

Universidade Federal do Paraná
Setor de Ciências Exatas
Departamento de Estatística
Programa de Especialização em *Data Science* e *Big Data*

Tiago Edelmo De Liz Estacio

Planejamento de demanda de Peças de Reposição

**Curitiba
2019**

Tiago Edeldo De Liz Estacio

Planejamento de demanda de Peças de Reposição

Monografia apresentada ao Programa de Especialização em *Data Science* e *Big Data* da Universidade Federal do Paraná como requisito parcial para a obtenção do grau de especialista.

Orientador: Prof. Wagner Hugo Bonat

Curitiba
2019

Planejamento de demanda de Peças de Reposição

Spare parts Demand Planning

Tiago Edeldo De Liz Estacio

Departamento de Estatística, Universidade Federal do Paraná

Resumo

Realizar um planejamento de demanda de peça para reposição é de extrema importância para uma indústria e engloba diversas áreas e etapas. A realização de um levantamento dos dados e previsão de consumo é uma das primeiras etapas do processo. O presente estudo iniciou com a criação de um banco de dados relacional, agrupando dados de diferentes plataformas. Foram aplicadas Técnicas de Séries Temporais utilizando os modelos: ARIMA, Suavização Exponencial, Suavização Exponencial + Box-Cox, Rede Neural e Combinação de todos os modelos citados. Como critério de seleção para cada peça foi utilizado o erro absoluto médio. Para auxiliar as próximas etapas do planejamento, o banco de dados relacional e os resultados das previsões dos modelos foram incorporados em uma ferramenta de BI (*Business Intelligence*).

Palavras-chave: Planejamento de Demanda; Séries Tempoais; Banco de dados relacional

Abstract

Spare parts demand planning is extremely important for an industry and covers several areas and steps. Conducting a data search and predicting consumption is one of the first steps in the process. The present study started with the creation of a relational database, grouping data from different platforms. Temporal Series techniques were applied using the following models: ARIMA, Exponential Smoothing, Exponential Smoothing + Box-Cox, Neural Network and Combination of all the mentioned models. The mean absolute error was used as the selection criterion for each piece. To assist in the next planning steps, the relational database and model prediction results have been embedded in a BI (*Business Intelligence*) tool.

Keywords: Spare parts demand, Temporal Series, relational database

1. Introdução

Planejar bem é uma qualidade de toda empresa bem-sucedida. O planejamento de demanda é particularmente importante, porque perpassa todos os setores da empresa e tem um objetivo que também é dividido por todos eles: vender/atender com mais precisão, conhecido como S&OP – *Sales and Operations Planning*.

A falta de um bom planejamento de demanda pode levar a dois péssimos cenários, que ilustram bem a importância dele.

O primeiro é a falta do seu produto nas prateleiras, enquanto a procura por ele está alta chamado de ruptura. Nada é pior do que falhar com seu cliente, nesse caso, você terá falhado muito. Além do desgaste que isso pode gerar na relação do público com a marca, você ainda perde oportunidades de venda ou deixar de atender um caso de garantia e isso é um dos piores casos. Pois, de acordo com o artigo 18 do CDC, o fornecedor e o fabricante têm 30 dias, a partir da reclamação,

para sanar o problema do produto. Extrapolado esse prazo, você pode exigir uma das alternativas previstas no artigo 18 do CDC: um produto similar, a restituição imediata da quantia paga ou o abatimento proporcional do preço.

O segundo cenário é produzir acima da procura e acabar com um estoque parado chamado *slowmovement*. Onde além de deixar de lucrar você terá despesas extras em armazenamento e provisionamento desses produtos parados.

Nesse artigo iremos focar nas primeiras etapas do S&OP: levantamento dos dados, criando um banco de dados relacional para poder realizar a projeção de demanda utilizando técnicas de series temporais para peças de fornecimento à produtos em garantia.

2. Levantamento de Dados

O conjunto de dados utilizado no presente estudo (relacionados à peças de produtos da linha branca) estão




Figura 1: Diagrama do ciclo completo do S&OP.

armazenados em plataformas distintas e não integradas. Com o objetivo de integrar as plataformas e avaliar quais informações são relevantes para o planejamento, um banco de dados foi criado utilizando o Sistema Gerenciador de Banco de Dados Relacional (SGBDR): Microsoft SQL Server.



Figura 2: Diagrama dos Softwares Disponíveis

Um Sistema Gerenciador de Banco de Dados Relacional (SGBDR) é um software que controla o armazenamento, recuperação, exclusão, segurança e integridade dos dados em um banco de dados. Um banco de dados relacional armazena dados em tabelas. Tabelas são organizadas em colunas, e cada coluna armazena um tipo de dados (inteiro, números reais, strings de caracteres, data, etc.). Os dados de uma simples “instância” de uma tabela são armazenados como uma linha. Tabelas tipicamente possuem chaves (primárias e estrangeiras), uma ou mais colunas que unicamente identificam uma linha na tabela. Para melhorar o tempo de acesso aos dados de uma tabela, são definidos índices. Um

índice provê uma forma rápida para buscar dados em uma ou mais colunas em uma tabela, da mesma forma que o índice de um livro permite que nós encontremos uma informação específica rapidamente.

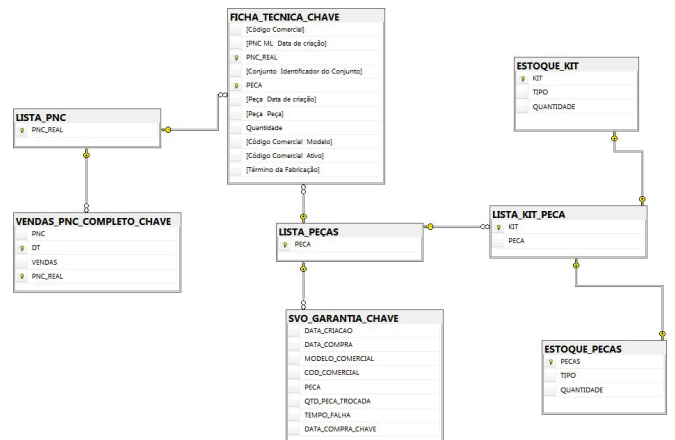


Figura 3: Exemplo de relação entre tabelas

Após a criação das tabelas (com dados de diferentes plataformas) e suas devidas interações, foi utilizado o Software R para realizar as previsões de demanda de consumo com técnicas de Séries Temporais.

3. Aplicação de técnicas de Séries Temporais

Nessa seção iremos aplicar algumas técnicas de Séries Temporais para prever a quantidade de peças que serão demandas, utilizando o software R. A tabela utilizada é composta com as seguintes informações:

- DT -> Data do pedido da peça
- COD_PECA -> Código de identificação da peça
- QTD_PECA_TROCADA -> Quantidade de peça requerida em Determinada data.

A partir do grande número de peças (8.530) e o curto histórico (1 ano e meio), foram treinados 5 modelos distintos (para cada peça). A avaliação dos modelos foi realizada através da análise da acurácia (erro absoluto médio - MAE Eq.(??)) no ambiente de treinamento.

O erro absoluto médio é calculado através da equação:

$$MAE = mean(|e_t|) \tag{1}$$

onde e representa o erro calculado no tempo t .

Os dados foram separados em treinamento e validação, onde o tamanho do conjunto de validação representa aproximadamente 20% da amostra total. O

	dt	COD_PECA	QTD_PECA_TROCADA
204697	2017-01-01	Y3001009600	0
204698	2017-02-01	Y3001009600	0
204699	2017-03-01	Y3001009600	0
204700	2017-04-01	Y3001009600	0
204701	2017-05-01	Y3001009600	1
204702	2017-06-01	Y3001009600	0
204703	2017-07-01	Y3001009600	0
204704	2017-08-01	Y3001009600	0
204705	2017-09-01	Y3001009600	0
204706	2017-10-01	Y3001009600	0
204707	2017-11-01	Y3001009600	0
204708	2017-12-01	Y3001009600	0
204709	2018-01-01	Y3001009600	0
204710	2018-02-01	Y3001009600	0
204711	2018-03-01	Y3001009600	0
204712	2018-04-01	Y3001009600	0
204713	2018-05-01	Y3001009600	0

Figura 4: Tabela base

conjunto de validação deve ser igual ou maior que o horizonte máximo de previsão necessário.



Figura 5: Diagrama de treinamento e teste

3.1. Modelos Aplicados

Os modelos testados nesse artigo são listados abaixo e encontram-se no pacote *forecast* do software R.

- **ARIMA**

Esta metodologia consiste em ajustar modelos autor-regressivos integrados de médias móveis, ARIMA(p,d,q), a um conjunto de dados.

```
1 ARIMA <- forecast(auto.arima(train, max.P= 0, max.Q
= 0, max.D= 0), h = h, level= 0.95)
```

Listing 1: Onde *train* é os dados de treinamento e *h* é quantidade de pontos que serão previstos

- **Suavização Exponencial - ETS**

Modelos de suavização são uma grande classe de métodos de previsão que se baseiam na ideia de que observações passadas contêm informações sobre o padrão da série temporal. O propósito dos métodos é distinguir um padrão de comportamento de qualquer outro ruído que possa estar contido nas observações da série e então usar esse padrão para prever valores futuros da série. Este é um esquema muito popular para produzir

uma Série Temporal suavizada. Enquanto na Média Móvel Simples as observações passadas são ponderadas igualmente, a Suavização Exponencial atribui pesos decrescentes exponencialmente quando a observação fica mais velha. Em outras palavras, observações recentes são tomadas com mais peso relativamente na previsão que as observações mais antigas.

```
1 ETS <- forecast(ets(train), h=h, level = 0.95)
```

Listing 2: Onde *train* é os dados de treinamento e *h* é quantidade de pontos que serão previstos

- **Rede Neural - NNAR**

As redes neurais artificiais são um método para solucionar problemas através da simulação do cérebro humano, inclusive em seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. São técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência.

```
1 NNAR <- forecast(nnetar(train), h=h, level = 0.95)
```

Listing 3: Onde *train* é os dados de treinamento e *h* é quantidade de pontos que serão previstos

- **Suavização Exponencial + Box-Cox - TBAS**

A transformação Box-Cox é uma das possíveis formas de contornar o problema de dados que não obedecem aos pressupostos da análise de capacidade, como por exemplo, normalidade dos dados. Nesse modelo após a transformação de Box-cox, a Suavização Exponencial é aplicada.

```
1 TBATS <- forecast(tbats(train, biasadj=TRUE), h=h)
```

Listing 4: Onde *train* é os dados de treinamento, *h* é quantidade de pontos que serão previstos e *biasadj* o controle de parâmetro para previsão (*TRUE* seria a média e *FALSE* a Mediana)

- **Combinação**

Uma maneira fácil de melhorar a precisão da previsão é usar vários métodos diferentes na mesma série temporal e calcular a média das previsões resultantes. John Bates e Clive Granger escreveram um famoso artigo (Bates & Granger, 1969), mostrando que a combinação de previsões geralmente leva a uma melhor precisão das previsões. Com essa metodologia vamos aplicar a combinação das metodologias apresentadas anteriormente.

```
1 Combination <- (ETS[["mean"]] + ARIMA[["mean"]] +
NNAR[["mean"]] + TBATS[["mean"]]) / 4
```

Listing 5: Código R do modelo de combinação

4. Resultados

Verificando os resultados das simulações dos modelos aplicados nos dados de requerimento de peças, podemos observar que ao se tratar de um histórico muito pequeno (1 ano e meio) alguns modelos não obtiveram bons resultados, mas em contrapartida alguns tiveram bons resultados. Na figura ?? podemos analisar a dispersão dos erros absolutos de cada modelo aplicado. E nas Figuras ?? e ?? podemos ver exemplos dos resultados dos modelos em algumas peças.




Figura 6: Box-Plot dos erros absolutos de cada modelo para cada peça.

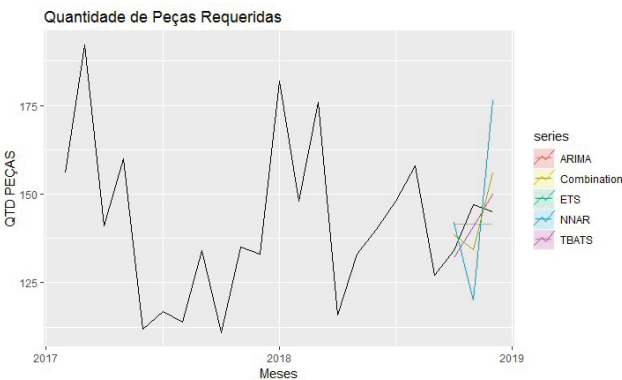


Figura 7: Nesse caso podemos observar que o modelo TBATS (Suavização Exponencial + Box-Cox) obteve o melhor ajuste.

Analisando os melhores ajustes para cada peça, concluímos que o modelo NNAR (Rede Neurais) apresentou o melhor ajuste em 37% dos dados, demonstrando que NNAR é uma boa alternativa de modelo de previsão quando o histórico de estudo é curto. Em contrapartida, esse modelo obteve as maiores variações no erro absoluto médio, demonstrado na Figura ?. O modelo ARIMA apresentou o segundo melhor ajuste (em 20% dos dados), porém seus resultados foram constantes e sem efeito de sazonalidade.

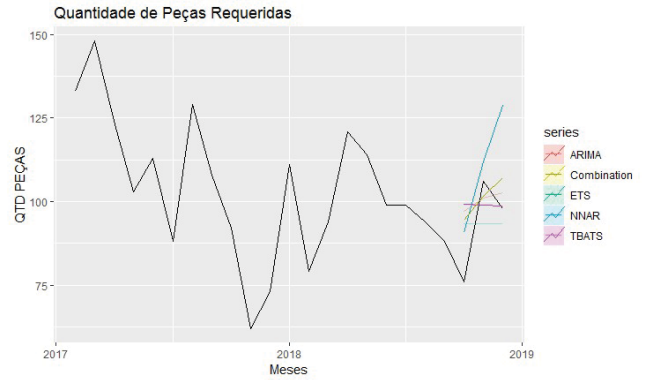


Figura 8: Nesse caso o modelo Combination (combinação das médias dos modelos) que teve o melhor ajuste.

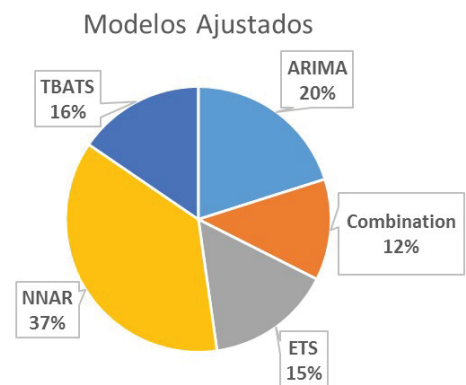


Figura 9: Distribuição dos modelos aplicados aos dados

5. Conclusão

Com a utilização de técnicas de séries temporais para a projeção de consumo de peças obtém bons resultados. Ao longo do tempo, o modelo será ajustado e com um maior histórico poderemos gerar projeções mais acuradas.

Mas somente com a previsão de consumo de peça não podemos fazer um bom planejamento, o trabalho de coleta e tratamento de dados para criação de um banco de dados relacional é de extrema importância, pois para auxiliar o planejador/analista para tomada de decisão. As relações entre as informações das tabelas facilitam o acesso e entendimento das informações relevantes para um bom planejamento de demanda: *lead time*, quantidade em estoque, tempo em estoque, lote mínimo do fabricante e etc.

A partir da criação do banco de dados relacional e das projeções realizadas, uma ferramenta de BI (*Business Intelligence*) será escolhida com o objetivo de criar uma interface amigável e de fácil acesso aos dados das distintas plataformas.

Agradecimentos

Agradeço ao Professor Wagner pelo suporte e orientações durante a realização do estudo e a minha noiva Ana Carolina pelo apoio dado no decorrer de toda especialização.

Referências

- [1] Hyndman, R. J., Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22, 679–688.
- [2] NUNES, Rizzatto., *curso de direito do consumidor*, (São Paulo: Saraiva, 2012).
- [3] R Development Core Team. (2010). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, url: <http://www.R-project.org>.
- [4] ILOS – Instituto de Logística e Supply Chain, Pesquisa: Análise do Processo de Planejamento da Demanda e SOP em Empresas Brasileiras, 2009/2010.