

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

Jhosefer da Silva

Modelos para Previsão de Demanda de Atendimento em Hospital

**Curitiba
2020**

Jhosefer da Silva

Modelos para Previsão de Demanda de Atendimento em Hospital

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. Dr. Wagner Hugo Bonat

Curitiba
2020

Modelos para Previsão de Demanda de Atendimento em Hospital

Jhosefer da Silva¹

Prof. Dr. Wagner Hugo Bonat²

Resumo

Um desenvolvimento didático para propor uma solução em relação a demanda de um hospital, prever a quantidade de atendimentos por hora no horizonte de um mês. A primeira parte do processo foi encontrar variáveis que pudessem ajudar a prever a quantidade de atendimentos que o hospital terá em seu dia, podendo assim, garantir sua efetividade. A segunda etapa consiste em testar modelos para utilização destas variáveis, sendo estes, modelos lineares generalizados, redes neurais e modelo automático de previsão existente no Facebook, chamado *Prophet*. A terceira etapa testa a acurácia. Cada um dos modelos propostos estimam a quantidade de atendimentos que serão realizados no próximo mês, os resultados estimados são comparados com os dados observados da base, com isso, para cada modelo foi calculado o erro absoluto e erro quadrático médio. A última etapa compara os resultados obtidos entre os modelos, onde todos tiveram bom desempenho e acurácia semelhante. Todos os 3 modelos podem ser considerados como possível solução para nosso estudo, porém, por utilizar menor recurso computacional e ter fácil implementação, recomendamos o modelo linear generalizado. **Palavras-chave:** Previsão de atendimentos, Redes Neurais, Prophet, Modelos lineares generalizados

Abstract

A didactic development to propose a solution in relation to the demand of a hospital, predict the number of appointments per hour over a month. The first part of the process was to find variables that could help us predict the number of appointments that the hospital will have in its day, thus being able to guarantee its effectiveness. The second step is to test models to use these variables, these being, generalized linear models, neural networks and prediction model existing on Facebook, called Prophet. The third step tests the accuracy. Each of the proposed models estimates the number of appointments that will be performed in the next month, the estimated results are compared with the observed data from the base, therefore, for each model the absolute error and mean square error were calculated. The last step compares the results obtained between the models, all of which had good performance and similar

accuracy. Any of the 3 models can be considered as a possible solution for our study, however, for using less computational resources and easy implementation, we recommend the generalized linear model.

Keywords: Forecast for appointments, Neural Network, Prophet, Generalized Linear Model

1 Introdução

Buscar meios que possam prever a quantidade de atendimentos é um assunto comum, pois influencia em custos, eficiência e no caso de um hospital, pode até influenciar em vidas. Para garantir que todos os pacientes sejam atendidos o hospital deve programar sua equipe em quantidade necessária para tal demanda. O objetivo do estudo é encontrar uma ferramenta capaz de auxiliar o hospital nesta tomada de decisão. Os dados são de contagem e serão avaliados os modelos lineares generalizados *Poisson*[1], redes neurais[2] e modelo de previsão existente no Facebook(*Prophet*) [3]. Inicialmente foi definido o período de desenvolvimento e validação da base, todos os modelos serão ajustados através da base de desenvolvimento e terão sua acurácia avaliada na base de validação.

A base de dados possui apenas registros das horas que ocorreram consultas, porém a resposta dos modelos deve atender todas as horas possíveis, devido a isso foi necessário um tratamento prévio nos dados onde adicionamos informações de horários onde também não ocorreram consultas.

Buscando melhorar a qualidade dos modelos foram criadas variáveis derivadas dos dados existentes na base, sendo estas, dia da semana e semana do mês. Na última etapa do estudo serão apresentados os resultados obtidos com cada um dos modelos e comparados com a base de validação. A métrica utilizada foi erro absoluto e erro quadrático médio. Por fim, os modelos serão avaliados buscando algo simples e efetivo para resolução do nosso problema.

2 Base de Dados

A base de dados foi disponibilizada pelo hospital e conta com 13.646 registros, onde cada registro é uma consulta realizada. As variáveis disponíveis são: data da consulta, horário da consulta e tipo de consulta.

¹Jhosefer da Silva & Big Data, jhosefersilva91@gmail.com.

²Prof. Dr. Wagner Hugo Bonat - DEST/UFPR.

2.1 Período de desenvolvimento e validação

Os dados foram armazenados de maneira simples, a cada consulta realizada era feito o registro do dia, hora e tipo de consulta. Os dados foram coletados de novembro de 2017 até setembro 2019, deste período, foram utilizados os dados de novembro-17 até agosto-19 como base de desenvolvimento de modelos e o último mês observado (setembro-19) como base de validação, todo modelo desenvolvido terá sua acurácia testada na base de validação.

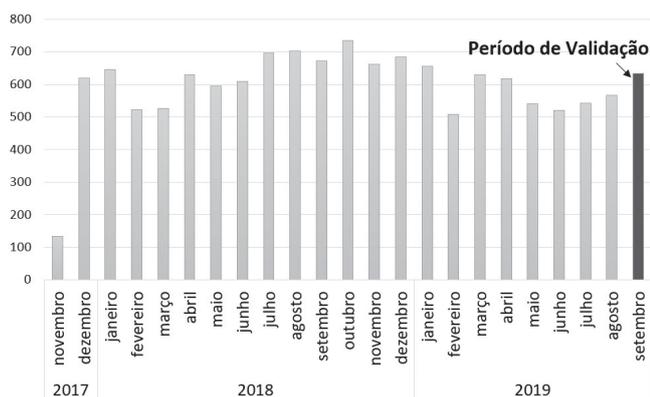


Figura 1: Quantidade de atendimentos por mês - Período de desenvolvimento e validação

Figura 1 nos mostra a volumetria da base, pelo fato de possuir poucas amostras de meses observados, descartamos a opção de sazonalidade dos meses nas análises.

2.2 Tratamentos dos dados

O objeto de estudo tem como característica ser uma variável de contagem, baseado nisso, a análise foi feita atribuindo a ele a distribuição de *Poisson*. Para trabalharmos nessa linha de pensamento alguns tratamentos foram necessários.

Os dados foram resumidos em quantidades de consultas por hora e com esse conceito também foi criado em uma linha de tempo os horários onde não houveram consultas. Este passo é essencial para que os modelos possam discriminar melhor em suas variáveis e contribuir para análises descritivas.

2.3 Criação de variáveis

Para enriquecer a base de dados e buscar informações que contribuam para o objetivo do estudo, foram criadas duas variáveis.

- ▶ Dia da Semana (Segunda-feira, Terça-feira, ...);
- ▶ Semana do mês (1ª Semana, 2ª Semana, ...).

2.4 Análise gráfica das variáveis

É de conhecimento prévio que o hospital tem seus horários e dias de picos de atendimento assim como tem

seus horários de baixa atividade. Sabendo disso, analisamos graficamente as variáveis criadas e tratadas considerando a distribuição de *Poisson* dos dados, sendo que no eixo x temos a quantidade média de clientes atendidos e no eixo y a probabilidade daquela quantidade ocorrer. A média utilizada para cálculo foi estimada através da base de dados tratada.

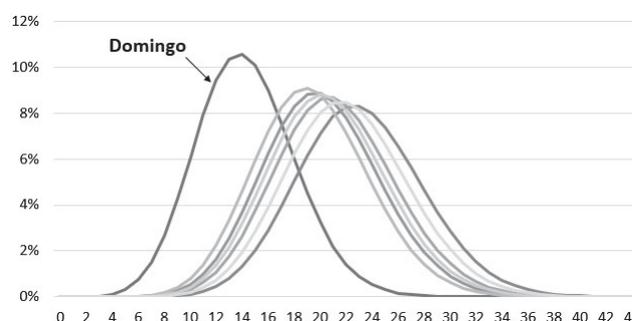


Figura 2: Probabilidade de ocorrência de consultas por dia da semana considerando a distribuição *Poisson*

Figura 2 sugere que existe diferença de quantidades de atendimentos entre os dias da semana, principalmente aos domingos, pois a curva de probabilidade de ocorrência de consultas está concentrada a esquerda, de modo que a maior chance de ocorrência de consultas sejam para quantidades menores. Por exemplo, a probabilidade de ocorrência de apenas 11 consultas no domingo é de 0,0791, enquanto nos demais dias da semana são em média 0,0073, ou seja, 10 vezes menor.

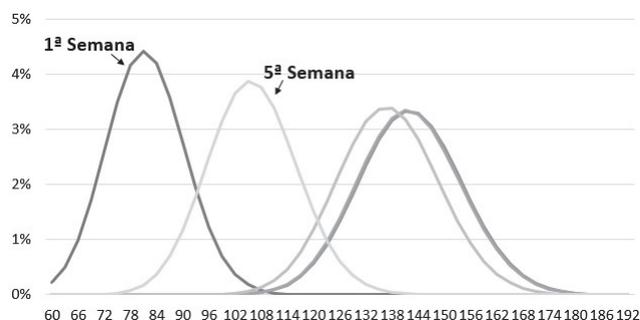


Figura 3: Probabilidade de ocorrência de consultas por semana do mês considerando a distribuição *Poisson*

Figura 3 sugere que existe diferença de quantidades de atendimentos entre as semanas do mês, principalmente na primeira e quinta semana. As curvas são bem separadas em relação as demais semanas que se concentram a direita, de modo que a maior chance de ocorrência de consultas sejam para quantidades menores. Por exemplo, a probabilidade de ocorrência de apenas 78 consultas na primeira semana é de 0,0416, enquanto na quinta semana é de 0,0008 e nas demais semanas é praticamente 0.

Figura 4 sugere que existe diferença de quantidades de atendimentos entre as horas do dia, podemos notar uma distância muito grande entre os períodos da manhã/tarde e períodos da noite/madrugada. A proba-

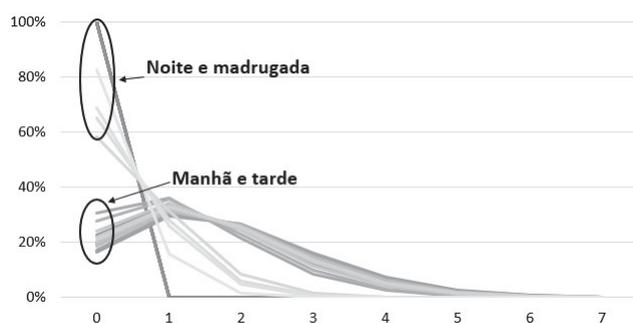


Figura 4: Probabilidade de ocorrência de consultas por hora do dia considerando a distribuição *Poisson*

bilidade de ocorrência de uma consulta ou mais é maior no período da manhã/tarde.

A análise gráfica mostrou que as variáveis influenciam na quantidade de atendimentos. O próximo passo é combinar os efeitos delas por meio da criação de modelos.

3 Metodologia

Para utilizar as informações/variáveis disponíveis na base, foram ajustados 3 tipos de modelos na tentativa de estimar a quantidade média de atendimentos que o hospital realizará por hora em cada dia do próximo mês.

O modelo 1 é o MLGs (Modelos Lineares Generalizados) o qual se trata de uma extensão dos modelos de regressão simples e múltipla. Eles possibilitam utilizar outras distribuições para os erros e uma função de ligação relacionando a média da variável resposta à combinação linear das variáveis explicativas.

Através dela é possível entender as causas de variação de um fenômeno e prever seu comportamento de acordo com as variáveis explicativas. Quando se tem apenas uma variável explicativa, a regressão é simples. Do contrário, tem-se uma regressão múltipla. [1]

Para este modelo, foi atribuída a distribuição de *Poisson*, a função de ligação *Log* e foi feita uma regressão múltipla utilizando as variáveis dia da semana, semana do mês e hora do dia.

O modelo 2 utiliza o método de redes neurais que pode ser definido como um sistemas de computação com nós interconectados que funcionam como os neurônios do cérebro humano. Usando algoritmos, elas podem reconhecer padrões escondidos e correlações em dados brutos, agrupá-los e classificá-los, e – com o tempo – aprender e melhorar continuamente.[2]

Para o treinamento da rede neural, utilizamos as variáveis dia da semana, semana do mês e hora do dia.

O modelo 3 é um método automatizado pelo time *Facebook's Core Data Science* da empresa *Facebook*, utilizado para previsão de series temporais diárias, mensais, anuais, considera sazonalidade e trata valores nulos e faltantes. [3]

4 Resultados

Os modelos foram gerados utilizando o período de desenvolvimento e foram avaliados na base de validação. O resultado foi plotado Modelo(estimado) x Validação(realizado) e tem sua acurácia medida através do erro absoluto e erro quadrático médio.

4.1 Modelo 1 - Modelos lineares generalizados

Para aplicação da metodologia foi usado o *software R*[6] com pacote *forecast*[4]. A fórmula do modelo utiliza as variáveis Hora, Dia da Semana e Semana do mês. O modelo linear generalizado final mostrou resultados satisfatórios e é capaz de estimar a quantidade média de atendimentos por hora.

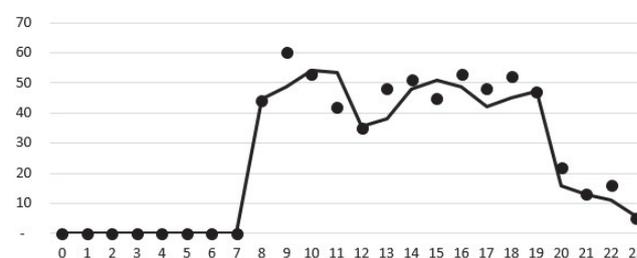


Figura 5: Número de consultas estimadas pelo Modelo Linear Generalizado x Número de consultas realizadas da base de Validação - Por hora do dia

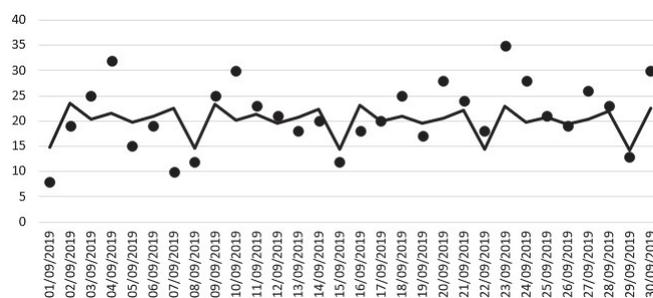


Figura 6: Número de consultas estimadas pelo Modelo Linear Generalizado x Número de consultas realizadas da base de Validação - Por dia do mês

As figuras 5 e 6 mostram o resultado do modelo 1 comparado a base de validação. Estimadas as quantidades de consultas por hora e por mês, sabemos que, quanto mais próxima a linha fica dos pontos observados, maior é a acurácia do modelo, consequentemente, menor serão os erros. O erro absoluto deste modelo foi de 414,52 e o erro quadrático médio de 635,53.

4.2 Modelo 2 - Redes neurais

Para aplicação da metodologia foi usado o *software R*[6] com pacote *NNET*[5]. O modelo de redes neurais utiliza

das mesmas variáveis do modelo linear generalizado, porém a rede neural conta com 2 parâmetros que podem influenciar no resultado, a quantidade de camadas ocultas e quantidade de iterações realizadas para aprendizado da rede. Foi gerado um modelo simples com 5 camadas ocultas e 100 iterações e comparado com um modelo mais complexo de 24 camadas e até 3000 iterações. Ao compararmos os erros dos modelos concluiu-se ambos são capazes de atender o objetivo do nosso estudo. O modelo mais complexo não tem ganho significativo que justifique sua escolha, logo, optamos por seguir com modelo mais simples.

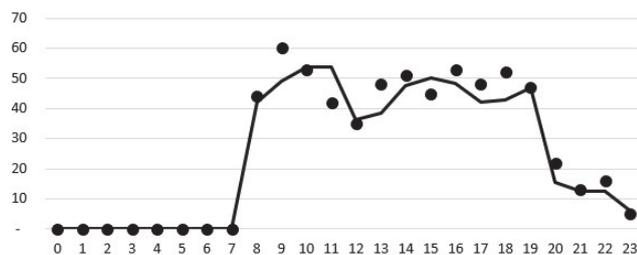


Figura 7: Número de consultas estimadas pela Rede Neural Simples x Número de consultas realizadas da base de Validação - Por hora do dia

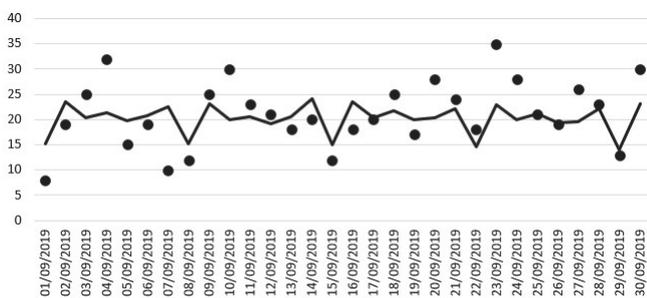


Figura 8: Número de consultas estimadas pela Rede Neural Simples x Número de consultas realizadas da base de Validação - Por dia do mês

As figuras 7 e 8 mostram o resultado do modelo 2 comparado a base de validação. Estimadas as quantidades de consultas por hora e por mês, sabemos que, quanto mais próxima a linha fica dos pontos observados, maior é a acurácia do modelo, conseqüentemente, menor serão os erros. O erro absoluto da rede neural simples é de 416,18 e o erro quadrático médio de 645,05, enquanto o erro da rede neural complexa possui 412,60 e 626,50, respectivamente.

4.3 Modelo 3 - Prophet Facebook

Para aplicação da metodologia foi usado o *software* R[6] com pacote *Prophet*[3]. O modelo *Prophet* é um modelo automático, nele apenas adicionamos a base de dados de desenvolvimento em formato de série temporal e o algoritmo cria uma projeção do período solicitado, neste caso, foi projetado o período de validação.

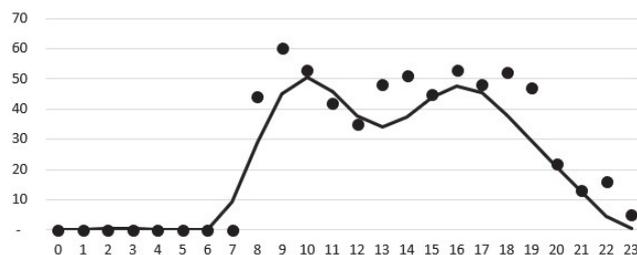


Figura 9: Número de consultas estimadas pelo modelo Prophet x Número de consultas realizadas da base de Validação - Por hora do dia

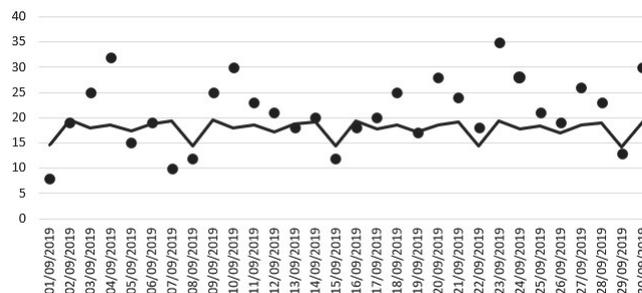


Figura 10: Número de consultas estimadas pelo modelo Prophet x Número de consultas realizadas da base de Validação - Por dia do mês

As figuras 9 e 10 mostram o resultado do modelo 3 comparado a base de validação. Estimadas as quantidades de consultas por hora e por mês, sabemos que, quanto mais próxima a linha fica dos pontos observados, maior é a acurácia do modelo, conseqüentemente, menor serão os erros. O erro absoluto desse modelo foi de 423,19 e erro quadrático médio de 680,29.

5 Discussão

Um dos objetivos foi identificar variáveis que pudessem ajudar na projeção de atendimentos do hospital. As variáveis Hora, Dia da semana e Semana do mês foram criadas e se mostraram significativas em todos modelos testados. Os resultados nos deram 3 opções válidas de ferramentas de projeção, dentre estas, a que consome menor recurso computacional e possui resultado tão satisfatório quanto aos demais é o modelo linear generalizado, pois possui fácil aplicabilidade através de sua fórmula e requer entrada de apenas 3 variáveis para estimar a quantidade de atendimentos médios na hora em questão. Por ser um modelo probabilístico o MLG permite também o cálculo da probabilidade de ocorrência de outras quantidades de consultas.

Agradecimentos

Agradeço ao Prof. Dr. Wagner Hugo Bonat por toda ajuda e orientação durante o período do curso e durante o desenvolvimento deste estudo, a meu grande amigo

Felipe Werner pelo apoio e contribuição neste artigo e a minha amada esposa Renata Lopes Ribeiro por todo apoio, incentivo e paciência em todo período da especialização.

Referências

- [1] Oliviera, Bruno *O que são modelos lineares Generalizados*, Operdata, Publicado 15 de Abril de 2019 Disponível em: <https://operdata.com.br/blog/o-que-sao-modelos-lineares-generalizados/>
- [2] *Redes Neurais, o que são e qual sua importância?*, SAS, Acessado 14 de Setembro de 2020 Disponível em: https://www.sas.com/pt_br/insights/analytics/neural-networks.html
- [3] Sean Taylor and Ben Letham (2020), *prophet: Automatic Forecasting Procedure*. R package version 0.6.1., <https://CRAN.R-project.org/package=prophet>
- [4] Hyndman R, Athanasopoulos G, Bergmeir C, Caceres G, Chhay L, O'Hara-Wild M, Petropoulos F, Razbash S, Wang E, Yasmeeen F (2020), *forecast: Forecasting functions for time series and linear models*, R package version 8.12, <http://pkg.robjhyndman.com/forecast>
- [5] Venables, W. N. and Ripley, B. D. (2002), *Modern Applied Statistics with S. Fourth Edition*. Springer, New York. ISBN 0-387-95457-0, <http://www.stats.ox.ac.uk/pub/MASS4>
- [6] 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>.