

Uso de modelos de séries temporais para previsões de safras de milho no estado de Mato Grosso

The use of time series models for forecast corn production in Mato Grosso state
Uso de modelos de series temporales para pronósticos de cultivos de maíz en el estado de Mato Grosso

Recebido: 23/10/2019 | Revisado: 25/10/2019 | Aceito: 26/10/2019 | Publicado: 31/10/2019

Rodolfo Benedito Zattar da Silva

ORCID: <https://orcid.org/0000-0003-2075-5622>

Universidade Federal de Mato Grosso, Brasil

E-mail: rodolfoengenheiro@hotmail.com

Rosângela Natalina Zattar da Silva

ORCID: <https://orcid.org/0000-0001-5891-9544>

Secretaria de Estado de Educação de Mato Grosso, Brasil

E-mail: rosazattar@hotmail.com

Fábia Fernanda da Costa Aires

ORCID: <https://orcid.org/0000-0003-0723-3846>

Universidade de Cuiabá, Brasil

E-mail: fabia_aires@hotmail.com

Eduardo José Oenning Soares

ORCID: <https://orcid.org/0000-0002-3548-6579>

Universidade do Estado de Mato Grosso, Brasil

E-mail: eduardo.oenning@unemat.br

Resumo

O estado de Mato Grosso é o principal produtor de milho do país e sua produção vem aumentando a cada nova safra. Neste sentido, obter informações futuras da produção de milho se torna de fundamental importância para o adequado planejamento e acompanhamento das safras. Deste modo, o presente trabalho teve como objetivo realizar a comparação dos desempenhos apresentados pelos modelos de previsões de séries temporais e selecionar aquele que melhor se ajustou aos dados históricos para realizar previsões futuras da produção total de milho em Mato Grosso. Para isto, foram obtidos dados históricos das safras juntamente a Companhia Nacional de Abastecimento (CONAB) compreendendo o período de

1976/1977 a 2017/2018. Em seguida, foi analisado o padrão da série temporal, bem como as estatísticas descritivas dos dados obtidos. Posteriormente, foram desenvolvidas planilhas eletrônicas para aplicação e análise dos modelos avaliados. Com os resultados obtidos, verificou-se que o modelo de suavização exponencial com tendência (modelo linear de Holt) foi o que apresentou os menores erros de previsão, sendo selecionado para obter previsões das próximas 7 (sete) safras (2018/2019 a 2024/2025). A previsão obtida por este modelo para o fim do horizonte de previsão, na safra de 2024/2025, indica que a produção total de milho no estado de Mato Grosso terá um aumento de aproximadamente 70% quando comparada com a produção da safra de 2017/2018.

Palavras-chave: Séries temporais; Modelos de previsão; Produção de milho.

Abstract

The Mato Grosso State is the main producer of corn of the Brazil and its production has been increasing every year. In this sense, is very important to gain information about future production to planning and monitoring of the corn crops. In this way, the main aim of this paper is to compare the performance showed by the forecast models of time series and to choose the best model. The historical data of corn crop from 1976/1977 to 2017/2018 was obtained with CONAB (The Brazilian National Supply Company). Then, the time series pattern was analyzed, as well as the descriptive statistics of the data obtained. Subsequently, electronic spreadsheets were developed for application and analysis of the evaluated models. With the results it was verified that the trend exponential smoothing model (Holt's linear model) presented the smallest prediction errors, and then it was selected to predict the next seven crops (from 2018/2019 to 2024/2025). The forecast obtained by this model for the 2024/2025 crop indicates that total corn production in the state of Mato Grosso will increase by approximately 70% compared to the 2017/2018 crop production.

Keywords: Time series; Forecast models; Corn production.

Resumen

El estado de Mato Grosso es el principal productor de maíz en el país y su producción aumenta con cada nuevo ciclo de cultivo. En este sentido, obtener información futura sobre la producción de maíz adquiere una importancia fundamental para la planificación y el monitoreo adecuados de la producción. Por lo tanto, el presente trabajo tuvo como objetivo comparar los rendimientos presentados por los modelos de pronóstico de series de tiempo y seleccionar aquel que muestre el mejor ajuste a los datos históricos para hacer pronósticos

futuros de la producción total de maíz en Mato Grosso. Para esto, se obtuvieron datos históricos de las cosechas de la Compañía Nacional de Abastecimiento (CONAB) para el período comprendido entre 1976/1977 y 2017/2018. Luego, se analizó el patrón de la serie temporal, así como las estadísticas descriptivas de los datos obtenidos. Posteriormente, se desarrollaron hojas de cálculo electrónicas para la aplicación y el análisis de los modelos evaluados. Con los resultados obtenidos, se verificó que el modelo de suavizado exponencial de tendencia (modelo lineal de Holt) presentó los menores errores de pronóstico, siendo seleccionado para obtener pronósticos de las próximas 7 (siete) cosechas (2018/2019 a 2024/2025). El pronóstico obtenido por este modelo para el final del horizonte de pronóstico para la cosecha 2024/2025 indica que la producción total de maíz en el estado de Mato Grosso aumentará aproximadamente un 70% en comparación con la producción de cultivo 2017/2018.

Palabras clave: Series de tiempo; Modelos de pronóstico; Producción de maíz.

1. Introdução

O agronegócio é uma das principais atividades econômicas do Brasil, sendo muito importante para a sua balança comercial. O milho tem sido o segundo grão mais produzido e exportado, ficando atrás apenas da soja. Este cereal é o principal componente utilizado na produção de suplementação animal, destinado a um dos principais segmentos da exportação brasileira, que é a cadeia produtiva de proteína animal (Souza, Reis, Raymundo, & Pinto, 2018).

O estado de Mato Grosso apresenta lugar de destaque no contexto do agronegócio brasileiro, sendo o principal produtor de milho. Os dados da última safra (2017/2018) disponibilizados pela Companhia Nacional de Abastecimento (CONAB), demonstram que, neste estado foram destinados 4.498,4 mil hectares para o cultivo desta cultura, produzindo 26.400,6 mil toneladas e resultando em uma produtividade de aproximadamente 5.869 kg por hectare (Conab, 2019).

A importância da produção de produtos primários para a economia mato-grossense, que está restrita às commodities agrícolas, tem repercutido de forma positiva para nas esferas política, econômica e social, principalmente quando se analisa os aspectos quanto aos efeitos provocados por este setor na geração de emprego e renda (Costa, Cândido, & Macedo, 2016).

Sendo assim, realizar a modelagem e previsões da série temporal de produção total de milho a partir de modelos de séries temporais, é de suma importância para o planejamento de

safras, bem como para tomar decisões relacionadas às atividades de plantio e comercialização de culturas como a do milho (Silva, Aires, Oenning, Porto, & Ultramari, 2019).

Uma série temporal consiste em um conjunto de observações de uma variável que são obtidas em intervalos de tempo regulares (Levine, Stephan, & Szabat, 2016). Deste modo, as previsões de uma variável realizadas com base em modelos de séries temporais, possuem como pressuposto que as projeções futuras são obtidas a partir dos seus padrões observados no presente e no passado. Neste sentido, a aplicação de modelos de séries temporais para realizar previsões de commodities agrícolas brasileiras tem sido cada vez mais frequente (Cas, 2018; Nomelini et al., 2017; Silva et al., 2019).

Sendo assim, este trabalho teve como objetivo realizar a aplicação de modelos de séries temporais e selecionar aquele que apresentou o melhor desempenho para prever valores futuros da produção total de milho no estado de Mato Grosso.

Para isto, o trabalho foi dividido em cinco seções, que incluem esta introdução. Na seção 2 é apresentada a revisão da literatura quanto aos modelos abordados. A seção 3 apresenta a metodologia adotada para a condução dos trabalhos. Na seção 4, encontram-se a apresentação dos resultados e a discussão. A seção 5 traz as conclusões do trabalho.

2. Revisão bibliográfica

2.1 Modelos de previsões baseados em séries temporais

Os modelos de séries temporais buscam extrair um padrão dos dados observados e, com base nele, realiza-se a projeção para prever valores futuros da série estudada (Rosienkiewicz, Chlebus, & Detyna, 2017).

De modo geral, uma série temporal pode apresentar um dos seguintes padrões (Levine et al., 2016): i) tendência, consistindo em um padrão de movimento gradual a longo prazo de modo que os dados são direcionados de forma crescente ou decrescente; ii) sazonalidade, onde ocorrem flutuações regulares de curto prazo e que se repetem em intervalos constantes de tempo devido a influência de algum fator sazonal; iii) ciclicidade, que consiste em variações ondulatórias de longo prazo com períodos irregulares para suas ocorrências; e, iv) irregularidade, que são as mudanças que ocorrem nos dados devido aos eventos excepcionais (difíceis de serem presumidos) e, portanto, considerados nos modelos.

Dentre os modelos de séries temporais têm-se o de média móvel simples, média móvel ponderada, suavização exponencial com tendência e suavização exponencial com tendência e

sazonalidade, sendo que as principais características deles são apresentados a seguir.

O método da média móvel simples consiste na obtenção de previsões futuras a partir da média aritmética dos valores observados nos n períodos mais recentes, como apresentado na Equação (1) (Ali, Babai, Boylan, & Syntetos, 2017):

$$MMS_n = \frac{\sum_{t=1}^n Y_t}{n} \quad (1)$$

Em que: MMS_n é a média móvel simples dos dados dos últimos n períodos, Y_t é o valor observado no instante de tempo t e n é o número de períodos.

Na média móvel ponderada, as previsões são obtidas atribuindo pesos para os valores observados nos últimos n períodos, de modo que a soma dos pesos seja igual a 1 (um). Geralmente, realiza-se as previsões com base nos últimos 3 (três) períodos de modo que é atribuído um peso de 0,5 para o valor mais recente, 0,3 para o penúltimo valor e 0,2 para o valor mais antigo (Sridevi, Palaniappan, & Palanisamy, 2018). As previsões pelo método da média móvel ponderada são obtidas através da Equação (2):

$$MMP_n = (Y_{t-1} P_1) + (Y_{t-2} P_2) + (Y_{t-3} P_3) \quad (2)$$

Onde: MMP_n é a média móvel ponderada dos dados dos últimos n períodos, Y_t é o valor observado no instante de tempo t , P é o peso atribuído a cada valor observado e n é o número de períodos.

A suavização exponencial simples se apresenta como um método mais aprimorado para se obter previsões quando comparado com as médias simples e ponderada. Esta técnica é indicada para séries temporais que não apresentam as componentes tendência e sazonalidade (Veiga, Veiga, Puchalski, Coelho, & Tortato, 2016). As previsões são obtidas considerando a previsão e o erro do período anterior que é corrigido por uma constante de suavização α (com valor que varia de 0 a 1), conforme a Equação (3) (Bergmeir, Hyndman, & Benítez, 2016):

$$F_t = F_{t-1} + \alpha(Y_{t-1} - F_{t-1}) \quad (3)$$

Sendo que: F_t é a previsão para o instante de tempo t , α é a constante de suavização e Y_t é o valor observado no instante de tempo t .

O método de suavização exponencial com tendência, conhecido por método linear de Holt, é indicado para séries temporais que apresentam tendência de crescimento ou decrescimento. Tal método leva em consideração duas constantes de suavização, sendo α para o nível e (β) para a tendência da série temporal analisada, de modo que as previsões são obtidas através de um conjunto de três equações (Veiga et al., 2016), conforme apresentado a seguir:

$$F_{t+m} = L_t + b_t m \quad (4)$$

$$L_t = \alpha Y_t + (1 - \alpha) \quad (5)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (6)$$

Em que: F_{t+m} é a previsão para o instante de tempo $t + m$, L_t representa a estimativa do nível da série temporal no período t , b_t é a estimativa de tendência da série temporal no período t , m é o número de períodos à frente que se deseja obter previsões ($m = 1, 2, 3, \dots$), Y_t é o valor observado no período t , α e β são as constantes de suavização (com valores entre 0 e 1, não correlacionados).

Por fim, a suavização exponencial com tendência e sazonalidade, também denominado de método linear de Holt-Winters, é indicado quando os dados analisados apresentam tendência e sazonalidade. Para realizar previsões, o modelo faz uso de um conjunto de quatro equações, sendo três para estimativa do nível, tendência e sazonalidade, respectivamente, bem como três constantes de suavização (α , β e γ) (Hyndman & Athanasopoulos, 2014).

Dependendo do comportamento sazonal dos dados, o modelo de Holt-Winters pode ser aditivo ou multiplicativo. De acordo com Holt (2004), a forma aditiva deste modelo é geralmente indicada quando a amplitude (diferença entre o maior e menor valor no ciclo sazonal) é independente do seu nível, ou seja, a amplitude permanece constante nos ciclos sazonais. Já a forma multiplicativa é indicada para modelar séries temporais quando a amplitude da sazonalidade varia com o nível das séries analisadas.

O conjunto de equações utilizadas para obter previsões pelo modelo de Holt-Winters aditivo é apresentado a seguir (Makridakis, Wheelwright, & Hyndman, 1998):

$$F_{t+m} = (L_t + b_t m) + S_{t-s+m} \quad (7)$$

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (8)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (9)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (10)$$

Onde: F_{t+m} é a previsão para o período $t + m$, L_t é o nível da série temporal, b_t é a estimativa da tendência, S_t é o componente sazonal, m são os períodos a frente que se deseja obter previsões, ($m = 1, 2, 3, \dots$), Y_t é o valor observado no período t , s é o período de sazonalidade, α , β e γ são constantes de suavização (com valores entre 0 e 1, não correlacionados).

As Equações (11) – (14) são utilizadas para obtenção de previsões através do modelo de Holt-Winters multiplicativo (Makridakis et al., 1998):

$$F_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (11)$$

$$L_t = a \frac{Y_t}{S_{t-s}} + (1-a)(L_{t-1} + b_{t-1}), \quad (12)$$

$$b_t = \beta(L_t - L_{t-1}) + (1-\beta)b_{t-1} \text{ e} \quad (13)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1-\gamma)S_{t-s}, \quad (14)$$

Em que: F_{t+m} , L_t , b_t , S_t , m , Y_t , s , α , β e γ já foram definidos anteriormente.

2.2 Medidas de acurácia

As análises dos desempenhos apresentados por todos os modelos analisados foram realizadas a partir das medidas de acurácia apresentadas por Makridakis et al., (1998), sendo elas: i) Erro Absoluto Médio ou *Mean Absolute Error* (MAE); ii) Raiz Quadrada do Erro Quadrático Médio ou *Root-Mean-Square Error* (RMSE); iii) Erro Percentual Absoluto Médio ou *Mean Absolute Percentage Error* (MAPE).

O Erro Absoluto Médio ou *Mean Absolute Error* (MAE) é calculado a partir da Equação (15):

$$\text{MAE} = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n} \quad (15)$$

De modo que: \hat{y}_t é o valor previsto no instante t , n é o número de observações, y_t é o valor observado no instante de tempo t .

Por sua vez, a Raiz Quadrada do Erro Quadrático Médio ou *Root-Mean-Square Error* (RMSE) é calculada através da Equação (16).

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (16)$$

Sendo que: \hat{y}_t é o valor previsto no instante t , n é o número de observações, y_t é o valor observado no instante de tempo t .

Por fim, o Erro Percentual Absoluto Médio ou *Mean Absolute Percentage Error* (MAPE) pode ser determinado com base na Equação (17):

$$\text{MAPE} = \frac{\sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{n} \quad (17)$$

Em que: \hat{y}_t é o valor previsto no instante t , n é o número de observações, y_t é o valor observado no instante de tempo t .

3. Metodologia

3.1 Classificação da pesquisa

Quanto à sua natureza, este estudo pode ser classificado como uma pesquisa aplicada, que de acordo com Prodanov & Freitas (2013), procura construir conhecimentos para soluções práticas na resolução de problemas peculiares, envolvendo verdades e interesses locais. No caso do presente trabalho, esta classificação se deve ao fato que o mesmo procurou avaliar os desempenhos apresentados por modelos de previsões baseados em séries temporais e selecionar aquele que melhor se ajustou aos dados históricos para prever as safras futuras de milho de um único estado brasileiro.

Em relação a abordagem utilizada, a pesquisa é classificada como quantitativa, que segundo Knechtel (2014), consiste em um tipo de pesquisa que busca atuar sobre um determinado problema, baseando-se na avaliação de uma teoria e sendo composta por variáveis que são quantificadas em números para que possam ser analisadas de forma estatística. O objetivo é constatar se as generalizações que estão previstas na abordagem teórica se sustentam ou não. Neste estudo, foram utilizados modelos matemáticos/estatísticos para obter previsões de safras de milho e também para mensurar seus desempenhos quanto aos erros de previsão.

Quanto aos objetivos, trata-se de uma pesquisa exploratória. Este tipo de pesquisa busca apresentar informações detalhadas quanto ao tema estudado, facilitar a sua delimitação, definir seus objetivos ou ainda formular as hipóteses do trabalho, ou até mesmo, descobrir um novo direcionamento para o estudo realizado. Comumente, a pesquisa exploratória assume o formato de pesquisas bibliográficas e estudo de caso (Gil, 2017). Sendo assim, no presente trabalho buscou-se primeiramente fazer um levantamento bibliográfico em relação ao tema abordado e somente em seguida realizou-se as demais análises como um estudo de caso.

Por fim, em relação aos procedimentos, o trabalho é classificado como um estudo de caso. Segundo Gil (2017), o estudo de caso tem como característica a busca detalhada e de forma profunda de um ou poucos objetos para possibilitar o seu amplo e detalhado conhecimento. Logo, neste trabalho buscou-se entender como a produção total de milho evoluiu historicamente no estado de Mato Grosso, evidenciando o padrão da série temporal, discutindo os fatores associados ao crescimento da produção e fazendo a extrapolação dos dados com o intuito de prever as safras futuras deste cereal.

3.2 Coleta e análise dos dados

Foram utilizados dados históricos da produção total (1ª e 2ª safras) de milho do estado de Mato Grosso, disponibilizados pela Companhia Nacional de Abastecimento (CONAB), no seguinte endereço eletrônico: < <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras?start=20>>. Os dados utilizados possuem periodicidade anual e o período de análise se estendeu desde o início da série histórica na safra de 1976/1977 até a safra de 2017/2018, totalizando 42 observações.

Primeiramente, realizou-se uma análise gráfica da série temporal estudada com o intuito de identificar o seu comportamento. Em seguida, foram calculadas as estatísticas descritivas, tais como média, desvio-padrão, valores mínimos e máximos da série temporal.

Logo após, para realizar as modelagens e obter as previsões dividiu-se o conjunto de dados em duas partes, sendo que as 30 primeiras observações foram utilizadas para a inicialização dos modelos e as demais para a validação dos mesmos. Todas as análises, modelagens e previsões da série temporal estudada foram realizadas através de planilhas eletrônicas desenvolvidas para estes fins.

Por fim, foi realizada a verificação do desempenho apresentado por cada modelo analisado considerando as medidas de acurácia (MAE, RMSE e MAPE) apresentadas anteriormente. O modelo que apresentou o melhor desempenho, ou seja, o menor erro de previsão, foi selecionado para prever as próximas 7 (sete) safras (2017/2018 até 2024/2025) de milho no estado de Mato Grosso.

4. Resultados e Discussão

O cultivo de milho no estado de Mato Grosso é realizado conforme o calendário agrícola apresentado no Quadro 1.

Quadro 1: Épocas de plantio e colheita do milho no estado de Mato Grosso.

Safras	Plantio	Colheita
1ª	Outubro a dezembro	Fevereiro a abril
2ª	Fevereiro e março	Junho e julho

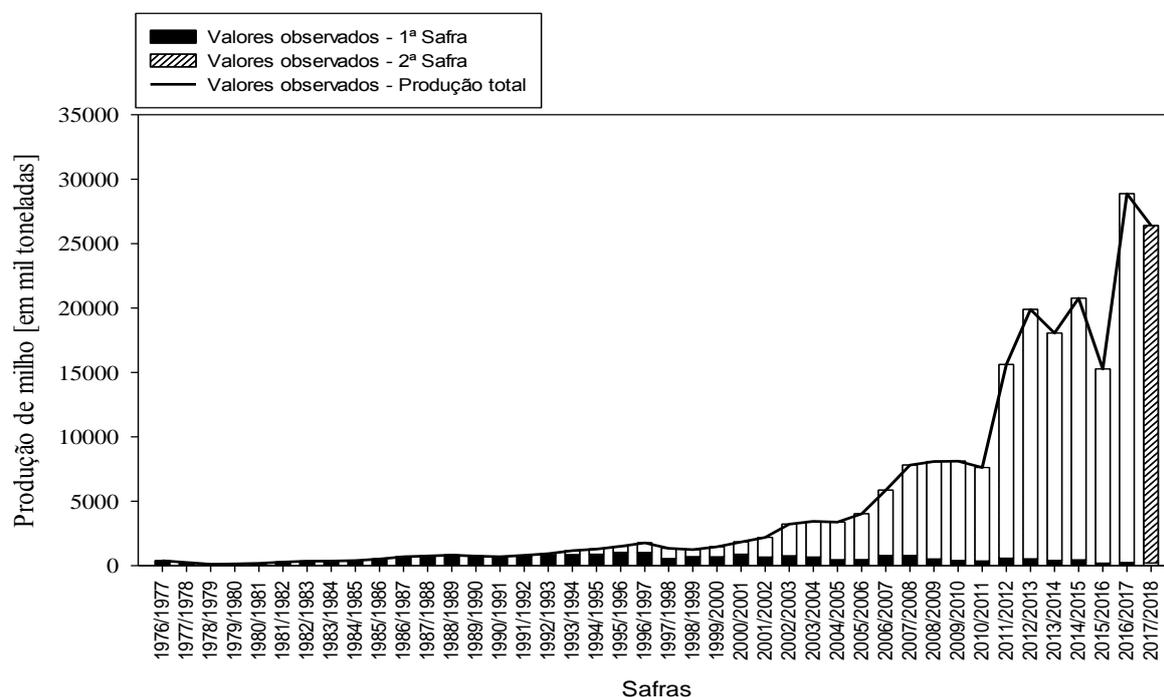
Fonte: Empaer (2019)

Com base nas informações apresentadas no Quadro 1, pode-se verificar que o plantio e a colheita do milho em Mato Grosso ocorrem em dois períodos distintos, sendo que no primeiro período (1ª safra), tanto o plantio quanto a colheita, são realizados no mesmo

período de cultivo da soja. Já na segunda safra (denominada de safrinha), o cultivo é realizado após a colheita da soja. O primeiro registro de produção de milho safrinha em Mato Grosso foi na safra de 1991/1992, sendo que a partir da safra de 1999/2000 superou o volume produzido na 1ª safra e, desde então, tem sido cada vez mais crescente (Figura 1).

A Figura 1 apresenta as séries históricas da produção de 1ª e 2ª safras, bem como da produção total de milho no estado de Mato Grosso durante o período analisado, ou seja, desde a primeira safra (1976/1977) até a última registrada (2017/2018).

Figura 1: Séries históricas de produção de milho no estado de Mato Grosso.



Fonte: Conab (2019)

Pode-se verificar na Figura 1 que a série temporal de produção total de milho em Mato Grosso apresenta uma tendência de crescimento ao longo dos anos e não apresenta comportamento sazonal. Além disso, observa-se que o volume de produção de milho de 1ª safra no estado é praticamente inexpressivo quando comparado com a produção de 2ª safra (safrinha). De acordo com a Empresa Brasileira de Pesquisa Agropecuária (Embrapa, 2015), isto ocorre devido ao aumento da importância da soja no mercado internacional, o que levou esta cultura a disputar áreas com o milho no cultivo de verão e, conseqüentemente, mais agricultores a escolherem a cultivarem soja no verão e milho na segunda safra. O cultivo de milho em segunda safra foi introduzido pelos produtores visando ter mais uma opção de produção durante o inverno. Isto está relacionado a dois fatores, sendo eles: i) necessidades de

mecanismos de sucessão de cultura com a soja e também para a produção de cobertura morta para a área no sistema de plantio direto, sendo o milho safrinha utilizado para estes fins, plantado logo após a colheita da soja; e, ii) demanda crescente de milho no período de entressafra, provocando aumento dos preços de grãos no respectivo período (Embrapa, 2015).

É possível observar também na Figura 1 que a série temporal apresenta níveis diferentes para os períodos das safras de 1976/1977 a 1991/1992, 1992/1993 a 2001/2002, 2002/2003 a 2005/2006, 2006/2007 a 2010/2011, 2011/2012 a 2015/2016 e 2016/2017 a 2017/2018. As estatísticas descritivas para cada um desses períodos são apresentadas na Tabela 1.

Tabela 1: Estatísticas descritivas por período da produção total de milho em Mato Grosso.

Períodos	Média	Desvio-padrão	Valor mínimo	Valor máximo
1976/1977 a 1991/1992	470,00	250,62	118,00	827,20
1992/1993 a 2001/2002	1.478,54	370,46	935,20	2.199,80
2002/2003 a 2005/2006	3.521,72	350,02	3.227,80	4.028,30
2006/2007 a 2010/2011	7.498,26	935,74	5.864,90	8.118,10
2011/2012 a 2015/2016	17.917,56	2.466,91	15.271,60	20.763,40
2016/2017 a 2017/2018	27.633,80	1.744,01	26.400,60	28.867,00

Fonte: Elaborada pelos autores

Os resultados apresentados na Tabela 1 mostram que a produção média tem aumentado de forma considerável, sendo que os principais fatores que contribuíram para este crescimento foram: a expansão da agricultura para as áreas do cerrado; a procura por novas tecnologias pelos agricultores; desenvolvimento de sementes adaptadas às condições climáticas do estado; compra de maquinários e equipamentos que apresentam desempenho e rendimento melhores; e, desenvolvimento de técnicas que permitem reduzir perdas físicas e de qualidade dos grãos (SNA, 2016).

As análises dos modelos de séries temporais não incluíram os modelos de Holt-Winters nas suas formas aditiva e multiplicativa, respectivamente, visto que a série temporal de produção total de milho em Mato Grosso não apresenta comportamento sazonal. Deste modo, apenas os modelos de média móvel simples, média móvel ponderada, suavização exponencial simples e suavização exponencial com tendência (modelo linear de Holt) foram aplicados e avaliados para obtenção de previsões da respectiva série histórica.

Sendo assim, as previsões pelo modelo de média móvel simples foram obtidas considerando as 3 (três) observações mais recentes da série temporal. No modelo de média móvel ponderada foram utilizados os seguintes pesos: 0,5 para a observação mais recente, 0,3 para a segunda mais recente; e, 0,2 para a terceira. As constantes de suavização (α e β)

utilizadas foram: $\alpha = 0,76$ para o modelo de suavização exponencial simples; e, $\alpha = 0,76$ e $\beta = 1,00$ para o modelo de suavização exponencial com tendência. Cabe ressaltar que estas constantes foram determinadas de modo que minimizassem os erros de previsão.

Para selecionar o modelo que apresentou o melhor desempenho (menores erros de previsão), foram realizadas análises das medidas de acurácia de cada modelo na fase de validação, ou seja, para as últimas 12 observações do conjunto de dados (Tabela 2).

Tabela 2: Medidas de acurácia dos modelos analisados na fase de validação.

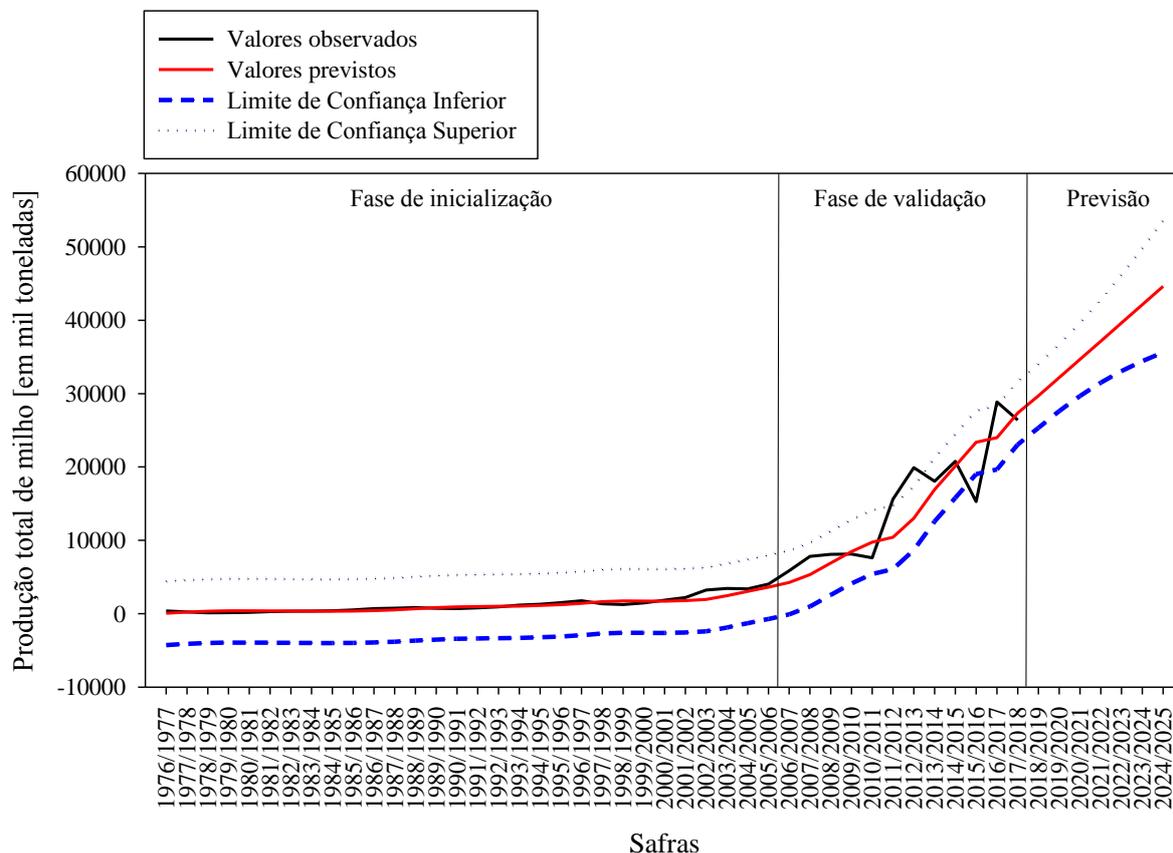
Modelos de previsão	Medidas de acurácia		
	MAE	RMSE	MAPE
Média Móvel Simples	4.388,45	5.406,81	28,25%
Média Móvel Ponderada	4.818,29	5.767,79	31,25%
Suavização Exponencial Simples	3.403,80	4.970,84	21,48%
Suavização Exponencial com Tendência	2.958,89	3.880,61	21,40%

Fonte: Elaborada pelos autores

A partir dos resultados apresentados na Tabela 2, verifica-se que o modelo que apresentou o melhor desempenho foi o de suavização exponencial com tendência (modelo linear de Holt), sendo selecionado para prever safras futuras de milho no estado de Mato Grosso. Este resultado vai ao encontro com o esperado, visto que a série temporal analisada apresenta tendência de crescimento e o modelo escolhido é indicado para modelar e prever série que apresenta tal comportamento.

Na Figura 2 são apresentados os ajustes dos valores previstos pelo modelo selecionado e seus respectivos intervalos de confiança aos valores observados nas fases de inicialização e validação, bem como as previsões para as próximas 7 (sete) safras de milho (2017/2018 a 2024/2025) no estado de Mato Grosso.

Figura 2: Ajustes dos valores previstos pelo modelo de suavização exponencial com tendência aos observados de produção total de milho em Mato Grosso.



Fonte: Elaborada pelos autores

Os valores previstos de produção total de milho para as próximas 7 (sete) safras em Mato Grosso e seus respectivos intervalos de confiança são apresentados também na Tabela 3. Além disso, são apresentadas as variações percentuais dos valores futuros previstos em relação a produção registrada na safra 2017/2018, que foi de 26.400,60 mil toneladas.

Tabela 3: Produção total prevista de milho, limites de confiança e variação percentual de cada safra em relação à safra de 2017/2018

Safra	Produção total prevista (em mil toneladas)	Limite de Confiança Inferior	Limite de Confiança Superior	Variação percentual
2018/2019	29.711,42	25.364,67	34.058,17	12,54%
2019/2020	32.194,43	27.647,47	36.741,39	21,95%
2020/2021	34.677,43	29.709,40	39.645,46	31,35%
2021/2022	37.160,44	31.520,95	42.799,93	40,76%

2022/2023	39.643,44	33.091,13	46.195,76	50,16%
2023/2024	42.126,45	34.448,01	49.804,89	59,57%
2024/2025	44.609,45	35.622,17	53.596,74	68,97%

Fonte: Elaborada pelos autores

Com base nos resultados da Tabela 3, observa-se que o volume de produção esperado no fim do horizonte de previsão (safra de 2024/2025) será de aproximadamente 70% maior quando comparado com a safra de 2017/2018. Logo, as informações apresentadas na Tabela 3 são muito importantes e poderão ser utilizadas pelos agentes envolvidos no processo de cultivo e comercialização do milho no estado de Mato Grosso para auxiliá-los no processo de tomada de decisão nos mais diversos elos e partes desta cadeia produtiva. Deste modo, este estudo contribui para disponibilizar informações sobre previsões de safras ao segmento do agronegócio, ao setor público e também aos administradores rurais, de modo que tenham uma ferramenta importante para o desenvolvimento de suas atividades.

Este estudo concentrou esforços na mesma linha de trabalho de estudiosos que também aplicaram e avaliaram os desempenhos de técnicas de previsões para prever outros indicadores de milho, tais como o preço no mercado brasileiro e em diversas regiões do país (Cas, 2018; Marchezan & Souza, 2010; Tibulo & Carli, 2014).

5. Conclusões

O presente trabalho buscou avaliar os desempenhos apresentados pelos modelos de séries temporais aplicados à série temporal de produção total de milho em Mato Grosso e selecionar o que melhor se ajustou aos dados históricos para prever safras futuras.

Com a análise gráfica, verificou-se que a série temporal estudada não apresentou comportamento sazonal, mas sim uma tendência de crescimento ao longo dos anos. Além disso, foi possível verificar que a série histórica apresentou níveis diferentes para diversas safras ao longo do período analisado, indicando mudança de patamar, ou seja, de crescimento para a produção de milho no estado de safras em safras.

Deste modo, pôde-se verificar que o modelo de suavização exponencial com tendência (modelo linear de Holt) foi o que apresentou os menores erros de previsão, sendo selecionado para obter previsões das próximas 7 (sete) safras (2018/2019 a 2024/2025). Este achado vai ao encontro com o esperado tendo em vista que o modelo selecionado é o mais indicado para modelar e prever séries temporais que apresentam tendência de crescimento.

A previsão obtida pelo modelo selecionado indica que no final do horizonte de

previsão, ou seja, na safra de 2024/2025, a produção total de milho em Mato Grosso será de aproximadamente 70% maior quando comparado com a safra de 2017/2018, onde a produção foi de 26.400,60 mil toneladas.

Por fim, para trabalhos futuros, recomenda-se aplicar outros modelos que não foram considerados para modelagem e previsões da série temporal estudada, tais como os modelos autorregressivos, integrados e de médias móveis (ARIMA), bem como as técnicas de combinação de previsões.

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.

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.

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.

Conab – Companhia Nacional de Abastecimento. *Série histórica das safras*: 2019. Acesso em 21 de agosto, em <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras?start=20>.

Costa, C. A., Cândido, G. A., & Macedo, L. B. (2016). Análise descritiva e comparativa do programa soja plus no estado de Mato Grosso: uma abordagem a partir da responsabilidade social empresarial. *Revista de Administração e Negócios da Amazônia*, 8(3), 292–314.

Embrapa - Empresa Brasileira de Pesquisa Agropecuária. *Embrapa Milho e Sorgo*: 2015. Acesso em 27 de agosto, em https://www.spo.cnptia.embrapa.br/conteudo?p_p_lifecycle=0&p_p_id=conteudoportlet_WAR_sistemasdeproducao6_1galceportlet&p_p_col_count=1&p_p_col_id=column-1&p_p_state=normal&p_r_p_-293187_sistemaProducaoId=7905&p_r_p_996514994_topicoId=8668&p_p_mode=view.

Empaer - Empresa Mato Grossense de Pesquisa Assistencia e Extensao Rural. *Calendário agrícola*: 2019. Acesso em 27 de setembro, em <http://www.empaer.mt.gov.br/-/8066843-calendario-agricola?ciclo=>

Gil, A. C. (2017). *Como elaborar projetos de pesquisa*. São Paulo: Atlas.

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

Hyndman, R. J., & Athanasopoulos, G. (2014). Optimally Reconciling Forecasts in a Hierarchy. *Foresight: The International Journal of Applied Forecasting*, (35), 42–48.

Knechtel, M. R. (2014). *Metodologia da pesquisa em educação: uma abordagem teórico-prática dialogada*. Curitiba: Intersaberes.

Levine, D. M., Stephan, D. F., & Szabat, K. A. (2016). *Estatística - Teoria e Aplicações - Usando Microsoft Excel*. Rio de Janeiro: LTC.

Makridakis, S. G., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: Methods and Applications*. 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. (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).

Prodanov, C. C., & Freitas, E. C. (2013). *Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico*. Novo Hamburgo-RS: Feevale.

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

SNA - Sociedade Nacional de Agricultura. *Milho é uma das principais fontes de alimento do brasileiro com importância estratégica no agronegócio*: 2016. Acesso 25 de setembro, em <https://www.sna.agr.br/milho-e-uma-das-principais-fontes-de-alimento-do-brasileiro-com-importancia-estrategica-no-agronegocio/>

Silva, R. B. Z., Aires, F. F. C., Oenning, E. J., Porto, A. G., & Ultramari, 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 - BJPE*, 5(3), 67–81.

Souza, A. E., Reis, J. G. M., Raymundo, J. C., & Pinto, R. S. (2018). Estudo da produção do milho no Brasil. *South American Development Society Journal*, 4(11), 182–194.

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.

Tibulo, C., & Carli, V. (2014). Previsão do preço do milho, através de séries temporais. *Scientia Plena*, 10, 1–10.

Veiga, C. P., Veiga, C. R. P., Puchalski, W., Coelho, L. 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.

Porcentagem de contribuição de cada autor no manuscrito

Rodolfo Benedito Zattar da Silva – 55%

Rosângela Natalina Zattar da Silva – 15%

Fábia Fernanda da Costa Aires – 15%

Eduardo José Oenning Soares – 15%