

Panorama Nacional da Cultura da Laranja e Previsões Agrícolas para o Estado de São Paulo

Carla Adriana Pizarro Schmidt, Camila Ciello, Ingridy Maria Xavier Miranda, Jandrei Sartori Spancerski, José Airton Azevedo dos Santos

Resumo: O Brasil é um dos maiores produtores de laranja do mundo. O cultivo tem importância econômica no mercado de importação e exportação uma vez que necessita de um clima específico para produção em abundância. Nesse contexto, o objetivo foi de avaliar o panorama nacional do cultivo da laranja no Brasil, utilizando modelos que podem ser aplicáveis às séries temporais. Primeiramente elaborou-se um panorama da citricultura no Brasil, para tanto utilizou-se de análise de componentes principais e agrupamento, realizado com apoio do software Tanagra, realizou-se uma análise descritiva dos dados e por fim a previsão da área plantada, área colhida, da produção e do rendimento da laranja para o ano de 2019 do estado de São Paulo. Com a análise do cenário da laranja do Brasil, percebeu-se que todos os estados brasileiros cultivam laranjas, sendo o estado de São Paulo o que apresenta maior área destinada ao cultivo e produção, enquanto que o estado do Paraná se destaca em produtividade sendo esta superior inclusive à produtividade do estado de São Paulo. Com os resultados obtidos foi possível estabelecer o melhor modelo de suavização exponencial para cada caso. O software NNQ mostrou-se capaz de auxiliar na realização das previsões pelos diversos métodos, bem como na indicação dos melhores modelos com base nos valores dos erros, U de Theil e Akaike que indicou como um tratamento estatístico eficiente dos dados brutos e os modelos MNA e MNM como os melhores modelos de suavização exponencial para essa análise e previsão.

Palavras chave: Agronegócio, Ferramentas Estatísticas, Produção, Suavização Exponencial.

Orange Culture National Overview and Agricultural Forecasts for São Paulo State

Abstract: Brazil is one of the largest orange growers in the world. Cultivation has economic importance in the import and export market since it needs a specific climate for abundant production. In this context, the objective was to evaluate the national panorama of orange cultivation in Brazil, using models that may be applicable to time series. Firstly, a panorama of citriculture in Brazil was elaborated. For this, we used principal component analysis and clustering, performed with the support of Tanagra software, a descriptive analysis of the data was performed and finally the forecast of the planted area, harvested area of orange production and yield for the year 2019 of the state of São Paulo. With the analysis of the orange scenario in Brazil, it was noticed that all Brazilian states cultivate oranges, with the state of São Paulo presenting the largest area destined to cultivation and production, while the state of Paraná stands out for its superior productivity. including the productivity of the state of São Paulo. With the obtained results it was possible to establish the best exponential smoothing model for each case. The NNQ software was able to assist in making predictions by the various methods, as well as in indicating the best models based on error values, Theil and Akaike U which indicated as an efficient statistical treatment of raw data and the MNA models. and MNM as the best exponential smoothing models for this analysis and prediction.

Key-words: Agribusiness, Statistical Tools, Production, Exponential Smoothing.

1. Introdução

O Brasil encontra-se entre os maiores produtores de citros, com destaque para a produção de laranja. Um elevado percentual da fruta produzida no país é destinado para a indústria, o que faz com que o país seja o maior fornecedor de suco de laranja do mundo com 79% do mercado mundial e com mais de 90% da produção brasileira exportada (VIDAL, 2018). A citricultura, um dos mais tradicionais setores do agronegócio brasileiro, passa por importantes transformações estruturais. Desde o início dos anos 2000, a cadeia da laranja tem sido desafiada por uma série de grandes mudanças que acontecem dentro e fora de seus limites, que afetam diretamente a vida de seus integrantes (NEVES, 2017).

O Brasil está com uma projeção de aumento, de acordo com o *United States Department of Agriculture - USDA* (2019) de 26% para a safra de 2018/2019 sendo possibilitado pelo clima favorável que resultou em um excelente florescimento e frutificação. Diante da importância que a produção de laranja tem para o Brasil e para o mercado mundial, na comercialização da laranja *in natura* bem como para seus processados, torna-se imprescindível conhecer e analisar seu cenário futuro, sendo que para isso pode-se adotar ferramentas que auxiliem essa análise com vistas a ampliar o conhecimento sobre a situação atual e futura dessa cultura.

Uma maneira de analisar o cenário da cultura de laranja no Brasil e entender o que mais influencia na produção de laranja e quais os estados que possuem mais destaque é utilizar técnicas estatísticas que possibilitam uma análise do mercado de atuação, ou do mercado que se pretende investir, influenciando diretamente nas tomadas de decisão, e aumentando as chances de assertividade.

No caso da análise do mercado de uma região, é necessário utilizar um número consideravelmente grande de variáveis, tendo em vista a dificuldade de se examinar todas as combinações de grupos possíveis em um grande volume de dados. Por isso, desenvolveram-se diversas técnicas capazes de auxiliar na formação dos agrupamentos, para assim facilitar a análise de dados (TOLEDO, 2006).

Os métodos estatísticos multivariados são utilizados com o propósito de simplificar e facilitar a interpretação do fenômeno que está sendo estudados, por meio da construção de índices ou variáveis alternativas que sintetizam a informação original dos dados, organizando-os em uma estrutura de fácil visualização (MINGOTI, 2005; MOURA et al.2006).

Dentre os métodos estatísticos multivariados, serão utilizados neste estudo, a análise dos componentes principais, e análise de agrupamentos (*cluster*). A análise de componentes principais consiste em transformar um conjunto de variáveis originais em outro conjunto de variáveis de mesma dimensão denominadas de componentes principais, que são independentes entre si e detém com o propósito de reter, em ordem de estimação, o máximo de informação, em termos da variação total contida nos dados (VARELLA, 2008).

A análise de cluster tem como propósito reunir objetos, baseando-se nas características dos mesmos, ou seja, ela classifica de acordo com que cada elemento tem de similar em relação a outros pertencentes a determinado grupo (CORRAR; PAULO; DIAS FILHO, 2012).

Para análise do cenário futuro, umas das ferramentas para aumentar a assertividade das decisões conseguindo prever certos acontecimentos, tendências e sazonalidades é a previsão estatística. De acordo com o Tubino (2009), as previsões possuem uma função muito importante nos processos de planejamento dos sistemas de produção, permitindo que seus gestores antevejam o futuro e planejem adequadamente suas ações, para isso é preciso

adotar ferramentas que auxiliam essa análise e ampliem o conhecimento.

Krajewski, Ritzman e Malhotra (2009) explicam que as ferramentas utilizadas se baseiam em modelos matemáticos de previsão e são deveras importantes, pois têm papel fundamental como guias para o planejamento estratégico da produção, finanças e vendas de um produto.

Após mais de 50 anos de uso generalizado, a suavização exponencial ainda é um dos métodos estatísticos de previsão mais relevantes dentre os atualmente disponíveis (GOODWIN, 2010). Assim, os modelos de suavização exponencial são utilizáveis e altamente relevantes na prática, possuem uma base teórica sólida, o que torna qualquer tentativa de melhorar a precisão das previsões realizadas por esse método bastante trabalhosa, exigindo um esforço bem considerável (BERGMEIR et al., 2016).

Diante do exposto, esse trabalho teve como finalidade realizar uma avaliação do panorama nacional do cultivo da laranja no Brasil, utilizando modelos que podem ser aplicáveis às séries temporais, especialmente para o estado de São Paulo.

2. Metodologia da Pesquisa

Esta pesquisa pode ser classificada como básica, pois de acordo com a definição de Gil (2010), reúne estudos com o propósito de preencher uma lacuna de conhecimentos, buscando resolver problemas globais. Quanto à abordagem, caracteriza-se como pesquisa quantitativa e refere-se àquilo que pode ser quantificável, ou seja, as opiniões e informações sobre determinado evento ou fenômeno são traduzidas em números, para que assim possam ser classificadas e analisadas. Para tanto, faz-se necessário a utilização de recursos e de técnicas estatísticas, tais como: percentagem, média, moda, mediana, desvio-padrão, coeficiente de correlação (KAUARK, 2010).

O método de pesquisa utilizado pode ser classificado como documental, uma vez que se utilizou de uma coleta de dados restrita a documentos, escritos ou não, a partir de fontes primárias de informação, como é o caso das fontes estatísticas de informação governamentais muito utilizadas nesse estudo. Para realização do embasamento e melhoria do conhecimento a respeito do assunto antes da elaboração do estudo utilizou-se uma consulta bibliográfica a qual abrange de toda a bibliografia já tornada pública, desde publicações em revistas, monografias, livros até meios de comunicações como o rádio (MARCONI & LAKATOS, 2010).

A princípio foram coletados os dados históricos da área plantada, área colhida, da produção e do rendimento médio do cultivo da laranja entre os anos de 2014 e 2018, diretamente da base de dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2019) para todo o Brasil. A seguir, elaborou-se um panorama da citricultura no Brasil, para tanto utilizou-se de análise de componentes principais e agrupamento, realizado com apoio do *software* Tanagra, utilizado como ferramenta para a mineração de dados.

Após a coleta desses dados, eles foram agrupados por meio do *Software* Microsoft® Excel. Os índices sazonais foram obtidos por decomposição dos dados e os diversos modelos de suavização exponencial possíveis foram gerados e testados por meio do *software* NNQ, um *add in* do Microsoft® Excel para o Estado de São Paulo que é o principal estado produtor de laranjas do Brasil.

O NNQ-Estatística na qual as siglas representam Núcleo de Normalização e Qualimetria tem como objetivo desenvolver aplicações abordando controle estatístico de qualidade, estatística industrial e de previsão. O *software* NNQ (2019), é vinculado e localizado no Departamento

de Engenharia de Produção e Sistemas da Universidade Federal de Santa Catarina (UFSC).

Na sequência realizou-se uma análise descritiva dos dados e os resultados estatísticos de previsão foram apresentados, juntamente com uma análise das séries temporais, realizada por meio das técnicas de modelagem estatística de suavização exponencial. Devido à sua simplicidade e transparência, bem como a sua capacidade de se adaptar a muitas situações diferentes os modelos de suavização exponencial são muito utilizados (BERGMEIR et al., 2016).

Os modelos de suavização exponencial se caracterizam por decompor uma série temporal em componentes, suavizar seus valores passados e depois recompor as componentes para fazer as previsões. Os métodos tratados pelo software são: ANA, MNA, AAA, MAA, AAdA, MAdA, MNM, MAM, MAdM, MMM, MMdM, nos quais a primeira letra de cada sigla significa o tipo de correção de erros, podendo ser aditiva ou multiplicativa, a segunda letra corresponde a presença de tendência (aditiva, aditiva amortecida, multiplicativa e multiplicativa amortecida) e a última letra condiz com o tipo de sazonalidade, que pode ser aditiva ou multiplicativa.

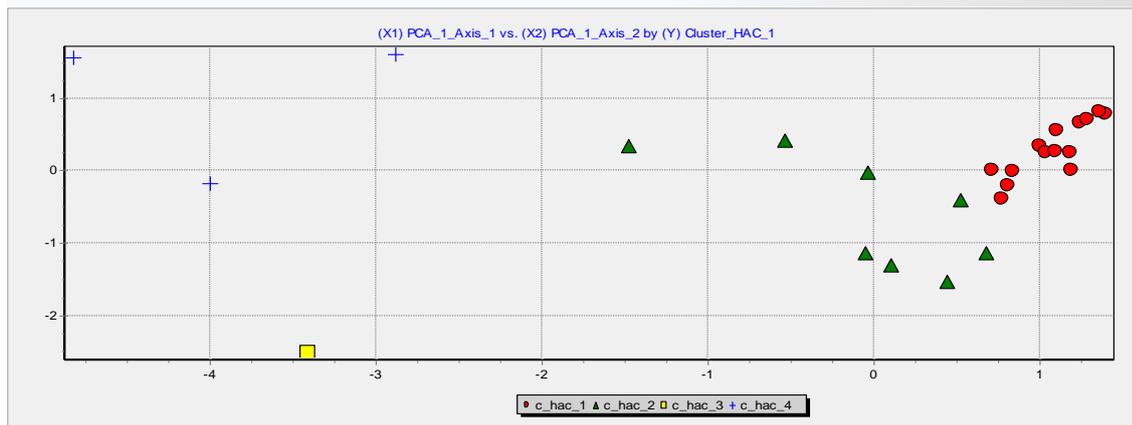
Com a utilização do NNQ-Estatística foi possível propor um método de suavização exponencial que mais se aproximou do ideal para realizar previsões futura para os conjuntos de dados, sendo que neste caso, utilizou-se o valor de Akaike (AIC) para minimizar o erro amostral, conforme indicado pelo próprio software. Com o intuito de validar o modelo escolhido ao conjunto de dados, comparou-se as previsões realizadas para o ano de 2019 com os dados reais já disponíveis para este ano no site do IBGE (2019).

3. Resultados e Discussão

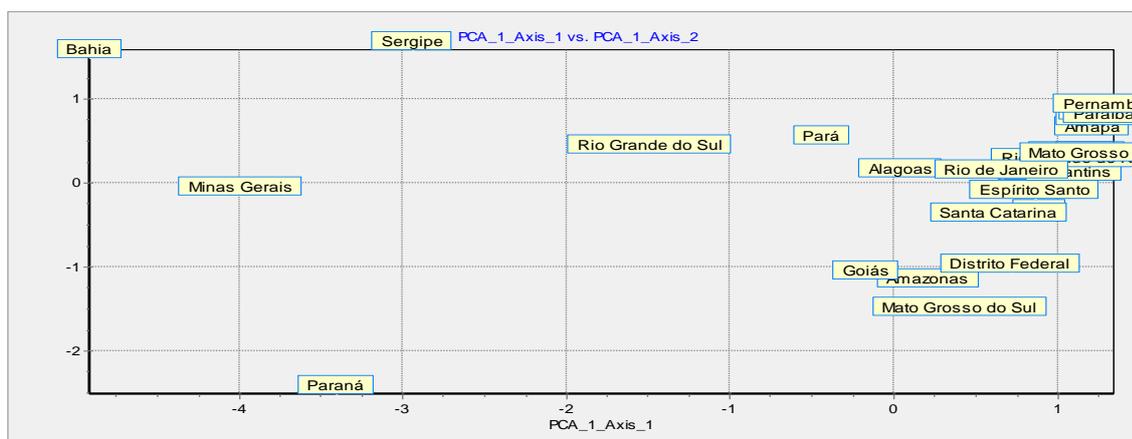
Inicialmente notou-se que a laranja é produzida em todos os estados do Brasil, independente do clima, existe área plantada com laranjas ao longo de todo o território nacional. O estado de São Paulo se destacou dos demais e por conta dos valores das variáveis encontradas para o estado de São Paulo terem sido *Outliers* devido a sua área destinada ao cultivo e produção de laranjas ser muito superior aos demais estados, este foi mantido fora do agrupamento. Notou-se que quatro grupos puderam ser identificados sobre um gráfico de componentes principais (Figuras 1A e 1B).

A primeira componente foi capaz de explicar 70,02 % da variabilidade dos dados e se correlacionou mais com as variáveis produção (-0,97), área colhida (-0,96) e plantada (0,95), enquanto que a segunda componente explicou 20,43 % da variabilidade dos dados e se correlacionou mais com a produtividade das plantas (-0,82), todos os valores de correlação calculados foram negativos. Por mais que o Paraná tenha área destinada ao cultivo próxima a de outros estados, a produtividade foi mais elevada nesse estado, o que pode ter sido o fator determinante para que este não fosse agrupado a nenhum outro ficando isolado em um grupo, denominado grupo hac_3 (Figura 1a).

Nos outros grupos ficaram congregados respectivamente três, oito e quatorze estados. A área de cultivo foi determinante no agrupamento dos três estados (Grupo hac_4 – Bahia, Sergipe e Minas Gerais). A produtividade foi semelhante e principal responsável pelo agrupamento dos oito estados agrupados no grupo hac_2 (Amazonas, Pará, Alagoas, Santa Catarina, Rio Grande do Sul, Mato Grosso do Sul, Goiás e Distrito Federal) enquanto que a produção dos demais estados foi a principal responsável pela formação do grupo hac_1.



(A)



(B)

Fonte: Autoria Própria

Figura 1 – Gráficos ilustrativos da dispersão dos estados obtidos por meio de Análise de Componentes Principais (ACP), mostrando as duas primeiras componentes principais nos eixos x e y. (A) Gráfico de agrupamento dos estados. (B) Identificação dos estados no agrupamento.

Com os dados históricos coletados, realizou-se uma análise mais aprofundada para o estado de São Paulo, principal produtor nacional de laranjas. Inicialmente verificou-se a estatística descritiva para a área plantada e colhida, para a produção e para o rendimento de produção de laranja daquele estado (Tabela 1).

	Área Plantada (hectares)	Área Colhida (hectares)	Produção (toneladas)	Rendimento (ton/ha)
Mínimo	386770	354161	9208186	24540
Média	453139,75	414646,23	11717638,93	28365,9
Mediana	455000	425359	11700000	26318
Máximo	502356	455000	14300000	37117
Desvio Padrão da Média	3865,68	3823,91	164981,56	460,53
Desvio Padrão	29943,41	29619,86	1277941,70	3567,29
Coeficiente de Variação	6,61 %	7,14%	10,91%	12,58%

Fonte: Autoria própria (2019).

Tabela 1 – Estatística descritiva da série anual de dados de 2014 até 2018 da área plantada e colhida, da produção e rendimento da laranja para o estado de São Paulo.

As medidas de tendência central, média e mediana conseguem resumir em um único valor o que ocorre tipicamente com a série de dados temporais. Quando essas medidas apresentaram diferenças, mostra-se que a série de dados contém valores que fogem da tendência central, ou seja, que não representam os dados como um todo. Neste caso, pode-se dizer que as medidas são próximas.

O desvio padrão é uma medida de dispersão que indica a variabilidade que os dados apresentam entre si. Se todos os dados são iguais, não há dispersão. Para valores próximos uns dos outros, temos uma pequena dispersão. E se os dados são muito diferentes entre si, a dispersão é grande.

Neste caso, temos um desvio padrão que pode ser considerado alto, isso ocorre por se tratarem de valores muito grandes, entretanto o coeficiente de variação pode ser classificado entre baixo para área e médio para produção e rendimento, e nesse caso percebe-se que não se nota grande dispersão entre os dados mensais coletados para os cinco anos estudados.

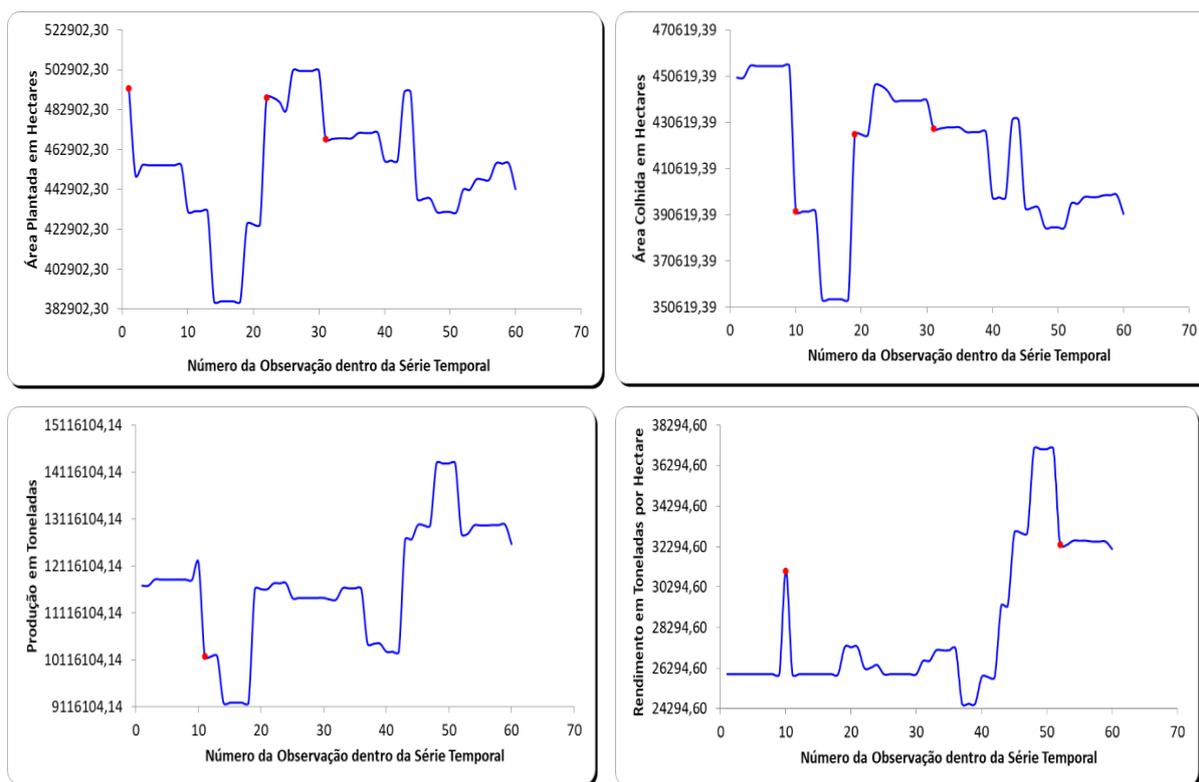
A diferença entre o menor valor da amostra (mínimo) e o maior valor da mostra (máximo) ilustra que os valores de área plantada, colhida, produção e rendimento foram variáveis ao longo dos anos acompanhados. Na sequência realizou-se as previsões futuras para as variáveis: área plantada, área colhida, produção e rendimento da laranja no Estado de São Paulo, para o ano de 2019, com base em suas séries temporais históricas por meio dos métodos de suavização exponencial.

Nos gráficos ilustrados na Figura 2 observa-se a série temporal completa utilizada, bem como os pontos onde foram identificados pelo software NNQ alguns *outliers* nos resíduos avaliados pelo modelo, esses pontos que alteram grandemente o comportamento da série geralmente costumam atrapalhar as análises e prejudicar a precisão da previsão e, portanto, devem ser conhecidos e levados em conta, logo no início de qualquer previsão.

De acordo com Koehler et al. (2012), podem ser descritos vários tipos de *outliers* incluindo os aditivos, os que ocasionam uma mudança de nível na série ou mesmo uma mudança transitória, os autores explicam ainda que para previsões realizadas por suavização exponencial, quanto mais próximos do final da série eles estiverem maiores serão as chances desses valores prejudicarem as previsões.

Nas variáveis estudadas, áreas colhida e plantada foram identificados três valores, enquanto que, para produção foi encontrado apenas um e para rendimento dois *outliers* nos erros da previsão. Como esses valores são reais da série temporal não se recomenda que sejam removidos ou alterados, porém sua presença tem grandes possibilidade de prejudicar a previsão, sendo que no caso dos dados estudados o *outlier* que mais pode prejudicar as previsões desse estudo é o que aparece no final da série de rendimento.

Para escolha do melhor método foram aplicadas algumas análises de decomposição nos dados a fim de identificar as variações cíclicas que a série sofre em um período de tempo.



Fonte: Autoria própria (2019).

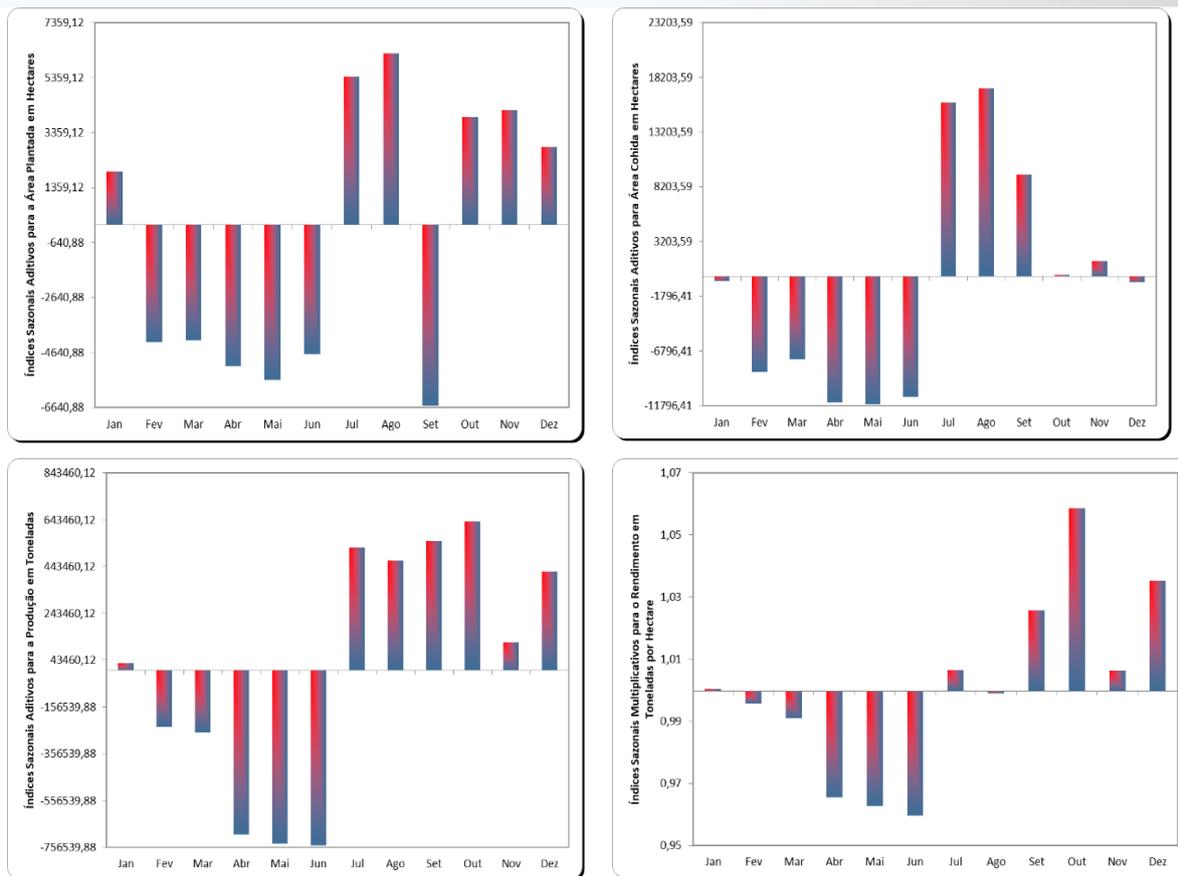
Figura 2 – Conjunto de dados do cultivo da laranja para o estado de São Paulo ilustrando os *outliers* encontrados.

Através da Figura 3 pode-se visualizar a decomposição dos dados em índices sazonais, sendo que foram escolhidos índices aditivos ou multiplicativos para serem mostrados de acordo com os modelos que melhor se ajustaram aos dados.

Com a decomposição dos índices sazonais é possível perceber a tendência para o início do é de que tanto a área plantada e colhida, como a produção e o rendimento apresentem mais baixas, já de julho a dezembro exibem uma tendência de aumento na maior parte dos meses.

A seguir os dados foram analisados por meio dos diversos modelos possíveis de suavização exponencial, com auxílio do software NINQ. O software avalia os modelos ajustados a partir de quatro tipos de erro, o valor de r_1 (autocorrelação), o U de Theil e o Akaike (AIC).

Todos os valores de U de Theil dos modelos apresentados na Tabela 2 foram inferiores a 1,0 o que significa que todos os modelos calculados apresentam previsões melhores que um modelo ingênuo de previsão e os valores dos quatro tipos de erros foram pequenos, variando em termos de erros percentuais entre 2,01 % e 3,21 %.



Fonte: Autoria própria (2019).

Figura 3 – Decomposição do conjunto de dados do cultivo da laranja para o estado de São Paulo em índices sazonais anuais.

Na Tabela 2 encontram-se os valores de r_1 e do Akaike (AIC) para cada uma das variáveis estudadas. Utilizou-se o menor valor do critério de Akaike (AIC) para escolha e indicação do melhor modelo.

Observando-se os resultados apresentados na Tabela 2 foi possível verificar que os valores de r_1 foram baixos, mostrando a ausência de autocorelação nos dados. Levando-se em conta o menor valor do AIC o método escolhido pelo software para produção, área plantada e colhida foi o MNA e para o rendimento foi o MNM.

O modelo MNA realiza a correção do erro de forma multiplicativa, trata a sazonalidade de forma aditiva e não identifica nenhuma tendência para tratar. O modelo MNM realiza a correção de erros de forma multiplicativa, trata a sazonalidade também de forma multiplicativa e não faz nenhum tratamento para a tendência.

Métodos	Área Plantada (hectares)		Área Colhida (hectares)		Produção (toneladas)		Rendimento (ton/ha)	
	r1	AIC	r1	AIC	r1	AIC	r1	AIC
ANA	0,005	1438,939	-0,002	1423,622	0,002	1857,999	-0,023	1137,491
MNA	-0,026	1438,365	-0,009	1421,395	0,002	1854,733	0,001	1133,221
AAA	0,005	1443,527	0,002	1428,044	0,001	1862,449	-0,013	1141,451
MAA	-0,027	1442,902	-0,005	1426,062	0,004	1858,689	0,015	1136,357
AAdA	0,006	1444,979	0,000	1429,738	0,000	1863,796	-0,007	1142,750
MAdA	-0,026	1444,387	-0,007	1427,518	0,003	1860,444	0,016	1138,525
MNM	-0,026	1438,584	-0,009	1424,459	0,005	1859,648	-0,005	1131,816
MAM	-0,027	1443,125	-0,005	1429,147	0,005	1863,692	0,005	1135,041
MAdM	-0,026	1444,604	-0,007	1430,588	0,001	1865,387	0,023	1136,692
MMM	-0,027	1443,161	-0,006	1428,992	0,005	1863,903	0,006	1135,383
MMdM	-0,031	1444,388	-0,017	1430,266	0,012	1863,227	0,027	1135,492

Fonte: Autoria própria (2019).

Tabela 2 – Valores calculados para o coeficiente de autocorrelação e critério de Akaike.

A Tabela 3 apresenta em maiores detalhes esses modelos e os valores de alfa, beta, gama e fi calculados pelo NNQ.

Percebeu-se que não foi necessário o uso das constantes de tendência nem de amortecimento para nenhum dos modelos escolhidos e que os maiores valores encontrados foram para correção de nível e os menores para a sazonalidade, sendo que se pode notar que o que mais influenciou na variação dos valores dessas variáveis estudadas referentes ao cultivo da laranja no Estado de São Paulo foi o nível.

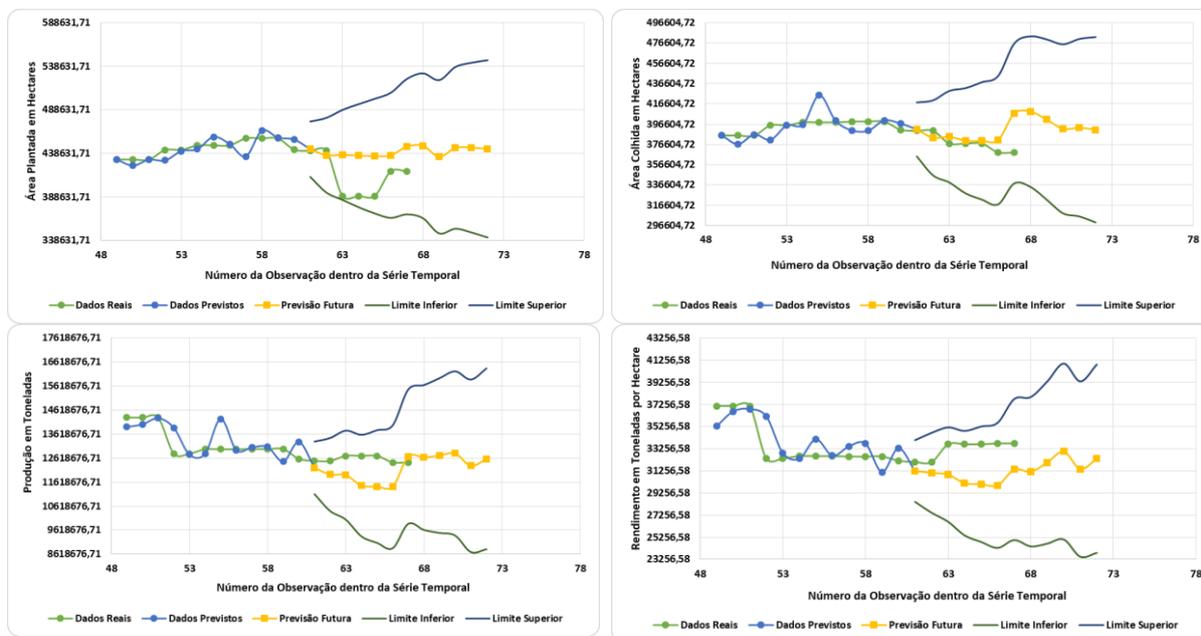
O nível é o valor médio da observação no período estudado (valor observado retirando a sazonalidade, se houver, e o erro aleatório).

Variáveis	Modelos	Coeficientes calculados para os modelos			
		Alfa Nível	Beta Tendência	Gama Sazonalidade	Fi Amortecimento
Área Plantada	MNM	0,92	0,00	0,01	0,00
Área Colhida	MNA	0,99	0,00	0,01	0,00
Produção	MNA	0,99	0,00	0,01	0,00
Rendimento	MNM	0,83	0,00	0,01	0,00

Fonte: Autoria própria (2019).

Tabela 3 – Melhores modelos escolhidos para as previsões e valores calculados pelo NNQ para os coeficientes dos modelos.

A Figura 4 ilustra os dados reais e previstos, bem como a previsão futura e seus limites inferiores e superiores de previsão, com os quais realizou-se uma validação dos modelos escolhidos comparando-se sete meses de dados reais, para área de cultivo, produção e produtividade.



Fonte: Autoria própria (2019).

Figura 4 – Valores previstos e limites de confiança para a previsão ao longo do ano de 2019, com base nos modelos escolhidos para cada série de dados referentes ao cultivo de laranja no estado de São Paulo.

Percebeu-se através dos resultados obtidos, uma proximidade dos valores previstos com os valores reais da área colhida da produção e do rendimento da laranja para o ano de 2019, notou-se ainda que em nenhum momento a previsão ultrapassou os limites inferiores e superiores confirmando assim a eficácia dos modelos de previsão escolhidos para prever o comportamento dos dados.

Para o mês de fevereiro de 2019 a previsão se aproximou muito do limite inferior de previsão para a variável área plantada, tal fato pode ser atribuído a alguma dificuldade no plantio encontrada nesse mês cabendo destacar que o processo de plantio pode ser afetado por muitas variáveis tais como existência de mudas, clima e preparo do solo para plantio.

4. Conclusão

Estudos quantitativos são muito importantes com vista a realização de previsões futuras com base em dados passados, mas a avaliação do contexto político e econômico não pode ser ignorado nas previsões. Todos os estados brasileiros cultivam laranjas em maior ou menor quantidade, mas o cultivo se estende por todo o território nacional, sendo o estado que apresenta maior área destinada ao cultivo e produção o estado de São Paulo, enquanto que o estado do Paraná se destaca em produtividade sendo esta superior inclusive à produtividade do estado de São Paulo.

Com os resultados obtidos foi possível estabelecer o melhor modelo de suavização exponencial para cada caso. O software NNQ mostrou-se capaz de auxiliar na realização das previsões pelos diversos métodos, bem como na indicação dos melhores modelos com base nos valores dos erros, U de Theil e Akaike que indicou como um tratamento estatístico eficiente dos dados brutos e os modelos MNA e MNM como os melhores modelos de suavização exponencial para essa análise e previsão.

Os modelos utilizados para as previsões estatísticas mostraram-se eficazes, pois obteve-se resultados muito próximos aos limites esperados. A escolha do melhor modelo de previsão para cada caso, foi capaz de permitir uma análise futura da área plantada, área colhida, produção e rendimento médio dessa cultura com reduzidos valores de erros de previsão.

Espera-se que os resultados encontrados nas previsões possam servir de auxílio para futuras decisões e estratégias do produtor, da agroindústria, do consumidor e principalmente para o governo, uma vez que a laranja é um cultivo de impacto no mercado Brasileiro sendo bem representativa no cenário das exportações.

Agradecimentos

A segunda autora agradece pela oportunidade de participar como bolsista da UTFPR pelo programa de bolsas de iniciação científica do ano de 2018/2019. Sem este auxílio financeiro não seria possível a realização e conclusão do presente estudo.

Referências

BERGMEIR, C.; HYNDMAN, R. J.; BENÍTEZ, J. M. Bagging exponential smoothing methods using STL decomposition and Box–Cox transformation. **International Journal Of Forecasting**, [s.l.], v. 32, n. 2, p.303-312, abr. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.ijforecast.2015.07.002>.

CORRAR, Luiz J.; PAULO, Edilson; DIAS FILHO, José Maria. **Análise multivariada para os cursos de administração, ciências contábeis e economia**. São Paulo: Atlas, 2012. 541 p.

GIL, A. C. **Como elaborar projetos de pesquisa**. 5. ed. São Paulo: Atlas, 2010. 184 p.

GOODWIN, P. The Holt–Winters approach to exponential smoothing: 50 years old and going Strong Foresight: **The International Journal of Applied Forecasting**, 19, pp. 30-33. 2010.

IBGE. **Produção Agrícola Municipal**. 2019. Disponível em: <<https://sidra.ibge.gov.br/tabela/1618>>. Acesso em: 15 ago. 2019.

KAUARK, F. da S.; MANHÃES, F. C.; MEDEIROS, C. H. **Metodologia da pesquisa**: Um guia prático. Itabuna / Bahia: Litterarum, 2010. 89 p. Disponível em: <[http://197.249.65.74:8080/biblioteca/bitstream/123456789/713/1/Metodologia da Pesquisa.pdf](http://197.249.65.74:8080/biblioteca/bitstream/123456789/713/1/Metodologia_da_Pesquisa.pdf)>. Acesso em: 16 maio 2018.

KRAJEWSKI, L. J.; RITSMAN L. P.; MALHOTRA M. K. **Administração de Produção e Operações**. São Paulo, 2009.

KOEHLER, Anne B. et al. A study of outliers in the exponential smoothing approach to forecasting. **International Journal Of Forecasting**, [s.l.], v. 28, n. 2, p.477-484, abr. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.ijforecast.2011.05.001>.

MARCONI, M. de A.; LAKATOS, E. M. **Fundamentos de metodologia científica**. 7. ed. São Paulo: Atlas, 2010. 297 p.

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: Uma abordagem aplicada**. 2. ed. Belo Horizonte: UFMG, 2005.

MOURA, M. C. S. de et al. ESTUDO MULTIVARIADO DE SOLOS URBANOS DA CIDADE DE TERESINA. **Quim. Nova**, São Paulo, v. 29, n. 3, p.429-435, mar. 2006. Disponível em: <<http://www.scielo.br/pdf/%0D/qn/v29n3/29266.pdf>>. Acesso em: 18 set. 2018.

NEVES, M. F.; TROMBIN, V. G. **Anuário da Citricultura 2017**. 2017. Disponível em: <http://www.citrusbr.com/download/biblioteca/CitrusBR_Anuario_2017_alta.pdf>. Acesso em: 25 ago. 2019.

NNQ - Núcleo de Normalização e Qualimetria. **Previsão**. 2019. Disponível em: <<https://qualimetria.ufsc.br/publicacoes/software/previsao/>>. Acesso em: 22 ago. 2019.

TOLEDO, C. E. V. **Análises Estatística Multivariada e Filogenética Dos Dipnoiformes Brasileiros: COMPARAÇÕES BIÓTICAS COM O GONDWANA OCIDENTAL**. 2006. 212 f. Tese (Doutorado) - Curso de Pós-graduação em Geociências, Universidade Estadual Paulista, Instituto de Geociências e Ciências Exatas, Rio Claro, 2006. Disponível em: <https://repositorio.unesp.br/bitstream/handle/11449/103010/toledo_cev_dr_rcla.pdf?sequence=1&isAllowed=y>. Acesso em: 22 set. 2019.

TUBINO, D. F. **Planejamento e controle da Produção**. 2. ed. São Paulo: Atlas, 2009. 190 p.

USDA – United States Department Of Agriculture. **Citrus: World Markets and Trade**. 2019. Disponível em: <<https://apps.fas.usda.gov/psdonline/circulars/citrus.pdf>>. Acesso em: 17 ago. 2019.

VARELLA, C. A. A. **Análise de Componentes Principais**. 2008. Disponível em: <<http://www.ufrrj.br/institutos/it/deng/varella/Downloads/multivariada%20aplicada%20as%20ciencias%20agrarias/Aulas/analise%20de%20componentes%20principais.pdf>>. Acesso em: 18 set. 2018.

VIDAL, M. de F. **Citricultura na Área de Atuação do BNB**. 2018. Disponível em: <https://www.bnb.gov.br/documents/80223/4049480/41_Citrus_2018.pdf/11e22002-730c-a18b-0d0f-479f9e4d3309>. Acesso em: 26 ago. 2019.