

Comparação de Métodos de Previsão de Demanda em uma Montadora de Veículos Agrícolas

Alessandro Kahmann (UFRGS) 00136876@ufrgs.br
João Francisco Vieira da Fontoura (UFRGS) jhueao@hotmail.com
Rodolfo Reinaldo Hermes Petter (UFRGS) rodolfopetter@gmail.com
Ricardo Augusto Cassel (UFRGS) cassel@producao.ufrgs.br

Resumo

A previsão de demanda é parte importante para a tomada de decisões em diversas áreas empresariais. No intuito de melhorar a performance operacional de uma cadeia de suprimentos, já houveram diversos estudos na área para definir qual o melhor método de previsão de demanda. Este trabalho faz um estudo de caso através da comparação entre três métodos de previsão de demanda, aplicados em um banco de dados oriundos de uma empresa que atua na área de venda de veículos agrícolas. Com o auxílio de medidas de desempenho para avaliar o melhor método, concluiu-se que o Método de Suavização Exponencial Simples obteve o melhor resultado em comparação ao Método Linear de Holt e o Método de Tendência Amortecida, tanto na soma total das séries quanto na comparação individual nas diferentes linhas de veículos vendidos.

Palavras-chave: Previsão de demanda, Seleção de Modelos, Suavização Exponencial Simples, Método Linear de Holt, Tendência Amortecida.

Comparison of Demand Forecasting Methods in an Agricultural Vehicles Assembler

Abstract

The demand forecasting is an important part in decision making process in many business areas. In order to improve the operational performance of a supply chain, several studies have already been done to define which is the best demand forecasting method. This paper is a case study by comparing three demand forecasting methods, applied in a database derived from an agricultural vehicles company. Using performance measures to evaluate the best method, this work concluded that the Simple Exponential Smoothing method obtained better results compared to Holt's Linear Method and the Damped Trend method. This result is valid in the total sum of the series and in individual comparison in different lines of sold vehicles.

Keywords: Demand Forecasting, Model Selection, Simple Exponential Smoothing, Holt's Linear Method, Damped Trend.

1. Introdução

A concorrência afeta diversos setores da economia. Esse ambiente competitivo e instável leva as empresas a melhorarem seus processos, dentre eles, a previsão de produção e demanda, cuja função é antecipar a demanda futura (SILVA *et al.*, 2002).

A previsão de demanda possui um importante determinante no desempenho de diversas áreas

na gestão de organizações (PELLEGRINI; FOGLIATTO, 2001). Acar e Gardner Jr. (2012) citam que, para garantir a operacionalização matemática, a maioria dos pesquisadores tem assumido operações bastante simplificadas para sistemas e estrutura de custos. Kotler (2000) mostra que a previsão de demanda é utilizada por diversos setores de uma empresa, dentre eles o setor de finanças, que se baseia nos resultados das previsões para determinar o caixa da empresa necessário para investimentos, e o setor de produção, com o objetivo de determinar a produção de um período, evitando assim estoques desnecessários, ou falta de produtos. Fildes e Kingsman (2010) acrescenta que uma das vantagens de melhorar as técnicas de previsão de demanda é aprimoramento das decisões de regras de inventário, pois uma má especificação do modelo implica em aumento dos custos. A acurácia de uma previsão de demanda está relacionada à habilidade do método em estimar com precisão valores futuros (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1998).

O conceito de previsão de demanda é frequentemente confundido com o planejamento estratégico dentro das organizações (ARMSTRONG, 2001). A distinção destes conceitos está na distinção entre eventos não controláveis (comportamento de consumidores, concorrentes, economia nacional e mundial) e eventos internos controláveis (decisões sobre marketing e produção). As previsões estão ligadas ao primeiro conceito, enquanto tomadas de decisão aplicam-se ao segundo conceito, enquanto o planejamento faz a ligação entre os dois (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1998).

Sabe-se que previsões de demanda podem ser concebidas através de métodos quantitativos, qualitativos, ou uma combinação de ambos (PELLEGRINI, 2000; WERNER; RIBEIRO, 2003). Neste artigo, são utilizados apenas métodos quantitativos, aqui denominados como métodos de previsão. A maioria dos métodos de previsão baseia-se no princípio de que dados antigos possuem informações sobre o padrão de comportamento da variável em análise. O objetivo desses métodos é distinguir o padrão de qualquer ruído que possa estar contido nas observações.

Para a execução desse trabalho, são utilizadas apenas suavizações exponenciais. Os três métodos comparados são: (i) a Suavização Exponencial Simples (SES), (ii) o método Linear de Holt e o (iii) método de Tendência Amortecida. A comparação entre estes métodos será realizada através dos respectivos valores RMSE (*root mean square error* ou raiz do erro médio quadrático) e MASE (*mean absolute scaled error* ou erro médio absoluto escalado) utilizados em Makridakis *et al.* (1982).

Na seção seguinte, é apresentada uma breve explicação dos métodos de previsão de demanda e das medidas de desempenho. Logo após, na seção 3, são apresentados os procedimentos metodológicos. Na seção 4, são apresentados os resultados do estudo. Por fim, na seção 5, são realizadas conclusões sobre o trabalho, bem como a proposição de trabalhos futuros a serem realizados sobre esse tema.

2. Referencial teórico

São utilizados três métodos de previsão de demanda neste trabalho: (i) a Suavização Exponencial Simples, (ii) o método de Suavização Linear de Holt e o (iii) método de Tendência Amortecida. Para se ter uma ideia do quanto uma previsão é precisa, é necessário haver uma forma de estimar o erro. Para tal objetivo são usadas as medidas de desempenho RMSE e a MAPE, que quantificam o erro de forma que seus resultados não sejam afetados por diferenças de escalas.

2.1 Métodos de Previsão de Demanda

O avanço da computação e suas tecnologias têm permitido o aumento do monitoramento de

processos e o armazenamento de tais informações. Este avanço acaba, por vezes, possibilitando a criação de bancos de dados cada vez maiores, chegando a um limite onde a análise de tais dados está acima da capacidade humana de processamento, tornando necessário o estudo de métodos de análise computacionais (LIU; YU, 2005). A previsão de demanda é uma técnica que se utiliza de dados passados para encontrar padrões comportamentais de uma determinada série temporal a fim de se realizar estimativas futuras. Com base na previsão de demanda, criam-se políticas como, por exemplo, sistema de estoques, demanda de materiais e custos. Alguns motivos que justificam a utilização de técnicas de previsão de demanda são a necessidade de diminuir riscos inerentes a processos decisórios e o fato do aumento na acurácia da previsão diminuir as perdas financeiras resultantes de tais incertezas (HOLLAUER *et al.*, 2008, PELLEGRINI; FOGLIATTO, 2001, PRICE; SHARP, 1986).

Existem diversos métodos para realizar a previsão de demanda. Alguns mais complexos, envolvendo diversos parâmetros, outros mais simples. É importante ressaltar que a utilização de métodos mais complexos não garante melhores resultados. Em algumas situações, métodos mais simples podem obter resultados igualmente satisfatórios ou melhores em relação aos mais complexos, isso tudo depende da série temporal com que se está trabalhando e qual método melhor se encaixa (PELLEGRINI, 2000).

2.1.1 Suavização Exponencial Simples

A Suavização Exponencial Simples (SES) caracteriza-se por ser uma técnica de simples aplicação e, por isso, frequentemente é utilizada em empresas. Como consequência, é também utilizada em trabalhos que comparam métodos de previsão de demanda (ACAR; GARDNER JR., 2012; HYNDMAN; KOEHLER, 2006; PELLEGRINI, 2000; PELLEGRINI; FOGLIATTO, 2001).

As previsões através da SES dependem de apenas três dados: a previsão mais recente, o valor real mais recente e a constante α de suavização. Esta constante determina a ponderação dada aos outros dois valores. Esta técnica melhor atua em séries temporais que se mantêm constante sobre um nível médio (MAKRIDAKIS *et al.*, 1998).

A equação da SES é dada por

$$P_t = \alpha V_{t-1} + (1 - \alpha)P_{t-1} \quad (1)$$

Onde:

P_t é a previsão para o período t

V_{t-1} é o valor real para o período t-1

α é a constante de suavização

Como o valor de α determina uma proporção, seu valor deve estar no intervalo [0,1].

O método de Suavização Exponencial Simples assume que os dados da série temporal apresentam apenas componentes de nível e ruído. Se os dados apresentarem sazonalidade ou algum tipo de tendência, a Suavização Exponencial Simples não é o método mais adequado (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1998).

2.1.2 Método Linear de Holt

Holt (2004) criou um método de suavização exponencial que fosse aplicável às séries com tendência linear. O método utiliza-se de duas constantes de suavização, α e β , onde, assim

como na SES, possuem valores entre 0 e 1 e não relacionados (MAKRIDAKIS *et al.*, 1998). Sua flexibilidade, aliada a economia de processamento computacional (importante à época), tornou esta ferramenta especialmente utilizável em situações de previsões de demanda para vendas (HOLT, 2004).

Assim como a SES, o Método Linear de Holt, apesar de sua simplicidade teórica, também é amplamente utilizado em empresas e em pesquisas empíricas. (ACAR; GARDNER JR., 2012; HYNDMAN; KOEHLER, 2006, PELLEGRINI; FOGLIATTO, 2001; SOHN; LIM, 2008).

As equações do Método Linear de Holt são:

$$L_t = \alpha V_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (2)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (3)$$

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

Onde:

L_t é a estimativa do nível da série no período t

b_t é a estimativa da tendência da série no período t

V_t é o valor real para o período t

P_{t+m} é a previsão para o período t+m

α e β são as constantes de suavização

A equação (1) faz uma estimativa do nível, enquanto (2) faz uma estimativa da inclinação da série temporal. Do resultado destas duas equações, (3) calcula a previsão do m-ésimo próximo período.

2.1.3 Método de Tendência Amortecida

Esse método foi desenvolvido em uma série de três trabalhos, (GARDNER; MCKENZIE, 1985; GARDNER; MCKENZIE, 1988; GARDNER; MCKENZIE, 1989). Baseado no método de Holt–Winters (HOLT, 2004; WINTERS, 1960), este método visa suavizar a tendência existente em um período de dados. Em seu trabalho de revisão, Armstrong (2006) cita o Método de Tendência Amortecida como uma ferramenta que deve melhorar a acurácia de previsões em casos práticos.

Segundo o Método de Tendência Amortecida para suavizações exponenciais é um método que geralmente produz os melhores resultados em testes empíricos de comparações de métodos de previsão de demanda (GARDNER JR.; MCKENZIE, 2010).

As fórmulas para a modelagem através do Método de Tendência Amortecida são:

$$L_t = L_{t-1} + \theta b_{t-1} + \alpha e_t \quad (5)$$

$$b_t = \theta b_{t-1} + \alpha \beta e_t \quad (6)$$

$$P_t = L_t + \theta b_t \quad (7)$$

Onde:

L_t é a estimativa do nível da série no período t

b_t é a estimativa da tendência da série no período t

P_t é a previsão para o período t

e_t é o “one-step-ahead error”

θ , α , β são as constantes de suavização

Assim como no Método Linear de Holt, no Método de Tendência Amortecida as equações (5) e (6) calculam respectivamente o nível e a tendência da série temporal, enquanto a equação (7) calcula a previsão do período seguinte.

2.2 Medidas de desempenho

Utilizar medidas de desempenho é uma das maneiras de quantificar a diferença entre os valores estimados de um modelo e os dados reais. Uma vez que previsões de demandas não são perfeitas, se torna necessário utilizar recursos para avaliar a adaptabilidade de um modelo a uma série temporal. Algumas medidas de desempenho mostram a adequação relativa, outras são de precisão e ainda há as que tentam capturar a capacidade de acerto de tendência. Tais ferramentas estatísticas possibilitam o julgamento isento das vantagens do modelo (HOLLAUER *et al.*, 2008; HYNDMAN; KOEHLER, 2006; SANT’ANA *et al.*, 2010; WEATHERFORD; KIMES, 2003).

A análise de significância dos modelos foi rechaçada uma vez que o objetivo deste trabalho é verificar os modelos em previsões de demanda (ao invés de seu ajuste em relação à série temporal). Mais informações sobre o viés de estudar a significância dos modelos é encontrado em Armstrong (2007).

Considerando o erro de um período da previsão como $e_t = V_t - P_t$, ou seja, a diferença entre o valor real e a previsão, são mostradas, a seguir, as duas medidas de desempenho utilizadas neste artigo.

2.2.1 Raiz do Erro Médio Quadrático (RMSE)

A RMSE baseia-se na raiz da média quadrática. Apesar de aparentemente redundante, quando utilizado esta medida de desempenho, o erro, independentemente de ser positivo ou negativo, será somado ao valor final, evitando que erros com valores positivos e negativos se anulem.

Segundo Hyndman e Koehler (2006), o RMSE é uma medida comumente utilizada em dados com mesma escala. Portanto é uma ferramenta de bom desempenho quando utilizada para comparar diferentes métodos em um banco de dados uniforme, porém não deve ser aplicado em bancos de dados com séries temporais em escalas diferentes.

Definindo como t o período em análise dentro de n períodos, a equação para o RMSE é:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (8)$$

2.2.2 Erro Médio Absoluto Escalado (MASE)

Encontrado em Hyndman e Koehler (2006), o MASE é descrito como uma medida de desempenho de métodos de previsão de demanda com aplicação mais generalizada, sem os empecilhos encontrados em outras medidas. Medidas de desempenho, como o Erro Médio Absoluto Percentual e *Thiel's U*, não são aplicáveis pelo fato de o banco de dados possuir muitos períodos com valores iguais a zero, impedindo a execução ou obrigando a ter uma correção no cálculo. Essa medida é livre de erros e pode ser utilizada para comparar métodos de previsão de demanda assim como comparar a acurácia entre séries temporais.

Mantendo as nomenclaturas anteriores, a equação da medida MASE é dada por:

$$MASE = \frac{1}{n} \sum_{t=1}^n \left(\frac{|\varepsilon_t|}{\frac{1}{n-1} \sum_{i=2}^n |v_i - v_{i-1}|} \right) = \frac{\sum_{t=1}^n |\varepsilon_t|}{\frac{n}{n-1} \sum_{i=2}^n |v_i - v_{i-1}|} \quad (9)$$

Observa-se no denominador a média de previsões de demanda simples, onde se utiliza o valor da demanda real do período anterior como previsão para o período atual.

3. Procedimentos Metodológicos

O banco de dados é oriundo de uma empresa vendedora de veículos agrícolas, detentora de revendedoras em todo o país. Dentre os veículos vendidos, há uma divisão destes em cinco diferentes linhas existentes. Dentro destas linhas de veículos há diversos modelos, mas, uma vez que as peças de montagem de linhas dentro de um mesmo modelo são semelhantes, a divisão de modelos não será considerada. Dessa forma, o agrupamento será dado, primeiramente, pela revendedora e, logo após, pela linha do veículo.

Os dados são referentes a 33 períodos consecutivos entre os anos de 2010 e 2012. Por existirem revendedoras que não possuem vendas constantes de determinadas linhas, foi determinado um ponto de corte. Basicamente, se dentro destes 33 períodos não houver um total mínimo de 35 vendas, esta linha é adicionada à categoria “outros” dentro da sua revendedora. A categoria “outros” também está submetida a este ponto de corte. Portanto, se após somadas as linhas sem o mínimo de vendas a categoria “outros” não obtiver 35 vendas, esta também é excluída do banco. Tal corte poderia ser realizado de acordo com a curva ABC, como em Pellegrini e Fogliatto (2001), de cada revendedora, mas, como não há valor relacionado às linhas, foi determinado este modo de divisão. Portanto as séries temporais são divididas por linha dentro de cada uma das revendedoras, podendo, então, cada revendedora ter seis tipos diferentes de grupos (as linhas 1 a 4 e o grupo “outros”). Destas divisões, foram geradas 150 séries temporais.

Neste trabalho desejamos encontrar o método que melhor prevê as demandas de cada um dos grupos, portanto não será analisada a aderência dos modelos aos dados, mas sim o erro em relação às previsões. Para isso, os dados históricos são separados em porções de treino e teste. Na porção de treino, para a geração dos modelos de previsão de demanda, são utilizados os primeiros 24 períodos. Separados os períodos de cada série temporal, são aplicados os três modelos de suavização exponencial na parte de modelagem, onde os melhores parâmetros são automaticamente encontrados pelo *software* SPSS®. A partir destes modelos, são geradas previsões para os próximos 9 períodos. Uma vez geradas as previsões, elas são comparadas às demandas reais da porção de teste e então são calculadas as duas medidas de desempenho para cada um dos três modelos. A comparação dos resultados se dará através destas medidas.

4. Resultados

A comparação dos métodos ocorre pela média das medidas de desempenho de todos os grupos. O método que apresentar a menor média é considerado o de melhor desempenho segundo a medida de desempenho analisada.

Modelo	SES	Holt	Tendência Amortecida
RMSE	5,08	5,77	5,58
MASE	1,02	1,19	1,16

Fonte: Os autores

Tabela 1 - Médias das medidas de desempenho para cada modelo

Julgando pelo RMSE e o MASE da Tabela 1, conclui-se que o modelo que melhor se adequou a todos os dados foi o de Suavização Exponencial Simples, seguido pelo modelo de Tendência Amortecida e por último o modelo Linear de Holt.

Apesar de se verificar o resultado de todos os dados agrupados, a análise dos métodos a cada grupo também se mostra interessante, pois assim é observada a influência de cada grupo e suas características. Normalmente, em um processo pode haver centenas ou milhares de séries temporais simultaneamente. Na prática, uma possibilidade é a seleção de um modelo para todas as séries e a outra é a criação de uma regra que seleciona o melhor modelo para cada uma das séries (SHAH, 1997). Para fazer esta comparação, observam-se os dados em seus respectivos grupos (Tabela 2).

Modelo	Linha 1 (29)		Linha 2 (70)		Linha 3 (3)		Linha 4 (9)		Outros (39)	
	RMSE	MASE	RMSE	MASE	RMSE	MASE	RMSE	MASE	RMSE	MASE
SES	4,06	0,86	7,11	0,92	4,30	0,73	4,29	1,57	2,42	1,20
Holt	4,85	1,14	8,18	1,08	3,97	0,71	4,65	2,01	2,50	1,28
Tendência Amortecida	4,69	1,10	7,83	1,04	3,98	0,72	4,77	2,03	2,49	1,27

Fonte: Os autores

Tabela 2 - Médias das medidas de desempenho para cada modelo, separado por grupos

Na Tabela 2, é observado que o modelo SES é o que melhor se adequa aos dados mesmo separados em seus respectivos grupos. A exceção da Linha 3 pode ser justificada pelo fato de existirem apenas 3 séries temporais neste grupo, o que torna o resultado próximo ao inconclusivo por não apresentar uma base sólida para a modelagem.

5. Conclusões

Um importante passo para a correta administração de uma empresa passa por prever as vendas de seus produtos em determinado período de tempo. Uma acurada previsão destes números possibilita uma melhor adequação da empresa em relação à sua política de produção, previsão de custos, entre outros.

Por haver diversos métodos de modelagem de séries temporais para previsão de demanda, o presente trabalho teve como objetivo encontrar o método de suavização exponencial que melhor se adapta aos dados de venda de uma empresa do ramo de veículos agrícolas. Para tal, foram utilizados valores de demanda da empresa em questão em um determinado período de tempo. Separando em duas porções, uma para calibrar o modelo e outra para testá-lo, foram utilizados 3 métodos de suavização exponencial: (i) o Método de Suavização Exponencial Simples (SES); (ii) o Método Linear de Holt; e (iii) o Método de Tendência Amortecida.

A partir dos valores previstos, foram utilizadas duas medidas de desempenho: (i) o Raiz do Erro Médio Quadrático e o (ii) Erro Médio Absoluto Escalado. O método gerador do modelo que mostrar o menor valor nestas medidas será considerado o mais adequado à série temporal.

O resultado que afirma que a SES foi o método que mais se adequou às séries temporais. Apesar de inesperado, mostra que, dependendo da espécie de dados com que se trabalha, o excesso de coeficientes de uma suavização pode atrapalhar no resultado final. Uma possibilidade para tal acontecimento é a existência de dados ruidosos, ou simplesmente a inexistência de base para tais coeficientes, portanto fora incluídos no modelo de forma inacurada ou incorreta.

Uma pergunta óbvia a se acrescentar é se o método de SES é melhor que o método implementado na empresa em estudo. Porém não há a adoção de um método definido, o que inviabiliza tal comparação.

Uma sugestão para pesquisas futura é a inclusão de valores para haver uma comparação financeira das previsões, assim com há em Acar e Gardner Jr. (2012). Com o acréscimo dos valores de cada linha, entre ele valores de pedidos e estoque, se tornaria possível a comparação de gastos entre os modelos.

Referências Bibliográficas

ACAR, Y., GARDNER JR., E.S. *Forecasting method selection in a global supply chain*. International Journal of Forecasting, v. 28, n. 4, p. 842-848, 2012.

ARMSTRONG, J. *Principles of Forecasting: a Handbook for Researches and Practitioners*. Boston: Kluwer Academic Publishers, 2001.

ARMSTRONG, J.S. *Significance tests harm progress in forecasting*. International Journal of Forecasting, v. 23, n. 2, p. 321-327, 2007.

FARIA, E.L.; ALBUQUERQUE M.P.; ALFONSO, J.L.G.; ALBUQUERQUE, M.P.; CAVALCANTE, J.T. *Previsão de séries temporais utilizando métodos estatísticos*. CBPF - Centro Brasileiro de Pesquisas Físicas, 2008.

FILDES, R., KINGSMAN, B.G. *Incorporating demand uncertainty and forecast error in supply chain planning models*. Journal of the Operational Research Society, v. 62, n. 3, p. 483-500, 2010.

GARDNER JR, E.S.; MCKENZIE, E. *Forecasting trends in time series*. Management Science, v.31, n. 10, p. 1237-1246, 1985.

GARDNER JR, E.S.; MCKENZIE, E. *Model identification in exponential smoothing*. Journal of the Operational Research Society, v. 39, p. 863-867, 1988.

GARDNER JR, E.S.; MCKENZIE, E. *Seasonal exponential smoothing with damped trends*. Management Science, v. 35, n. 3, p. 372-376, 1989.

GARDNER JR, E.S.; MCKENZIE, E. *Why the Damped trend works*. Journal of the Operational Research Society, v. 62, n. 6, p. 1177-1180, 2010.

HYNDMAN, R.J., KOEHLER, A.B. *Another look at measures of forecast accuracy*. International Journal of Forecasting, v. 22, n. 4, p. 679-688, 2006.

HOLLAUER, G., ISSLER, J.V., NOTINI, H.H. *Prevendo o crescimento da produção industrial usando um número limitado de combinações de previsões*. Economia Aplicada, São Paulo, v.12, n.2, p.177-198, 2008.

HOLT, C.C. *Forecasting seasonals and trends by exponentially weighted moving averages*. International Journal of Forecasting, v. 20, n. 1, p. 5-10, 2004.

KOTLER, P. *Administração de Marketing: A Edição do Novo Milênio*. São Paulo: Prentice Hall, 2000.

LIU, H.; YU, L. *Toward integrating feature selection algorithms for classification and clustering*. Transactions on Knowledge and Data Engineering, v. 17, n. 4, p. 491-502, 2005.

MAKRIDAKIS, S.; ANDERSEN, A.; CARBONE, R.; FILDES, R.; HIBON, M.; LEWANDOWSKI, R.; NEWTON, J.; PARZEN, E.; WINKLER, R. *The accuracy of extrapolation (time series) methods: Results of a forecasting competition*. Journal of Forecasting, v. 1, n. 2, p. 111-153, 1982.

MAKRIDAKIS, S.; WHEELWRIGHT, S.C.; HYNDMAN, R.J. *Forecasting methods and applications*. 3ª Ed., New York: John Wiley & Sons, 2008.

PELLEGRINI, F.R. *Metodologia para implementação de sistemas de previsão de demanda*. (Dissertação De Mestrado em Engenharia de Produção), Porto Alegre: UFRGS, 2000.

PELLEGRINI, F.R.; FOGLIATTO, F.S. *Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso*. Revista Produção, v.11, n.1, p. 43-64, 2001.

PRICE, D.H.R., SHARP, J.A. *A comparison of performance of different univariate forecasting methods in a model of capacity acquisition in UK electricity supply.* International Journal of Forecasting, v. 2, n. 3, p. 333-348, 1986

SANT'ANA, C.H.; LEITE, J.C.B. MOSSÉ, D. *Previsão de Carga para Economia de Energia em Aglomerados de Servidores Web.* XXVIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos, 2010.

SHAH, C. *Model selection in univariates time series forecasting using discriminant analysis.* International Journal of Forecasting, v. 13, n. 4, p. 489-500, 1997.

SILVA, W.V.; SAMOHYL, R.W.; COSTA, L.S. *Comparação entre os métodos de previsão univariados para o preço médio da soja no Brasil.* XXII Encontro Nacional de Engenharia de Produção (ENEGEP), Curitiba – PR, 2002.

SOHN, S.Y.; LIM, M. *The effect of forecasting and information sharing in SCM for multi-generation products.* European Journal of Operational Research, v. 186, n. 1, p. 276-287, 2008.

WEATHERFORD, L.R., KIMES, S.E. *A comparison of forecasting methods for hotel revenue management.* International Journal of Forecasting, v. 19, n. 3, p. 401-415, 2003.

WERNER, L.; RIBEIRO, J.L.D. *Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais.* Revista Gestão & Produção, v. 10, n. 1, p. 47-67, 2003.

WINTERS, P.R. *Forecasting sales by exponentially weighted moving averages.* Management Science, v. 6, n. 3, p. 324-342, 1960.