

Previsão de taxas de falhas utilizando o Método de Box & Jenkins

Débora Morales¹ (UFPR) debora_mo2@hotmail.com

Naiara Fernanda Johnsson² (UFPR) nai_johnsson@hotmail.com

Resumo:

O presente artigo propõe a aplicação da metodologia de Box & Jenkins para redução da taxa de falha na previsão de componentes utilizados na fabricação de computadores de uma empresa na região de Curitiba. O objetivo é comparar o método de previsão utilizado pela empresa com o método de previsão proposto Box & Jenkins. Foram analisadas amostras de 30 componentes em um período de 36 meses. Como resultado final, determinou-se que a metodologia Box & Jenkins se mostrou mais eficaz e mais adequada, que a metodologia aplicada pela empresa. Com os resultados das previsões realizadas a empresa poderá optar pelo uso da metodologia porposta para o melhor planejamento e controle de seus estoques.

Palavras chave: Taxa de falhas, Metodologia Box & Jenkins, Controle de estoques.

Forecast of failure rates using the Box & Jenkins Method

Abstract

This paper proposes the application of the Box & Jenkins methodology to reduce the failure rate in the prediction of components used in the manufacture of computers of a company in the Curitiba region. The objective is to compare the forecasting method used by the company with the proposed forecast method Box & Jenkins. Thirty components samples were analyzed over a period of 36 months. As a final result, it was determined that the Box & Jenkins methodology proved to be more effective and more adequate than the methodology applied by the company. With the results of the forecasts made, the company may choose to use the methodology for better planning and control of its inventories.

Key-words: Failure Rate, Box & Jenkins Methodology, Stock Control.

1. Introdução

No ambiente corporativo algumas prioridades estratégicas são comuns. Geralmente as empresas buscam uma estrutura que permita redução de custos, aumento da satisfação dos clientes e ampliação do seu negócio.

Dentro da indústria de bens manufaturados, a componente de serviços, especialmente no setor de tecnologia, no qual, tem apresentado importância significativa. Pode ser por meio de serviços prestados que a empresa diferencie seus produtos da concorrência.

Atualmente, empresas de ramos diversificados precisam de um acompanhamento e prestação de serviços ao longo do ciclo de vida de seu produto, a fim de manter a eficácia do produto até o fim de sua garantia gerando um maior vínculo entre o fabricante e cliente.

Neste artigo foi analisado a taxa de falha de 30 componentes utilizados na montagem de computadores de uma empresa do ramo de tecnologia na região de Curitiba. Os 30 componentes estudados são os de maior demanda e grande peso na estrutura do estoque da empresa. Objetivou-se estudar o comportamento dos componentes ao longo do tempo, a fim de identificar as quantidades de falhas e prever a taxa de falha mais próxima do real,

embasando o cálculo que determina a quantidade de cada um dos 30 componentes necessários para suprir a demanda de quebra durante o período de garantia do produto final.

Neste contexto, o presente trabalho pretende apresentar uma metodologia utilizada na área de previsão de demanda por intermédio de séries temporais, conhecida como a metodologia Box & Jenkins.

2. Taxa de falha

A Taxa de falhas é definida como a frequência com que as falhas ocorrem num certo intervalo de tempo medida pelo número de ocorrências por cada hora de operação ou número de operações do componente (NETO, 2012).

De acordo com Braga (2012), a taxa de falha é definida como a relação entre o número de componentes que apresentam defeitos e o número de elementos no começo do tempo de operação multiplicado pelo tempo de operação.

Segundo Villemeur (1992), uma falha pode ser classificada conforme os itens apresentados abaixo:

- Quanto à repentinidade
 - Falha repentina: falha que não resulta em uma perda progressiva do desempenho e que não pode ser antecipada por análise prévia ou monitoramento.
 - Falha gradual: falha devido a uma gradual mudança com tempo de uma dada característica de uma entidade, que geralmente pode ser antecipada por análise prévia ou monitoramento.
- Quanto ao grau
 - Falha parcial: falha resultante do desvio das características além dos limites especificados, mas que, no entanto não causam uma completa perda das funções.
 - Falha total: falha resultante do desvio das características além dos limites especificados e que causam uma completa perda das funções.
- Quanto à repentinidade e ao grau
 - Falha catastrófica: falha que é ao mesmo tempo repentina e total.
 - Falha degradante: falha que é ao mesmo tempo parcial e gradual. Ao longo do tempo pode levar a uma falha total.

3. Séries temporais

Uma série temporal é uma coleção de observações feitas sequencialmente pelo tempo (CHATFIELD, 2016). Segundo Ribeiro e Paula, (2000), uma série temporal é definida como um conjunto de observações de uma dada variável, geralmente distribuídas de maneira equidistante no tempo, e que possuem como característica central a presença de uma dependência serial entre elas.

As técnicas de utilização de séries temporais são baseadas em modelos quantitativos que executam uma lógica utilizando operações matemáticas a fim de gerar uma previsão estatística. Esta lógica permite avaliar os dados históricos para conhecer o comportamento do sistema, a partir do pressuposto de que o mesmo é estável, extrapolando o conhecimento adquirido para o futuro (STAUDT, 2011).

De acordo com Morettin e Toloi (2006) os objetivos para analisar uma série temporal pode-se estar interessado em:

1. Investigar o mecanismo gerador da série temporal;
2. Fazer previsões de valores futuros da série, a curto ou a longo prazo;
3. Descrever apenas o comportamento da série, o que neste caso inclui a construção do gráfico, a verificação da existência de tendências, ciclos e variações sazonais, a construção de histogramas e diagramas de dispersão;
4. Procurar periodicidades relevantes nos dados;

Ainda, segundo (MORETTIN; TOLOI, 2006), as séries temporais, são analisadas sobre dois principais enfoques: no domínio temporal e no domínio das frequências. Os modelos são classificados em paramétricos, cujo, o foco será a análise no domínio do tempo, e os não paramétricos cuja análise é realizada no domínio da frequência.

3.1 Metodologia Box & Jenkins

A análise de séries temporais, segundo Box & Jenkins (1976), tem como objetivo principal a realização de previsão. Essa metodologia permite que valores futuros de uma série sejam previstos tomando por base apenas seus valores presentes e passados. Isso é feito através da correlação temporal entre os valores existentes.

De acordo com Pellegrini e Fogliatto (2001), os modelos Box & Jenkins, conhecidos por *Auto Regressive Integrated Moving Average* (ARIMA), são modelos matemáticos que visam captar o comportamento da correlação seriada, ou autocorrelação entre os valores da série temporal, aos quais são utilizados para realizar previsões futuras.

Os modelos ARIMA são uma generalização dos modelos autorregressivos de médias móveis (ARMA). A representação ARIMA (p,d,q) refere-se, respectivamente, às ordens de auto regressão, de integração e de média móvel sendo:

- p é o número de termos auto regressivos (AR)
- d é o número de diferenças
- q é o número de termos da média móvel (MA)

O procedimento padrão para utilização da metodologia de previsão ARIMA consiste nos seguintes passos, segundo Box & Jenkins (1976):

1. Realiza-se a diferenciação da série original tantas vezes quanto necessário para torná-la estacionária;
2. Identifica-se os valores p e q através da análise das funções de autocorrelação (FAC) e de autocorrelação parcial (FACP) estimadas e a estimação dos parâmetros (ϕ_i , $i = 1, \dots, p$ e θ_i , $i = 1, \dots, q$).

A análise destas funções permite a tomada de decisão acerca do número p de parâmetros autorregressivos e do número q de parâmetros de médias móveis.

3. Realizam-se as previsões, obtenção dos novos valores da série e os intervalos de confiança para as mesmas.

3.2 Ruído Branco

Segundo Bueno (2008), uma sequência ε_t é considerado um ruído branco se para cada valor da série, tem-se média zero, variância constante e autocorrelação igual à zero. A média zero é conveniência, pois seria possível especificar um ruído branco cuja média fosse diferente de zero. Entretanto, pode-se centrar em zero tal série, sem prejuízo de suas demais propriedades.

Em suma, uma sequência $\{\varepsilon_t\}$ de variáveis aleatórias é dita um ruído branco quando:

$$E\{\varepsilon_t\} = 0; \forall t$$

$$E\{\varepsilon_t^2\} = \sigma^2, \forall t$$

$$\text{Cov}\{\varepsilon_t \varepsilon_{t-j}\} = 0, \text{ para } j \neq 0$$

A representação de um ruído branco pode ser feita como $RB \sim (0, \sigma^2)$.

3.3 Modelos de Box & Jenkins

3.3.1 Modelos autorregressivo AR (p)

Segundo (MORETTIN; TOLOI, 2006) um modelo autorregressivo de ordem p , denotado por $AR(p)$ é tal que:

$$Z_t = \Phi_1 \cdot Z_{t-1} + \Phi_2 \cdot Z_{t-2} + \dots + \Phi_p \cdot Z_{t-p} + a_t$$

onde a_t é um ruído branco;

A função de autocorrelação de um processo autorregressivo é constituída de uma mistura de polinômios, exponenciais e senóides amortecidas e é infinita em extensão. Já a função de autocorrelação parcial não é nula somente para defasagens menores que p (BOX *et al.*, 2015).

3.3.2 Modelos médias móveis MA (q)

Segundo (MORETTIN; TOLOI, 2006) um modelo de médias móveis ordem q , denotado por $MA(q)$ é tal que, para um processo de média nula,

$$Z_t = \mu + a_t - \theta_1 \cdot a_{t-1} + \theta_2 \cdot a_{t-2} - \dots - \theta_q \cdot a_{t-q}$$

onde a_t é um ruído branco.

Segundo (MORETTIN; TOLOI, 2006) a FAC. de um processo $MA(q)$ se anula para defasagens maiores do que q , sendo, portanto, finita.

3.3.3 Modelos autorregressivo e de médias móveis ARMA (p, q)

(MORETTIN; TOLOI, 2006) sugerem que para muitas séries encontradas na prática, se o objetivo for um modelo com um número reduzido de parâmetros, isto é, mais parcimonioso, a inclusão de termos tanto autorregressivos quanto de médias móveis é adequada.

Portanto, um modelo deste tipo, denotado por $ARMA(p, q)$ pode ser escrito da forma:

$$Z_t = \Phi_1 \cdot Z_{t-1} + \Phi_2 \cdot Z_{t-2} + \dots + \Phi_p \cdot Z_{t-p} - \theta_1 \cdot a_{t-1} - \theta_2 \cdot a_{t-2} - \dots - \theta_q \cdot a_{t-q} + a_t$$

(MORETTIN; TOLOI, 2006), verificam que se a função de autocorrelação de um processo $ARMA(p, q)$ se comporta:

- Se $q < p$ a FAC. consiste numa mistura de exponenciais e/ou senóides amortecidas;
- Se $q \geq p$, os primeiros $q - p - 1$ não seguirão este padrão.

A função de autocorrelação parcial, por sua vez, se comporta por exponenciais e/ou senóides amortecidas (veja (BOX *et al.*, 2015)).

3.3.3 Modelos autorregressivos integrados de médias móveis ARIMA (p, 3d, q)

Os modelos discutidos até agora são apropriados para séries temporais estacionárias. Assim, para ajustar estes modelos a uma série temporal observada, é necessário remover as fontes de variação não estacionárias. Por exemplo, se a série observada for não estacionária na média, pode-se tentar remover a tendência tomando-se uma ou mais diferenças, que é uma abordagem muito utilizada em séries financeiras. Se d for um número inteiro não negativo, então uma série temporal Z_t é dita ser um processo ARIMA(p, d, q) ou um processo ARMA integrado de ordem d se uma série Z_t é não estacionária, segundo (MORETTIN; TOLOI, 2006), a série

$$W_t = Z_t - Z_{t-d}$$

é uma diferença de Z_t . O modelo ARIMA (p, d, q) é um caso especial de processo integrado no sentido de que supõe que a d -ésima diferença de uma série não estacionária pode ser representada por um modelo ARMA(p, q), estacionário.

3.4 Função de Autocorrelação (FAC)

Seja

$$\rho_k = \frac{\gamma_k}{\gamma_0}$$

Onde γ_k é a covariância de defasagem k , dada por

$$\gamma_k = E\{X_t \cdot X_{t+k}\}$$

e γ_0 é a variância. O estimador de ρ_k pode ser calculado através de

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0}$$

onde $\hat{\gamma}_k$ representa a covariância amostral na defasagem k , calculada por

$$\hat{\gamma}_k = \frac{1}{n} \sum_{t=1}^{n-k} (X_t - \bar{X}) \cdot (X_{t+k} - \bar{X})$$

e $\bar{\gamma}_0$ é a variância, a saber

$$\hat{\gamma}_0 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \hat{\sigma}_X^2$$

Outro conceito muito importante no que se refere à dependência de elementos (BOX *et al.*, 2015) propõe a função de autocorrelação parcial (FACP) de defasagem k , denotada por ϕ_{kk} , e que, segundo Morettin & Toloi (2006), mede a correlação dependente entre X_t e Z_{t-k} depois de eliminada a influência de $X_{t-1}, \dots, X_{t-k+1}$.

3.5 Função de Autocorrelação Parcial (FACP)

Segundo Morettin & Toloi (2006) a análise da autocorrelação parcial é aquela em que se deseja medir o quanto Z_t e Z_{t+k} estão relacionados, mas com os efeitos dos z 's intermediários controlados. Os coeficientes de autocorrelação parcial medem o relacionamento entre Z_t e Z_{t+k} , este coeficiente é denotado por Φ_{kk} e é estimado por $\hat{\Phi}_{kk}$ da amostra.

Seja Φ_{kj} o j -ésimo coeficiente em um processo autorregressivo de ordem k , tal que Φ_{kk} é o último coeficiente,

$$Z_t = \phi_{k1}Z_{t-1} + \phi_{k2}Z_{t-2} + \dots + \phi_{kk}Z_{t-k} + a_t$$

Para calcular a FACP para as defasagens (lags) $k=1, 2, 3, \dots$ o que se faz é ajustar sucessivamente os modelos: AR(1) obtendo-se ϕ_{11} , AR(2) obtendo-se ϕ_{22} e assim sucessivamente. Da FAC tem-se

$$\rho_j = \Phi_{k1}\rho_{j-1} + \Phi_{k2}\rho_{j-2} + \dots + \Phi_{k(k-1)}\rho_{j-k+1} + \Phi_{kk}\rho_{j-k}$$

Onde $j = 1, 2, 3, \dots, k$, que pode ser escrita na forma das equações de Yule-Walker

$$\rho_1 = \Phi_{k1}\rho_0 + \Phi_{k2}\rho_1 + \dots + \Phi_{k(k-1)}\rho_{k-2} + \Phi_{kk}\rho_{k-1} \quad j = 1$$

$$\rho_2 = \Phi_{k1}\rho_1 + \Phi_{k2}\rho_0 + \dots + \Phi_{k(k-1)}\rho_{k-3} + \Phi_{kk}\rho_{k-2} \quad j = 2$$

.....

$$\rho_k = \Phi_{k1}\rho_{k-1} + \Phi_{k2}\rho_{k-2} + \dots + \Phi_{k(k-1)}\rho_1 + \Phi_{kk}\rho_0 \quad j = k$$

Resolvido o sistema de equações tem-se os valores de Φ_{kk} para os lags $k=1, 2, 3 \dots$

3.6 Teste da Raiz do Erro quadrático médio (RMSE)

Uma medida frequentemente utilizada para estimar a qualidade de um modelo pode ser calculada utilizando

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$

Na qual n é o número de amostras, x_i é o valor fornecido pelo modelo para a i -ésima amostra e $\bar{x}$ é a média dos valores de todas as amostras.

3.7 Testes de Box-Pierce

É um teste para as autocorrelações dos resíduos estimados que, apesar de não detectar quebras

específicas no comportamento de ruído branco, podem indicar se esses valores são muito altos.

Se o modelo for apropriado, a estatística:

$$Q(K) = n(n+2) \sum_{j=1}^K \frac{\hat{r}_j^2}{n-j}$$

terá aproximadamente uma distribuição χ^2 com $k-p-q$ graus de liberdade.

3.8 Teste do periodograma acumulado dos resíduos

No teste do periodograma acumulado, compara-se o periodograma acumulado da série dos resíduos com o de um ruído branco, com o intuito de se encontrar componentes periódicos (MONTGOMERY, 1976).

4. Método de Pesquisa

O estudo apresenta observações de parque e percentual de falhas do período de 36 meses decorrentes de outubro de 2013 a setembro de 2016, dos componentes selecionados pela Empresa X para a realização do estudo. O banco de dados é constituído de observações passadas e atuais sobre parque em garantia e demanda chamados por componentes. Na análise parque em garantia é todo equipamento que está em campo e que ainda está dentro do prazo de garantia. A demanda é extraída a partir de todos os chamados abertos por autorizadas que solicitam trocas de componentes. Após a coleta de dados, foi gerada uma base e consolidada as informações, onde obtém-se a taxa de falha atual, dividindo a demanda por parque em garantia de cada um dos 30 componentes do estudo. No final dos cálculos todas as taxas foram multiplicadas por cinco mil, para garantir uma maior precisão nos dados. Para análise dos resultados foi utilizado o *software Statgraphics®*.

4.1 Metodologia da Empresa X

A empresa X utiliza o método da média das taxas de falhas de seus componentes nos três últimos meses, que foi denominado ME (método da empresa) sendo:

$$ME = \frac{V_{t-3} + V_{t-2} + V_{t-1}}{3}$$

Onde:

ME_i – Média Aritmética dos três meses

V_{t-k} – Observações, com $k = 1, 2, 3$.

Este método está baseado no conceito de média móvel, pois, a cada novo tempo, abandona-se o mais antigo e considera-se um novo dado. A desvantagem é que esse método ajusta-se lentamente a mudanças e utiliza peso igual para cada período, desconsiderando o fato de equívocos recentes possuírem um impacto maior sobre demandas futura, desconsiderando certas sazonalidades existentes ao longo do período.

4.2 Descrição para aplicação dos métodos de Box & Jenkins

Passo 1: Construir o gráfico da série e verificar se existe estacionariedade e sazonalidade.

Passo 2: Construir o gráfico do Periodograma Acumulado e verificar se existe parte sistemática para ajustar.

Passo 3: Construir os gráficos da Função de Autocorrelação e da Função de Autocorrelação Parcial.

Passo 4: Verificar quais modelos a série pode ser ajustada.

Passo 5: Escolher e ajustar os prováveis modelos ARIMA que possam ser os mais adequados.

Passo 6: Determinar a Raiz do Erro Médio Quadrático (RMSE) dos modelos propostos.

Passo 7: Analisar o teste de Box-Pierce.

Passo 8: Verificar a normalidade dos resíduos.

Passo 9: Construir o Periodograma dos Resíduos para os modelos sugeridos do(s).

Para a construção de modelos de previsão confiáveis que utilizam a metodologia Box e Jenkins é importante considerar os nove passos descritos acima (Box *et al.*, 2015).

5. Resultados

Foram analisados 30 componentes em 36 meses sendo três últimos meses deixados para teste. Por se tratar de um número grande de componentes e, conseqüentemente, de gráficos será apresentado somente o componente 15 com aplicação do método Box e Jenkins. Portanto as figuras descritas referem-se apenas para este componente.

5.1 Análise de Box & Jenkins

5.1.1 Gráfico da Série Temporal




Figura 1- Gráfico da série temporal para a componente 15.

Na Figura 1 observa-se que a série não apresenta sazonalidade, o que também pode ser analisado a não estacionaridade, sendo assim precisa de diferenciações para torna-la estacionária.

5.1.2 Periodograma da Série




Figura 2- Gráfico do periodograma para a componente 15.

Na Figura 2 o periodograma mostra que existe parte sistemática para ajustar, o que pode ser verificado pelos os valores fora dos limites.

5.1.3 Função de Autocorrelação Estimada




Figura 3 -Gráfico da função de autocorrelação estimada para a componente 15.

5.1.4 Função de Autocorrelação Parcial Estimada




Figura 4- Gráfico da função de autocorrelação parcial estimada para a componente 15.

De acordo com as Figuras 3 e 4 os gráficos de autocorrelação estimada (FAC) e autocorrelação parcial estimada (FACP), apresentam um possível modelo a ser testado o ARMA (2,2), porém foram testados mais modelos com a finalidade de exemplificar o método de Box & Jenkins.

5.1.5 Modelos analisados

Serão testados os seguintes modelos para prever a taxa de falha do Componente 15.

ARIMA (1,1,0)	ARIMA (3,2,2)	ARIMA (2,2,2)
ARIMA (1,2,0)	ARIMA(2,2,1)	ARIMA (3,2,1)
ARIMA (1,0,0)	ARIMA (2,1,2)	
ARIMA (2,2,0)	ARIMA (1,0,1)	

5.2 Escolha do melhor Modelo

5.2.1 Teste do Erro quadrático médio (RMSE)

Os resultados da tabela 1 mostram os valores do teste da Raiz do Erro Quadrático Médio (RMSE) para os modelos testados.

MODELO	RMSE	Box-Pierce p-valor
ARIMA(1,1,0)	0,4898	0,5801
ARIMA(1,2,0)	0,5761	0,0129
ARIMA(1,0,0)	0,4673	0,4064
ARIMA(2,2,0)	0,4073	0,2608
ARIMA(3,2,2)	0,4087	0,0882
ARIMA(2,2,1)	0,4019	0,2585
ARIMA(2,1,2)	0,4056	0,2690
ARIMA(1,0,1)	0,4763	0,2092
ARIMA(2,2,2)	0,3264	0,2475
ARIMA(3,2,1)	0,3965	0,2218

Fonte: (Os Autores 2017).

Tabela 1 - Testes RMSE e Box-Pierce

Observa-se que o modelo ARIMA(2,2,2) apresentou o menor RMSE dentre todos os modelos testados para o componente 15, então o próximo passo é verificar o teste de Box-Pierce para verificar se o modelo ajustado é adequado.

5.2.2 Teste de Box-Pierce

Para o teste de Box-Pierce o modelo ARIMA(2,2,2) apresentou um p-valor de 0,2475, logo com um nível de significância de 0,05, não devemos rejeitar a hipótese, assim o modelo ARIMA(2,2,2) é adequado para o comportamento da série.

5.2.3 Teste do Periodograma Acumulado




Figura 5 - Periodograma acumulado dos resíduos para o modelo ARIMA (2,2,2).

De acordo com a Figura 5 do periodograma dos resíduos para o modelo ARIMA(2,2,2), foi observado a inexistência quase total de partes sistemáticas nos resíduos a serem absorvidas, logo os resíduos estão próximos ao ruído branco.

5.3 Comparação dos métodos

Aplicando o método de Box & Jenkins o melhor modelo para a previsão de taxa de falhar para o Componente 15 é o ARIMA (2,2,2)

A previsão da taxa de falhas para o componente 15 pelo modelo ARIMA(2,2,2) para os meses de julho, agosto e setembro de 2016 foram respectivamente: 0,30; 0,28; 0,09.

A previsão para a Empresa X para o mesmo componente no mesmo período seria: 0,59; 0,44; 0,52.

Os valores observados reais no mesmo período foram: 0,26; 0,89; 0,72.

Pode-se verificar que o modelo ARIMA(2,2,2) foi capaz de fazer uma previsão mais assertiva no mês de julho sobre o comportamento da taxa de falhas para o componente 15.

A Tabela 2 apresenta um comparativo mensal e geral entre as previsões feitas pelas metodologias de Box & Jenkins e empresa X, foram analisados todos os resultados obtidos no estudo para os 30 componentes comparando às previsões realizadas pelos modelos ARIMA.

PERÍODO	ARIMA	EMPRESA
Julho	67%	33%
Agosto	59%	41%
Setembro	52%	48%
Percentual médio	59%	41%

Fonte: (Os Autores 2017).

Tabela 2- Comparação entre Box & Jenkins e Empresa X

Observa-se na Tabela 2 que o método Box & Jenkins fez previsões mais assertivas nos três períodos dos meses de estudo. Com uma média de acertos de 59% referente às previsões de Box & Jenkins em relação aos valores reais observados.

6. Conclusão

Os modelos ARIMA da metodologia Box & Jenkins obtiveram resultados significativos, capazes de fazer previsões mais assertivas quando comparado ao método utilizado na Empresa X. Se ao invés de 36 meses fossem selecionados 50, como recomendado pelos autores do método, a previsão teria um maior índice de assertividade. As previsões de Box & Jenkins tiveram uma média de acertos de 59% em relação aos valores reais nesta análise.

Podemos concluir que, embora a diferença não seja tão grande entre as previsões dos dois métodos de Box & Jenkins, se mostrou mais assertivo que o método utilizado pela empresa X.

Referências

BOX, G. E. P. & JENKINS, G.M. *Times Series Analysis, forecasting and control*, Editora Holden Day, 1976.

BOX, G. E., JENKINS, G. M., REINSEL, G. C., & LJUNG, G. M. *Time series analysis: forecasting and control*. John Wiley & Sons. 2015.

BUENO, R. L. S. *Econometria de Séries Temporais*, Editora Cengage Learning, 2008.

CHATFIELD, C. *The analysis of time series: an introduction*. CRC press, 2016.

CHAVES NETO, A. *Notas de aula de Análise Séries Temporais*, 2012.

MONTGOMERY, D.C., JOHNSON, L.A., *Forecasting and Time Series Analysis*, New York, McGraw-Hill Book Co., 1976.

MORETTIN, P; TOLOI, C. *Análise das Séries Temporais*. 2. ed. São Paulo. Editora Universidade de São Paulo, 2006.

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, novembro, 2001.

RIBEIRO; L. C.; VIEIRA P. A. *Previsão de população através dos modelos ARIMA de Box e Jenkins*, 2000 – In: Encontro Nacional de Estudos Populacionais: Universidade Federal de Minas Gerais, Caxambu, 2000. Disponível em: www.abep.nepo.unicamp.br/anais_2000.htm.

STAUDT, F. H., *Estudo de métodos de previsão de demanda com incorporação de julgamentos*. Dissertação (Mestrado). Programa de Pós-graduação em Engenharia de Produção, Universidade Federal de Santa Catarina. Santa Catarina, 2011.

VILLEMEUR, A. *Reliability, availability, maintainability and safety assessment*. Chippenham, WIL: John Wiley & Sons, 1992. v. 1: methods and techniques.