

## CADERNOS DO IME – Série Estatística

Universidade do Estado do Rio de Janeiro - UERJ  
ISSN on-line 2317-4536 / ISSN impresso 1413-9022 - v.49, p.17-34 2020  
DOI: 10.12957/cadest.2020.57913

# ESTUDO DE MÉTODOS PARA PREVISÃO DA PRODUÇÃO DE GRÃOS NO BRASIL VIA SÉRIES TEMPORAIS

Simone Beatriz Wolfart

Universidade Tecnológica Federal do Paraná - UTFPR Pato Branco – PR  
[simonebeatrizwolfart@hotmail.com](mailto:simonebeatrizwolfart@hotmail.com)

José Donizetti de Lima

Universidade Tecnológica Federal do Paraná - UTFPR Pato Branco – PR  
[donizetti@utfpr.edu.br](mailto:donizetti@utfpr.edu.br)

Gilson Adamczuk Oliveira

Universidade Tecnológica Federal do Paraná - UTFPR Pato Branco – PR  
[gilson@utfpr.edu.br](mailto:gilson@utfpr.edu.br)

Armenio Fritsch Neto

Universidade Tecnológica Federal do Paraná - UTFPR Pato Branco – PR  
[armenio\\_19@hotmail.com](mailto:armenio_19@hotmail.com)

### Resumo

*A previsão é uma ferramenta fundamental para se posicionar estrategicamente frente aos negócios futuros. O objetivo deste artigo é estudar a previsão da produção de grãos no Brasil, utilizando os dados históricos disponibilizados pela CONAB, no período de 1976/1977 a 2018/2019, via análise de séries temporais. Foi utilizado o método Box & Jenkins para realizações das previsões. A definição do melhor modelo foi por meio da avaliação dos erros de previsão calculados para cada modelo e escolhido o que melhor representa a série analisada. O modelo que mais se adequou foi o ARIMA (1,1,2), com MAPE de 7,1% (validação) e 5,4%(teste) com AIC 18,05. Com os resultados obtidos na previsão da produção, percebeu-se que o modelo escolhido atendeu a expectativa da previsão, pois gerou resultados dentro dos limites inferiores e superiores de variação com 95% de confiança.*

**Palavras-chave:** *Produção de grãos, Previsões, Séries Temporais.*

## 1. Introdução

A agricultura brasileira vem apresentando intenso aumento da produção e da produtividade. O expressivo volume de compras chinesas desencadeadas a partir do início da década de 2000, estimulou esse aumento e criou as bases econômicas que propiciaram os investimentos necessários. Ampliou-se o mix de produtos e o número de países para os quais o Brasil exporta alimentos. Os produtores intensificaram o uso de seus recursos e se capacitaram para gerir os seus estabelecimentos com crescentes cuidados administrativos e gerenciais. Dessa forma, o sucesso passou a ser cada vez mais dependente da capacidade do produtor de se apropriar das inovações (EMBRAPA, 2018).

A produção brasileira de grãos deverá passar de 236,7 milhões de toneladas em 2018/19 para 300 milhões de toneladas em 2028/29. Isso indica um acréscimo de 63 milhões de toneladas à produção atual. Em valores relativos, representa um acréscimo de 27,0%, ou uma taxa anual de crescimento de 2,4%. A área de grãos deve expandir-se dos atuais 62,8 milhões de hectares para 72,4 milhões de hectares em 2028/29. Essas estimativas são compatíveis com a expansão da produção de grãos nos últimos dez anos, no qual a produção cresceu 58,0% (CONAB, 2019). Esse resultado indica haver potencial de crescimento para atingir os valores projetados. Milho de segunda safra, soja e trigo devem continuar gerando o crescimento de grãos (MAPA, 2019).

O crescimento da população e o processo de urbanização, somados à elevação da renda e ao incentivo à produção e ao consumo dos biocombustíveis, fizeram com que a demanda por alimentos e produtos agrícolas tivesse aumento considerável a partir da década de 2000 com previsão de manutenção desse cenário nas próximas décadas. Projeta-se que, em 2025, os países em desenvolvimento serão responsáveis por 96% do consumo adicional de grãos e 88% de produtos de origem animal (OECD-FAO, 2017).

Outros fatores relevantes a serem considerados quando se analisa a demanda por produtos agrícolas no comércio mundial são a taxa de câmbio e o preço do petróleo. Projeções realizadas por várias organizações indicam a apreciação do dólar e preços baixos para o petróleo na próxima década (European Commission, 2016; OECD-FAO, 2016; Estados Unidos, 2017b). Se, por um lado, o dólar mais alto favorece as exportações brasileiras de commodities, por outro pressiona os custos de produção, que poderão ser parcialmente compensados pela redução do preço do petróleo (EMBRAPA, 2018).

O principal aspecto a ser considerado no cenário das projeções do ano de 2020 é a pandemia do COVID-19. Esta afetou profundamente a trajetória da economia brasileira ao longo de 2020 e 2021. Apesar dos enormes problemas trazidos pelo coronavírus, o ano de 2020, é considerado como de excelentes resultados para a produção agropecuária, e também em faturamento para o setor. Segundo a CONAB, a safra de grãos deste ano deve ser de 250,8 milhões de toneladas. Esta é a maior safra que o país já teve (MAPA, 2020).

A previsão de demanda é a base para o planejamento estratégico da produção, pois, é a partir dela que as organizações podem dimensionar os planos de capacidade, fluxo de caixa, estoques, mão de obra, etc (MONTGOMERY; JENNINGS; KULAHCI, 2008). Diante dessa discussão, tem-se o seguinte problema: Como realizar a previsão de produção de grãos no Brasil para a próxima década?

A previsão é a etapa inicial no processo de negócios, Werner e Ribeiro (2006) afirmam que, quanto maior a acuracidade de uma previsão, menor será o risco no processo decisório, além de facilitar o planejamento e o controle sobre os insumos e necessários para a produção. Quaisquer que sejam as circunstâncias ou horizontes de tempo envolvidos, a previsão é uma aliada importante ao planejamento eficiente (HYNDMAN, ATHANASOPOULOS, 2018).

As situações de previsão variam amplamente em seus horizontes temporais, fatores determinantes, resultados reais, tipos de padrões de dados e muitos outros aspectos. Os métodos de previsão podem ser simples, como usar a observação mais recente como previsão, ou altamente complexo, como redes neurais e sistemas econométricos de equações simultâneas. A escolha do método depende de quais dados estão disponíveis, da previsibilidade e a quantidade a ser prevista (HYNDMAN, ATHANASOPOULOS, 2018).

Existem métodos estatísticos que, embora eficientes em determinadas aplicações, apresentam algum grau de complexidade, tais como a classe de modelos de séries temporais como parâmetros variantes no tempo, da família GARCH (generalized autoregressive conditional heteroskedascity). Estes modelos tem demonstrado que explicam propriedades estatísticas das séries temporais e sob ponto de vista prático, o domínio da previsão (DUARTE; FONSECA, 2003). Assim, este trabalho tem como objetivo estudar a produção de grãos e obter uma previsão da safra para a próxima década.

## 2. Referencial teórico

Nesta seção é abordado inicialmente um panorama do setor agrícola, custos de produção de grãos e apresentados as séries temporais com ênfase nos métodos Autoregressivos Integrados de Média Móvel (ARIMA) e Suavização Exponencial (SE).

### 2.1. Cenário atual do setor

Pesquisa realizada pelo IBGE, destaca que em 2017, haviam 15,1 milhões de pessoas ocupadas nos estabelecimentos agropecuários. Isso representou uma queda de 1,5 milhões de pessoas em relação ao Censo Agro de 2006. Nos estabelecimentos da Agricultura Familiar (AF), a população ocupada se reduziu em 2 milhões de pessoas, enquanto nos estabelecimentos não caracterizados dessa forma, deu-se o oposto: um aumento de 702,9 mil trabalhadores (IBGE, 2019).

Cerca de 77% dos estabelecimentos foram classificados como de AF e foram responsáveis por 23% do valor da produção, ocupando 23% da área total dos estabelecimentos agropecuários. Trabalhavam na AF cerca de 10,1 milhões de pessoas, ou 67% da mão de obra dos estabelecimentos agropecuários. A média de ocupados por estabelecimento caiu de 3,2 pessoas, em 2006, para 3,0 pessoas, em 2017. Em sentido oposto, o número de tratores cresceu 49,9% no período e chegou a 1,22 milhões de unidades (IBGE, 2019).

De 2006 para 2017, cresceu em 143% a contratação de mão de obra para os estabelecimentos agropecuários com intermediação de terceiros, passando de 251.652 para 611.624 no período. O Censo Agro 2017 contou 5.073.324 estabelecimentos agropecuários no Brasil, com redução de 2,0% em relação a 2006. Mas a área dos estabelecimentos cresceu 5,8% no período e chegou a 351.289.816 hectares. Com exceção do Nordeste, houve aumento de área em todas as regiões. No Sul, esse aumento ocorreu mesmo com a queda no número de estabelecimentos (IBGE, 2019).

O milho foi cultivado em 1,6 milhões de estabelecimentos agropecuários, que produziram 88 milhões de toneladas em 15,8 milhões de hectares. Analisando a última década, observa-se que a cultura teve expressivo incremento de produtividade (56%). A soja apresentou um aumento de 123% na produção, alcançando 103 milhões de toneladas em 31 milhões de hectares, um aumento de 72% na área colhida (IBGE, 2019).

## 2.2. Custos de produção agrícola

A gestão de custos nas empresas rurais, assim como nas indústrias, abrange dois aspectos principais: o processo produtivo e as atividades comerciais. O custo de produção agrícola é uma excepcional ferramenta de controle e gerenciamento das atividades produtivas, pois gera importantes informações para subsidiar a tomada de decisão pelos produtores rurais e a formulação de estratégias pelo setor público. Para administrar com eficiência e eficácia uma unidade produtiva agrícola, é imprescindível, dentre outras variáveis, o domínio da tecnologia e do conhecimento dos resultados dos gastos com os insumos e serviços em cada fase produtiva da lavoura, que tem no custo um indicador importante das escolhas do produtor (CONAB, 2010).

O custo de produção é definido como a soma dos valores de todos os recursos (insumos e serviços) utilizados no processo produtivo de uma atividade agrícola, em certo período de tempo, e que podem ser classificados em curto e longo prazos. A estimativa dos custos está ligada à gestão da tecnologia, ou seja, à alocação eficiente dos recursos produtivos e ao conhecimento dos preços desses recursos (CARNEIRO et al., 2019).

A análise da atividade produtiva pode ser realizada tomando por base os custos de produção e os preços de venda do produto. Essa relação possibilita a análise financeira, levando em conta a remuneração obtida com a comercialização, a cobertura do custeio, dos custos variável, operacional e total. O resultado pode gerar os índices de análise quantitativa do ponto de equilíbrio e a geração de diversos indicadores que podem auxiliar na análise de rentabilidade da unidade produtiva (CONAB, 2010).

Ao se falar em custos, deve-se definir os conceitos em termos econômicos. O custo econômico considera os custos explícitos, que se referem ao desembolso efetivamente realizado, e os custos implícitos nos quais não ocorrem desembolsos efetivos, como é o caso da depreciação e do custo de oportunidade, que se refere ao valor que um determinado fator poderia receber em algum uso alternativo (CASTRO, 2009).

Os custos estão diretamente ligados ao lucro das atividades desenvolvidas, pois compõe o contexto geral no demonstrativo de resultados, onde Lucro é demonstrado pelas Receitas menos Custos e Despesas. No mundo atual, as estratégias bem-sucedidas que combinam proporções diferentes de liderança de custos, diferenciação de produtos e foco em mercado parecem ser a chave para obter uma posição no setor de atividade em que se enquadra (BREALEY, 2013).

A Conab tem conhecimento e experiência acumulada (desde 1976) na elaboração de custo de produção agrícola e a sua metodologia tem sido observada por entidades estatais e não-estatais para estudos e fonte de informação para tomada de decisões políticas, administrativas, econômicas, financeiras e operacionais.

### **2.3. Séries temporais**

Uma série temporal é qualquer conjunto de observações ordenadas no tempo. As séries temporais possibilitam aos usuários gerar previsões baseadas em informações do seu passado e fornece uma visão da dinâmica do relacionamento entre as variáveis. A principal característica desse tipo de conjuntos de dados é que suas observações são relacionadas, e que é possível analisar e modelar esta relação para estimar como essas observações se comportarão no futuro (BAYER e SOUZA, 2010; EHLERS, 2009; MORRETIN e TOLOI, 2006).

O objetivo da análise de uma série temporal consiste em elaborar um modelo estatístico que descreva adequadamente a procedência da série, de maneira que as implicações teóricas do modelo sejam compatíveis com as pautas de amostras observadas nas séries temporais. Depois do modelo elaborado, a partir da série temporal, pode ser utilizado para prever a evolução futura da série ou explicar a relação entre os distintos componentes do modelo (BAYER e SOUZA, 2010).

Para Morettin e Toloí (2006), os principais objetivos para analisar uma série temporal são: investigar o mecanismo gerador da série temporal, ou seja, qual o evento que origina a série; fazer previsões dos valores futuros da série, que podem ser de curto e longo prazo; descrever o comportamento da série temporal, tais como sazonalidade e tendência que podem auxiliar no comportamento da série; e procurar periodicidades relevantes nestes dados que tenham maior correlação das séries temporais analisadas.

Os modelos da família Box & Jenkins e também os modelos SE são duas abordagens bastante utilizadas para previsão de séries temporais e fornecem abordagens complementares para o problema. Embora os modelos de SE sejam baseados em uma descrição da tendência e sazonalidade nos dados, os modelos ARIMA visam descrever as autocorrelações nos dados (HYNDMAN e ATHANASOPOULOS, 2018).

## 2.4. Estudos correlatos ao tema

Estudos anteriores destacam a importância de realizar previsões de produção, como na pesquisa Lima et al. (2016), no estudo de uma abordagem sistemática para avaliar o desempenho de técnicas individuais e suas combinações para prever a demanda de água urbana, usaram três técnicas de previsão: suavização exponencial (ES), média móvel integrada autorregressiva sazonal (SARIMA) e modelos de redes neurais artificiais (RNA). Catorze combinações de previsões avaliadas com o objetivo de melhorar a precisão da estimativa. Essa abordagem sistemática foi aplicada aos dados mensais durante um intervalo de 2000 a 2011. Dados de 10 cidades do estado do Paraná, Brasil, foram avaliados. De acordo com o critério MAPE (Average Absolute Percentage Error), os resultados indicam que a escolha do modelo mais preciso de ES ou SARIMA produz o melhor desempenho global de previsão, que apresentou o menor desvio padrão (0,667%) e um MAPE de 3,297%.

O MAPA realiza o trabalho de projeções do agronegócio no Brasil, a última versão publicada foi em 2019, apresenta as projeções nacionais, e de regiões selecionadas e utiliza-se de vários estudos realizados por instituições nacionais e internacionais através das quais têm-se informações adicionais sobre tendências e cenários. Nesta atualização das projeções para os próximos 10 anos a safra de grãos terá uma produção por volta de 300,1 milhões de toneladas, e corresponde a um acréscimo de 26,8% sobre a atual safra que está estimada em 236,7 milhões de toneladas. As projeções foram realizadas utilizando modelos econométricos específicos. São modelos de séries temporais que têm grande utilização em previsões de séries. Estes trabalhos dão referências e indicações que servem de direção dos resultados dos modelos usados em previsões (MAPA, 2019).

## 3. Metodologia

Para o presente trabalho foram utilizados dados de livre acesso em sites governamentais, série histórica da produção da safra de grãos – CONAB (Companhia Nacional de Abastecimento), projeções do agronegócio – MAPA (Ministério da Agricultura, Pecuária e Abastecimento).

As projeções da produção, área plantada, de grãos no Brasil realizadas pelo MAPA para o Brasil são através dos seguintes métodos estatísticos: Suavização Exponencial, Modelos de Box e Jenkins (ARIMA) e Modelos em Espaço de Estados.

Para cada produto aplicaram-se os três métodos, porém foi escolhido apenas um modelo. O critério da escolha do modelo baseou-se em comparações com outras tendências apresentadas e com a familiaridade de especialistas do setor analisado (MAPA, 2018).

Dada a complexidade de alguns dos modelos de previsão, para realização deste estudo, decidiu-se pela utilização de pacotes computacionais. O *Statgraphics*, um dos pacotes estatísticos genéricos mais difundidos, possui as opções dos modelos de decomposição, ARIMA e SE no seu módulo de *forecasting*, apresentando uma interface amigável (PELLEGRINI e FOGLIATTO, 2001; STATGRAPHICS, 2020). Nesse estudo, optou-se pelo ajuste de modelos ARIMA até ordem 2 e por dispor-se de um histórico relativamente longo, onde esses métodos se destacam.

Em relação a abordagem do problema, esta pesquisa é quantitativa, pois utiliza-se de técnicas e recursos padronizados já existentes na literatura. É bibliográfica quanto aos procedimentos técnicos, portanto, elaborada a partir de materiais já publicados em livros e artigos de periódicos, teses, dissertações e congressos científicos (GIL, 2002).

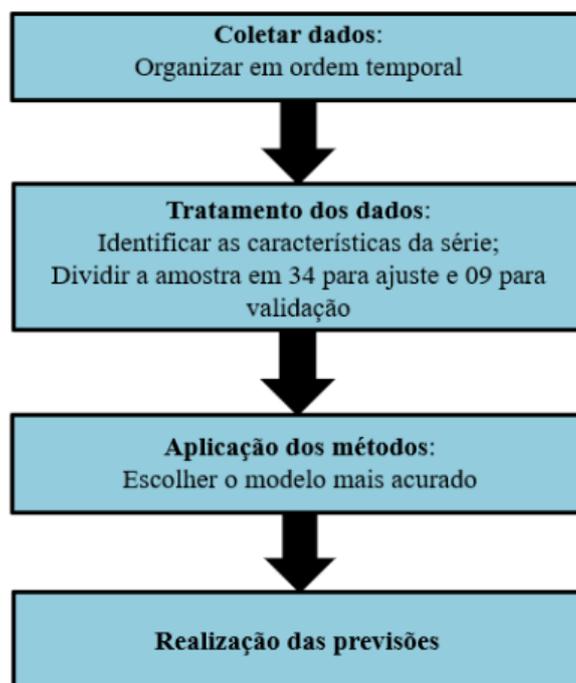
Inicialmente na construção do modelo estatístico, foi realizada a análise das séries temporais para identificar o comportamento e selecionar a melhor técnica que se ajusta aos dados (modelos ARIMA até ordem 2). As análises dos dados foram realizadas no software *Statgraphics*.

A acurácia das previsões nos dados reservados para a validação é a última e a mais importante medida da performance preditiva de um modelo (ZOU et al., 2007). Neste estudo, a amostra coletada é dividida em duas partes. A primeira parte deve constar de aproximadamente 80% das observações, sendo estas utilizadas para o ajuste dos modelos. As observações restantes são reservadas para verificar a acurácia do modelo eleito. Para a escolha do modelo mais adequado, em cada classe, utiliza-se o critério AIC (AKAIKE, 1976). Para que o modelo eleito por este critério seja adequado é preciso que a acurácia da validação seja maior ou igual à do ajuste (STATGRAPHICS, 2020). Neste estudo, a amostra coletada foram os anos safra de 1976/1977 a 2018/2019, totalizando 43 períodos, sendo 34 (79%) para ajuste do modelo e 09 (21%) para validação. Assim, segue-se de perto a recomendação usual (80% treinamento e 20% teste) conforme (HYNDMAN e ATHANASOPOULOS, 2018).

Para previsão serão considerados os 10 períodos.

A Figura 1 ilustra a estrutura do modelo proposto para a realização das previsões.

Figura 1 – Estrutura do modelo de previsão



Fonte: Adaptado de Ferro et al, (2019) e Lima et al., (2016).

Busca-se ilustrar as etapas que devem ser percorridas na identificação de um modelo o qual se considera adequado para gerar as previsões. Como ponto de partida para a formação do banco de dados, deve-se coletar os dados e organizá-los em ordem temporal. Na sequência, parte-se para o tratamento preliminar da série em estudo de acordo com o que preconiza a teoria de séries temporais: separação da série em ajuste e validação. Para atingir o objetivo proposto, conforme destaca a Figura 1, são executadas quatro fases. Inicialmente, na primeira fase, caracteriza-se pela coleta dos dados que posteriormente são tratados e organizados a fim de possibilitar a obtenção de modelos de previsão.

#### 4. Resultados e discussões

Nesta seção serão apresentados os resultados obtidos com a análise dos dados históricos da produção de grãos no Brasil. Primeiramente, será apresentada uma estatística descritiva dos dados para posteriormente apresentar a escolha do modelo de previsão para os próximos 10 anos. A Tabela 1 apresenta os dados da área de cultivo e da produção de grãos no Brasil, disponibilizado pela CONAB.

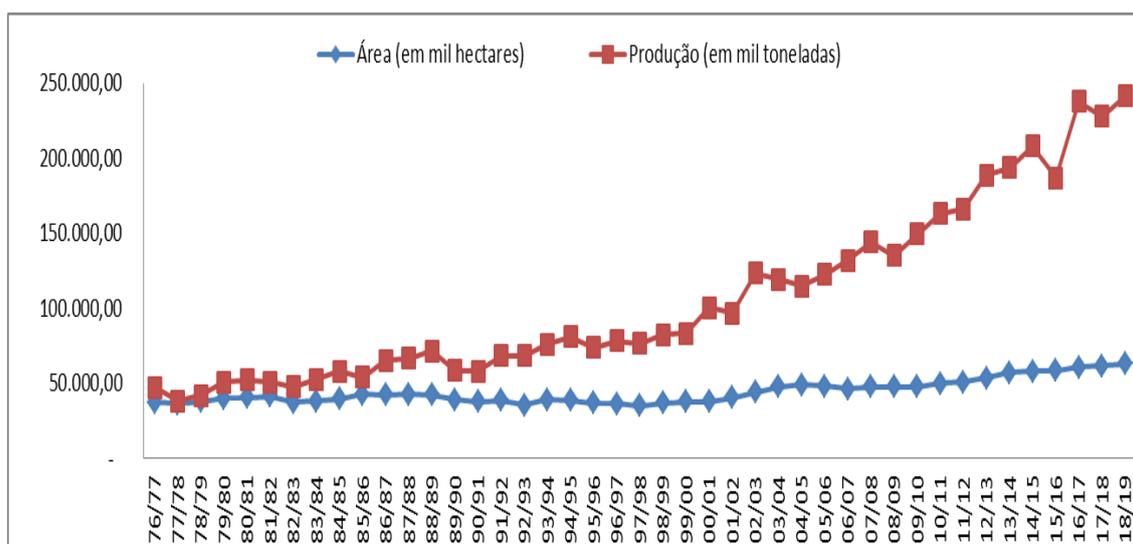
Tabela 1 – Área de cultivo (mil hectares) e Produção de Grãos (mil toneladas)

Safra	Área	Produção	Safra	Área	Produção	Safra	Área	Produção
1976/77	37.318,94	46.943,13	1990/91	37.893,70	57.899,60	2004/05	49.068,20	114.695,00
1977/78	36.570,56	38.213,36	1991/92	38.492,30	68.400,10	2005/06	47.867,62	122.530,78
1978/79	37.495,21	41.554,73	1992/93	35.621,30	68.253,20	2006/07	46.212,60	131.750,60
1979/80	40.158,18	50.871,22	1993/94	39.094,00	76.035,00	2007/08	47.411,20	144.137,30
1980/81	40.384,04	52.212,21	1994/95	38.538,90	81.064,90	2008/09	47.674,40	135.134,50
1981/82	41.174,89	50.861,08	1995/96	36.970,90	73.564,70	2009/10	47.415,70	149.254,90
1982/83	37.212,29	47.654,56	1996/97	36.574,80	78.426,70	2010/11	49.872,61	162.803,00
1983/84	38.020,93	52.431,00	1997/98	35.000,80	76.558,70	2011/12	50.885,20	166.172,10
1984/85	39.692,66	58.143,30	1998/99	36.896,20	82.437,89	2012/13	53.562,97	188.658,05
1985/86	42.533,95	53.925,17	1999/00	37.824,30	83.029,93	2013/14	57.060,00	193.622,01
1986/87	42.062,05	64.949,26	2000/01	37.847,30	100.266,88	2014/15	57.914,70	207.770,01
1987/88	42.810,70	66.307,57	2001/02	40.235,00	96.799,00	2015/16	58.335,99	186.610,40
1988/89	42.243,34	71.487,59	2002/03	43.946,80	123.168,00	2016/17	60.889,30	237.671,35
1989/90	38.945,00	58.280,33	2003/04	47.422,50	119.114,20	2017/18	61.721,80	227.679,29
						2018/19	62.958,60	241.335,73

Fonte: Elaborada pelos autores com dados da CONAB

Por meio dos dados coletados, observa-se que a área produzida não teve muita variação. Por outro lado, a produção de grãos teve um aumento expressivo, como pode ser observada na Figura 2, a qual apresenta a série temporal dos períodos disponíveis para análise.

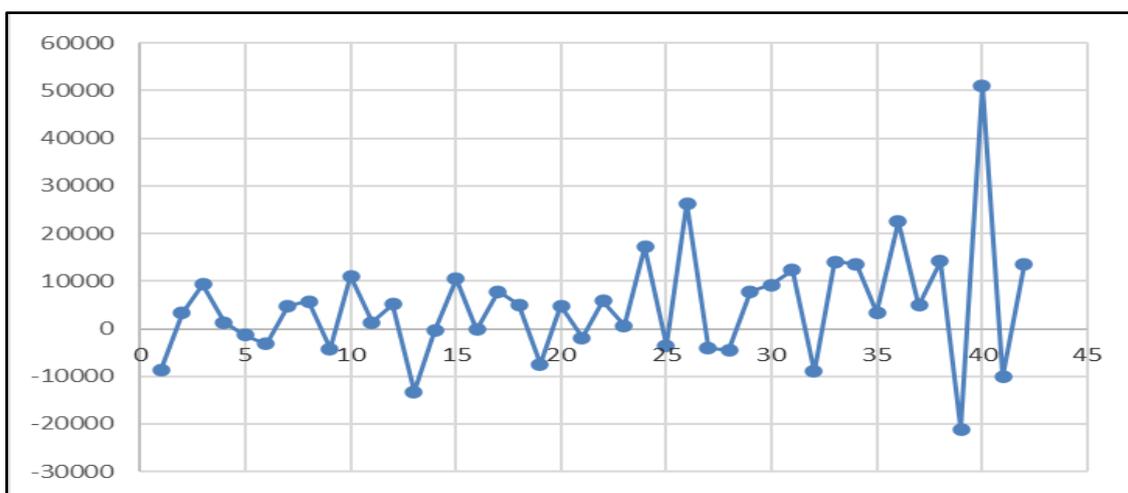
Figura 2 – Série temporal da área de cultivo e da produção de grãos por ano safra



Fonte: Elaborada pelos autores com dados da CONAB

A Figura 2 ilustra o comportamento da série ao longo dos anos. Percebe-se uma crescente produção anual de grãos. Esse fato decorre em função da elevação da produtividade, visto que a área se manteve praticamente constante no intervalo de tempo observado. Esta verificação é consistente, pois os dados de produção de grãos são os valores cumulativos de cada ano-safra. Fazendo-se uma diferença ( $d=1$ ) percebe-se que já é possível estabilizar a série conforme figura 3 para poder então modelar pelo método ARIMA.

Figura 3 – Série temporal da área de cultivo e da produção de grãos por ano safra ( $d=1$ )



Fonte: Elaborada pelos autores a partir dos resultados no *statgraphics*

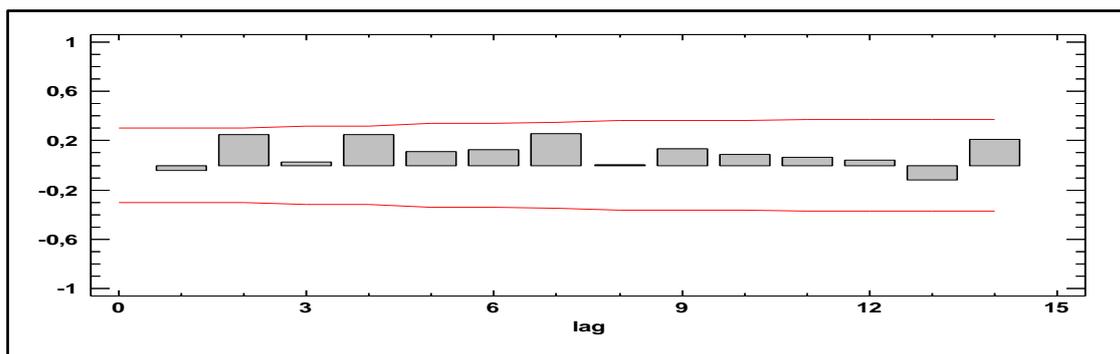
Seguindo a metodologia proposta, a obtenção do modelo mais adequado foi baseada nos testes estatísticos das séries temporais disponíveis, utilizando o critério AIC, o qual apresentou o modelo mais adequado para realização de previsão ser o Modelo ARIMA(1,1,2) com AIC = 18,05 (Tabela 2) com os resultados de ajuste na Tabela 3. As representações das autocorrelações (FAC) e autocorrelações parciais (FAP) para esse modelo estão apresentadas, respectivamente, nas Figuras 4 e 5.

Tabela 2 – Parâmetros do modelo selecionado ARIMA (1,1,2)

	parâmetro	Valor $t$	Valor $p$
AR(1)	1,037	38,68	<0,001
MA(1)	1,516	9,81	<0,001
MA(2)	-0,569	-3,40	<0,001

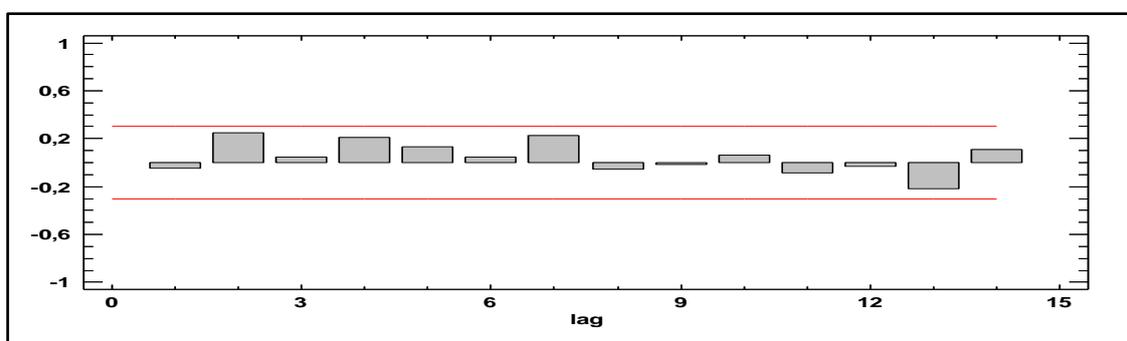
Fonte: Elaborada pelos autores a partir dos resultados no *statgraphics*

Figura 4 – Autocorrrelação dos resíduos (FAC) para o modelo ARIMA (1,1,2)



Fonte: Elaborada pelos autores a partir dos resultados no *statgraphics*

Figura 5 – Autocorrrelação parcial dos resíduos (FACP) para o modelo ARIMA (1,1,2)



Fonte: Elaborada pelos autores a partir dos resultados no *statgraphics*

A Tabela 3 apresenta os valores previstos para produção com os 43 dados históricos de cada ano safra de 1976/1977 até 2018/2019.

Tabela 3 – Previsão de produção de grãos ARIMA (1,1,2)

Período	Safra	Produção	Previsão	Resíduos	Ajuste/ Validação
1	76/77	46.943,10	d = 1		A
2	77/78	38.213,40	48.009,80	(9.796,49)	A
3	78/79	41.554,70	45.823,10	(4.268,40)	A
4	79/80	50.871,20	46.141,80	4.729,41	A
5	80/81	52.212,20	51.815,40	396,83	A
6	81/82	50.861,10	55.384,90	(4.523,79)	A
7	82/83	47.654,60	55.972,40	(8.317,82)	A
8	83/84	52.431,00	54.242,60	(1.811,57)	A
9	84/85	58.143,30	56.042,80	2.100,54	A
10	85/86	53.925,20	60.325,10	(6.399,96)	A
11	86/87	64.949,30	59.948,80	5.000,43	A
12	87/88	66.307,60	65.638,90	668,72	A

13	88/89	71.487,60	69.385,90	2.101,64	A
14	89/90	58.280,30	73.715,70	(15.435,40)	A
15	90/91	57.899,60	68.243,20	(10.343,60)	A
16	91/92	68.400,10	64.920,00	3.480,13	A
17	92/93	68.253,20	69.664,30	(1.411,09)	A
18	93/94	76.035,00	72.186,40	3.848,64	A
19	94/95	81.064,90	77.421,40	3.643,54	A
20	95/96	73.564,70	82.779,00	(9.214,32)	A
21	96/97	78.426,70	80.859,20	(2.432,50)	A
22	97/98	76.558,70	82.242,10	(5.683,41)	A
23	98/99	82.437,90	82.119,40	318,48	A
24	99/00	83.029,90	85.214,90	(2.184,95)	A
25	00/01	100.267,00	87.159,40	13.107,50	A
26	01/02	96.799,00	97.594,50	(795,48)	A
27	02/03	123.168,00	100.828,00	22.339,70	A
28	03/04	119.114,00	116.473,00	2.641,52	A
29	04/05	114.695,00	122.018,00	(7.322,61)	A
30	05/06	122.531,00	121.049,00	1.481,51	A
31	06/07	131.751,00	124.726,00	7.024,70	A
32	07/08	144.137,00	131.915,00	12.222,40	A
33	08/09	135.135,00	142.220,00	(7.085,31)	A
34	09/10	149.255,00	141.837,00	7.417,87	A
35	10/11	162.803,00	148.824,00	13.978,80	V
36	11/12	166.172,00	160.176,00	5.995,64	V
37	12/13	188.658,00	167.231,00	21.427,20	V
38	13/14	193.622,00	182.637,00	10.984,60	V
39	14/15	207.770,00	192.820,00	14.950,30	V
40	15/16	186.610,00	204.748,00	(18.137,40)	V
41	16/17	237.671,00	198.239,00	39.432,10	V
42	17/18	227.679,00	222.808,00	4.870,84	V
43	18/19	241.336,00	230.373,00	10.962,50	V

Fonte: Elaborada pelos autores a partir dos resultados no *statgraphics*

Durante o período em que os dados reais estão disponíveis, ele também exibe os valores previstos do modelo ajustado e os resíduos (previsão de dados). No entanto foram feitos as previsões para os próximos 10 anos, que estão representados na Tabela 4. A média dos 10 anos é coerente com as projeções feito pelo MAPA para os próximos 10 anos “a safra de grãos terá uma produção por volta de 300,1 milhões de toneladas” (seção 2.4).

Tabela 4 – Previsão de produção de grãos para períodos futuros

Período	Safra	Previsão	Limite inferior	Limite superior
44	19/20	253.127,00	237.263,00	268.992,00
45	20/21	264.919,00	247.031,00	282.807,00
46	21/22	277.145,00	256.929,00	297.361,00
47	22/23	289.821,00	266.988,00	312.655,00
48	23/24	302.965,00	277.237,00	328.693,00
49	24/25	316.592,00	287.701,00	345.483,00
50	25/26	330.721,00	298.406,00	363.037,00
51	26/27	345.371,00	309.374,00	381.369,00
52	27/28	360.561,00	320.624,00	400.498,00
53	28/29	376.310,00	332.176,00	420.443,00
Média		311.753,20	283.372,90	340.133,80

Fonte: Elaborada pelos autores a partir dos resultados no *statgraphics*

Para as safras além do final da série, a Tabela 4, mostra limites inferiores e superiores para as previsões. Esses limites mostram onde é provável que o valor real dos dados em um momento futuro selecionado esteja com 95,0% de confiança, assumindo que o modelo ajustado seja apropriado para os dados. Foram realizados testes estatísticos através do *statgraphics* que apresentam na Tabela 4, as medidas de acurácia.

Tabela 5 – Resultado de testes estatísticos e modelos ARIMA testados

Modelo	AIC	MAPE (treinamento)	MAPE (validação)
ARIMA (1,1,2)	18,05	7,07%	5,38%
ARIMA (2,1,1)	18,08	7,57%	5,51%
ARIMA (0,1,0)	18,15	8,59%	8,28%
ARIMA (2,1,2)	18,20	7,73%	5,59%
ARIMA (0,1,1)	18,21	8,47%	8,24%
ARIMA (1,1,0)	18,24	8,52%	8,10%
ARIMA (0,1,2)	18,26	8,71%	7,56%
ARIMA (2,1,0)	18,26	8,74%	7,18%
ARIMA (1,1,1)	18,27	8,63%	7,72%

Fonte: Elaborada pelos autores a partir dos resultados no *statgraphics*

A Tabela 5 apresenta os resultados do ajuste de modelos diferentes aos dados. O modelo com o menor valor do Critério de Informação de AKAIKE (AIC) é o modelo ARIMA (1,1,2), além de apresentar os menores valores para o MAPE. Neste estudo, esse modelo foi o que melhor ajustou-se aos dados. Estes resultados corroboram as conclusões do estudo de Ferro et al., (2019), os quais apontam que a escolha do critério de verificação

de precisão de previsões influencia na classificação dos métodos com relação ao desempenho de previsão.

Quando realizada a previsão de produção, foi identificada a presença de ciclos de tendência na série de dados. Foi identificado variabilidade nos dados e uma tendência de aumentar ao longo dos anos. Com os resultados obtidos na previsão de produção praticados, percebeu-se que o modelo escolhido atendeu a expectativa da previsão, pois gerou resultados dentro dos limites inferiores e superiores de previsão com 95,00% de confiança.

## 5. Considerações finais

A elaboração do estudo com a finalidade de prever a produção de grãos se mostra como uma importante ferramenta para os gestores públicos, diante de um ambiente de incertezas e variações, permitindo a antecipação a eventuais problemas e agir de forma preventiva colaborando expressivamente para o planejamento.

O conhecimento de diferentes modelos de análise de séries temporais combinado com a praticidade que os softwares estatísticos possuem, facilita a definição do melhor modelo de previsão, diante dos dados históricos, considerando sempre um critério de escolha (FERRO et al., 2019).

Para validar a metodologia proposta, foi considerada a produção total de grãos por ano-safra. De fato, obteve-se êxito com as previsões do modelo ARIMA (1,1,2). Assim, conclui-se, que as previsões são estratégias adequadas que se adequam melhor para a produção brasileira de grãos, pois proporciona resultados aceitáveis do ponto de vista da acurácia.

Dessa forma, o objetivo da pesquisa foi alcançado, ou seja, estudar a produção de grãos e obter uma previsão da safra para a próxima década. A média dos 10 anos é coerente com as projeções feito pelo MAPA para os próximos 10 anos, sendo que a vantagem é que tem-se previsões detalhadas com intervalos de confiança úteis para análise estratégicas (cenários normal, otimista e pessimista).

Convém observar que o comportamento das séries temporais de área utilizada e produção realizada apresentam crescimento. É possível identificar que o crescimento da produção possui fator relativamente maior do que a área utilizada. Isso sugere uma análise ampliada da relação área utilizada versus produção realizada dando margem a novos

estudos afim de estabelecer horizontes planejamento. Importante entender o limite de produtividade a ser alcançado e assim embasar decisões de possíveis investimentos em estudos para melhorar a produtividade ou em ampliar a área de produção.

Ainda existem questões a serem investigadas em relação a novos métodos de previsão. O manuseio de séries temporais abrangendo outros fatores não apresentados nesse estudo, bem como a utilização da técnica de redes neurais ou outras técnicas de combinações, por exemplo. Isso estabelece uma gama de possibilidades para realização de trabalhos futuros.

## Referências

- AKAIKE, H. (1976). **Canonical correlation analysis of time series and the use of an information criterion, in Systems Identification: Advances and Case Studies** (eds. R. K. Mehra and D. G. Lainiotis), Academic Press, New York, pp. 27-96.
- BAYER, F. M.; SOUZA, A. M. Wavelets e modelos tradicionais de previsão: Um estudo comparativo. **Revista Brasileira de Biometria**, São Paulo. v.28, p.40-61, 2010.
- BREALEY, R. A. **Princípios de finanças corporativas** [recurso eletrônico] Richard A. Brealey, Stewart C. Myers, Franklin Allen. tradução: Celso Roberto Paschoa ; revisão técnica: João Carlos Douat. – 10. ed. – Dados eletrônicos. – Porto Alegre : AMGH, 2013.
- CARNEIRO, D. M.; DUARTE, S. L.; COSTA, S. A. da. Determinantes dos custos da produção de soja no Brasil, **Custos e @gronegócio on line** - v. 15, n. 1, Jan/Mar - 2019.
- CASTRO, E. R. de. **Teoria dos Custos**. In: SANTOS, Maurinho Luiz dos et al. Microeconomia Aplicada. Visconde do Rio Branco: Suprema, 2009.
- CONAB - Companhia Nacional de Abastecimento. **Custos de produção agrícola: a metodologia da Conab**. -- Brasília : Conab, 2010.
- CONAB. Companhia Nacional de Abastecimento. **Série histórica das safras**. Disponível em: <<https://www.conab.gov.br/info-agro/safras/série-historica-das-safras?start=10>> acesso em 28/09/2019.
- DUARTE, E. M.; FONSECA, J. S. A .da A análise da volatilidade do índice PSI-20 baseado em modelos ARCH E GARCH. Estudos de gestão. **Portuguese Journal of Management Studies**, 2003.
- EHLERS, R. S. **Análise de Séries Temporais**. 5. ed. 2009. Disponível em: <<http://www.icmc.usp.br/~ehlers/stemp/stemp.pdf>>. Acesso dia 26/10/2019.
- EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária Ministério da Agricultura, **Pecuária e Abastecimento. VISÃO 2030, O Futuro da Agricultura Brasileira**. Brasília, DF, 2018. Disponível em: <<https://www.embrapa.br/visao/o-futuro-da-agricultura-brasileira>>. Acesso em 05/10/2019.
- FERRO, W.A.; LIMA, J.D. de; TRENTIN, M.G. Combinações de Métodos Quantitativos na Previsão de Demanda de Vendas de Eletrodomésticos. **GEPROS. Gestão da Produção, Operações e Sistemas**, v. 14, n. 5, p. 67 - 88, 2019.
- GIL, Antônio Carlos. **Como elaborar projetos de pesquisa**. 4. ed. - São Paulo: Atlas, 2002.

HYNDMAN, R.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. O Texts, Monash University, Australia, 2018.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Censo Agropecuário 2017**. Rio de Janeiro, 2019. Disponível em: < <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/21814-2017-censo-agropecuario.html?=&t=publicacoes>> Acesso em 03/11/2019.

LIMA, J. D. de; BATISTUS, D. R.; ADAMCZUK, G. O.; TRENTIN, M. G.; POZZA, C. B. A study of the performance of individual techniques and their combinations to forecast urban water demand. **Espacios**, v.37, n.22, p.5, 2016.

Mancuso; A. C. B.; Werner, L. A comparative study on combinations of forecasts and their individual forecasts by means of simulated series. **Acta Scientiarum**, Technology, v. 41, e41452, 2019.

MAPA - Ministério da Agricultura, Pecuária e Abastecimento. **Projeções do Agronegócio**. Brasília, 2019.

MAPA - Ministério da Agricultura, Pecuária e Abastecimento. **Projeções do Agronegócio**. Brasília, 2020.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Séries Analysis and Forecasting**. Hoboken: John Wiley & Sons, Inc., 2008.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: Edgar Blucher, 2006.

PELLEGRINI, F.R.; FOGLIATTO, F.S. Metodologia para Implantação de Sistemas de Previsão de Demanda – técnicas e estudo de caso. **Anais do XXI ENEGEP** – Encontro Nacional de Engenharia de Produção – CD-ROM. Salvador, 2001.

STATGRAPHICS CENTURION XVI. Version 16.1.11. User's Guide. 2020.

WERNER, L.; RIBEIRO J. **Modelo Composto para Prever Demanda Através da Integração de Previsões**. Produção, Vol.16, n. 3, p.493-509, 2006.

ZOU, H.F.; XIA, G.P.; YANG, WANG, H.Y. An investigation and comparison of artificial neural network and time series models for Chinese food grain price forecasting. **Neurocomputing**. v. 70. 2007. p. 2913–2923.

## **STUDY OF METHODS FOR FORECASTING GRAIN PRODUCTION IN BRAZIL THROUGH TIME SERIES**

### **Abstract**

*Forecasting is a fundamental tool to strategically position yourself for future business. The objective of this article is to study the prediction of grain production in Brazil, using historical data made available by CONAB, in the period from 1976/1977 to 2018/2019, through time series analysis. The Box & Jenkins method was used for forecasting. The definition of the best model was made by evaluating the forecast errors calculated for each model and choosing the one that best represents the analyzed series. The most suitable model was ARIMA (1.1.2), with a MAPE of 7.1% (validation) and 5.4% (test) with AIC 18.05. With the results obtained in the production forecast, it was noticed that the chosen model met the forecast expectation, as it generated results within the lower and upper limits of variation with 95% confidence.*

**Key-words:** *Grain production, Forecasts, Time Series.*