



ISSN: 2447-5580

Disponível em: <http://periodicos.ufes.br/BJPE/index>



ARTIGO ORIGINAL

OPEN ACCESS

PREVISÕES DE INDICADORES DA SOJA NO ESTADO DE MATO GROSSO A PARTIR DE MODELOS BASEADOS EM SÉRIES TEMPORAIS

FORECASTS OF SOYBEAN INDICATORS IN THE MATO GROSSO STATE FROM MODELS BASED ON TIME-SERIES

Rodolfo Benedito Zattar da Silva^{1*}, Fábila Fernanda da Costa Aires², Eduardo José Oenning³, Alexandre Gonçalves Porto⁴, & Alexandre Volkmanh Ultramar⁵

¹ Universidade Federal de Mato Grosso, Faculdade de Engenharia, Campus Universitário de Várzea Grande, Av. Projetada A, S/Nº, Bairro Chapéu do Sol, CEP 78156-105, Várzea Grande – MT; ² Universidade de Cuiabá, Campus Barão, Cuiabá-MT; ^{3,4,5} Universidade do Estado de Mato Grosso, Campus Universitário Dep. Est. Renê Barbour, Barra do Bugres-MT.

^{1*} rodolfoengenheiro@hotmail.com ² fabia_aires@hotmail.com ³ eduardo.epa@gmail.com ⁴ agporto@unemat.br ⁵ professoralexandre215@gmail.com

ARTIGO INFO.

Recebido em: 26/01/2019

Aprovado em: 21/02/2019

Disponibilizado em: 05/07/2019

PALAVRAS-CHAVE:

Séries temporais; previsões; indicadores; soja.

KEYWORDS:

Times-series; forecasts; indicators; soybean.

*Autor Correspondente: Silva, R.B.Z.da.

RESUMO

O estado de Mato Grosso se destaca como o maior produtor nacional de soja. Diante deste contexto, realizar o processo de modelagem e previsão dos indicadores desta cultura se configura como uma atividade muito importante para o planejamento e acompanhamento das safras. Deste modo, o presente trabalho teve como objetivo realizar a aplicação e avaliação dos desempenhos apresentados pelos modelos baseados em séries temporais para previsões de produção, área plantada e produtividade da soja no estado de Mato Grosso. Para isto, foram coletados dados históricos na base de dados Série Histórica das Safras da Companhia Nacional de Abastecimento (CONAB), referentes aos períodos das safras de 1976/1977 a 2016/2017. Todos os processos de análises, modelagens e previsões foram realizados através de planilhas eletrônicas desenvolvidas para estes fins. Com os resultados obtidos, pôde-se verificar que os modelos que apresentaram os

melhores desempenhos para prever os indicadores da soja foram os de suavização exponencial com tendência para a série histórica de produção, suavização exponencial simples para a série histórica da área plantada e média móvel ponderada para a série temporal da produtividade. Estes modelos foram então utilizados para obter as previsões da safra de 2017/2018 destes indicadores.

ABSTRACT

The Mato Grosso State stands out as the largest national soybean producer in Brazil. Given this context, the modeling and forecasting process of the indicators of this crop is a very important activity for the planning and monitoring of the crops. In this sense, the present work had the objective of applying and evaluating the performances presented by the models based on time series for forecasts of production, planted area and soybean yield in the Mato Grosso State. For this purpose, historical data were collected from the Historical Data Series of the National Company of Supply (CONAB), referring to the crops periods from 1976/1977 to 2016/2017. All analysis, modeling and forecasting processes were performed through spreadsheets. With the results obtained, it was possible to verify that the models that presented the best performances to predict the soybean indicators were those of exponential smoothing with trend (or linear model of Holt) to the historical series of production, simple exponential smoothing for the historical series of the planted area and weighted moving average for the time series of productivity. These models were then used to obtain forecasts for the 2017/2018 crops of these indicators



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

INTRODUÇÃO

A soja tem sido considerada como uma das mais importantes culturas para o contexto da economia mundial. O maior produtor mundial desta oleaginosa é os Estados Unidos, seguido pelo Brasil. Os dados mais recentes divulgados pela Companhia Nacional de Abastecimento (CONAB), mostram que, no Brasil, esta cultura ocupou uma área de 35,149 milhões de hectares, produção de 119,281 toneladas e uma produtividade média de 3.394 kg por hectare na safra de 2017/2018 (CONAB, 2018).

O estado de Mato Grosso tem se consagrado como o maior produtor de soja no contexto nacional com uma produção de 32,306 milhões de toneladas na safra de 2017/2018. O segundo maior produtor é o estado do Paraná com 19,170 milhões de toneladas, seguido pelo Rio Grande do Sul com 17,150 milhões de toneladas (CONAB, 2018).

Tendo em vista a representatividade econômica que o estado de Mato Grosso possui no cenário nacional e internacional com a produção de soja, realizar modelagens e previsões das séries históricas de indicadores desta cultura, se configura como uma atividade de fundamental importância para o planejamento de safras e o processo de tomada de decisões como um todo.

Isto, porque, as informações relacionadas às previsões de indicadores de *commodities* como a soja, permitem que os agentes envolvidos nas atividades de produção e comercialização de tais *commodities* possam tomar decisões relacionadas ao planejamento do volume de estoque para o consumo interno, produção e exportação de biodiesel, planejamento da área plantada, investimentos em tecnologias emergentes, aumento de produtividade, bem como ajudar as instituições públicas na identificação de necessidade de investimentos no agronegócio, dentre outras (Nomelini, et al., 2017).

Os modelos de previsões baseados em séries temporais refletem os padrões de oscilações passadas de uma determinada variável e, posteriormente, utiliza estas informações para previsões das oscilações em momentos futuros (Pindyck & Rubinfeld, 2004). Diversos pesquisadores utilizaram modelos baseados em séries temporais para previsões de indicadores de *commodities* produzidas e comercializadas no Brasil, dentre os quais se destacam: Cas (2018) que realizou a aplicação de modelos para previsões de preços de milho no mercado brasileiro, Nomelini et al. (2017) que utilizaram modelos para previsões de produção, óleo, área e produtividade de soja no Brasil e Rocha et al. (2015) que fizeram uso de modelos para previsões do preço do café arábica tipo 6 no Brasil.



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

Diante deste contexto, a realização deste estudo apresenta uma série de contribuições para os contextos social, da literatura e da Engenharia de Produção. Para o contexto social, as informações obtidas neste trabalho permitem que os agentes públicos possam realizar previsões de recolhimentos de impostos gerados pelo setor que, posteriormente, são convertidos em previsões de investimentos em obras e serviços públicos. Além disso, tais informações podem auxiliar nas previsões da necessidade de emprego de mão-de-obra para o setor, que é um importante indicador econômico. Para a literatura, as aplicações de modelos de previsões comumente utilizados por diversos autores utilizando outras bases de dados, reforçam que os mesmos são robustos para serem utilizados em uma base de dados de uma determinada região e de uma cultura específica da cadeia produtiva do agronegócio. Por fim, para o campo da Engenharia de Produção, o estudo fornece informações importantes para os profissionais que atuam tanto na atividade direta de produção de soja quanto para aqueles que atuam em organizações à montante e à jusante desta cadeia para realizarem os planejamentos das operações em seus respectivos campos de atuação, que incluem os planejamentos financeiros/econômicos, de apoio à produção, bem como da logística de abastecimento e de distribuição.

Sendo assim, o presente trabalho teve como objetivo aplicar e avaliar os desempenhos apresentados pelos modelos baseados em séries temporais para obtenção de previsões da produção, área plantada e produtividade de soja no estado de Mato Grosso.

O trabalho está dividido em cinco seções, incluindo esta introdução. Na seção 2, é apresentada a revisão bibliográfica em relação ao tema abordado. Na seção 3, são apresentados os procedimentos metodológicos adotados na execução do estudo. Já na seção 4, são apresentados os resultados obtidos. Por fim, a seção 5, apresenta as considerações finais do trabalho.

2 REVISÃO BIBLIOGRÁFICA

As técnicas de previsão são classificadas basicamente em dois grupos que dependem do contexto da análise e da disponibilidade de informações. Assim, as técnicas são classificadas em: i) qualitativas; e, ii) quantitativas (Caniato, Kalchschmidt, & Ronchi, 2011).

Segundo Rosienkiewicz et al. (2017), a simplicidade e os custos relativamente baixos são as principais características das técnicas qualitativas. Elas são apropriadas para situações em que há pouco ou nenhum registro de dados, sendo menos estruturadas quando comparadas com as



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

técnicas quantitativas. O método Delphi, analogia histórica e grupo focal se configuram como as principais técnicas qualitativas utilizadas no campo acadêmico e empresarial.

Por sua vez, as técnicas quantitativas precisam de um conjunto de dados históricos para obtenção das previsões. As previsões através destas técnicas são obtidas por meio de modelos causais ou baseados em séries temporais. Os modelos causais se preocupam em identificar e compreender as variáveis que interferem nos padrões da variável estudada. Já os modelos baseados em séries temporais são utilizados para se extrair um padrão e, a partir da projeção dele, obter as previsões futuras (Rosienkiewicz, et al., 2017)

Os modelos causais são estruturados por meio de análise de regressão e podem ser divididos em: i) regressão linear simples; e, ii) regressão linear múltipla. Dentre os principais modelos baseados em séries temporais, se encontram os métodos de decomposição, médias móveis (simples e ponderada), modelos de suavização exponencial e os modelos de Box-Jenkins (ARIMA).

A seguir, são apresentadas as principais características dos modelos quantitativos de previsão baseados em séries temporais que foram considerados para análise no presente trabalho, sendo eles: média móvel simples, média móvel ponderada, suavização exponencial simples, suavização exponencial com tendência (modelo linear de Holt) e suavização exponencial com tendência e sazonalidade (modelo de Holt-Winters).

2.1 MODELOS DE PREVISÕES BASEADOS EM SÉRIES TEMPORAIS

A previsão pelo método de previsão denominado de média móvel simples é obtida a partir da escolha dos dados de um determinado número de períodos, geralmente os mais recentes. Ela consiste na média aritmética dos n últimos períodos dos dados observados (Ali, Babai, Boylan, & Syntetos, 2017).

Já a média móvel ponderada consiste em uma variação da média móvel simples. A principal diferença entre esta técnica e a média móvel simples, é que na média móvel ponderada é considerado um peso maior para o último período observado, outro ligeiramente menor para o penúltimo período e assim por diante até o último período considerado para que se vá para a estimativa. Deste modo, a soma dos pesos atribuídos deve ser igual a um (Sridevi, Palaniappan, & Palanisamy, 2018).

A suavização exponencial simples é um método mais sofisticado em relação às médias móveis simples e ponderada, considerando apenas o nível da série temporal no processo de



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

modelagem (Veiga, Veiga, Puchalski, Coelho, & Tortato, 2016). Esta técnica parte do princípio que os dados mais recentes são mais importantes para a previsão do que os mais antigos. Sendo assim, os dados mais recentes são atribuídos com um peso maior para obter a previsão. O modelo usa a média móvel ponderada com pesos que diminuem exponencialmente à medida que novos dados são observados, acrescentando uma parcela do erro de previsão (Bergmeir, Hyndman, & Benítez, 2016).

Já a suavização exponencial com tendência ou modelo linear de Holt, é usualmente aplicado quando os dados apresentam uma tendência linear de crescimento ou decrescimento, considerando duas constantes de suavização (α e β) e três equações (Da Veiga, et al., 2016).

Por fim, é apresentado o modelo de suavização exponencial com tendência e sazonalidade ou método linear de Holt-Winters. Esta técnica é comumente usada em situações em que os dados possuem tendência e sazonalidade e apresenta duas formas distintas para sua aplicação, sendo elas: i) multiplicativa; e, ii) aditiva. O tipo de abordagem a ser utilizada depende da forma como ocorre a sazonalidade, sendo que a atuação dos índices sazonais é a principal diferença entre elas. A abordagem multiplicativa é recomendada para séries temporais em que a amplitude do ciclo sazonal (diferença entre o maior e menor ponto deste ciclo) aumenta com o tempo. Já a abordagem aditiva é utilizada para séries temporais em que a amplitude é constante ao longo do tempo (Holt, 2004).

O Quadro 1 apresenta o conjunto de equações dos modelos apresentados acima e que foram avaliados para obtenção das previsões. No Quadro 1, MMS_n é a média móvel simples de n períodos, MMP_n é a média móvel ponderada de n períodos, F é o valor da observação prevista, Y é o valor da observação real, P é o peso atribuído ao valor real do período, L é a estimativa do nível da série temporal, b é a estimativa de tendência da série temporal, S é o índice sazonal da série temporal, α , β e γ são as constantes de suavização (com valores entre 0 e 1, não correlacionados, que controlam o peso relativo ao nível, à tendência e à sazonalidade, respectivamente), t é o instante de observação no tempo ($t = 1, 2, 3...$) e, m são os períodos à frente que se deseja obter previsões ($m = 1, 2, 3...$).



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

Quadro 1: Equações dos modelos de previsão

Modelos	Equações	Nº
Média Móvel Simples	$MMS_n = \frac{\sum_{t=1}^n Y_t}{n}$	(1)
Média Móvel Ponderada	$MMP_n = (Y_t \times P_t) + (Y_{t-1} \times P_{t-1}) + (Y_{t-2} \times P_{t-2})$	(2)
Suavização Exponencial Simples	$F_t = F_{t-1} + \alpha(Y_{t-1} - F_{t-1})$	(3)
Suavização Exponencial com Tendência (modelo linear de Holt)	$F_{t+m} = L_t + b_t m$	(4)
	$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1})$	(5)
	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	(6)
Suavização Exponencial com Tendência e Sazonalidade (Holt-Winters - método multiplicativo)	$F_{t+m} = (L_t + b_t m) S_{t-s+m}$	(7)
	$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1})$	(8)
	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	(9)
	$S_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	(10)
	$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s}$	(11)
Suavização Exponencial com Tendência e Sazonalidade (Holt-Winters - método aditivo)	$F_{t+m} = (L_t + b_t m) + S_{t-s+m}$	(12)
	$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$	(13)
	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	(14)
	$S_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	(15)
	$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$	(15)

3 PROCEDIMENTOS METODOLÓGICOS

A classificação de uma pesquisa científica é realizada por categorias que se dividem quanto à sua natureza, à abordagem do problema, aos objetivos e aos procedimentos utilizados (Prodanov & Freitas, 2013). O Quadro 2 apresenta a classificação da presente pesquisa.

Quadro 2: Classificação da pesquisa

Categorias	Classificação
Natureza	Pesquisa aplicada
Abordagem	Pesquisa quantitativa
Objetivos	Pesquisa exploratória
Procedimentos	Estudo de caso

Segundo Prodanov & Freitas (2013), a pesquisa aplicada busca gerar conhecimentos para uma abordagem prática na resolução de problemas específicos que envolvem verdades e interesses locais. A classificação do presente trabalho como uma pesquisa aplicada, se deve ao fato que buscou-se avaliar os desempenhos de técnicas de previsão e selecionar aquela mais acurada para obter previsões futuras dos indicadores da soja no estado de Mato Grosso.

A pesquisa quantitativa consiste na mensuração do objetivo estudado, ou seja, busca transformar as informações em números para uma análise efetiva dos mesmos (Bicudo, 2006).



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

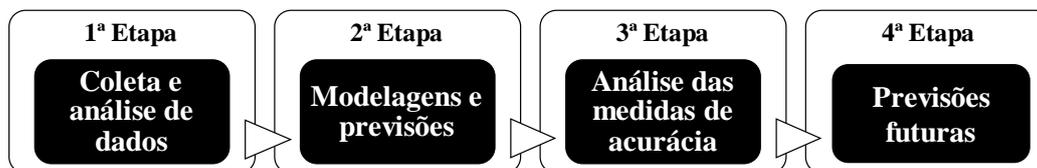
No presente trabalho, foram utilizados modelos matemáticos para obtenção das previsões, bem como de indicadores de desempenho para mensurar a acurácia de tais modelos.

Já a pesquisa exploratória procura proporcionar informações detalhadas em relação ao assunto estudado, facilitar a delimitação do tema, definir os objetivos ou até mesmo formular as hipóteses do estudo, ou ainda, fazer a descoberta de um novo foco para o trabalho a ser desenvolvido. Geralmente, este tipo de pesquisa assume as formas de pesquisa bibliográfica e estudo de caso (Gil, 2008).

O estudo de caso tem como principal característica a pesquisa detalhada e aprofundada de um ou poucos objetos com o intuito de possibilitar o amplo e detalhado conhecimento (Gil, 2008).

Com o intuito de atingir o objetivo proposto, o estudo foi realizado em quatro etapas principais, conforme apresentado na Figura 1. Na sequência, são apresentados de forma detalhada como foram realizadas cada uma dessas etapas.

Figura 1: Etapas de execução do trabalho



1ª Etapa – coleta e análise de dados: nesta etapa foram obtidos os dados da produção, área plantada e produtividade da cultura da soja no estado de Mato Grosso. Os dados utilizados para as modelagens e previsões das séries temporais destes três indicadores possuem 41 observações, com periodicidade anual, iniciando na safra de 1976/1977 e terminando na safra de 2016/2017. As séries históricas foram obtidas na base de dados Safras da Companhia Nacional de Abastecimento (CONAB), disponível através do seguinte endereço: [https://www.conab.gov.br](https://www.conab.gov.br/index.php/info-agro/safras/serie-historica-das-safras?Start=20)

[/index.php/info-agro/safras/serie-historica-das-safras?Start=20](https://www.conab.gov.br/index.php/info-agro/safras/serie-historica-das-safras?Start=20). Como um processo de análise preliminar, as séries históricas foram representadas graficamente para auxiliar na identificação dos seus padrões para, posteriormente, realizar as modelagens e previsões através dos modelos apresentados anteriormente na revisão bibliográfica.

2ª Etapa – modelagens e previsões: nesta etapa, foi realizada primeiramente a divisão do conjunto de dados das três séries históricas estudadas. Tais séries temporais foram divididas



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

em duas partes, sendo que as 31 primeiras observações foram utilizadas para treino (ajuste dos modelos) e as demais para validação (verificação dos ajustes dos modelos). Todos os processos de análises, modelagens e previsões das séries históricas foram realizados fazendo-se o uso de planilhas eletrônicas desenvolvidas para estes fins. As constantes de suavização (α e β) dos modelos de suavização exponencial simples e com tendência foram determinadas com auxílio do aplicativo de otimização Solver do MS Excel. Este aplicativo realiza a variação dos valores das constantes (α e β) com o objetivo de minimizar os erros utilizados considerados como parâmetros para avaliar as acurácias dos modelos.

3ª Etapa – análise das medidas de acurácia: os desempenhos apresentados pelos modelos de previsões aplicados, foram avaliados através das seguintes medidas de acurácia: i) Erro Absoluto Médio ou *Mean Absolute Error* (MAE); ii) Erro Quadrático Médio ou *Mean Squared Error* (MSE); e, iii) Erro Percentual Absoluto Médio ou *Mean Absolute Percentage Error* (MAPE). As equações destas medidas de acurácia são apresentadas no Quadro 3.

Quadro 3: Equações das medidas de acurácia

Siglas	Equações	Nº
MAE	$\frac{\sum_{t=1}^n E_t }{n}$	(16)
MSE	$\frac{\sum_{t=1}^n (E_t)^2}{n}$	(17)
MAPE	$\frac{\sum_{t=1}^n E_t/Y_t * 100}{n}$	(18)

De modo que: E_t é o erro de previsão no instante t ; n é o número de observações; Y_t é a observação real no tempo t ; e, $t = 1, 2, \dots, n$.

4ª Previsões futuras: os modelos que apresentaram os melhores desempenhos, ou seja, os menores erros de previsões para cada série histórica analisada, foram utilizados para obtenção das previsões para o próximo período (safra de 2017/2018). Posteriormente, os valores previstos para a safra de 2017/2018 foram comparados com os dados reais divulgados oficialmente pela Companhia Nacional de Abastecimento (CONAB) para verificar as precisões dos modelos selecionados.

4 APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

As Figuras 2, 3 e 4 apresentam as séries temporais com as respectivas linhas de tendência da produção, área plantada e produtividade da cultura da soja no estado de Mato Grosso.



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

Figura 2: Série histórica da produção de soja no estado de Mato Grosso

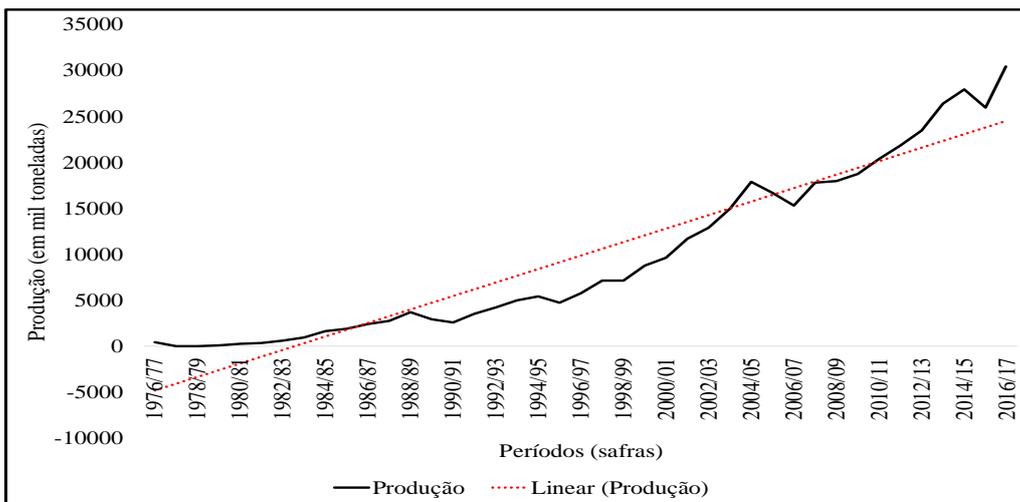


Figura 3: Série histórica da área plantada de soja no estado de Mato Grosso

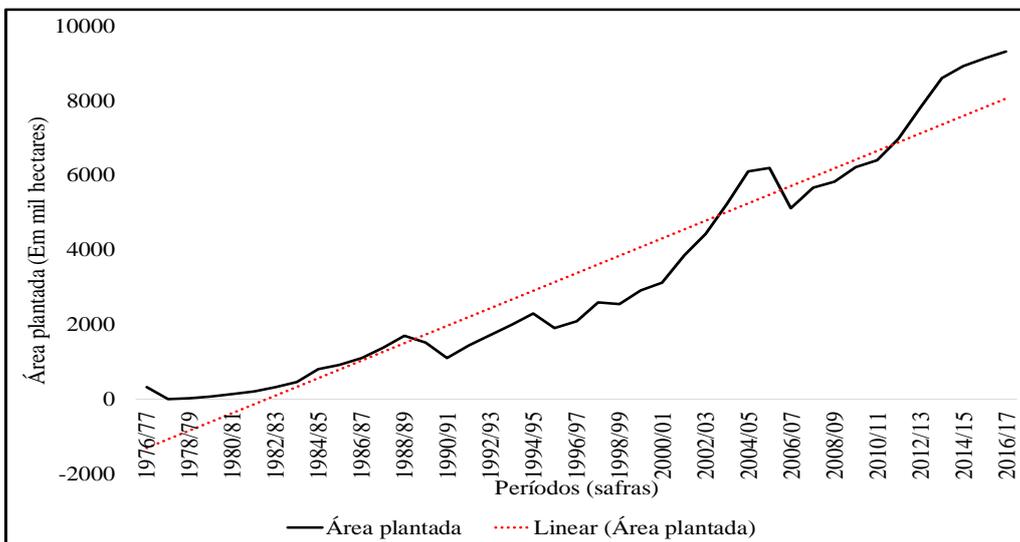
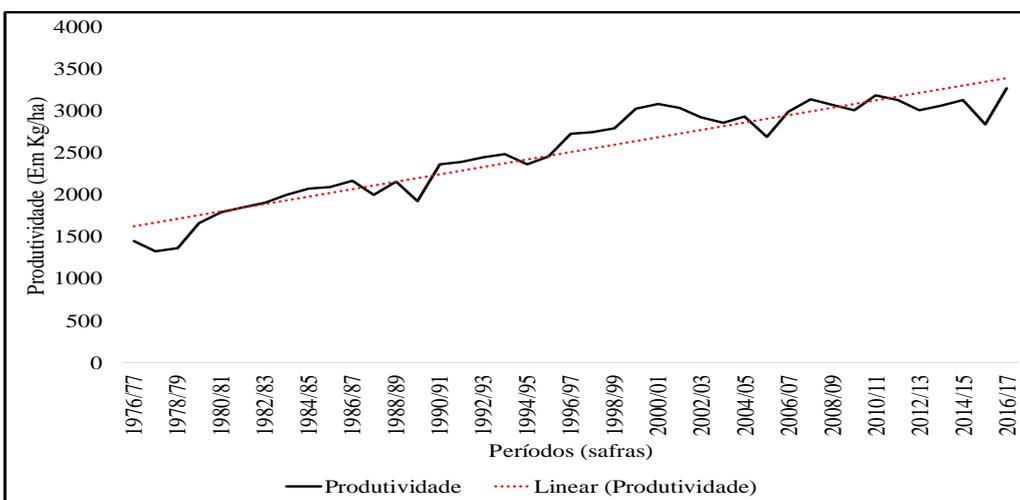


Figura 4: Série histórica da produtividade da soja no estado de Mato Grosso



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

A partir das análises gráficas das séries temporais apresentadas nas Figuras 2, 3 e 4, respectivamente, pode-se verificar que elas apresentam uma tendência de crescimento ao longo dos anos. Além disso, é possível observar ainda que as mesmas não apresentam padrões sazonais e, por isso, não foram aplicados e avaliados os desempenhos dos modelos de suavização exponencial com tendência e sazonalidade (modelo linear de Holt-Winters) nas suas abordagens multiplicativa e aditiva, respectivamente. Deste modo, foram aplicados e avaliados apenas os modelos de média móvel simples, média móvel ponderada, suavização exponencial simples e suavização exponencial com tendência (modelo linear de Holt).

As previsões através da média móvel simples foram obtidas a partir das 3 últimas observações de cada série temporal. Para obter as previsões para as três séries temporais analisadas pelo modelo de média móvel ponderada foram considerados os seguintes pesos: 0,5 para a observação mais recente; 0,3 para a segunda observação mais recente; e, 0,2 para a terceira mais recente, nessa ordem, conforme proposto na Equação 2 e que são comumente utilizados na literatura. As constantes de suavização (α) para o modelo de suavização exponencial simples foram determinadas através da minimização dos erros de previsão com uso do Solver, sendo elas: $\alpha = 0,96$ para as séries temporais da produção e área plantada; e, $\alpha = 1,00$ para a série temporal de produtividade. Já as constantes de suavização (α e β) obtidas para o modelo de suavização exponencial com tendência, foram os seguintes: $\alpha = 0,25$ e $\beta = 1,00$ para a série temporal de produção; $\alpha = 0,31$ e $\beta = 0,72$ para a série de área plantada; e, $\alpha = 0,67$ e $\beta = 0,08$ para a série histórica de produtividade.

O Quadro 4 apresenta os valores das medidas de acurácia para todos os modelos analisados, obtidos na fase de validação (10 últimas observações) do conjunto de dados de cada série temporal.

Quadro 4: Medidas de acurácia dos modelos analisados na fase de validação

Série temporal	Modelos	Medidas de acurácia		
		MAE	MSE	MAPE
Produção	Média Móvel Simples ($n = 3$)	2.473,52	7.957.335,19	10,42%
	Média Móvel Ponderada	2.765,95	9.744.914,93	11,59%
	Suavização Exponencial Simples	1.938,95	4.959.798,74	8,13%
	Suavização Exponencial com Tendência	1.871,14	4.801.546,47	8,08%
Área plantada	Média Móvel Simples ($n = 3$)	737,11	741.301,50	9,47%
	Média Móvel Ponderada	849,04	978.222,42	10,88%
	Suavização Exponencial Simples	432,93	248.503,69	5,90%
	Suavização Exponencial com	690,01	648.065,00	9,46%



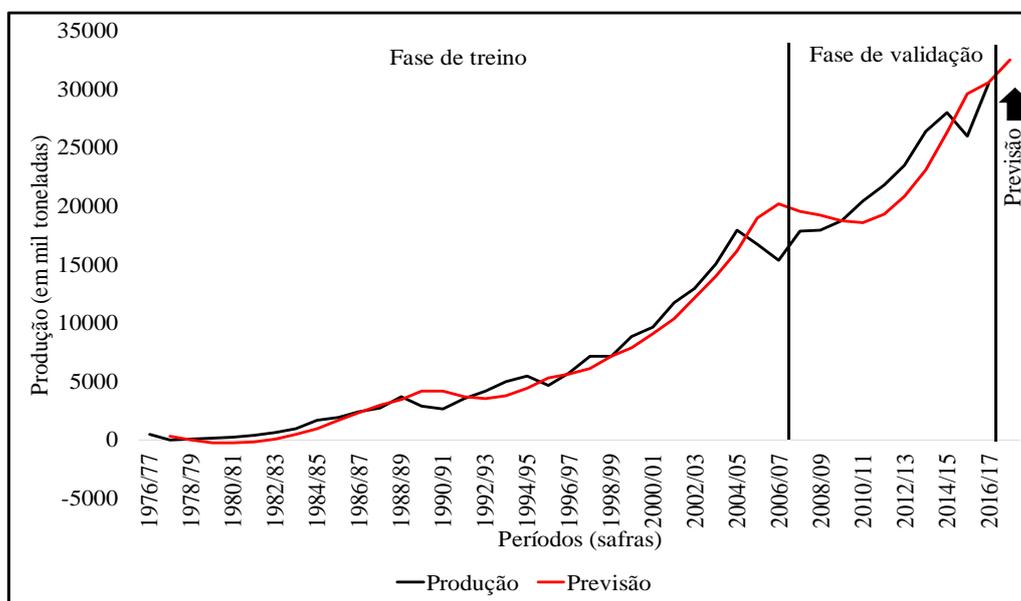
Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

	Tendência			
Produtividade	Média Móvel Simples ($n = 3$)	129,60	23.892,13	4,19%
	Média Móvel Ponderada	128,90	23.452,69	4,17%
	Suavização Exponencial Simples	147,20	35.052,60	4,75%
	Suavização Exponencial com Tendência	137,99	28.825,75	4,50%

Com os resultados apresentados no Quadro 4, pode-se observar que os modelos que apresentaram os melhores desempenhos, ou seja, os menores erros de previsão foram os seguintes: suavização exponencial com tendência para a série histórica de produção; suavização exponencial simples para a série temporal de área plantada; e, média móvel ponderada para a série histórica de produtividade. Estes modelos foram então escolhidos para serem utilizados na obtenção das previsões dos respectivos indicadores para a safra de 2017/2018.

As Figuras 5, 6 e 7 apresentam os ajustes dos valores previstos pelos modelos selecionados às observações reais, bem como as previsões para o próximo período (safra 2017/2018) para as séries históricas de produção, área plantada e produtividade, respectivamente.

Figura 5: Ajustes dos valores previstos pelo modelo de suavização exponencial com tendência aos dados reais da produção de soja em Mato Grosso



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

Figura 6: Ajustes dos valores previstos pelo modelo de suavização exponencial simples aos dados reais da área plantada de soja em Mato Grosso

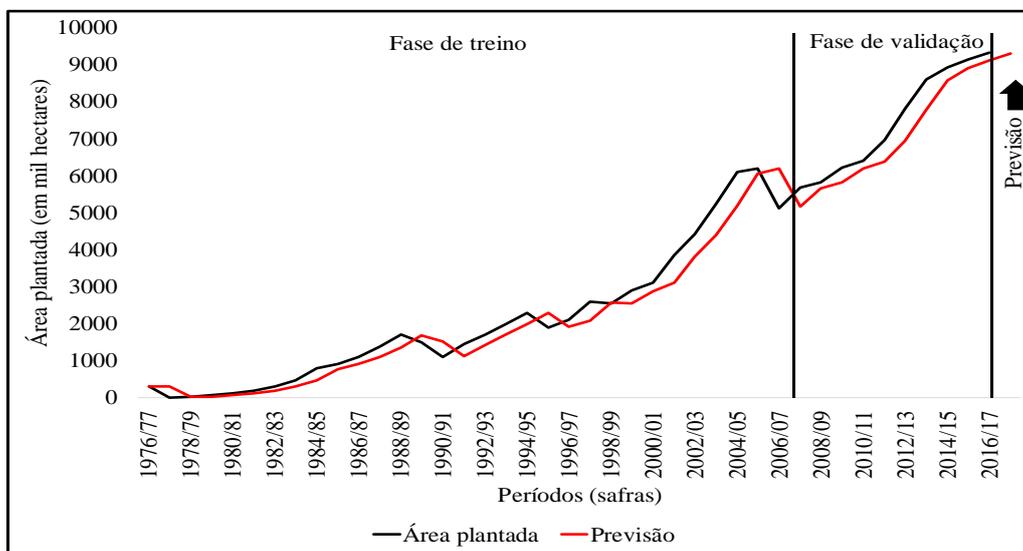
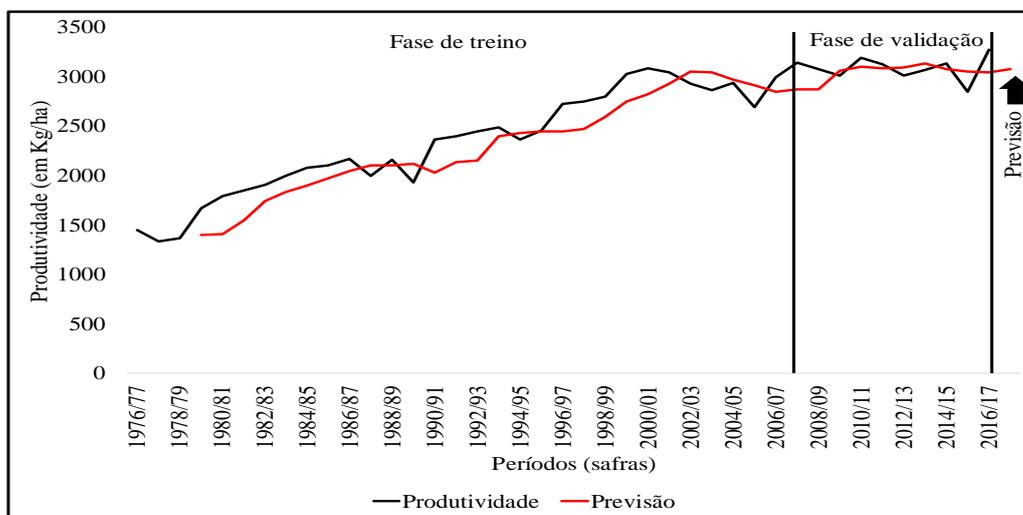


Figura 7: Ajustes dos valores previstos pelo modelo de média móvel ponderada aos dados reais da produtividade de soja em Mato Grosso



Os valores previstos pelos modelos selecionados para a safra de 2017/2018 da produção, área plantada e produtividade da soja no estado de Mato Grosso, bem como os valores reais divulgados pela Companhia Nacional de Abastecimento (CONAB) para esta mesma safra e as variações percentuais das previsões em relação aos dados reais, são apresentados no Quadro 5.



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

Quadro 5: Valores previstos, valores reais e as variações percentuais para os indicadores da soja no estado de Mato Grosso na safra de 2017/2018

Indicadores	Valores previstos (safra 2017/2018)	Valores reais (safra 2017/2018)	Variações percentuais
Produção	32.510,42	32.306,10	+ 0,63%
Área plantada	9.315,58	9.518,60	- 2,18%
Produtividade	3.077,00	3.394,00	- 10,30%

A partir dos resultados apresentados no Quadro 5, pode-se verificar que o valor previsto da produção de soja para a safra de 2017/2018 foi de 32.510,42 mil toneladas. Deste modo, o valor previsto foi superior em 204,32 mil toneladas em relação ao valor real, indicando que o valor previsto foi superior em 0,63%. Já a previsão da área plantada foi de 9.315,58 mil hectares, enquanto o valor real foi de 9.518,60 mil hectares. Sendo assim, o valor previsto foi inferior em 203,02 mil hectares, ou seja, inferior em 2,18% em relação ao valor real observado para a safra de 2017/2018. Por fim, o valor previsto da produtividade para a safra de 2017/2018 foi de 3.077,00 Kg/hectare e o valor real foi de 3.394,00 Kg/hectare. Isto indica que o valor previsto foi inferior em 10,30% quando comparado com o valor real observado.

Os resultados obtidos no presente trabalho poderão ser utilizados pelos agentes envolvidos com as atividades da cultura da soja no estado de Mato Grosso para a realização de planejamentos e acompanhamentos das safras, pois os mesmos indicam que os valores previstos se aproximam dos valores observados. Além disso, este estudo adota a mesma linha de trabalho de outros pesquisadores que buscaram realizar aplicações e análises dos desempenhos de técnicas de previsão para prever valores futuros de indicadores de soja em outras regiões do país, dentre os quais se destacam: Marchezan & Souza (2010) que utilizaram um modelo de previsão para prever preços de soja no estado do Rio Grande do Sul; Arthus et al. (2017) que avaliaram os desempenhos de modelos de previsão para o cenário de rendimento de soja na região oeste do Paraná; e, Souza et al. (2018) que analisaram modelos de previsão para prever os preços do saco de soja pago aos produtores rurais do estado de São Paulo.

5 CONCLUSÃO

Este estudo realizou modelagens e previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais, de modo que tais informações possam



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

fornecer subsídios aos agentes deste setor nos processos de planejamentos e acompanhamentos das safras.

Com os resultados obtidos, verificou-se que os modelos que apresentaram os melhores desempenhos (menores erros de previsão) para prever os indicadores da soja foram os seguintes: suavização exponencial com tendência para a série histórica de produção; suavização exponencial simples para a série histórica da área plantada; e, média móvel ponderada para a série temporal da produtividade.

Deste modo, estes modelos foram selecionados para obtenção das previsões dos respectivos indicadores para a safra de 2017/2018. Sendo assim, os valores previstos para a safra de 2017/2018 foi 0,63% maior que o valor real para a série temporal da produção e 2,18% e 10,30% inferiores aos valores reais para as séries históricas de área plantada e produtividade da soja, respectivamente.

Para trabalhos futuros, recomenda-se fazer o uso de outros modelos de previsões que não foram considerados neste estudo, tais como Redes Neurais Artificiais (RNA) e modelos de Box e Jenkins. Além disso, sugere-se realizar a combinação de previsões com o intuito de obter previsões mais acuradas.

REFERÊNCIAS

Ali, M.M., Babai, M.Z., Boylan, J.E., & Syntetos, A.A. (2017). Supply chain forecasting when information is not shared. *European Journal of Operational Research*, 260(3), 984–994.

Arthus, M.G., Camatti, J.A., Bortoletto, W., Junior, O.F., & Ignácio, P.S. de A. (2017). Planejamento da safra de soja no oeste do Paraná. *Produto & Produção*, 17(4).

Bicudo, M.A.V. (2006). Pesquisa qualitativa e pesquisa quantitativa segundo a abordagem fenomenológica. In: Borba, M.C.; Araújo, J.L. (Org.) *Pesquisa qualitativa em educação matemática*. 2. ed. Belo Horizonte: Autêntica.

Bergmeir, C., Hyndman, R.J., & Benítez, J.M. (2016). Bagging exponential smoothing methods using STL decomposition and Box-Cox transformation. *International Journal of Forecasting*, 32(2), 303–312.

Caniato, F., Kalchschmidt, M., & Ronchi, S. (2011). Integrating quantitative and qualitative forecasting approaches: Organizational learning in an action research case. *Journal of the Operational Research Society*, 62(3), 413–424.

Cas, C.G. (2018). Application of the ARIMA model to forecast the price of the commodity corn. *Revista Gestão da Produção Operações e Sistema*, 11(1), 263–279.



Citação (APA): Silva, R B.Z. da, Aires, F.F. da C.A., Oenning, E J., Porto, A.G., & Ultrami, A V. (2019). Previsões de indicadores da soja no estado de Mato Grosso a partir de modelos baseados em séries temporais. *Brazilian Journal of Production Engineering*, 5(3): 67-81.

CONAB – Companhia Nacional de Abastecimento. Série histórica das safras: 2018. Disponível em: <<https://www.conab.gov.br/index.php/info-agro/safras/serie-historica-das-safras?Start=20>>

>. Acesso em: 26/12/2018.

Gil, A.C. (2008). *Como elaborar projetos de pesquisa*. 4.ed. São Paulo: Atlas.

Holt, C.C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, 20(1), 5–10.

Makridakis, S., Wheelwright, S., & Hyndman, R.J. (1998). *Forecasting: Methods and Applications*. 3^a ed. New York: John Wiley & Sons.

Marchezan, A., & Souza, A.M. (2010). Previsão do preço dos principais grãos produzidos no Rio Grande do Sul. *Ciência Rural*, 40(11), 2368–2374.

Nomelini, Q.S.S., Ferreira, E.B., Nogueira, D.A., Golynski, A.A., Golynski, A., & Villa, T.E. de. (2017). Uso de modelagem univariada e multivariada com séries temporais como ferramenta de gestão do agronegócio na cultura de soja do Brasil. *Revista ESPACIOS*, 38(8).

Pindyck, R.S., & Rubinfeld, D.L. (2004). *Econometria: modelos e previsões*. ed. 4. São Paulo: Campus – Elsevier.

Prodanov, C.C.; Freitas, E.C. (2013). *Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico*. 2.ed. Novo Hamburgo – RS: Universidade Feevale.

Rocha, L.C.S., Carvalho, L.A. de, Junior, P.R., Paiva, A.P. de, & Valério, V.E. de M. (2015). Previsão da cotação do Café Arábica Tipo 6 utilizando o modelo de previsão ARIMA. *Produção em Foco*, 5(1), 170–186.

Rosienkiewicz, M., Chlebus, E., & Detyna, J. (2017). A hybrid spares demand forecasting method dedicated to mining industry. *Applied Mathematical Modelling*, 49, 87–107.

Souza, C.C. de, Andrade, J.O. de, Lemes, L.H.B., Viganó, H.H. da G., & Kazama, A.S. (2018). Análise do padrão estacional e previsão dos preços da soja aos produtores do estado de São Paulo, BRASIL. *Extensão Rural*, 25(1), 78–92.

Sridevi, U.K., Palaniappan, S., & Palanisamy, N. (2018). A profit prediction model with time series analysis for retail store. *International Journal of Pure and Applied Mathematics*, 119(2), 1931–1940.

Veiga, C.P.da, Veiga, C.R.P.da, Puchalski, W., Coelho, L.dos S., & Tortato, U. (2016). Demand forecasting based on natural computing approaches applied to the foodstuff retail segment. *Journal of Retailing and Consumer Services*, 31, 174–181.

