) em milhões de hectares

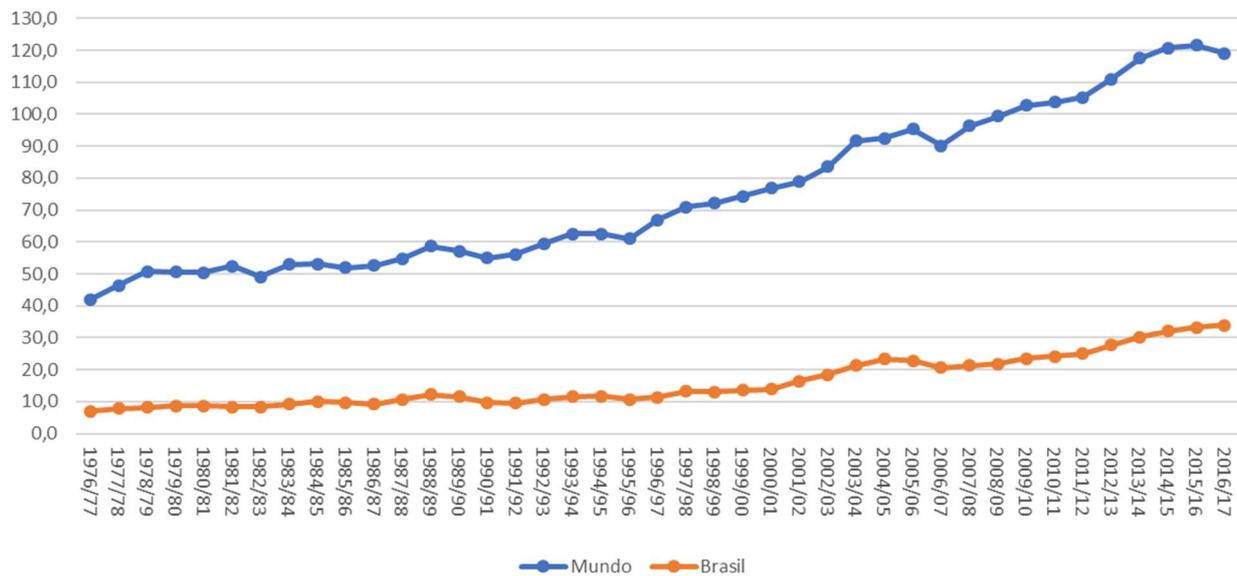


Figura 2. Série histórica da área plantada. Fonte: dados extraídos de Conab; Faostat; USDA (2018)

Produtividade da soja (1976/77 - 2016/17) em toneladas por hectare

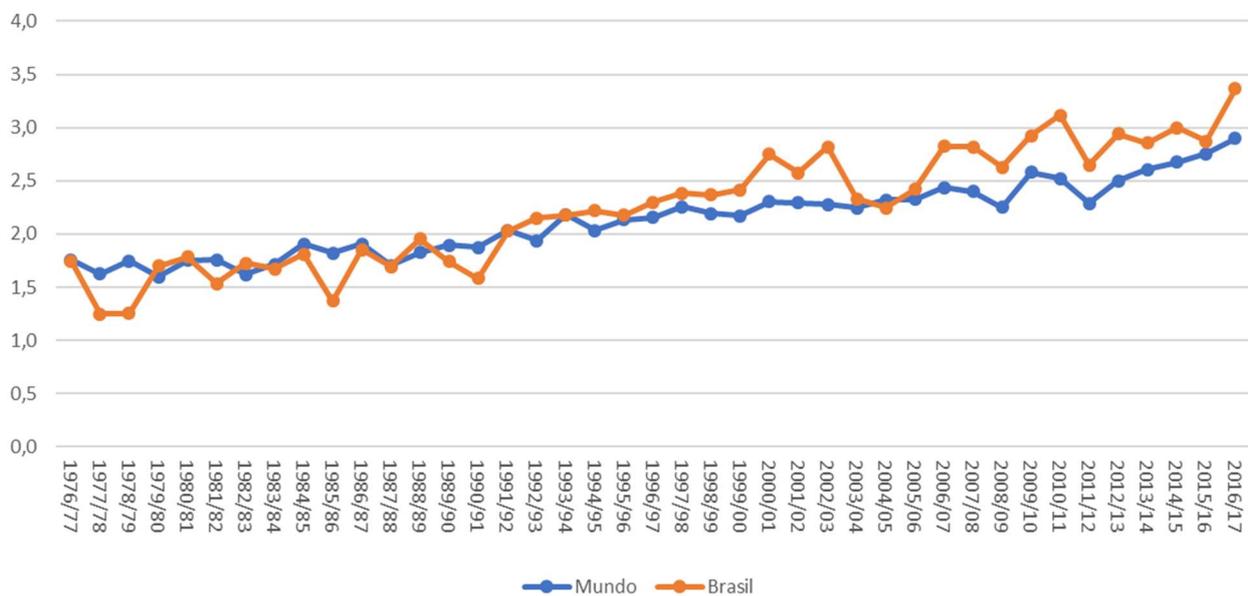


Figura 3. Série histórica da produtividade. Fonte: dados extraídos de Conab; Faostat; USDA (2018)

Em 1976/77 a produtividade mundial era de 1,8 ton ha⁻¹ e a brasileira de 1,7 ton ha⁻¹. Apesar de algumas variações, a produtividade nacional acompanhou o crescimento da média mundial até 1999/00, contudo, a partir desse período, nota-se um crescimento acima da média.

Atualmente, a produtividade mundial atinge 2,9 ton ha⁻¹ e a brasileira 3,4 ton ha⁻¹.

Por fim, a Figura 4 mostra um comparativo entre a produção no Brasil e no mundo nos últimos 41 anos.

Produção da soja (1976/77 - 2016/17) em milhões de toneladas

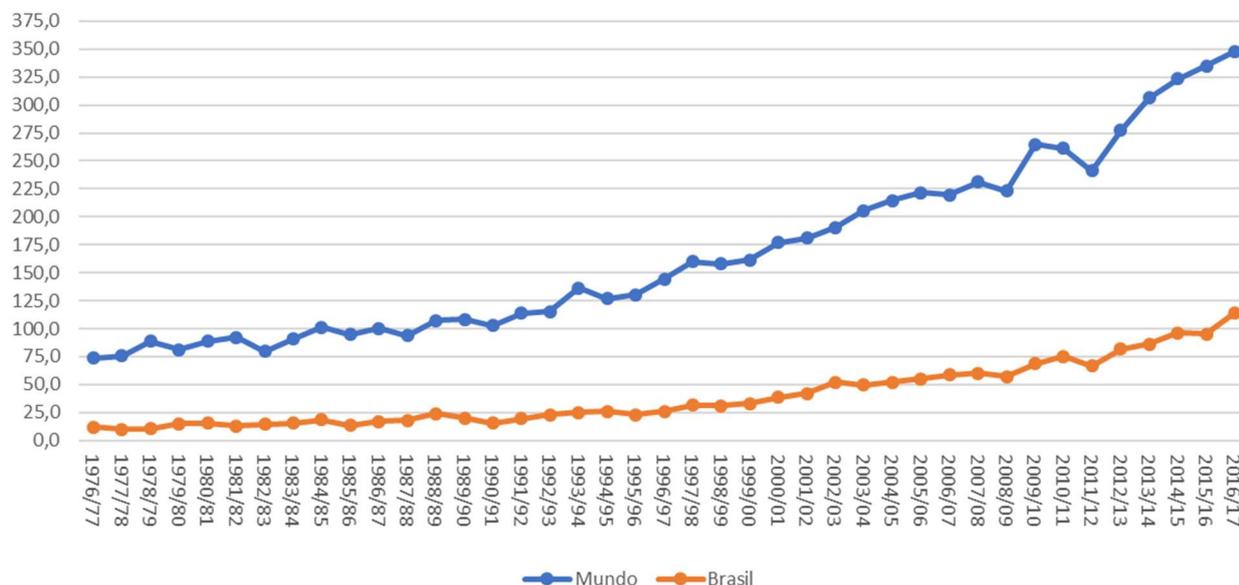


Figura 4. Série histórica da produção. Fonte: dados extraídos de Conab; Faostat; USDA (2018)

A produção mundial da soja em 1976/77 foi de 73,9 milhões de toneladas e a do Brasil 12,1 toneladas. Atualmente, o mundo produz 348,1 milhões de toneladas e o Brasil cerca de um terço dessa produção, 114,1 milhões de toneladas.

Esse aumento significativo na produção, deve-se a aumentos conjugados na produtividade e na área plantada. Assim, por meio dessas duas variáveis é possível se inferir a variação na produção.

De acordo com Pereira (2017), o maior desafio da agricultura é produzir comida suficiente para uma população mundial crescente. Assim sendo, torna-se importante projetar a produção no intuito de se tomar medidas decisórias. Para se realizar esse trabalho, é comum a utilização de modelos clássicos de previsões, por meio de análises de tendência de séries históricas.

Contudo, os modelos clássicos permitem que sejam feitas as previsões de uma única série, ou seja, não é possível conjugar diferentes séries temporais para esse intuito, desse modo, ao se projetar a produção, pouco importaria a variação na área plantada e na produtividade.

Além disso, ao se analisar as previsões em cada série, nem sempre ocorrem variações proporcionais, isso acontece, porque as séries apresentam suas características individuais de aleatoriedade, sazonalidade e tendência. Ao se estimar a variação na área plantada e

produtividade, pode-se estimar a previsão na produção pelo produto dessas duas variáveis. Entretanto, ao se aplicar modelos de projeção apenas na produção, percebe-se que os resultados das projeções não são equivalentes.

Visando uma solução mais abrangente, propõe-se nesse trabalho, a elaboração de uma rede neural artificial, com variáveis de entrada área plantada e produtividade para simular produções nacionais da soja em tempos futuros.

Laboissiere et al. (2015) propuseram uma RNA para prever o comportamento de ações de três empresas brasileiras de fornecimento de energia. A RNA se mostrou eficaz diante de um problema não linear que envolve análise aprofundada de índices, variáveis de abertura e fechamento, preço mínimo e máximo, bem como outros dados de entrada. Os autores sustentam, que esse tipo de análise só foi possível por meio da metodologia de RNA proposta.

Redes neurais artificiais (RNA) são ótimas para aprender padrões por meio de um conjunto de dados e tem sido úteis na resolução de problemas complexos e não lineares; uma resposta abrangente aos problemas de inteligência computacional de alta importância.

Redes Neurais Artificiais (RNA)

Em analogia as redes neurais biológicas,

uma rede neural artificial é um agregado de unidades computacionais conhecidas por neurônios artificiais (Figura 5). Cada neurônio possui terminais de entrada similares aos dendritos dos neurônios biológicos, por onde as informações são inseridas, posteriormente computadas, resultando um valor de saída que será propagado para outras unidades até a última camada provendo a resposta da rede (Ko et al., 2010; Kocamaz et al., 2016; Gomes et al., 2016; Silva et al., 2016, Wang et al., 2016).

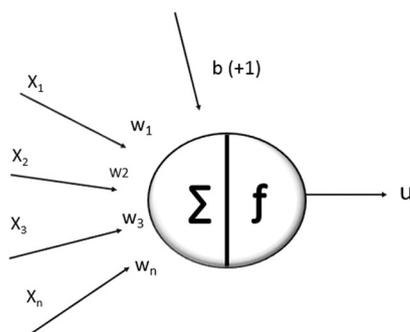


Figura 5. Neurônio artificial. Adaptado de Silva (2016)

As redes neurais podem ser treinadas para aprenderem sobre determinado padrão, sendo capazes de generalizar, ou seja, estimar dados incompletos ou desconhecidos, o que difere das técnicas tradicionais. É uma solução matemática capaz de lidar com problemas não-lineares e complexos (Ko et al., 2010; Kocamaz et al., 2016; Gomes et al., 2016; Silva et al., 2016, Wang et al., 2016).

O treinamento de uma RNA ocorre por meio de uma amostra de dados ocorridos no passado ($X_1...X_n$) ou de padrões relacionados a determinado objeto ou situação. Os dados inseridos no sistema alimentam os terminais de entrada do neurônio artificial. Cada dado é multiplicado por um peso específico ($W_1...W_n$), o que irá resultar em uma soma ponderada. Esse cálculo subtraído do limiar de ativação do neurônio (b), resulta no potencial de ativação a ser computado pela função apropriada que por sua vez irá replicar o resultado para os demais elementos da rede (Ko et al., 2010; Kocamaz et al., 2016; Gomes et al., 2016; Silva et al., 2016, Wang et al., 2016).

Material e Métodos

Os dados utilizados nesse trabalho foram coletados da Companhia Nacional de Abastecimento (CONAB) na série histórica de produção, produtividade e área plantada da soja no Brasil entre 1977 e 2017 (41 anos). A série está disponível em planilha do MS Excel no site da organização (CONAB, 2018).

Para criação e configuração da RNA utilizou-se o software Matlab R2017b. Foi criada uma Nonlinear Autoregressive Network with External Input NARX, considerada uma ótima solução para series temporais com múltiplas variáveis (Beale et al., 2017). A RNA foi elaborada com 25 neurônios e 5 atrasos (delay), (Figura 6). Os dados da planilha do MS Excel foram importados em dois vetores variáveis $x(t)$ e $y(t)$; para a variável $x(t)$ foram inseridos os dados de área plantada e produtividade e para a variável $y(t)$ os dados concernentes a produção (target).

Para treinamento, validação e teste foi selecionado o algoritmo Levenberg-Marquardt backpropagation e a configuração padrão do Matlab, com: 70% dos dados para treinamento, 15% para validação e 15% para teste; a performance foi estimada pelo erro quadrático médio (Beale et al., 2017)

Após o treinamento, o software forneceu os algoritmos para as simulações executadas nesse trabalho. Realizou-se simulações multi-step prediction em closed-loop e step ahead prediction em open-loop (Figura 7).

A simulação em múltiplos passos (multi-step prediction) é realizada em toda a série, considerando-se os valores originais e os valores previstos para cada período (Beale et al., 2017) Essa análise é comum em estudos de séries temporais, visando perceber-se a capacidade da função ou do algoritmo em realizar previsões. A diferença entre os dados originais e os previstos representam o erro estimado para previsões na série temporal. A partir dessa simulação calculou-se o erro percentual médio absoluto.

A simulação passo à frente (step ahead prediction) realiza a previsão para o próximo período (Beale et al., 2017), ou seja, a produção da soja para a safra 2017/2018.

A seguir, são demonstrados os resultados e discussões, primeiro sobre o treinamento e outros dados performados pelo software e após, sobre as simulações realizadas.

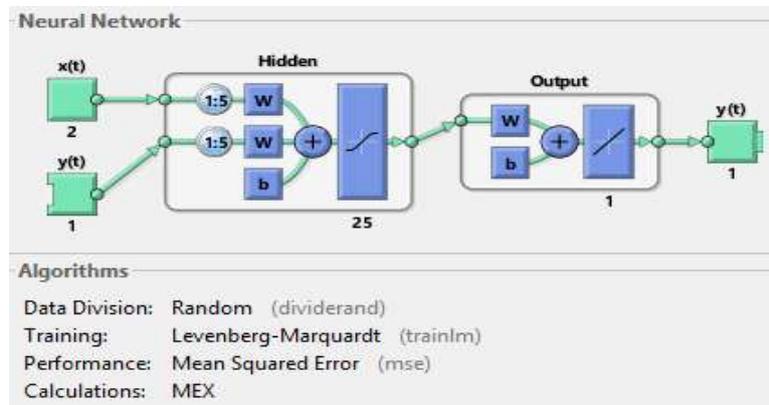


Figura 6. Neural Network. Fonte: Elaborado no Matlab R2017b

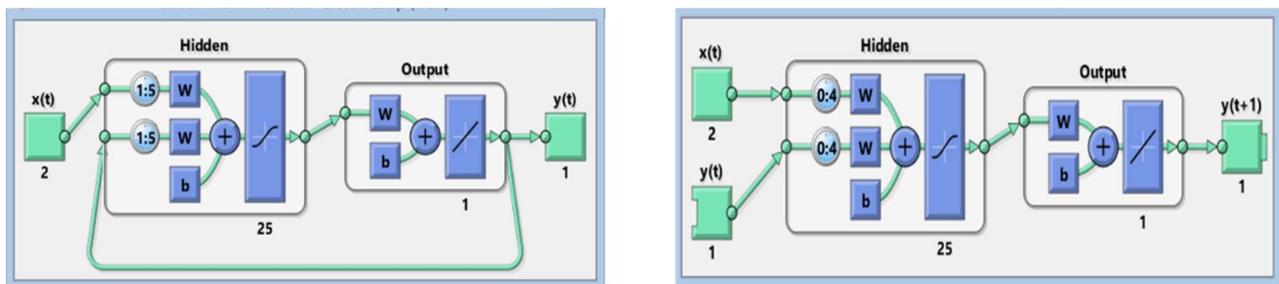


Figura 7. Multi-step prediction (esq.); step ahead prediction (dir.). Fonte: elaborado no Matlab R2017b

Resultados

Treinamento, validação e teste

Foram realizadas duas iterações (epochs) que dizem respeito ao aprendizado da rede após o processo de retroalimentação, realizado pelo algoritmo backpropagation (Beale et al., 2017). A Figura 8 demonstra a regressão e o coeficiente de correlação múltipla para as variáveis usadas em treinamento, validação e teste; além do conjunto com todas as variáveis.

A correlação múltipla é usada para explicar o comportamento do conjunto das variáveis. Pode ser obtido através da correlação entre os valores originais e os valores previstos; quanto mais próximo de 1, melhor (Costa neto, 2002). Os resultados apresentados na Figura 8, corroboram com uma rede apta a realizar inferências.

Os dados foram performados pelo Matlab

R2017b, onde se vê na Figura 9 a série temporal para 36 períodos (1982-2017); os primeiros cinco anos (1977-1981) não são apresentados pois serviram de atraso (delay), ocasionando um deslocamento da série e permitindo projeções futuras.

A resposta (response) representa o reconhecimento de padrões, ou seja, o aprendizado da rede; a diferença é o erro em relação aos dados originais (pontos azuis, vermelhos e verdes). Percebe-se que, com o deslocamento no tempo, a RNA minimizou o erro.

Além disso, como resultados preliminares, nota-se que a serie temporal analisada é tendenciosa para crescimento, com pouca aleatoriedade e nenhuma sazonalidade. A maior guinada de crescimento, pode ser percebida a partir do décimo sexto período, correspondente a safra de 1996/97.

A seguir são demonstradas as simulações e previsões realizadas.

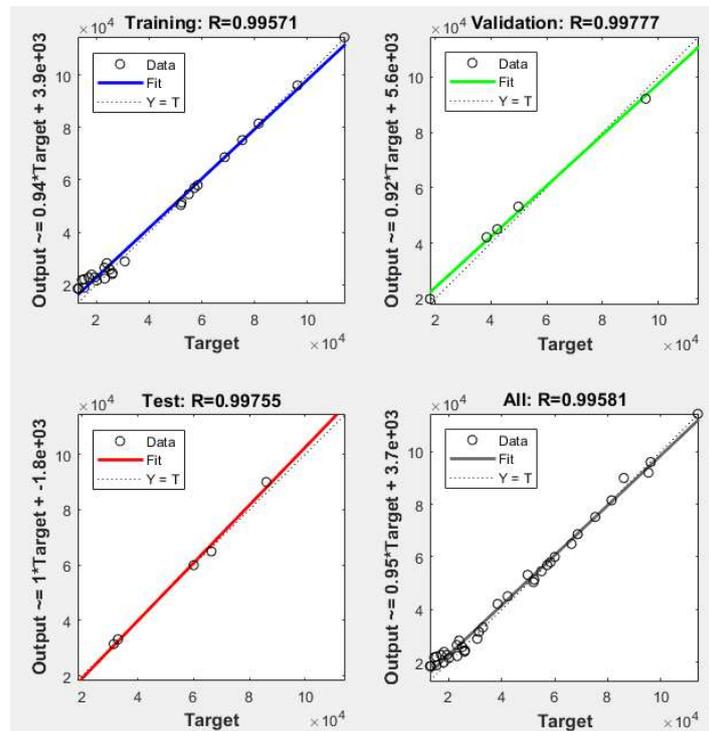


Figura 8. Treinamento da RNA. Fonte: elaborado no Matlab R2017b

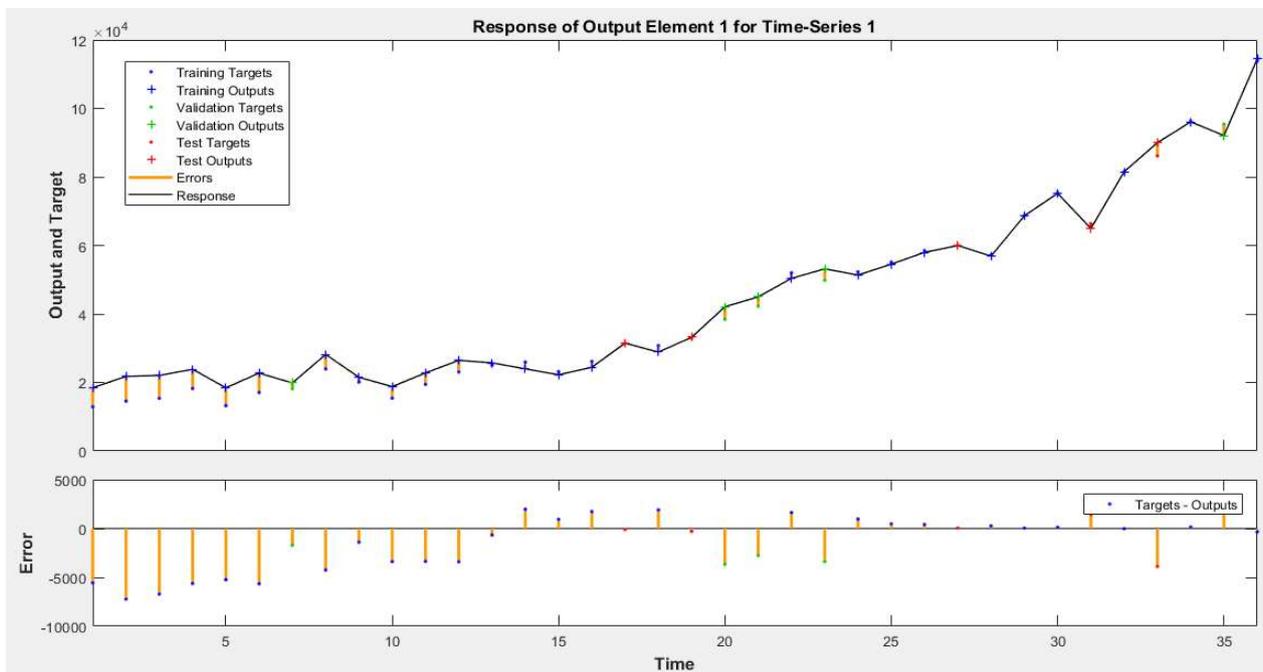


Figura 9. Dados originais. Fonte: elaborado no Matlab R2017b

Simulações e Previsões

A primeira simulação realizou previsões para cada período da série e comparou com os dados originais. As diferenças representam o erro estimado para previsões na série temporal. O

resultado dessa simulação pode ser verificado no gráfico da Figura 10.

Nesse caso, a resposta (response) diz respeito aos valores previstos, sendo que os pontos azuis representam os dados originais. O erro percentual médio absoluto calculado para

previsões foi de 17%.

A seguir foi realizada a simulação passo à frente (Figura 11), que demonstra a previsão para o próximo período, ou seja, a produção da soja para a safra 2017/2018.

Essa simulação retornou o mesmo

resultado da série temporal original, mais a previsão para a safra 2017/18, totalizando 42 anos da produção da soja no Brasil. Foi previsto uma produção de 108,1 milhões de toneladas, ou seja, uma pequena queda de 5% em relação à safra 2016/17.

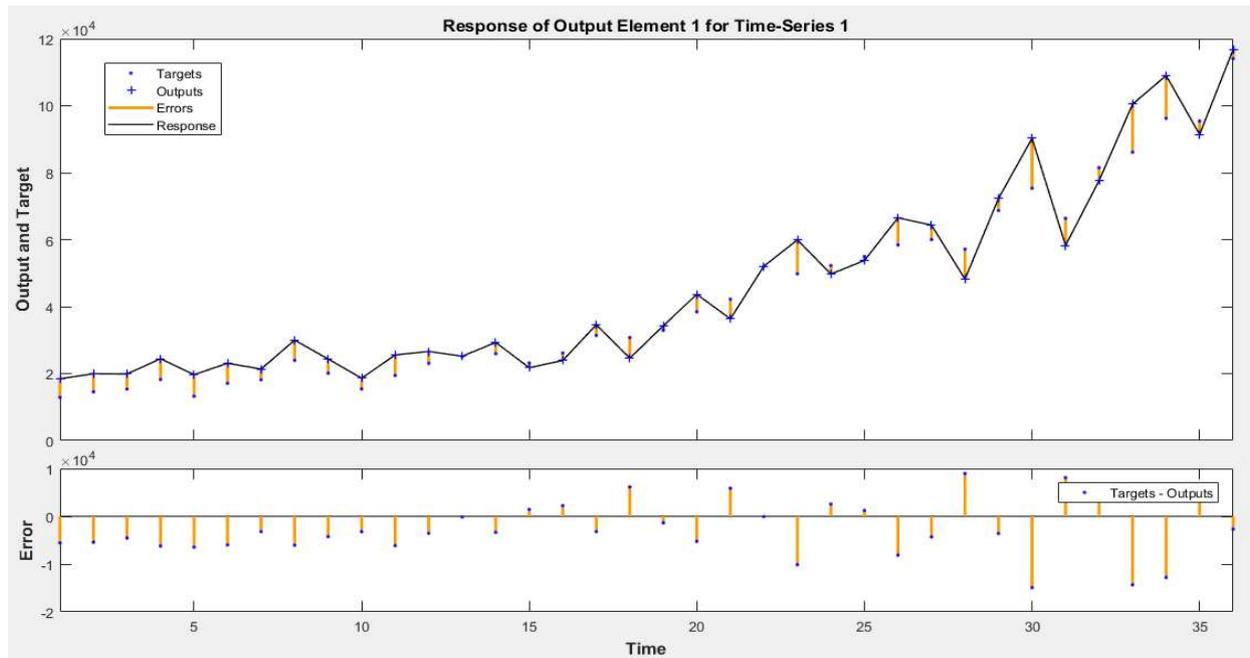


Figura 10. Dados originais e previstos. Fonte: elaborado no Matlab R2017b

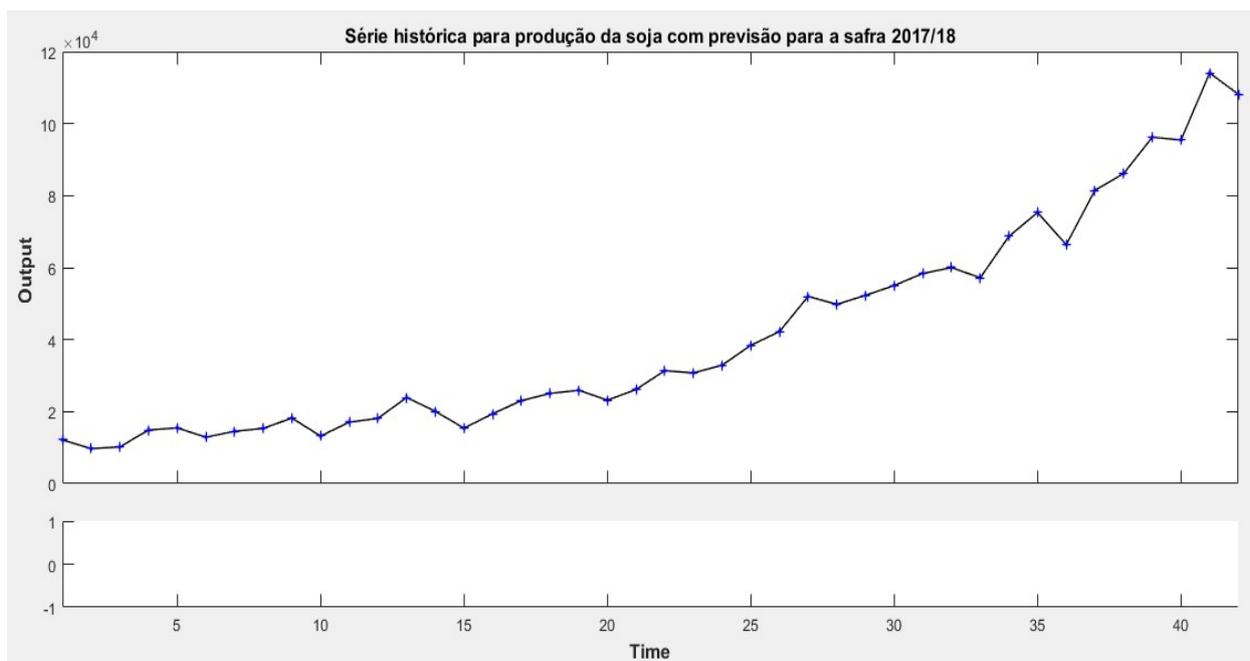




Figura 11. Previsão de um período a frente. Fonte: elaborado no Matlab R2017b

Discussão

A CONAB (2018) prevê uma queda de cerca de 1% na produção da safra 2017/2018, estima-se que isso ocorrerá em função de uma involução na produtividade de 4%, porém de um aumento na área plantada de 3%. Essa queda na produção prevista corrobora com a tendência demonstrada pelo modelo de RNA proposto nesse trabalho, muito embora, esse último tenha inferido um resultado pouco mais pessimista.

Apesar desse cenário, o Ministério da Agricultura, Pecuária e Abastecimento (MAPA), através de metodologia própria de projeção, onde são utilizados três modelos econométricos: Passeio Aleatório (Random Walk), Box & Jenkins (Arima) e Modelo de Espaço de Estados, estima uma produção nacional da soja em 129,2 milhões de toneladas, para a safra de 2025/2026; se isso se concretizar o Brasil poderá superar os Estados Unidos na produção do grão.

Dentre os 129,2 milhões de toneladas previstos, estima-se que 53,4 milhões de toneladas serão para o consumo interno e 78 milhões de toneladas para exportações. Isso equivale a um aumento de 35,1% na produção, 22,6% no consumo e 41% nas exportações ao se considerar um período de 10 anos (2015/16 – 2025/26) (MAPA, 2016).

Ainda de acordo com o MAPA (2016), o crescimento na produção deverá ocorrer principalmente em função do aumento da área plantada, podendo atingir 43,2 milhões de hectares em 2026. Isso deve ocorrer, porque alguns estados do nordeste do Brasil, apesar de infraestrutura deficitária, têm se mostrado promissores promovendo uma expansão da área plantada nacional.

Percebe-se uma expansão para esses estados, uma vez que as regiões sul e centro-oeste (maiores produtoras) operam no limite da área plantada, podendo otimizar a produção através do emprego de novas tecnologias no intuito de se maximizar a produtividade.

Apesar da expansão da área plantada, o cuidado de se evitar o avanço em áreas nativas, deve ser observado, sendo fator de limitação para futuras explorações. Outros fatores que podem

afetar a produção são: competição por água e terra, mudanças e incertezas climáticas, políticas governamentais e declínio nos serviços (Pereira, 2017). Nesse contexto, é importante a aplicação de modelos de governança, principalmente em relação a irrigação, pois envolve água e energia, recursos cada vez mais escassos e discutidos em fóruns mundiais.

Em contraponto, as inundações ou excessos podem também prejudicar a produção de grãos. Ghalkhani et al. (2013) propuseram sistemas inteligentes dinâmicos, sendo esses: uma rede neural artificial e um sistema híbrido que combina redes neurais com lógica fuzzy (rede neural fuzzy); ambos os sistemas demonstraram bons resultados para simulações e previsões de inundações de forma dinâmica, ou seja, em tempo real.

Embora a RNA utilizada nesse trabalho tenha sido estática, ou seja, tenha lidado com dados sem novas entradas, há a possibilidade de se trabalhar no futuro com modelos dinâmicos; outra característica que difere dos modelos clássicos de previsões.

Com o crescimento acelerado da população mundial, tornam-se importantes as discussões sobre a produção de grãos. Um tipo de commodity muito apreciado na alimentação de pessoas e na criação de animais tem sido a soja, com um volume expressivo de 348,1 milhões de toneladas produzidos durante a safra de 2016/17. Desse valor, o Brasil produziu cerca de um terço, o que demonstra sua importância no mercado mundial do agronegócio.

Nesse contexto, objetivou-se inicialmente, analisar as séries temporais da área plantada, produtividade e produção da soja brasileira nos últimos 41 anos. As séries analisadas apresentaram tendência de crescimento, nenhuma sazonalidade e pouca aleatoriedade.

Conclusão

Diante desse cenário, foi proposto um modelo de rede neural artificial para se realizar previsões da soja. O modelo proposto atendeu as expectativas, com erros mínimos, demonstrados na correlação múltipla do treinamento, validação e



teste das variáveis. A simulação em “múltiplos passos” foi útil para se extrair o erro percentual médio absoluto em relação a capacidade da rede de se fazer previsões. Foi detectado um erro de 17%, que poderá ser minimizado em trabalhos futuros. A simulação “um passo a frente” previu uma produção de 108,1 milhões de toneladas, para a safra 2017/2018, ou seja, uma pequena queda de 5% em relação à safra 2016/17. Apesar dessa perspectiva, o Ministério da Agricultura, Pecuária e Abastecimento, estima um crescimento para os próximos anos e se isso se concretizar o Brasil poderá superar os Estados Unidos na produção do grão em 2025/2026.

A principal limitação desse trabalho diz respeito a comparação com os modelos clássicos de previsões. A RNA foi proposta, pois permitiu a utilização conjugada de três séries distintas, porém relacionadas no modelo de previsão, principal diferença em relação aos modelos clássicos. Apesar desse diferencial, dos resultados obtidos e da capacidade da rede neural apontada pela literatura, faz-se necessário comparar os resultados conseguidos, com outros modelos de previsões, objetivando-se apontar o melhor entre eles para essas variáveis.

Em trabalhos futuros pretende-se atualizar os dados da série histórica e utiliza-los em modelos clássicos de previsões, além da rede neural em diferentes configurações; os diferentes modelos poderão ser comparados e classificados, provendo uma resposta a lacuna encontrada nessa contribuição.

Agradecimentos

Os autores agradecem a Sunsetti Treinamentos e Serviços e a Universidade Paulista UNIP pelo apoio financeiro.

Referências

BEALE, M.H.; HAGAN, M.T.; DEMUTH, H.B. Neural Network Toolbox. Getting Started Guide, 2017

CONAB. Companhia Nacional de Abastecimento. Séries Históricas de Área Plantada, Produtividade e Produção. Disponível em: <<https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras>>, acesso em: 10/05/2018.

COSTA NETO, PEDRO L. Estatística. 2ª edição. São Paulo. Blucher, 2002.

DEAGRO. Departamento do Agronegócio. “Balança Comercial Brasileira do Agronegócio - Consolidado 2017” Disponível em: <<http://www.fiesp.com.br/indices-pesquisas-e-publicacoes/balanca-comercial/attachment/file-20180118113431-bca2017/>>, acesso em: 10/05/2018

FAOSTAT. Food and Agriculture Organization of the United Nations. Disponível em: <<http://www.fao.org/faostat/en/#data/QC>>, acesso em: 10/05/2018

IBGE. Instituto Brasileiro de Geografia e Estatística (2018). “Apresentação PIB 2017”. Agência de Notícias IBGE. Disponível em: <<https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/20166-pib-avanca-1-0-em-2017-e-fecha-ano-em-r-6-6-trilhoes.html>>, acesso em: 10/05/2018

GHALKHANI, H.; GOLIAN, S.; SAGHAFIAN, B.; FAROKHNI, A.; SHAMSELDIN, A. Application of surrogate artificial intelligent models for real-time flood routing. Water and Environment Journal, vol. 27, n. 4, pp 535-548., 2013

GOMES, LUIZ F.A.M.; MACHADO, MARIA A.S.; CALDEIRA, ANDRE M.; SANTOS, DANILO J.; NASCIMENTO, WALLACE J. D. Time Series Forecasting with Neural Networks and Choquet Integral. Information Technology and Quantitative Management (ITQM). Procedia Computer Science v. 91. pp. 1119 – 1129, 2016

KO, M.; TIWARI, A.; MEHNEN, J. . A Review of Soft Computing Applications in Supply Chain Management. Applied Soft Computing v. 10(3), pp.661–674, 2010

KOCAMAZ, UGUR ERKIN; TASKIN, HARUN, UYAROGLU, YILMAZ, GOKSU, ALPER. Control and Synchronization of chaotic supply chains using inteligente approaches. Computers & Industrial Engineering vol. 102, pp. 476-487,



2016

LABOISSIERE, L.A., FERNANDES, R.A., LAGE, G.G.. Maximum and minimum stock price forecasting of brazilian power distribution companies based on artificial neural networks. *Applied Soft Computing* vol 35, pp. 66 – 74, 2015

MAPA. Ministério da Agricultura, Pecuária e Abastecimento. Projeções do Agronegócio. Brasil 2015/16 a 2025/26. Projeções de Longo Prazo. Secretaria de Política Agrícola - SPA. Departamento de Crédito e Estudos Econômicos, 2016

MDCI. Ministério e Desenvolvimento Indústria e Comércio Exterior (2018). “Séries Históricas - Balança Comercial Brasileira 1989-2017”. Disponível em: <<http://www.mdic.gov.br/comercio-exterior/estatisticas-de-comercio-exterior/series-historicas>>, acesso em: 10/05/2018

PEREIRA, LUIS. S. Water, Agriculture and Food: Challenges and Issues. *Water Resources Management*. vol. 31, n. 10, pp 2985–2999, 2017

SILVA, IVAN N.; SPATTI, DANILO H.; FLAUZINO, ROGÉRIO A.. Redes neurais artificiais para engenharia e ciências aplicadas. Fundamentos teóricos e aspectos práticos. 2ª edição, revisada e ampliada. São Paulo. Artliber, 2016

USDA. United States Department of Agriculture. Foreign Agricultural Service. Table 11: Soybean Area, Yield, and Production, Disponível em: <<https://apps.fas.usda.gov/psdonline/app/index.html#/app/downloads>>, acesso em 12/09/2018.

WANG, JIAQIU; TSAPAKIS, IOANNIS; ZHONG, CHEN. A space-time delay neural network model for travel time prediction. *Engineering Applications of Artificial Intelligence*. vol. 52, pp. 145–160, 2016.