

DESEMPENHO DE TÉCNICAS E COMBINAÇÕES DE PREVISÕES: UM ESTUDO COM OS PORCENTUAIS RELACIONADOS COM O SISTEMA ÚNICO DE SAÚDE BRASILEIRO

PERFORMANCE TECHNIQUES AND COMBINING FORECASTS: A STUDY WITH THE PERCENTAGE RELATED WITH BRAZILIAN UNIFIED HEALTH SYSTEM

Liane Werner^{1,♦}, Vera Martins¹

RESUMO

Realizar previsões é uma atividade que permite a todos os setores industriais ou de serviços dimensionar suas necessidades para atender bem aos clientes. Para tanto, os gestores estão sempre em busca da previsão mais acurada. Sendo assim, este artigo apresenta por meio do estudo da série percentual da quantidade de procedimentos ambulatoriais não aprovados para pagamento pelo Sistema Único de Saúde (SUS) em relação ao total apresentado por este sistema, uma investigação para comparar o desempenho de previsões desta demanda. Os métodos utilizados foram: modelo de suavização exponencial e redes neurais artificiais, métodos de combinação de previsões pela média e por regressão. Foi possível observar que o método de combinação por regressão apresenta uma pequena superioridade em relação às demais técnicas.

Palavras chave: Combinação de previsões, Sistema Único de Saúde Brasileiro, previsão.

ABSTRACT

Perform forecasts is an activity that allows the industrial sector or services scale their needs to better attend the customers. For that, forecasters are always searching for more accurate predictions. Thus this paper presents a study through the data series of the percentage of the amount of outpatient procedures payment not approved by the Unified Health System (SUS) in relation to the total reported to that system, a research to compare the forecast techniques performance of this demand. The methods used in this study were: model of exponential smoothing and artificial neural networks, average forecast combination and regression forecast combination. It was possible to observe that the regression combination method showed mild superiority over the other techniques.

Keywords: Forecast Combination, Brazilian Unified Health System, forecasting.

¹ Professora. Instituto de Matemática e Estatística. UFRGS. Porto Alegre. Brasil

[♦]Autor para correspondência: werner.liane@gmail.com

Recebido: 18.11.2013 Aceito: 05.01.2015

INTRODUÇÃO

O desenvolvimento dos mercados possibilitou o desenvolvimento de muitas formas de realizar previsões. Para identificar o melhor ajuste preditivo a uma série disposta ao longo do tempo é necessário avaliar uma gama variada de técnicas, uma vez que o procedimento de realizar previsões envolve incerteza. Segundo Oliveira (2007), não existem dúvidas sobre a importância da previsão em planejamento em saúde, pois o gestor necessita antecipar os problemas de oferta e demanda por serviços de saúde e assim formar e treinar os profissionais desta área. Porém para obter boas previsões se faz primordial selecionar, por meio das medidas de acurácia, aquela que melhor represente o conjunto de dados.

Como cada forma de realizar a previsão (individualmente) pode capturar aspectos diferenciados nos dados, ao obter a previsão, uma opção é incorporar as diversas previsões em uma nova previsão (Armstrong, 2001; Werner, 2005). O método conhecido como combinação de previsões é uma destas opções. Ele agrega os mais diferentes aspectos dos dados obtidos através de diferentes técnicas de previsão (Webby & O'Connor, 1996).

Desde o artigo seminal de combinação de previsões, de autoria de Bates e Granger em 1969 até os dias atuais, muitos estudos buscam pela forma mais adequada de realizar a previsão, tanto em termos de acurácia, quanto em termos de complexidade (Martins & Werner, 2012; Costantine & Pappalardo, 2010; Chan *et al.*, 2004; Menezes *et al.*, 2000; Granger & Ramanathan, 1984; Bates & Granger, 1969).

Observar de forma investigativa qual método de previsão seria mais adequado para demandas administrativas do Sistema Único de Saúde no Brasil representa uma oportunidade de fornecer alternativas quantitativas aos responsáveis pelo planejamento da gestão em saúde.

Pelo exposto acima e pelo fato de que o previsor almeja sempre obter a previsão mais acurada (Abraham & Ledolter, 2005), este artigo se propõe a apresentar, por meio de um estudo com os percentuais de procedimentos ambulatoriais não aprovados pelo Sistema Único de Saúde Brasileiro, uma investigação para comparar o desempenho de formas de previsões de demanda, sugerindo assim uma forma quantitativa de realizar previsões na gestão em saúde. Para tanto, são comparados os modelos de suavização exponencial e redes neurais artificiais, além dos métodos de combinação de previsões pela média aritmética e por regressão.

Técnicas e métodos de combinação de previsão e suas medidas de acurácia

Em qualquer cenário, a previsão de demanda é um processo metodológico para determinação de dados futuros. Tal processo é baseado em modelos estatísticos, matemáticos ou econométricos ou ainda em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente definida (Martins & Laugen, 2006; Makridakis *et al.* 1998). Na área de gestão em saúde ainda necessita-se ajustar as técnicas conhecidas às séries de dados disponíveis.

Os modelos de suavização exponencial possuem grande popularidade em razão de sua simplicidade, eficiência computacional, e razoável precisão. O propósito dos modelos é distinguir o padrão de qualquer ruído que possa estar contido nas observações. Segundo Morettin e Tolo (2004), nas técnicas de suavização os valores extremos da série representam a aleatoriedade, sendo necessário suavizar esses extremos para possibilitar a identificação do padrão básico da mesma. Neste sentido, estes modelos realizam a remoção ou redução das flutuações de curto prazo, facilitando a visualização de tendências e padrões cíclicos presentes na série temporal; o ajustamento sazonal, por exemplo, representa uma forma de suavização, removendo as oscilações sazonais da série. Uma das técnicas mais populares de suavização para séries com tendência positiva ou negativa é o modelo de HOLT. Nesta forma de previsão, o nível e a tendência podem ser modelados de acordo com as equações (1) e (2).

$$\bar{Z}_t = \alpha Z_t + (1 - \alpha)(\bar{Z}_{t-1} + \hat{T}_{t-1}) \quad (1)$$

$$\hat{T}_t = \beta(\bar{Z}_t + \bar{Z}_{t-1}) + (1 - \beta)\hat{T}_{t-1} \quad (2)$$

Para as quais: \bar{Z}_t é o valor do nível da série no instante t, \hat{T}_t é o valor da tendência da série no instante t, e α e β são constantes de suavização, válidos para $t \geq 2$ e .

Outra técnica aplicada para modelar séries de tempo são modelos de redes neurais artificiais, as RNA's (Hair *et al.*, 2005). Estes modelos são menos populares que os modelos de suavização, principalmente em razão da complexidade, apesar da precisão, eficiência computacional e robustez. Outra vantagem de realizar uma modelagem de série temporal por meio desta técnica consiste no fato de que estes modelos lidam melhor com características de nãoestacionariedade (Haykin, 2001). Em estudo apresentado por Martins & Werner (2012) foi possível observar a superioridade deste modelo para previsões individuais. Uma forma de realizar previsões utilizando a metodologia de RNA's é simplificando a arquitetura da rede utilizando uma única camada oculta, modelando por meio do método conhecido como Multilayer Perceptron.

A prática usualmente estabelecida no processo de previsão é determinar as melhores previsões, entre algumas opções, por meio de medidas de acurácia. A melhor previsão é, então, aproveitada, e as outras, descartadas. Através do descarte de previsões classificadas como inferiores, muitas vezes, alguma informação útil é perdida. Logo, ao invés de escolher uma única técnica de previsão, parece razoável considerar informações provenientes de várias técnicas e combiná-las. Como ilustrado na figura 1 – Combinação de Previsões, esta forma de previsão consiste em gerar, com base em dados históricos, um modelo e após obtém-se uma previsão objetiva. Paralelamente, aplica-se outra técnica de previsão, de onde obtém-se uma outra previsão, neste caso, também objetiva. Estas previsões são, então, combinadas, gerando a previsão final (Webby & O'Connor, 1996).

Bates e Granger (1969) propuseram um método de combinar duas previsões, sendo assim considerados os precursores desse assunto. A prososta consiste de uma combinação linear de duas previsões objetivas, dando peso w para a primeira e peso $(1-w)$ para a segunda, conforme a equação (3) que fornece a previsão combinada FC.

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

onde: w é o peso atribuído a previsão e F_1 e F_2 são as previsões a serem combinadas.




Figura 1. Combinação de previsões
 Fonte: Adaptado de Webby & O'Connor, 1996.

Granger e Ramanathan (1984), chamaram a atenção para o fato de que os métodos convencionais de combinação de previsões poderiam ser vistos como uma forma estruturada de regressão. Segundo Montgomery *et al.* (2012) o método de Mínimo Quadrados Ordinários (MQO), é a primeira forma utilizada para obter as estimativas de um modelo de regressão. Sendo assim foi proposto por Granger e Ramanathan (1984) usar a previsão combinada como variável dependente na regressão e as previsões individuais como variáveis explicativas. O valor dos pesos w para cada previsão objetiva é obtido pela equação regressora.

Face a muitas controvérsias sobre qual o melhor método, às dificuldades na estimação dos pesos e a complexidade deste e outros métodos (de combinação), a combinação por média aritmética, além de ser um dos métodos mais conhecidos não costuma gerar dificuldades no momento da geração dos resultados. Para Menezes *et al.* (2000), uma possível resposta para o sucesso da média pode estar associada à instabilidade dos pesos ao longo do tempo na matriz de covariância dos erros das previsões individuais. Frente a isto, mesmo a média não possuindo pesos ótimos, pode dar origem a resultados melhores que os de métodos mais sofisticados. No caso da combinação desta forma de combinação, o w possui o mesmo valor para todas as previsões individuais envolvidas.

Porém para optar por qual previsão - individual ou combinação - é a melhor, é necessário mensurar a acuracidade do modelo aplicado. De acordo com Makridakis *et al.* (1998), em muitas situações a palavra acurácia refere-se à qualidade do ajuste, isto é, ao quão hábil é a técnica ou o modelo para reproduzir os dados que já são conhecidos. Entre as medidas de acurácia, mais utilizadas tem-se: o MAPE (erro percentual absoluto médio) que é uma medida relativa e a RMSE (a raiz quadrada do erro quadrático médio). Ressalta-se que é indicado calcular mais que um critério de comparação, visto que, ocasionalmente, critérios diferentes fornecem indicações diferentes.

MÉTODO PROPOSTO

Para realizar este estudo primeiramente foram revisados os principais tópicos que compõe este artigo: modelos de suavização exponencial e modelos RNA, métodos de combinação de previsão, especificamente pela média e por regressão, e por fim as medidas de acurácia. Ao obter previsões, o previsor almeja sempre uma alta acurácia, a proposição de constituir combinação de previsões ganhou força como forma de realizar tal tarefa. Porém ainda se busca por uma resposta de qual é o método mais adequado, o que não é diferente na área da gestão em saúde. Busca-se neste estudo, através do estudo da série temporal dos percentuais de procedimentos ambulatoriais não aprovados pelo Sistema Único de Saúde Brasileiro, realizar uma investigação comparativa do desempenho de formas de previsões de demanda, possibilitando a indicação de um método replicável em séries de dados similares em sistemas de saúde. Para tanto, se obteve o melhor modelo de suavização exponencial e o melhor RNA considerando o tipo multilayer perceptron com uma camada oculta, utilizando o software SPSS® versão 18. De posse das previsões destes modelos individuais, calcularam-se, no EXCEL®, as previsões via combinação - média e regressão - e após obteve-se e os respectivos erros para estas quatro formas de prever a demanda. A fim de comparar os modelos preditivos calcularam-se as medidas MAPE e RMSE possibilitando a identificação do método mais acurado para a série de dados utilizada, ou seja, o que apresenta as medidas de acurácia mais altas.

Caso prático

Muitos usuários não usufruem do direito universal à saúde, devido a dificuldade dos gestores para promover a integração entre estados, municípios e as redes assistenciais estatais (de Araujo & Costa, 2010). Assim como na área industrial, prever a demanda de serviços na área da saúde está intimamente ligado às tarefas de disponibilizar recursos, tanto humanos como de equipamentos, para viabilizar o atendimento eficaz aos pacientes, sendo

assim, é necessário que as previsões sejam realizadas em períodos curtos, no caso em períodos mensais. Então, coletou-se na base de dados do DATASUS (2012), a quantidade de procedimentos aprovados para pagamento pelas Secretarias de Saúde ao SUS e a quantidade de procedimentos apresentados para o pagamento. De posse destes dados calculou-se percentuais de procedimentos ambulatoriais não aprovados para pagamento pelo SUS. O período observado inicia-se em janeiro de 2008 e finaliza, com observações mensais, em novembro de 2012, compreendendo 59 períodos. Os valores observados encontram-se na figura 2, de onde se observa que até dezembro de 2009 a variabilidade flutua em torno de uma média, após este período começa apresentar tendência.

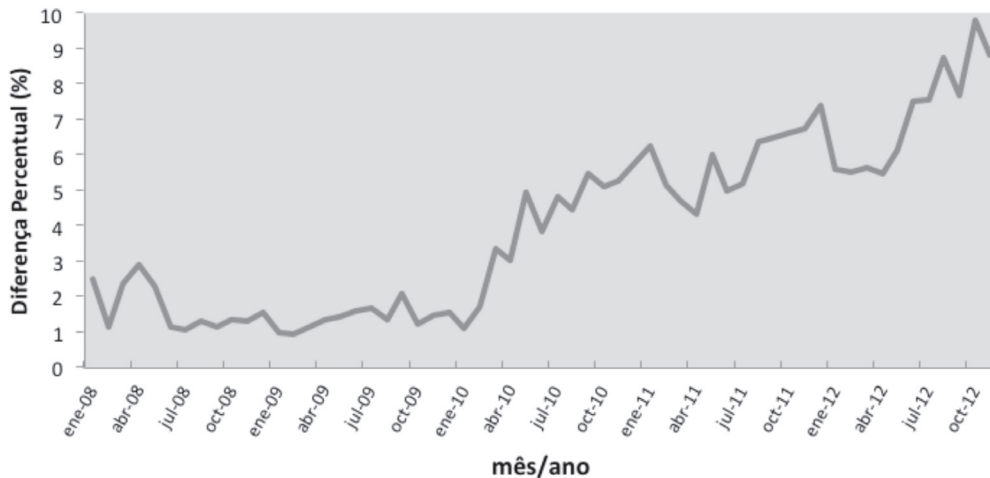


Figura 2. Diferença percentual entre solicitações e aprovações de pagamento [Fonte: dados fornecidos pela gerência da empresa em estudo]

Procedeu-se então a modelagem individual via suavização exponencial, de onde obteve-se o melhor modelo como sendo o winters-aditivo (obtido com a função expert) e a RNA obtida também no SPSS considerando o modelo multilayer perceptron, com uma camada oculta, obtida por treinamento online, considerando 70% da série para treino e 30% para teste.

De posse dos valores observados e como os modelos estabelecidos, foi possível obter, ao longo do tempo, as previsões para estes dois modelos. O passo seguinte foi realizar a combinação das previsões pelos dois métodos deste estudo. Na tabela 1 encontram-se as equações de como foram obtidas as previsões das combinações. Para cada um destes métodos, foi obtido o erro de previsão ao longo do tempo que a série foi analisada.

Tabela 1. Métodos de combinação e suas equações

Método	Equação da combinação
Média Aritmética	$F_c = 0,5F_1 + 0,5F_2$
Regressão	$F_c = 0,105 + 0,483F_1 + 0,539F_2$

Por fim, calcularam-se as medidas de acurácia: MAPE, RMSE para cada uma das quatro formas de previsão, que se encontram na tabela 2. Analisando estas medidas verifica-se que o método de combinação por regressão é o mais acurado e deve ser escolhido para realizar as previsões futuras desta série de dados. Assim, com este estudo prático, verifica-se por meio das medidas tradicionais de acurácia que a combinação de previsões por regressão tem se mostrado efetiva.

Tabela 2. Medidas de acurácia para os métodos de combinação

Método de Previsão	MAPE	RMSE
Winters-aditivo	0,213	0,683
RNA	0,186	0,651
Média	0,160	0,556
Regressão	0,142	0,552

CONSIDERAÇÕES FINAIS

Assim como em áreas de manufatura e prestação de serviços diversos, não há dúvidas sobre a importância da previsão de demanda aplicada para o planejamento em saúde. Neste setor em especial, a importância se apresenta na forma de dimensionamento de equipes de atendimentos, de disponibilização de equipamentos, entre outros. Porém para obter uma boa previsão se faz necessário selecionar, por meio de medidas de acurácia, aquela que melhor represente o conjunto de dados observado.

No caso deste estudo a série apresentada representa a quantidade de procedimentos ambulatoriais encaminhados ao SUS para pagamento e a efetiva aprovação destes procedimentos. Deste modo, procurou-se estabelecer qual o melhor modelo matemático de previsão para descrever o percentual de procedimentos não aprovados pelo SUS para pagamento. Utilizou-se para tanto técnicas de previsão individual (Suavização Exponencial e RNA) e de combinação de previsões (Média Aritmética e Regressão).

Como resultado, pode-se observar que, para esta série de dados, a melhor de forma de previsão é pelo método da Regressão, com previsões individuais realizadas pelas técnicas de Suavização Exponencial e RNA. A definição de melhor método é baseada no menor valor de duas medidas de acurácia: MAPE (0,142) e RMSE (0,552). Este resultado indica que para séries da área de gestão em saúde, com características similares às apresentadas pela série analisada, pode-se utilizar este método de previsão no intuito de planejar de forma mais objetiva às ações de atendimento a população.

Salienta-se, porém, que análises objetivando previsão de demanda focada especificamente para o SUS brasileiro ainda são recentes, inclusive pela recente disponibilidade dos dados para modelagens matemáticas e que, portanto, há algumas limitações nesta investigação. Os dados representam os valores para apenas um dos estados Brasileiros (Rio Grande do Sul), mas a metodologia empregada pode ser replicada para qualquer estabelecimento de saúde que possua procedimentos amortizados pelo SUS. Identificou-se também, por meio da observação desta série que há uma tendência de crescimento do percentual de não aprovações de pagamento de procedimentos, portanto, avaliar tal condição em cada estabelecimento de saúde pode ser um diferencial no momento de planejar os recursos financeiros.

REFERÊNCIAS

ABRAHAM, Bovas, and LEDOLTER, Johannes. Statistical methods for forecasting. New York: John Wiley & Sons, 2005.

BATES, John M., and GRANGER, Clive WJ. The combination of forecasts. *Operational Research Quarterly*, 1969, p. 451-468.

CHAN, Chi Kin., KINGSMAN, Brian G., and WONG, H. Determining when to update the weights in combined forecasts for product demand: an application of the CUSUM technique. *European Journal of Operational Research*, 2004, vol. 153, no 3, p. 757-768.

COSTANTINI, Mauro., and PAPPALARDO, Carmine. A hierarchical procedure for the combination of forecasts. *International journal of forecasting*, 2010, vol. 26, no 4, p. 725-743.

DATASUS. Produção Ambulatorial do SUS - Rio Grande do Sul. 2012. [Disponível em:] <<http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sia/cnv/qars.def>>

GRANGER, Clive W.J., and RAMANATHAN, Ramu. Improved methods of combining forecasts. *Journal of Forecasting*, 1984, vol. 3, no 2, p. 197-204.

HAIR JUNIOR, Joseph F., et al. *Análise multivariada de dados*. 5. ed. Porto Alegre: Bookman, 2005. 593 p.

HAYKIN, Simon. *Redes neurais: princípios e prática*. 2ed. Porto Alegre: Bookman, 2001.

MAKRIDAKIS, Syros., WHEELWRIGHT, Steven C., and HYNDMAN, Rob J. *Forecasting. Methods and Applications*. 3.ed. New York: John Wiley & Sons, 1998.

MARTINS, Petronio G., and LAUGENI, Fernando P. *Administração da Produção*. 2. ed. São Paulo: Saraiva, 2006.

MARTINS, Vera Lúcia Milani., and WERNER, Liane. Forecast combination in industrial series: A comparison between individual forecasts and its combinations with and without correlated errors. *Expert Systems with Applications*, October 2012, vol. 39, no 13, p. 11479-11486.

MENEZES, Lilian M., BUNN, Derek W., and TAYLOR, James W. Review of guidelines for the use combined forecast. *European Journal of Operational Research*, 2000, vol. 120, no1, p. 190-204.

MONTGOMERY, Douglas C., PECK, Elizabeth A., and Vining G, Geoffrey. *Introduction to linear regression analysis*. New York: John Wiley & Sons, 2012.

MORETTIN, Pedro A., TOLOI, Célia M. *Previsão de Séries Temporais*. Editado por Edgard Blucher. São Paulo, 2004.

OLIVEIRA, Sérgio Pacheco de. *Modelo de previsão de demanda de médicos para internação pelo SUS: estudo de caso para o Estado do Rio de Janeiro*. 2007. Tesis Doctoral. Universidade do Estado do Rio de Janeiro. Instituto de Medicina Social.

DE ARAÚJO SOUZA, Georgia Costa., and COSTA, Iris do Céu Clara. O SUS nos seus 20 anos: reflexões num contexto de mudanças. *Saúde e Sociedade*, 2010, vol. 19, no 3, p. 509-517.

WEBBY, Richard., and O'CONNOR, Marcus. Judgment and Statistical Time Series Forecasting: a Review of the Literature. *International Journal of Forecasting*, 1996, vol.12, no1, p.91-118.

WERNER, Liane. *Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião*. Thesi (PhD in Production Engineering). Porto Alegre: UFRGS, 2005.

