

Previsão da quantidade de leite cru industrializado no Rio Grande do Sul: usar modelos ou combinar modelos de previsão?

Liane Werner – Departamento de Estatística - UFRGS

Resumo: O leite além de ser um alimento completo, desempenha um relevante papel econômico e social, principalmente na geração de emprego e renda. Sendo o Rio Grande do Sul o segundo maior produtor nacional, este item do agronegócio que tem grande importância para o estado, e realizar previsões acuradas traz ganhos na tomada de decisão dos gestores públicos. Visando averiguar se é o uso de modelos ou combinações das previsões o mais acurado, será investigado quem proporciona maior acurácia para a quantidade de leite cru industrializado no RS entre julho de 1998 e junho de 2019. Para atender ao objetivo foram ajustados três modelos: um o SARIMA $(0,1,0)(0,1,1)_{12}$, um Holt-Winters multiplicativo e um de decomposição com estação sazonal 12. Também foram obtidas as combinações de previsão pela média, mediana e variância mínima para dois a dois dos modelos e dos três modelos. A acurácia, da combinação ou modelo, foi obtida por meio das medidas de acurácia: RMSE, MAPE e U de Theil. Para a medida de acurácia MAPE a combinação da média dos três modelos foi a mais acurada. Já para as medidas RMSE e U de Theil foi a combinação via variância mínima dos modelos Holt-Winters e de decomposição que apresentou tais medidas com menor valor. Comparando as medidas de acurácia dos modelos, tanto MAPE, como RMSE ou U de Theil, verificou-se que são inferiores a qualquer um dos valores das combinações consideradas. Reforçando assim que combinar previsões traz ganhos na acurácia.

Palavras chave: Previsão, , leite, séries temporais, combinação de previsão.

Forecasting the amount of processed raw milk in Rio Grande do Sul: using models or combining forecasting models?

Abstract: Besides being a complete food, milk plays a relevant economic and social role, especially in the generation of jobs and income. As Rio Grande do Sul is the second largest national producer, this agribusiness item that is of great importance to the state and making accurate forecasts brings gains in decision making by public managers. In order to determine whether the use of models or combinations of forecasts is the most accurate, it will be investigated who provides the highest accuracy for raw milk processed in RS between July 1998 and June 2019. To meet the objective, three models were adjusted: one SARIMA $(0,1,0)(0,1,1)_{12}$, one multiplicative Holt-Winters and one decomposition with seasonal season 12. The prediction by average median and minimum variance combinations, for two by two of the models and the three models were also obtained. The accuracy of the combination or model was obtained by measuring the accuracy: RMSE, MAPE and U of Theil. For the MAPE accuracy measure, the average combination of the three models was the most accurate. For the RMSE and U of Theil measurements, it was the combination by minimum variance of the Holt-Winters and decomposition models that presented such measures with lower value. Comparing the accuracy measures of the MAPE, RMSE or U of Theil models, it was found that they are inferior to any of the values of the considered combinations. This is reinforcing that combining forecasts brings gains in accuracy.

Keywords: Forecasting, Milk, Time Series, Combining Forecast.

1. Introdução

O leite é um alimento completo, contendo proteínas, vitaminas e sais minerais indispensáveis para o organismo humano e é importante em todas as idades. Além da sua importância nutricional, esta matéria-prima desempenha um relevante papel econômico e social, principalmente na geração de emprego e renda, uma vez que impulsiona o desenvolvimento de diversas atividades econômicas. Segundo Kischner et al. (2019) a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) divulgou que o Brasil é considerado atualmente, com 4% da produção, o quinto maior produtor mundial de leite.

Os dados preliminares divulgados pelo IBGE indicam que o segundo trimestre de 2019 apresentou uma retração de 6,4% no volume de leite inspecionado adquirido pelas indústrias lácteas brasileiras (5,8 bilhões de litros) em relação ao primeiro trimestre do ano (6,2 bilhões de litros), contudo, quando comparando com o mesmo período de 2018, a quantidade de leite foi 7,4% maior (CNA, 2019).

Dentre os estados brasileiros, o Rio Grande do Sul é o segundo maior produtor nacional respondendo por cerca de 13% da produção nacional, superado apenas pelo estado de Minas Gerais (KISCHNER et al., 2019). Sendo assim é um item do agronegócio gaúcho que tem grande importância para o estado, por isto realizar previsões a cerca deste produto traz ganhos na tomada de decisão dos gestores públicos.

Para realizar previsões podem-se utilizar modelos estatísticos que levam em consideração a variável em estudo nos momentos passados, conhecidos como modelos de séries temporais, ou então realizar uma transformação matemática das previsões resultantes destes modelos, conhecida como combinação de previsões. Independente da técnica usada, modelos ou combinações das previsões dos modelos, o objetivo é obter a previsão mais acurada.

Sendo assim, este artigo tem como objetivo realizar a análise de três modelos de séries temporais e combinar estes três modelos de três formas diferenciadas, buscando avaliar qual a técnica é mais acurada e usá-la para realizar previsões para a quantidade de leite cru industrializado no Rio Grande do Sul.

2. Referencial teórico

Quando os dados estão dispostos de forma sequenciada no tempo, eles podem ser analisados por modelos que buscam identificar padrões de comportamento que possam ser projetados para o futuro (MORETTIN; TOLOI, 2006). Dentre eles têm-se os modelos de decomposição, modelos de Suavização Exponencial e modelos ARIMA. Segundo Makridakis et. al (1998) os modelos de decomposição visam decompor os dados dividindo em subpadrões que identificam cada componente da série temporal separadamente. Já os modelos ARIMA (*Box-Jenkins*) são modelos matemáticos que visam captar o comportamento da correlação temporal dos dados ou autocorreção. Por sua vez, nos modelos de suavização exponencial os valores extremos da série são considerados flutuações aleatórias, e seu propósito é identificar um padrão básico utilizando uma ponderação diferente para cada valor da série temporal, sendo que os valores mais recentes recebam pesos maiores (MORETTIN; TOLOI, 2006)

Pellegrini (2000) afirma que uma série temporal pode exibir até quatro características em seu comportamento: média, sazonalidade, ciclo e tendência. Ao analisar uma série temporal, preliminarmente se realiza uma análise do gráfico de tempo, de onde se identifica os fatores que influenciam a mesma. Após, obtém-se modelos apropriados para representar os dados.

Os modelos de decomposição tentam identificar dois componentes separados do padrão básico subjacente que são: a tendência e os fatores sazonais. Esta discriminação pode frequentemente ajudar a entender melhor o comportamento da série temporal, e obter previsões acuradas (MAKRIDAKIS et. al, 1998). Tais modelos podem ser descritos conforme a equação (1), sendo que se o modelo for aditivo soma-se todas as componentes e caso o modelo seja multiplicativo, multiplica-se as componentes de tendência com a sazonalidade e após adiciona-se o erro.

$$Y_t = f(T_t, S_t, \varepsilon_t) \quad (1)$$

onde: Y_t é o valor da série temporal no momento t ; T_t é o valor da tendência no momento t ; S_t é o valor da sazonalidade no momento t e ε_t é o valor do erro aleatório no momento t .

Os modelos de suavização exponencial valorizam mais os últimos valores observados na série temporal através da ponderação exponencial dos mesmos, de acordo com a proximidade ao período da previsão. Sendo que conforme o comportamento da série temporal, Makridakis et. al (1998) sugerem a utilização de modelos específicos: (i) a suavização exponencial simples, é utilizada quando não há tendência ou sazonalidade na demanda; (ii) o modelo linear de *Holt* é usado para as séries que apresentam a componente tendência e (iii) os modelos de *Holt-Winters* são adequados para quando a série apresenta tanto o componente de tendência quanto o componente sazonal sendo que pode ser um modelo multiplicativo ou aditivo, dependendo do comportamento da estação sazonal. Tais modelos são descritos por equações com parâmetros de suavização para cada componente, à medida que se tem mais componentes para considerar, mais parâmetros serão estimados. Além disto, estes modelos são os mais utilizados frente a outras técnicas de previsão, conforme Pellegrini (2000), devido a sua simplicidade; facilidade de ajustes e boa acurácia.

Segundo Box; Jenkins (1976), como uma série temporal tem os dados coletados sequencialmente ao longo do tempo, espera-se que ela apresente correlação seriada. Sendo assim os modelos propostos por eles, os modelos ARIMA, podem ser resultado da combinação de três componentes: (i) AR: componente Auto Regressivo de ordem p ; (ii) I: componente Integração de d diferenciações; e (iii) MA: componente de Médias Móveis de ordem q . Para obtenção do modelo ARIMA (p,d,q) é necessário estimar os parâmetros do modelo que melhor se ajustam aos dados. Os modelos que contemplam as séries que apresentam autocorreção sazonal são conhecidos como SARIMA. Tais modelos contêm uma parte não sazonal, com parâmetros (p, d, q), e uma sazonal, com parâmetros (P, D, Q), onde s é a estação sazonal, conforme a equação (2).

$$(1 - \phi_1 L - \dots - \phi_p L^p)(1 - \Phi_1 L^s - \dots - \Phi_P L^{Ps})(1 - L)^d (1 - L^s)^D Z_t = (1 - \theta_1 L - \dots - \theta_q L^q)(1 - \Theta_1 L^s - \dots - \Theta_Q L^{Qs}) \varepsilon_t \quad (2)$$

onde: L é o operador de defasagem;

$(1 - \phi_1 L - \dots - \phi_p L^p)$ é a parte autoregressiva não sazonal de ordem p ;

$(1 - \Phi_1 L^s - \dots - \Phi_P L^{Ps})$ é a parte autoregressiva sazonal de ordem P e estação sazonal s ;

$(1 - L)^d$ é parte de integração não sazonal de ordem d ;

$(1 - L^s)^D$ é parte de integração sazonal de ordem D e estação sazonal s ;

$(1 - \theta_1 L - \dots - \theta_q L^q)$ é a parte não sazonal de médias móveis de ordem q ;

$(1 - \Theta_1 L^s - \dots - \Theta_Q L^{Qs})$ é a parte sazonal de médias móveis de ordem Q e estação sazonal s .

A literatura indica que a combinação linear de previsões em geral é mais acurada que as previsões individuais que a compõe (CLEMEN, 1989; COSTANTINI; PAPPALARDO, 2010). Já para a Nowotarski; Weron (2016) esta não é a maior vantagem da combinação, mas sim que seja escolhido um modelo que está bem ajustado aos dados.

A proposta de combinar diferentes previsões foi formalizada pela primeira vez por Bates e Granger (1969) conforme apresentado na equação (3).

$$F_c = wF_1 + (1 - w)F_2 \quad (3)$$

onde: F_c é a previsão combinada; F_1 e F_2 são as previsões a serem combinadas e w é o peso da previsão 1, assumindo que a previsão F_1 tenha maior variância dos erros absolutos e o peso é obtido entre a razão da variância dos erros absolutos da previsão 1 pela soma das variâncias dos erros absolutos de ambas previsões.

Conforme descrito em Werner(2005) várias propostas de combinar mais do que duas previsões foram apresentadas, uma das formas de combinar p combinações que foi estudada por Asku; Gunter (1992), é apresentada na equação (4).

$$F_c = w_1F_1 + w_2F_2 + \dots + w_pF_p, \text{ sendo que: } \sum_{i=1}^p w_i = 1, w_i \geq 0, \forall i \quad (4)$$

Para o caso em que p é igual três, Werner(2005) propôs a obtenção dos pesos dado conforme a equação (5).

$$w_i = \frac{1/\sigma_i^2}{1/\sigma_1^2 + 1/\sigma_2^2 + 1/\sigma_3^2} \quad (5)$$

onde: $i = \{1,2,3\}$ e σ_i^2 é a variância dos erros absolutos da previsão i .

Dentre os métodos de combinação, o mais popular de combinação de previsões individuais é a média aritmética, pois além de ser um dos métodos mais conhecidos é fácil de calcular (WALLIS, 2011). Outra estatística simples que tem resultados similares a média é obter a mediana dos modelos individuais em cada período de tempo do estudo. Conforme estudo realizado por Bichpuriya et al (2016) a mediana tem resultados similares a média.

Para optar por qual técnica de previsão - individual ou combinação - é a melhor, faz-se necessário obter medidas de acurácia De acordo com Makridakis et al.(1998), a palavra acurácia refere-se à habilidade do modelo ou da combinação em reproduzir os dados que já são conhecidos (qualidade do ajuste). Neste estudo dentre as existentes, são usadas: o MAPE (*Mean Absolute Percentage Error* ou erro percentual absoluto médio) dada pela equação (6) e a RMSE (*Root Mean Square Error* ou raiz quadrada do erro quadrático médio), apresentada pela equação (7) e o coeficiente U de Theil dado pela equação (8). É desejado que tais medidas sejam mais próximas de zero, o que significa que os erros de previsão gerados são menores, se mostrando adequado para realizar previsões, independentemente se for por meio de determinado modelo ou combinação.

$$\text{MAPE} = \left(\frac{1}{T}\right) \sum_{t=1}^T \left| \frac{(y_t - \hat{y}_t)}{y_t} \right| \cdot 100 \quad (6)$$

$$\text{RMSE} = \sqrt{\left(\frac{1}{T}\right) \sum_{t=1}^T (y_t - \hat{y}_t)^2} \quad (7)$$

$$U = \frac{\sqrt{\sum_{t=1}^T (y_t - \hat{y}_t)^2}}{\sqrt{\sum_{t=1}^T (y_t)^2 + \sum_{t=1}^T (\hat{y}_t)^2}} \quad (8)$$

onde: y_t é o valor da série observado no tempo t , \hat{y}_t é a previsão no tempo t , sendo $t=1, \dots, T$

3. Procedimentos metodológicos

A primeira etapa consiste na obtenção de dados da série histórica. Os dados foram obtidos no Sistema IBGE de Recuperação Automática – SIDRA do IBGE (<https://sidra.ibge.gov.br>) e se capturou a quantidade de leite cru industrializado no Rio Grande do Sul no período de julho de 1998 até junho de 2019 perfazendo 252 observações mensais. Inicialmente foi utilizado o período de julho de 1998 a junho de 2016 para ajuste dos modelos e para obtenção das previsões (dentro amostra) a um passo. Após serão calculadas as previsões para o período de julho de 2016 a junho de 2019 para verificar a adequação dos modelos com base nas medidas de acurácia.

Os modelos estatísticos a serem ajustados são: ARIMA, suavização exponencial e de decomposição e para tal, foi usado o pacote estatístico SPSS versão 18. Para o modelo de decomposição foi utilizada a rotina decomposição sazonal do SPSS que gerou os 12 índices e a componente de tendência. Para obter os demais modelos foi utilizada a rotina expert do software.

Após definidos os modelos e estimados os seus parâmetros, serão aplicadas as técnicas de combinação de previsão: média, mediana e variância mínima utilizando planilha EXCEL. A verificação da acurácia da combinação ou modelo se dará por meio das medidas RMSE, MAPE e U de Theil. Uma vez escolhido aquele que apresentar as melhores medidas será usada para calcular as previsões para o período de julho a dezembro de 2019.

4. Resultados e discussões

O interesse neste estudo é avaliar o que é mais adequado utilizar para prever a quantidade de leite cru no Rio Grande do Sul se usar modelos de séries temporais ou então uma combinação das previsões destes modelos. Na Figura 1 é apresentada a série temporal que alvo de estudo neste trabalho, de onde se percebe a existência de tendência e sazonalidade.

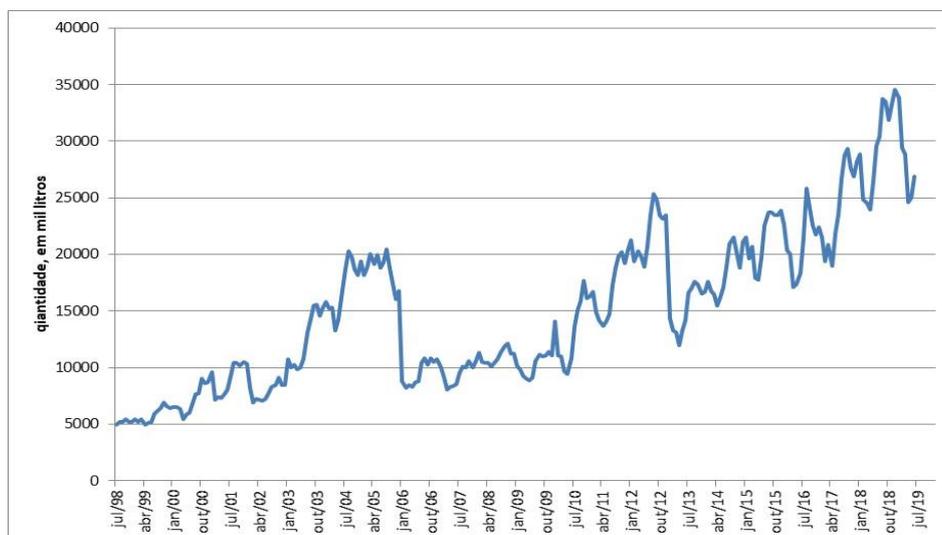


Figura 1 – Quantidade de leite cru industrializado no Rio Grande do Sul entre julho de 1998 até junho de 2019

Feita uma análise preliminar do comportamento da série em estudo, iniciou-se a modelagem dos três modelos sugeridos para este estudo. Para o modelo de decomposição foram estimadas as componentes sazonais para os 12 meses e foi obtida a componente de tendência. Porém, conforme Abraham; Ledolter (2005), para realizar previsões se utiliza uma regressão linear simples, onde a variável independente era a sequência do tempo. O modelo de suavização exponencial indicado consiste de um modelo Holt-Winters multiplicativo e as estimativas para os parâmetros do modelo foram: do coeficiente de ponderação exponencial do nível α igual a 0,865; do coeficiente de ponderação exponencial da tendência β igual a 0,01 e do coeficiente de ponderação exponencial do fator sazonal γ é igual a 0,798. Já para o modelo ARIMA foi ajustado o modelo SARIMA (0,1,0)(0,1,1)₁₂, sendo que as estimativas do parâmetro de média móvel sazonal é 0,957.

Uma vez que os modelos foram obtidos e seus parâmetros estimados. O próximo passo foi calcular as previsões (estimativa da série temporal um passo à frente, para o período observado). Feito este passo, passamos ao cálculo dos métodos de combinações de previsão. No caso do método da variância mínima foram obtidas as estimativas dos pesos w_1, w_2 , quando combinado os modelos dois a dois e os pesos w_1, w_2, w_3 , para quando combinado as três previsões, tais pesos encontram-se na tabela 1. Foram obtidas também as previsões das combinações média e mediana.

Modelos Combinados	w_1	w_2	w_3
SARIMA e Holt Winters	0,53548	0,46452	não existe
SARIMA e Decomposição	0,61396	0,38604	não existe
Holt-Winters e Decomposição	0,58691	0,41309	não existe
SARIMA, Holt-Winters e Decomposição	0,26806	0,30900	0,42294

Fonte: Elaborada pela autora

Tabela 1 – Estimativas dos pesos da combinação por variância mínima

De posse das previsões dos modelos e combinações, foram calculadas as medidas de acurácia RMSE, MAPE e U de Theil. Na tabela 2 são apresentadas estas medidas para os modelos individuais, sendo que os melhores valores para cada medida estão grifados em negrito. O Modelo de Holt-Winters ajustado para os dados do estudo apresentou o menor RMSE e MAPE e já o menor U de Theil foi obtido para o modelo SARIMA ajustado para os dados do estudo.

Modelo	RMSE	MAPE	U de Theil
SARIMA	0,05111	1265	0,03705
Holt-Winters	0,04910	1178	0,07080
Decomposição	0,08245	1486	0,04452

Fonte: Elaborada pela autora

Tabela 2 - Medidas de acurácia dos Modelos SARIMA, Holt-Winters e Decomposição do estudo

Na tabela 3 são apresentadas as medidas de acurácia para as combinações. Cabe salientar que nesta tabela são apresentadas as medidas para as variações de combinações de dois modelos e da combinação dos três modelos.

Combinação	Modelos	MAPE	RMSE	U de Theil
Média	SARIMA e Holt-Winters	0,04929	1223	0,03582
	SARIMA e Decomposição	0,05134	1015	0,02975
	Holt-Winters e Decomposição	0,05126	998	0,02926
	SARIMA, Holt-Winters e Decomposição	0,04500¹	985³	0,02883³
Mediana	SARIMA e Holt-Winters	0,04929	1223	0,03582
	SARIMA e Decomposição	0,05134	1015	0,02975
	Holt-Winters e Decomposição	0,05126	998	0,02926
	SARIMA, Holt-Winters e Decomposição	0,04843	1184	0,03471
Variância Mínima	SARIMA e Holt-Winters	0,04934	1224	0,03587
	SARIMA e Decomposição	0,04683²	999	0,02927
	Holt-Winters e Decomposição	0,04727³	974¹	0,02857¹
	SARIMA, Holt-Winters e Decomposição	0,04782	981²	0,02877²

Legenda: Índice 1: indica qual técnica de combinação que apresenta menor acurácia, para cada medida, idem para índice 2, que é o segundo com menor acurácia e o índice 3 para o terceiro

Fonte: Elaborada pela autora

Tabela 3 - Medidas de acurácia para as Combinações de Previsão do estudo

Como indicado na legenda os índices sobre escritos dentro da Tabela 3 indicam a ordem de melhor acuracidade que cada combinação apresenta para cada uma das três medidas. Para a medida de acurácia MAPE a combinação mais acurada foi aquela que considerou os três modelos usando a média como método para realizar a combinação. Para esta medida a combinação via variância mínima dos modelos SARIMA e de decomposição e segundo e em terceiro a terceiros combinação via variância mínima dos três modelos do estudo. Já para as medidas RMSE e U de Theil, foi a combinação via variância mínima dos modelos Holt-Winters e de decomposição apresentou a medida com menor valor, seguida da mesma forma de combinar, porém para os três modelos e em terceiro lugar a combinação pela média também dos três modelos.

Comparando as medidas de acurácia das Tabelas 2 e 3 é possível observa que a melhor medida de acurácia dos modelos, tanto MAPE, como RMSE ou U de Theil, são inferiores que qualquer um dos três valores das combinações para cada medida. Reforçando assim que combinar previsões traz ganhos na acurácia.

Como o previsor sempre busca o menor erro possível (ABRAHAM; LEDOLTER, 2005) e as três medidas não concordaram em quem apresentava maior acurácia, optou-se por realizar as previsões, de julho a dezembro de 2019, com duas técnicas de combinações. A combinação por média dos três modelos, que apresentou melhor MAPE e a combinação via variância mínima dos modelos Holt-Winters e Decomposição que apresentou as melhores medidas de RMSE e U de Theil.

Na figura 3 é apresentadas as séries da quantidade de leite cru industrializado no Rio Grande do Sul e as previsões para o período de janeiro a dezembro de 2019, de onde percebe-se que as combinações se ajustam bem a série. Para melhor visualizar das previsões, estas são apresentadas em detalhes no entre janeiro de 2017 e dezembro de 2019. Para este período final fica visível que as combinações acompanham o comportamento dos dados e ambas apresentam previsões próximas.



FIGURA 3 - Quantidade de leite cru industrializado no Rio Grande do Sul, no período de julho de 1998 a junho de 2019 e as previsões para julho a dezembro de 2019

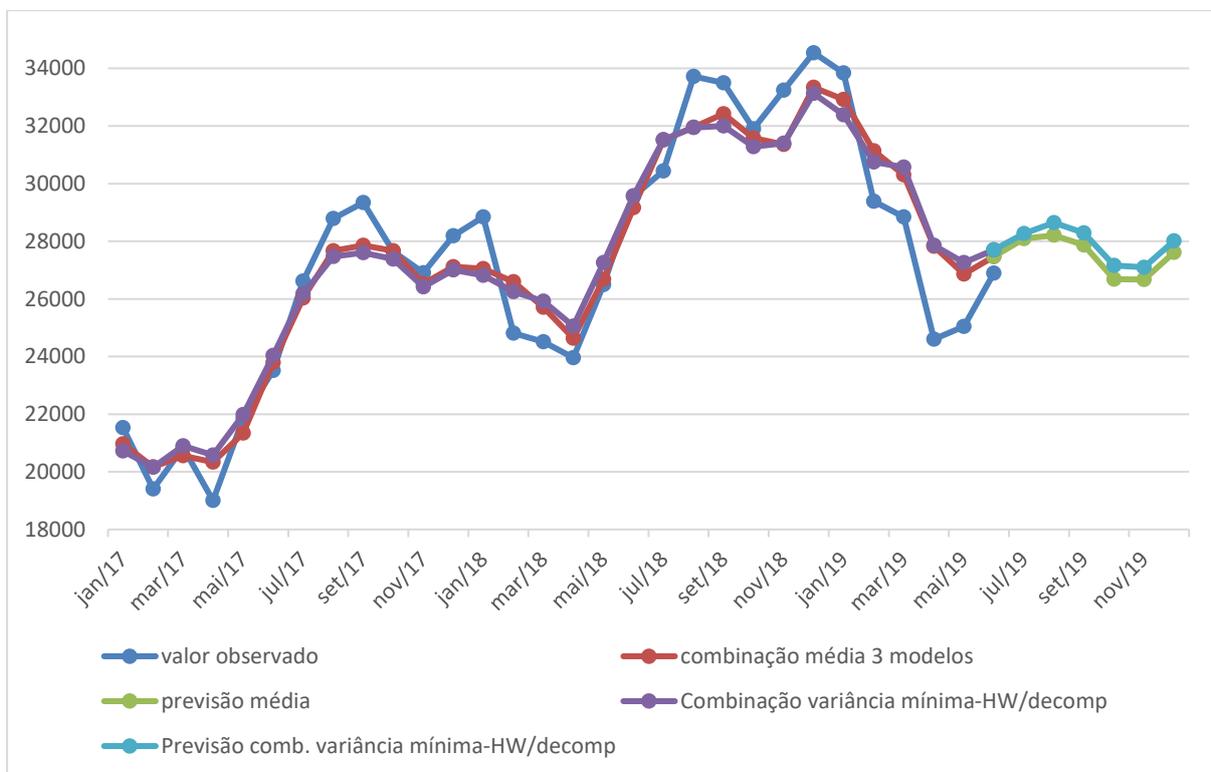


Figura 4 - Quantidade de leite cru industrializado no Rio Grande do Sul, no período de julho de 1998 a junho de 2019 e as previsões para julho a dezembro de 2019

5. Considerações finais

Neste artigo foram utilizados três modelos para obter previsões, os modelos: ARIMA e de suavização exponencial e de decomposição, sendo que os modelos que se ajustaram aos dados da séries em estudo, um modelos SARIMA (0,1,0)(0,1,1)₁₂, um modelo Holt-Winters multiplicativo e um modelo de decomposição com estação sazonal 12. Tais modelos foram usados como base para obter as combinações de previsões pela média, pela mediana e via variância mínima quando do uso de dois modelos ou para os três modelos.

Ao analisar os resultados das medidas de acurácia se conclui que as melhores combinações proporcionam melhores medidas de acurácia que os modelos ajustados, sendo assim para a quantidade de leite cru no Rio Grande do Sul, para os modelos estatísticos analisados, a combinação de previsões trazem melhores previsões. Neste caso, a combinação da média dos três modelos (SARIMA, Holt-Winters e Decomposição) e a combinação dos modelos Holt-Winters e decomposição via variância mínima.

Uma vez que o estado do Rio Grande do Sul está em segundo lugar na industrialização do leite cru no Brasil, é um grande produtor desta bebida alimentícia. Além de ser uma bebida nutricional por si, ela também é base para outros alimentos, como iogurtes, queijos e outros lácteos. Ter uma previsão acurada é de extrema importância, tanto para economia da indústria, como do estado e até do país.

Referências

ABRAHAM, B.; LEDOLTER, J. **Statistical Methods for Forecasting**. New York: John Wiley & Sons, 2005.

ASKU, C.; GUNTER, S. I. An Empirical Analysis of the Accuracy of AS, OLS, ERLS, and NRLS Combination Forecasts. **International Journal of Forecasting**, v. 8, n.1, p.27-43, 1992.

BATES, J. M.; GRANGER, C. W. J. The Combining of Forecasts. **Operational Research Quarterly**, v.20, n.4, p. 451-468, 1969.

BOX, G. E. P. & JENKINS, G. M. **Time Series Analysis**. Forecasting and Control. San Francisco: Holden-Day, 1976.

BICHPURIYA, Y. K.; SOMAN, S. A.; SUBRAMANYAM, A. Combining forecasts ins short term load forecasting: Empirical analysis and identifications of robust forecaster. **Sadahana**, v. 41, n. 10, p.1123 – 1133, oct. 2016.

CLEMEN, R. T. Combining Forecasts: A Review and Annotated Bibliography. **International Journal of Forecasting**, v. 5, n.4, p.559-583, 1989.

CNA. Pesquisa Trimestral de Abate de Animais, de Leite, Couro e Produção de Ovos de Galinha. Disponível em: <<https://www.cnabrasil.org.br/boletins/pesquisa-trimestral-de-abate-de-animais-de-leite-couro-e-producao-de-ovos-de-galinha>> Acesso em: 02 set. 2019.

COSTANTINI, M.; PAPPALARDO, C. A hierarchical procedure for the combination of forecasts. **International Journal of Forecasting**, v. 26, n.4, p.725–743, 2010.

KISCHNER, P.; BRUM, A. L.; MUENCHEN, J. V.; BASSO, D. A cadeira produtiva de leite na região nordeste do RS: estudo de caso do município de Ijuí. **Brazilian Journal of Development**, v.5, n.9, p. 15162- 15176, sep. 2019.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting**. Methods and Applications. Third Edition. New York: John Wiley & Sons, 1998.

MORETTIN, P. A. ; TOLOI, C. **Análise de séries temporais**. 2ª edição. São Paulo: Ed. Blucher, 2006.

NOWOTARSKI, J.; WERON, R. **To combine or not to combine? Recent trends in electricity price forecasting**, HSC Research Reports HSC/16/01, Hugo Steinhaus Center, Wroclaw University of Technology. 2016.

PELLEGRINI, F. R. **Metodologia para implementação de sistemas de previsão de demanda**. Porto Alegre: UFRGS, 2000. 146 p. Dissertação (mestrado) – Programa de Pós-Graduação em Engenharia de Produção, Escola de Engenharia. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

WALLIS, K. F. Combining forecasts – forty years later. **Applied Financial Economics**, v.21, n. 1 -2, p. 33-41, 2011.

WERNER, L. **Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião**. 2004. 166f. Tese (Doutorado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, UFRGS, Porto Alegre, 2005.