

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

Rafael Calegari

**USO DE TÉCNICAS DE PREVISÃO DE DEMANDA  
COMO FERRAMENTA DE APOIO À GESTÃO DE  
EMERGÊNCIAS HOSPITALARES COM ALTO GRAU  
DE CONGESTIONAMENTO**

Porto Alegre

2016

Rafael Calegari

**USO DE TÉCNICAS DE PREVISÃO DE DEMANDA COMO FERRAMENTA DE  
APOIO À GESTÃO DE EMERGÊNCIAS HOSPITALARES COM ALTO GRAU DE  
CONGESTIONAMENTO**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul como requisito parcial à obtenção do título de Mestre em Engenharia de Produção, modalidade Acadêmica, na área de concentração em Sistemas de Qualidade.

Orientador: Flávio Sanson Fogliatto, *Ph.D.*

Porto Alegre

2016

Rafael Calegari

**USO DE TÉCNICAS DE PREVISÃO DE DEMANDA COMO FERRAMENTA DE  
APOIO À GESTÃO DE EMERGÊNCIAS HOSPITALARES COM ALTO GRAU DE  
CONGESTIONAMENTO**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção na modalidade Acadêmica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul.

---

**Prof. Flávio Sanson Fogliatto, *Ph.D.***

Orientador PPGEP/UFRGS

---

**Prof. José Luis Duarte Ribeiro**

Coordenador PPGEP/UFRGS

**Banca Examinadora:**

Professora Márcia Elisa Soares Echeveste, Dra. (PPGEP/UFRGS)

Professora Carla Schwengber ten Caten, Dra. (PPGEP/UFRGS)

Professor Ricardo de Souza Kuchenbecker, Dr. (HCPA/UFRGS)

*Dedico este trabalho à Fernanda Rauber, à  
minha mãe Maria e ao meu pai Adelino.*

## **AGRADECIMENTOS**

Ao professor Flávio Fogliatto pelas muitas contribuições para o desenvolvimento deste trabalho.

À Sra Reni Rauber por todos os ensinamentos e pelos ótimos momentos que ficarão nas minhas lembranças para sempre.

Aos meus irmãos Renato e Eduardo pelo apoio incondicional ao longo de toda minha vida.

À professora Beatriz Schaan e à Jeruza Neyeloff do HCPA, que contribuíram muito para o desenvolvimento deste trabalho.

Aos professores e colegas do LOPP por toda contribuição, em especial ao professor Francisco Kliemann e aos colegas Filipe Lucini, Marcos Gerchman, Ana Paula Etges e Rafael Andreotti.

## RESUMO

Os serviços de emergências hospitalares (EH) desempenham um papel fundamental no sistema de saúde, servindo de porta de entrada para hospitais e fornecendo cuidados para pacientes com lesões e doenças graves. No entanto, as EH em todo o mundo sofrem com o aumento da demanda e superlotação. Múltiplos fatores convergem simultaneamente para resultar nessa superlotação, porém a otimização do gerenciamento do fluxo dos pacientes pode auxiliar na redução do problema. Nesse contexto, o tempo de permanência dos pacientes na EH (TPEH) é consolidado na literatura como indicador de qualidade do fluxo de pacientes. O tema desta dissertação é a previsão e gestão da demanda em EH com alto grau de congestionamento, que é abordado através de três artigos científicos. O objeto de estudo é o Hospital de Clínicas de Porto Alegre (HCPA). No primeiro artigo, são aplicados quatro modelos de previsão da procura por atendimento na EH, avaliando-se a influência de fatores climáticos e de calendário. O segundo artigo utiliza a técnica de regressão por mínimos quadrados parciais (PLS – *partial least squares*) para previsão de quatro indicadores relacionados ao TPEH para hospitais com alto grau de congestionamento. O tempo médio de permanência (TM) na EH resultou em um modelo preditivo com melhor ajuste, com erro médio absoluto percentual (MAPE - *mean absolute percent error*) de 5,68%. O terceiro artigo apresenta um estudo de simulação para identificação dos fatores internos do hospital que influenciam o TPEH. O número de exames de tomografias e a taxa de ocupação nas enfermarias clínicas e cirúrgicas (ECC) foram as que mais influenciaram.

Palavras-chave: Emergências hospitalares, Tempo de permanência, Previsão de demanda, Mínimos quadrados parciais.

## **ABSTRACT**

Emergency departments (ED) play a key role in the health system, serving as gateway to hospitals and providing care for patients with injuries and serious illnesses. However, EDs worldwide suffer from increased demand and overcrowding. Multiple factors simultaneously converge to result in such overcrowding, and the optimization of patient flow management can help reduce the problem. In this context, the length of stay of patients in ED (LSED) is consolidated in the literature as a patient flow quality indicator. This thesis deals with forecast and demand management in EDs with a high degree of congestion. The subject is covered in three scientific papers, all analyzing data from the Hospital de Clínicas de Porto Alegre's ED. In the first paper we apply four demand forecasting models to predict demand for service in the ED, evaluating the influence of climatic and calendar factors. The second article uses partial least squares (PLS) regression to predict four indicators related to LSED. The mean length of stay in the ED resulted in a model with the best fit, with mean percent absolute error (MAPE) of 5.68%. The third article presents a simulation study to identify the internal hospital factors influencing LSED. The number of CT exams and the occupancy rate in the clinical and surgical wards were the most influential factors.

**Keywords:** Emergency departments, Length of stay, Demand forecasting, Partial least squares regression

## LISTA DE FIGURAS

2.1 - Gráfico de dispersão da procura por atendimento na emergência do Hospital de Clínicas de Porto Alegre .....	29
2.2 - Variação da demanda na semana e no ano .....	30
3.1 - Exemplo de TPEH em função do número de dias e horários de entrada e saída .....	51
3.2 - Scree plot dos autovalores associados aos componentes principais obtidos a partir da matriz de correlações das variáveis independentes .....	53



## LISTA DE TABELAS

2.1 - Variáveis explanatórias utilizadas no MSARIMA .....	29
2.2 - Valores MAPE para cada método e para os 5 horizontes de previsão.....	31
3.1 - Médias, desvios-padrão, e valores mínimos e máximos das variáveis dependentes e independentes, estratificados conforme o intervalo de observação .....	51
3.2 - Testes de hipóteses para as médias das variáveis observadas em dias da semana e em finais de semana, com intervalo de confiança de 95% .....	52
3.3 - MAPE da previsão do TPEH pelo número de componentes principais incluídos no modelo, variância explicada e autovalores da matriz de correlação .....	53
4.1 - Média, desvio padrão, valores mínimos e máximos e significância das variáveis dependentes e independentes.....	73
4.2 - Efeito do aumento de 1,5 desvios padrão das variáveis independentes nos indicadores do TPEH .....	74

## SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>1</b>
1.1 Considerações Iniciais.....	1
1.2 Tema e Objetivos .....	3
1.3 Justificativa do Tema e dos Objetivos .....	3
1.4 Procedimentos Metodológicos .....	4
1.5 Estrutura da dissertação .....	5
1.6 Delimitações do Estudo .....	6
1.7 Referências.....	6
<b>2. ARTIGO 1: MODELOS DE PREVISÃO DE DEMANDA UTILIZANDO FATORES CLIMÁTICOS E DE CALENDÁRIO: DESEMPENHO NA PREVISÃO DA DEMANDA DE UMA EMERGÊNCIA HOSPITALAR DE ALTA COMPLEXIDADE .....</b>	<b>11</b>
2.1 Introdução .....	13
2.2 Métodos.....	15
2.2.1 Planejamento do estudo e cenário .....	15
2.2.2 Seleção dos participantes.....	15
2.2.3 Protocolo do estudo .....	16
2.2.4 Análise dos dados .....	17
2.3 Resultados .....	20
2.4 Discussão .....	21
2.5 Limitações.....	24
2.6 Conclusões .....	25
2.7 Referências.....	25
<b>3. ARTIGO 2: PREVISÃO DO TEMPO DE PERMANÊNCIA EM EMERGÊNCIAS HOSPITALARES UTILIZANDO REGRESSÃO POR MÍNIMOS QUADRADOS PARCIAIS .....</b>	<b>33</b>
3.1 Introdução .....	35
3.2 Método .....	37
3.2.1 Planejamento do estudo e cenário .....	37
3.2.2 Protocolo do estudo .....	38
3.2.3 Análise dos dados .....	40
3.2.4 Validação e avaliação do modelo .....	42
3.3 Resultados .....	43
3.4 Discussão .....	44
3.5 Limitações.....	46
3.6 Conclusões .....	47
3.7 Referências.....	47

<b>4. ARTIGO 3: IMPACTO DOS PROCESSOS INTERNOS DO HOSPITAL NO TEMPO DE PERMANÊNCIA DOS PACIENTES NA EMERGÊNCIA HOSPITALAR.....</b>	<b>54</b>
4.1 Introdução .....	56
4.2 Métodos.....	58
4.2.1 Planejamento do estudo e cenário .....	58
4.2.2 Protocolo do estudo .....	59
4.2.3 Análise dos dados .....	60
4.2.4 Validação e avaliação do modelo .....	62
4.3 Resultados .....	63
4.4 Discussão .....	65
4.5 Limitações .....	67
4.6 Conclusões .....	68
4.7 Referências.....	68
<b>5. CONSIDERAÇÕES FINAIS .....</b>	<b>75</b>
5.1 Conclusões .....	75
5.2 Sugestões para trabalhos futuros.....	76

## 1. Introdução

### 1.1 Considerações Iniciais

A Organização Mundial da Saúde (OMS) define o hospital como parte integrante da organização médica social, cuja função é proporcionar à população atenção médica completa, tanto preventiva quanto curativa, além de servir como centro de preparação e treinamento para profissionais em saúde e de cenário para pesquisas. Hospitais são estruturas complexas em que todos os processos e setores são fortemente interligados, sendo que o mau funcionamento de uma parte influencia negativamente toda a estrutura (BRASIL, 2002).

Nesse sistema complexo, os serviços de emergências hospitalares (EH) desempenham um papel fundamental, servindo de porta de entrada para hospitais e fornecendo cuidados imediatos para os pacientes. No entanto, as EH em todo o mundo sofrem com o aumento da demanda e superlotação (DERLET e RICHARDS, 2000; FORERO et al., 2010). Múltiplos fatores convergem simultaneamente para resultar nessa superlotação: o envelhecimento da população, aumento da incidência de doenças crônicas, aumento da procura por atendimento, aumento da complexidade dos cuidados, visitas não urgentes, profissionais não capacitados e escassez de leitos (LITVAK et al., 2001; FATOVICH et al., 2005; HOOT e ARONSKY, 2008; GENTILE et al., 2010; SCHMIDT et al., 2011).

O Brasil, visivelmente, possui uma escassez de ofertas de serviços hospitalares. No país existem aproximadamente 453 mil leitos, sendo 323 mil destinados para ao atendimento de pacientes do Sistema Único de Saúde (SUS), o que representa 1,63 leitos/mil habitantes (DATASUS, 2015). De acordo com a OMS, o número ideal de leitos é 3 leitos/mil habitantes, o que acarreta uma carência de 149 mil leitos no país (OMS, 2010). No Rio Grande do Sul, somente nos últimos 10 anos, houve redução de 36% no número de leitos (cerca de 3169 leitos). Esse é um problema grave, que tem gerado intervenções de órgãos governamentais para garantir a realização de procedimentos dentro de determinado período de tempo após seu diagnóstico inicial (Lei 12.732/12). Esse tipo de intervenção pode gerar impactos negativos no ambiente hospitalar, devido à obrigatoriedade da absorção dessa demanda. Como consequência, observa-se o aumento no tempo de espera dos pacientes com determinadas patologias (PLANALTO, 2014), influenciando diretamente o fluxo dos pacientes nas EH. Com todos esses fatores, o gerenciamento do fluxo de pacientes na EH é um desafio para todos os gestores de hospitais, especialmente os gestores das EH. Por essa razão, muitos

estudos abordam maneiras de auxiliar os gestores nas tomadas de decisões (RUOHONEN, 2006; KHURMA, 2008; BECK, 2009; WENG, 2011; KUO, 2012; BATARSEH, 2013; KADRI, 2014).

O elevado tempo de permanência em emergências hospitalares (TPEH) está entre as principais reclamações dos pacientes desses serviços. Definido como o tempo entre o registro do paciente na triagem até sua transferência para outra área, internação ou alta (GARDNER et al., 2007), o TPEH já é um indicador amplamente utilizado e consolidado de comparação de eficiência no fluxo dos pacientes (ASPLIN, 2006; RATHLEV et al., 2007). A presente dissertação apoia-se nesse instrumento e em modelos matemáticos, para identificar fatores, internos e externos ao hospital, que influenciam o fluxo dos pacientes na EH. Além disso, aplica modelos de previsão que podem auxiliar o planejamento e tomadas de decisões futuras. O número de pacientes que procuram atendimento está inserido nesse contexto, pois influencia diretamente a gestão interna dos pacientes. Esse número pode ser afetado por fatores externos ao hospital, como características climáticas e de calendário. Por essa razão, analisou-se a influência de fatores climáticos, como temperatura, pressão atmosférica e insolação, considerando até 7 dias anteriores. Em seguida, fatores internos do hospital foram avaliados. Número de exames, número de cirurgias, número de profissionais, taxas de ocupação e número de pacientes triados foram analisados em um modelo de regressão por mínimos quadrados parciais (PLS – *partial least squares*). Foi apresentada uma simulação na qual os valores de cada variável eram alterados individualmente, para que fosse possível identificar a influência de cada variável no TPEH, de forma independente.

O objeto de estudo dessa dissertação é a EH do Hospital de Clínicas de Porto Alegre HCPA. O HCPA é um hospital escola localizado na região sul do Brasil, integrante da rede de hospitais universitários do Ministério da Educação e vinculado academicamente à Universidade Federal do Rio Grande do Sul (UFRGS). Atualmente possui 843 leitos e aproximadamente 32000 admissões/ano. A EH opera 24 horas por dia, 7 dias por semana, ao longo de todo o ano, e trata pacientes do Sistema Único de Saúde (SUS). Recebe pacientes da cidade de Porto Alegre e da região metropolitana, totalizando uma população de aproximadamente 4 milhões. Os procedimentos de triagem seguem os critérios do Sistema de Triagem de Manchester (STM), que organiza os critérios de atendimento em cinco níveis de prioridade. As categorias são identificadas por cores, descrição do caso e tempos estimados de atendimento (TEA).

## 1.2 Tema e Objetivos

O tema dessa dissertação é previsão e gestão da demanda em EH com alto grau de congestionamento. Dois fatores em particular são de interesse: (i) o volume de pacientes que procuram atendimentos, e (ii) o fluxo de pacientes na EH, mais especificamente o TPEH. O objetivo geral do trabalho é avaliar os fatores que influenciam a procura por atendimento e o TPEH no HCPA.

Como objetivos específicos têm-se:

- Avaliar a influência de fatores climáticos e de calendário na procura por atendimento em uma EH com alto grau de congestionamento.
- Identificar os modelos de previsão que possuem maior acurácia na previsão da procura por atendimentos na EH do HCPA, para pacientes estratificados conforme o STM.
- Avaliar a utilização de quatro indicadores relacionados ao TPEH em EH com alto grau de congestionamento.
- Aplicar um modelo de previsão do TPEH baseado em regressão PLS.
- Avaliar os fatores internos do hospital que, de forma independente, influenciam no TPEH.

## 1.3 Justificativa do Tema e dos Objetivos

Já existem fortes evidências de que o congestionamento em EH influi diretamente no aumento do número de pacientes que saem sem receber atendimento (POLEVOI et al., 2005), na redução da qualidade do atendimento a pacientes com doenças graves (PINES et al., 2006), na redução da eficiência e eficácia das operações internas, na insatisfação de funcionários e pacientes (HOOT e ARONSKY, 2008; RICHARDSON e MOUNTAIN, 2009) e no aumento da mortalidade de pacientes (RICHARDSON e MOUNTAIN, 2009). Soluções comumente estudadas incluem o aumento de profissionais de saúde e de leitos hospitalares. No entanto, a identificação de fatores que contribuam para a melhoria do fluxo de pacientes, auxiliando na gestão otimizada da demanda e dos recursos disponíveis, também pode ser uma abordagem eficaz para combater esse problema (KOLKER, 2008; SCHWEIGLER et al., 2009; RABIN et al., 2012; KADRI et al., 2014). Por essas razões, justifica-se o estudo da previsão e gestão da demanda em EH com alto grau de congestionamento.

A previsão do número de pessoas que procuram atendimentos na EH pode auxiliar diretamente o gerenciamento do fluxo de pacientes. Previsões para longo horizontes podem ser úteis para reformulações estruturais e da equipe de profissionais (BATAL et al., 2001), enquanto previsões para curto prazo podem auxiliar o planejamento operacional diário dos recursos disponíveis (ABRAHAM et al., 2009). Porém, muitos estudos já demonstraram que a acurácia das previsões pode ser influenciada por fatores climáticos e de calendário (SUN et al., 2009; KAM et al., 2010; MARCILIO et al., 2013), o que indica que os métodos mais adequados variam conforme as características e a localização da EH em análise. Além disso, estratificar a previsão conforme a gravidade do paciente pode auxiliar a tomada de decisões referentes alocação de recursos internos, contribuindo positivamente para a gestão do fluxo de pacientes.

Apesar do grande número de estudos que abordam o TPEH, um número limitado cria ou aplica modelos matemáticos de previsão (GUL & GUNERI, 2015). Além da previsão, a compreensão do que influi nesse tempo de permanência é um ponto fundamental na melhoria do fluxo (KRALL et al., 2014). Questiona-se então, se determinados fatores internos, como recursos humanos disponíveis, realização de exames, cirurgias e a própria taxa de ocupação de leitos hospitalares, teriam impacto no TPEH. Muitos estudos relacionam variáveis internas do hospital com o TPEH (RATHLEV et al., 2007; GARDNER et al., 2007; WILER et al., 2012), porém apresentam TPEH muito inferiores aos apresentados em hospitais de países em desenvolvimento (MATTA & PEPE, 2008), o que pode modificar consideravelmente as análises. Sendo assim, prever o TPEH e identificar os fatores que o influenciam em hospitais com alto grau de congestionamento, ainda é um assunto a ser mais explorado.

#### **1.4 Procedimentos Metodológicos**

No presente trabalho os procedimentos metodológicos são classificados sob o ponto de vista de sua natureza, abordagem do problema, objetivos e procedimentos (SILVA & MENEZES, 2001). A pesquisa é de natureza aplicada, tendo em vista que é direcionada para uma aplicação prática que busca solucionar um problema específico. A abordagem do problema é quantitativa, pois faz uso de análises numéricas com ênfase no uso de métodos matemáticos e estatísticos. Quanto aos objetivos, trata-se de uma pesquisa explicativa, pois busca identificar fatores que contribuem para a ocorrência de eventos. Os procedimentos são caracterizados como estudo de caso.

## 1.5 Estrutura da dissertação

A dissertação está estruturada em cinco capítulos. O primeiro introduz o assunto abordado, apresenta e justifica o tema e os objetivos, explica o método de pesquisa adotado, apresenta a estrutura do trabalho, delimitações da dissertação e referências bibliográficas utilizadas.

O segundo capítulo traz o primeiro artigo, que analisa a acurácia de quatro modelos de previsão da procura por atendimento na EH do HCPA. Os modelos aplicados foram: suavização exponencial simples (SES), Holt-Winters, sazonal autoregressivo integrado de média móvel (SARIMA - *seasonal autoregressive integrated moving average*) e o SARIMA multivariado (MSARIMA - *multivariate seasonal autoregressive integrated moving average*). O MVSARIM incorpora os fatores climáticos e de calendário, para avaliar a influência desses fatores na procura por atendimento na EH. Os modelos foram aplicados considerando os horizontes de previsão de 1, 7, 14, 21 e 30 dias, estratificando os pacientes conforme a classificação da gravidade proposta pelo STM.

O terceiro capítulo apresenta o segundo artigo, em que é aplicado um modelo de previsão do TPEH baseado em regressão por mínimos quadrados parciais (PLS - *partial least squares*). Para a modelagem são utilizadas 4 variáveis dependentes e 16 variáveis independentes. O estudo testou a eficácia da previsão do TPEH a partir da análise de 4 indicadores; são eles: (i) soma total dos TPEH de todos os pacientes presentes no dia em análise (TT); (ii) soma do TPEH somente dos pacientes que entraram e saíram no mesmo dia (TTSC); (iii) TPEH médio de todos os pacientes (TM); (iv) TPEH médio somente daqueles que não permaneceram o dia completo (TMSC). As variáveis independentes são: número de exames de tomografias, ecografias e ressonâncias magnéticas; número de cirurgias eletivas no bloco, de urgência no bloco, eletivas no centro cirúrgico ambulatorial (CCA) e de urgência no CCA; quantidade de médicos, enfermeiros e técnicos em enfermagem trabalhando; taxa de ocupação do centro de terapia intensiva (CTI), taxa de ocupação nas enfermarias clínicas e cirúrgicas (ECC); número total de pacientes acolhidos no ED, pacientes classificados como emergência, muito urgente e urgente. Além disso, a acurácia do método é analisada conforme o indicador utilizado e o número de componentes principais retidos no modelo.

O quarto capítulo apresenta o terceiro artigo, que realiza simulações no modelo de previsão do TPEH baseado em regressão PLS. Para avaliar o impacto de cada variável de



forma independente no TPEH, realizou-se uma simulação no modelo de previsão. Alterou-se o valor da variável independente sob análise em 1,5 desvios-padrão, enquanto as demais variáveis eram mantidas com os valores médios, e a previsão era realizada novamente. Esse procedimento foi realizado com todas as 16 variáveis de forma independente.

O quinto capítulo apresenta as considerações finais com a conclusão do trabalho, onde os resultados são analisados em acordo com os objetivos e as delimitações do trabalho. Além disso, são sugeridos temas para futuras pesquisas.

## **1.6 Delimitações do Estudo**

Como principal limitação do estudo tem-se o fato de os dados analisados são provenientes de somente uma EH. Dessa forma, os resultados podem ser considerados somente para hospitais com características semelhantes as do presente estudo. Como fatores externos foram utilizados no estudo, para resultados mais genéricos é necessário repetir os procedimentos em hospitais localizados em regiões com características climáticas diferentes das de Porto Alegre.

## **1.7 Referências**

ABRAHAM, G.; BYRNES, G. B.; BAIN, C. A. Short-term forecasting of emergency inpatient flow. **Information Technology in Biomedicine, IEEE Transactions on**, v. 13, n. 3, p. 380-388, 2009.

ASPLIN, B. R. Measuring crowding: time for a paradigm shift. **Academic Emergency Medicine**, v. 13, n. 4, p. 459-461, 2006.

BATAL, H.; TENCH, J.; MCMILLAN, S.; ADAMS, J.; MEHLER, P. S. Predicting patient visits to an urgent care clinic using calendar variables. **Academic Emergency Medicine**, v. 8, n. 1, p. 48-53, 2001.

BATARSEH, O. G.; GOLDLUST, E. J.; DAY, T. E. SYSML for conceptual modelling and simulation for analysis: A case example of a highly granular model of an emergency department. In: **Winter simulation conference**. Winter Simulation Conference, 2013. p. 2398–2409.

BECK, E.; BALASUBRAMANIAN, H.; HENNEMAN, P. L. Resource management and process change in a simplified model of the emergency department. In: **Winter simulation conference**. Winter Simulation Conference, 2009. p. 1887-1895.

BRASIL, Ministério da Saúde. Manual Brasileiro de Acreditação Hospitalar. Secretaria de Assistência à Saúde. 3ed. Brasília: **Ministério da Saúde**, 2002.

DATASUS, 2015. <[http://cnes.datasus.gov.br/Mod\\_Ind\\_Tipo\\_Leito.asp](http://cnes.datasus.gov.br/Mod_Ind_Tipo_Leito.asp)> Acesso em 15/02/2015

DERLET, R. W.; RICHARDS, J. R. Overcrowding in the nation's emergency departments: complex causes and disturbing effects. **Annals of emergency medicine**, v. 35, n. 1, p. 63-68, 2000.

FATOVICH, D. M.; NAGREE, Y.; SPRIVULIS, P. Access block causes emergency department overcrowding and ambulance diversion in Perth, Western Australia. **Emergency Medicine Journal**, v. 22, n. 5, p. 351-354, 2005.

FORERO, R.; HILLMAN, K. M.; MCCARTHY, S.; FATOVICH, D.M.; JOSEPH, A. P.; RICHARDSON, D. B. Access block and ED overcrowding. **Emergency Medicine Australasia**, v. 22, n. 2, p. 119-135, 2010.

GARDNER, R. L.; SARKAR, U.; MASELLI, J. H.; GONZALES, R. Factors associated with longer ED lengths of stay. **The American journal of emergency medicine**, v. 25, n. 6, p. 643-650, 2007.

GENTILE, S.; VIGNALLY, P.; DURAND, A. C.; GAINOTTI, S.; SAMBUC, R.; GERBEAUX, P. Nonurgent patients in the emergency department? A French formula to prevent misuse. **BMC health services research**, v. 10, n. 1, p. 1, 2010.

GUL, M.; GUNERI, A. F. Forecasting patient length of stay in an emergency department by artificial neural networks. **Journal of Aeronautics & Space Technologies/Havacilik ve Uzay Teknolojileri Dergisi**, v. 8, n. 2, 2015.

HOOT, N. R.; ARONSKY, D. Systematic review of emergency department crowding: causes, effects, and solutions. **Annals of emergency medicine**, v. 52, n. 2, p. 126-136.e1, 2008.

KADRI, F.; HARROU, F.; CHAABANE, S.; TAHON, C. Time series modelling and forecasting of emergency department overcrowding. **Journal of medical systems**, v. 38, n. 9, p. 1-20, 2014

KAM, H. J.; SUNG, J. O.; PARK, R. W. Prediction of daily patient numbers for a regional emergency medical center using time series analysis. **Healthcare informatics research**, v. 16, n. 3, p. 158-165, 2010.

KHURMA, N.; BACIOIU, G. M.; PASEK, Z. J. Simulation-based verification of lean improvement for emergency room process. In: **Winter simulation conference**. Winter Simulation Conference, 2008. p. 1490–1499.

KOLKER, A. Process modeling of emergency department patient flow: Effect of patient length of stay on ED diversion. **Journal of Medical Systems**, v. 32, n. 5, p. 389-401, 2008.

KRALL, S. P.; CORNELIUS, A. P.; ADDISON, J. B. Hospital factors impact variation in emergency department length of stay more than physician factors. **Western Journal of Emergency Medicine**, v. 15, n. 2, p. 158, 2014.

KUO, Y. H.; LEUNG, J. M.; GRAHAM, C. A. Simulation with data scarcity: Developing a simulation model of a hospital emergency department. In: **Winter simulation conference**. Winter Simulation Conference, 2012. p. (pp. 1–12).

LITVAK, E.; LONG, M. C.; COOPER, A. B.; MCMANUS, M. L. Emergency department diversion: causes and solutions. **Academic emergency medicine: official journal of the Society for Academic Emergency Medicine**, v. 8, n. 11, p. 1108-1110, 2001.

MARCILIO, I.; HAJAT, S.; GOUVEIA, N.. Forecasting daily emergency department visits using calendar variables and ambient temperature readings. **Academic emergency medicine**, v. 20, n. 8, p. 769-777, 2013.

MATTA, I. E. A. D.; PEPE, V. L. E. Evaluation of emergency hospital services in the state of Rio de Janeiro. **Ciência & Saúde Coletiva**, v. 13, n. 5, p. 1637-1648, 2008.

OMS, Organização Mundial da Saúde. Financiamento dos Sistemas de Saúde: o caminho para a cobertura universal. **Relatório Mundial da Saúde – Comunidade dos Países de Língua Portuguesa**, 2010. Disponível em: <[http://www.who.int/whr/2010/whr10\\_pt.pdf](http://www.who.int/whr/2010/whr10_pt.pdf)> Acesso em: 15/02/2015

PINES, J. M.; HOLLANDER, J. E.; LOCALIO, A. R.; METLAY, J. P. The association between emergency department crowding and hospital performance on antibiotic timing for pneumonia and percutaneous intervention for myocardial infarction. **Acad Emerg Med**, v. 13, n. 8, p. 873-878, 2006.

PLANALTO, 2014. Disponível em: [www.planalto.gov.br/ccivil\\_03/ato2011-2014/2012/lei/112732.htm](http://www.planalto.gov.br/ccivil_03/ato2011-2014/2012/lei/112732.htm) Acesso em: 15/01/2016.

POLEVOI, S. K.; QUINN, J. V.; KRAMER, N. R. Factors associated with patients who leave without being seen. In: **Presented at the SAEM annual meeting**. 2004.

RABIN, E.; KOCHER, K.; MCCLELLAND, M.; PINES, J.; HWANG, U.; RATHLEV, N.; ASPLIN, B.; TRUEGER, N. S.; WEBER, E. Solutions to emergency department ‘boarding’ and crowding are underused and may need to be legislated. **Health Affairs**, v. 31, n. 8, p. 1757-1766, 2012.

RATHLEV, N. K.; CHESSARE, J.; OLSHAKER, J.; OBENDORFER, D.; MEHTA, S. D.; ROTHENHAUS, T.; CRESPO, S.; MAGAURAN, B.; DAVIDSON, K.; SHEMIN, R.; LEWIS, K.; BECKER, J. M.; FISHER, L.; GUY, L.; COOPER, A.; LITVAK, E. Time series analysis of variables associated with daily mean emergency department length of stay. **Annals of emergency medicine**, v. 49, n. 3, p. 265-271, 2007.

RICHARDSON, D. B.; MOUNTAIN, D. Myths versus facts in emergency department overcrowding and hospital access block. **Medical Journal of Australia**, v. 190, n. 7, p. 369, 2009.

RUOHONEN, T.; NEITTAANMAKI, P.; TEITTINEN, J. Simulation model for improving the operation of the emergency department of special health care. In: **Winter simulation conference**. Winter Simulation Conference 2006. p. 453–458

SCHMIDT, M. I.; DUNCAN, B. B.; SILVA, G. A.; MENEZES, A. M.; MONTEIRO, C. A.; BARRETO, S. M.; CHOR, D.; MENEZES, P. R. Chronic non-communicable diseases in Brazil: burden and current challenges. **The Lancet**, v. 377, n. 9781, p. 1949-1961, 2011.

SCHWEIGLER, L. M.; DESMOND, J. S.; MCCARTHY, M. L.; BUKOWSKI, K. J.; IONIDES, E. L.; YOUNGER, J. G. Forecasting models of emergency department crowding. **Academic Emergency Medicine**, v. 16, n. 4, p. 301-308, 2009.

SILVA, E. L.; MENEZES, E.M. **Metodologia da Pesquisa e Elaboração de Dissertação**. Florianópolis: UFSC, 2001.

SUN, Y.; HENG, B.; SEOW, Y.; SEOW, E. Forecasting daily attendances at an emergency department to aid resource planning. **BMC emergency medicine**, v. 9, n. 1, p. 1, 2009.

WENG, S. J.; CHENG, B. C.; KWONG, S. T.; WANG, L. M.; CHANG, C. Y. Simulation optimization for emergency department resources allocation. In: **Winter simulation conference**. Winter Simulation Conference 2006. p. 1231–1238.

WILER, J. L.; HANDEL, D. A.; GINDE A. A.; ARONSKY, D.; GENES, N. G.; HACKMAN, J. L.; HILTON, J. A.; HWANG, U.; KAMALI, M.; PINES, J. M.; POWELL, E.; SATTARIAN, M.; FU, R. Predictors of patient length of stay in 9 emergency departments. **The American journal of emergency medicine**, v. 30, n. 9, p. 1860-1864, 2012.

**2. Artigo 1: Modelos de previsão de demanda utilizando fatores climáticos e de calendário: desempenho na previsão da demanda de uma emergência hospitalar de alta complexidade**

Rafael Calegari<sup>1</sup>, Flavio S. Fogliatto<sup>1</sup>, Filipe R. Lucini<sup>1</sup>, Jeruza Neyeloff<sup>2</sup>,

Beatriz D. Schaan<sup>2</sup>

<sup>1</sup>Departamento de Engenharia de Produção, Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil;

<sup>2</sup>Divisão de Endocrinologia, Hospital de Clínicas de Porto Alegre/Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil;

## Resumo

**Objetivos:** Este estudo teve como objetivo analisar o desempenho de quatro modelos de previsão em prever a procura por atendimento médico em uma emergência hospitalar (EH) que lida com casos de alta complexidade, testando a influência de fatores climáticos e de calendário no comportamento da demanda.

**Métodos:** O estudo testou diferentes modelos matemáticos para prever a procura por atendimento na EH do Hospital de Clínicas de Porto Alegre (HCPA), que é um hospital escola localizado no sul do Brasil. Dados diários utilizados foram de 01 de janeiro de 2013, a 31 de maio de 2015. O banco de dados foi dividido em dois períodos, 26 meses de treino do modelo e 3 meses para teste. A precisão do modelo foi avaliada utilizando o erro absoluto médio percentual (MAPE – *mean absolute percentage error*), considerando horizontes de previsão de 1, 7, 14, 21 e 30 dias. A série temporal da demanda foi estratificada de acordo com a classificação do paciente, utilizando os critérios do Sistema de Triagem de Manchester (STM). Os modelos testados foram: suavização exponencial sazonal simples (SS); sazonal multiplicativo de Holt-Winters (SMHW); autoregressivo sazonal integrado de média móvel (SARIMA - *seasonal autoregressive integrated moving average*); e multivariado autoregressivo integrado de média móvel (MSARIMA - *multivariate seasonal autoregressive integrated moving average*). O modelo MSARIMA foi testado incorporando fatores climáticos e de calendário como variáveis independentes

**Resultados:** Durante o intervalo de tempo analisado neste estudo, 57128 pacientes procuraram atendimento médico na EH, sendo 51046 durante os 755 dias de treino, e 6.082 durante os 90 dias do período de teste. Em média, 68 pacientes por dia procuraram atendimento médico, variando de 26 a 119. Os dados mostraram diferenças estatisticamente significativas entre os dias de semana e finais de semana, mas não houve diferenças mensais significativas na demanda ao longo do ano. Os desempenhos dos modelos variaram de acordo com a classificação do paciente, sendo o SS a melhor escolha quando todos os pacientes foram considerados, e o SARIMA foi o mais preciso para a modelagem das demandas dos pacientes muito urgentes (MU) e urgentes (U). Os modelos SARIMA que consideram os fatores climáticos não melhoraram o desempenho dos modelos SARIMA, independente da classificação do paciente.

**Conclusões:** Nosso estudo confirma que a demanda diária da procura por atendimento na EH é caracterizado por padrões sazonais semanais. Além disso, indica que os modelos de previsão baseados puramente nas séries temporais podem ser usados para fornecer previsões precisas para a procura por atendimento em EH de alta complexidade, especialmente previsões de curto prazo. As precisões das previsões dependem do modelo escolhido, do horizonte de previsão e a classificação no STM.

## 2.1 Introdução

Os serviços de emergências hospitalares (EH) desempenham um papel fundamental no sistema de saúde, servindo de porta de entrada para hospitais e fornecendo cuidados para pacientes com lesões e doenças graves. No entanto, as EH em todo o mundo sofrem com o aumento da demanda e superlotação (DERLET & RICHARDS, 2000; FORERO et al., 2010). Múltiplos fatores convergem simultaneamente para resultar na superlotação das EH: o envelhecimento da população, aumento da incidência de doenças crônicas, aumento da procura por atendimento, aumento da complexidade dos cuidados, visitas não urgentes, profissionais não capacitados e escassez de leitos (SCHMIDT et al., 2011; FATOVICH et al., 2005; HOOT & ARONSKY, 2008; LITVAK et al., 2001; GENTILE et al., 2010). É importante ressaltar que o congestionamento nas EH tem implicações sobre a qualidade do atendimento oferecido aos pacientes, sobre a eficiência e eficácia das operações internas e na satisfação de funcionários e pacientes (RICHARDSON & MOUNTAIN, 2009; HOOT e ARONSKY, 2008). Soluções comumente estudadas para a superlotação incluem o aumento de profissionais de saúde e de leitos hospitalares; no entanto, a melhoria do fluxo de pacientes com a gestão otimizada dos recursos disponíveis também pode ser uma abordagem eficaz para combater o problema (KOLKER, 2008; RABIN et al., 2012; KADRI et al., 2014; SCHWEIGLER et al., 2009).

Nesse contexto, a previsão da procura pelos serviços de EH surge como uma ferramenta poderosa para apoiar decisões de planejamento dos recursos disponíveis (DAVIDSON et al., 2006; KADRI et al., 2014). Por exemplo, previsões de demanda de longo prazo podem ser utilizadas para planejamento de expansões de infraestrutura e equipes de profissionais (BATAL et al., 2001), enquanto as previsões de curto prazo podem contribuir com o planejamento operacional dos recursos disponíveis em uma base diária (ABRAHAM et



al., 2009). Técnicas de previsão são amplamente utilizadas nas áreas de engenharia, estatística, economia, porém bem menos frequentes em aplicações da área da saúde (JONES et al., 2008). A utilização de modelos de previsão para estimar a demanda por serviços de EH pode melhorar a qualidade do atendimento oferecido aos pacientes (BOYLE et al., 2012; KADRI et al., 2014). Os gerentes das EH podem, por exemplo, identificar o dia da semana com maior demanda e alinhar os materiais e recursos humanos para atingir melhores níveis de atendimento (ROTSTEIN et al., 1997; MARCILIO et al., 2013). Quanto maior o poder de predição do modelo de previsão dos pacientes que procuram atendimento na EH, melhor será a avaliação dos fatores que influenciam essa demanda (HOOT & ARONSKY, 2008; MARCILIO et al., 2013).

Estudos anteriores demonstram que os modelos de previsão da procura por atendimento em EH podem ser melhorados com a inclusão de fatores de calendário, como o dia da semana e do mês, e a proximidade de feriados (ROTSTEIN et al., 1997; SUN et al., 2009; BOYLE et al., 2012; MARCILIO et al., 2013), além de variáveis climáticas (SUN et al., 2009; KAM et al., 2010; MARCILIO et al., 2013); outros estudos, no entanto, demonstram o oposto (ZIBNERS et al., 2006; JONES et al., 2008). Uma explicação para isso é o fato de que as EH analisadas possuem características distintas, como localização e tipos de atendimentos e tipos de atendimentos realizados. O efeito de fatores climáticos, por exemplo, é dependente da localização geográfica do EH da qual os dados foram coletados. Dessa forma, é aconselhável sempre avaliar a influência dessas potenciais variáveis explicativas no desenvolvimento de um modelo de previsão para EH (MARCILIO et al., 2013).

Neste artigo nós avaliamos o desempenho de quatro modelos de previsão de demanda na predição da procura por atendimento médico em uma EH de um hospital universitário. Os três primeiros modelos avaliados em nosso estudo utilizam como dados de

entrada unicamente a série temporal de demandas passadas, enquanto o último modelo avalia os benefícios da inclusão de fatores climáticos e de calendário. Cinco horizontes de previsão foram utilizados: 1, 7, 14, 21 e 30 dias. Em oposição a outros estudos que investigam a utilização de técnicas de previsão para prever a demanda em EH (JONES et al., 2008; KAM et al., 2010; WAGON et al., 2009), nós analisamos dados de uma EH que só fornece cuidados a casos de alta complexidade. Além disso, pelas nossas pesquisas, nosso estudo inova ao estratificar a série temporal de acordo com a classificação do paciente, usando do Sistema de Triage de Manchester (STM).

## **2.2 Métodos**

### **2.2.1 Planejamento do estudo e cenário**

Este é um estudo retrospectivo que utiliza dados históricos da procura por atendimento médico em uma EH para desenvolver e comparar modelos de previsão capazes de prever demandas futuras. O estudo foi realizado no Hospital de Clínicas de Porto Alegre (HCPA), que é um hospital de escola localizado no sul do Brasil. A Comissão de Ética do HCPA aprovou o estudo e os autores cumpriram as recomendações da Declaração de Helsinki. Os dados de entrada foram as somas diárias de pacientes que receberam atendimento na EH, classificados em categorias de acordo com a STM. Os dados foram extraídos do sistema de gestão do hospital e os dados pessoais dos pacientes foram preservados.

### **2.2.2 Seleção dos participantes**

O estudo foi realizado na EH do HCPA. A emergência funciona 24 horas por dia, 7 dias por semana, durante todo o ano. Recebe pacientes da cidade de Porto Alegre e região

metropolitana, totalizando uma população de aproximadamente 4 milhões. Os dados diários dos pacientes admitidos na EH compreenderam o período entre 1 de janeiro de 2013, até 31 de Maio, 2015, incluindo todos os pacientes tratados entre as 00:00 e as 24:00 horas. Nesse intervalo foram atendidas 58430 pessoas.

Os dados meteorológicos históricos foram obtidos junto ao Instituto Nacional de Meteorologia (INMET), que monitora as condições meteorológicas 24 horas por dia durante todo o ano. Os métodos de coleta de dados utilizados pelo INMET estão em conformidade com os padrões internacionais definidos pela Organização Mundial de Meteorologia.

### **2.2.3 Protocolo do estudo**

A classificação dos pacientes, definida na triagem, segue os critérios do Sistema de Triagem de Manchester (STM) (MACKWAY-JONES, 1997). Este sistema organiza os critérios de atendimento em cinco níveis de prioridade. As categorias são identificadas por cores, descrição do caso e tempos estimados de atendimento (TEA); são elas: (i) vermelho – emergência (EM), necessita atendimento imediato, TEA = 0 minutos; (ii) laranja – muito urgente (MU), necessita atendimento com urgência, TEA  $\leq$  10 minutos; (iii) amarelo – urgente (U), paciente possui condições clínicas para aguardar atendimento, TEA  $\leq$  60 minutos; (iv) verde – pouco urgente (PU), paciente pode ser direcionado para o serviço ambulatorial, TEA  $\leq$  120 minutos; (v) azul – não urgente (NU), paciente deve ser direcionado para o serviço ambulatorial, TEA  $\leq$  240 minutos; e (vi) branco – não classificado. Como 96% dos pacientes são classificados como EM, MU e U, apenas estes foram incluídos na análise.

O banco de dados com histórico da demanda da EH foi dividido em dois períodos, um para treino e outro para teste. O primeiro período, de 1 de Janeiro de 2013 a 2 de março de 2015, foi utilizado para o ajuste do modelo aos dados (período de treino). O segundo período,

de 03 de março de 2015, a 31 de Maio, 2015, foi utilizado para a validação do modelo e para verificação do poder de predição (período de teste). Aproximadamente 94% dos pacientes triados na EH nos dois períodos foram classificados como MU ou U. Analisamos série composta por pacientes de todas as categorias, além de séries individuais contendo apenas os pacientes em categorias MU ou U.

O período de teste foi dividido em três intervalos de 30 dias: (i) 03/03/15 a 01/04/15, (ii) 02/04/15 a 01/05/15, e (iii) 02/05/15 e 31/05/15. O poder de predição dos modelos foi avaliado considerando horizontes de previsão de 1, 7, 14, 21 e 30 dias. Os modelos de previsão tiveram sua precisão verificada inicialmente para o primeiro intervalo de 30 dias. Em seguida o primeiro intervalo foi adicionado ao período de treino, os modelos foram recalibrados considerando os novos dados, e a precisão foi verificada para o segundo intervalo. O mesmo procedimento foi repetido ao testar o terceiro intervalo. A ideia foi atualizar continuamente o conjunto de treinamento com valores de demanda mais recentes, simulando o que acontece na prática.

#### **2.2.4 Análise dos dados**

Considerando que a superioridade de um determinado modelo de previsão sobre os outros depende dos dados em análise (DE GOOIJER & HYNDMAN, 2006; ARMSTRONG & FIELS, 2006), optou-se por avaliar o desempenho de vários modelos, e tentar identificar variáveis explicativas que poderiam influenciar a procura por atendimento na EH. Nós avaliamos o desempenho de quatro modelos de previsão baseados puramente na análise da série temporal; são elas: suavização sazonal simples (SS), sazonal multiplicativa de Holt-Winters (SMHW), sazonal autoregressivo integrado de média móvel (SARIMA), e multivariado sazonal autoregressivo integrado de média móvel (SARIMA). O modelo

MSARIMA foi testado incorporando fatores climáticos e de calendário como variáveis independentes, mostrados na Tabela 1. Todas as análises foram realizadas com o PASW Statistics 18 e Minitab 14.

O primeiro e segundo métodos testados são baseados em coeficientes de suavização exponencial. Tais modelos são capazes de capturar variações sistemáticas na série temporal ocasionadas por sazonalidade e/ou tendência, bem como mudanças bruscas no padrão de demanda, que são comuns em dados de EH (JONES et al., 2008). Neste estudo, os modelos que melhor se ajustaram aos dados foram a suavização sazonal simples (SS) e o sazonal multiplicativo de Holt-Winters (SMHW). SMHW apresenta duas variações: o modelo aditivo é preferido quando as variações sazonais são constantes ao longo da série, enquanto o modelo multiplicativo é preferido quando as variações sazonais estão mudando proporcionalmente ao nível de série (CHAMPION et al, 2007; WINTERS, de 1960; KOEHLER et al., 2001). Em nosso trabalho a forma multiplicativa demonstrou um melhor ajuste aos dados, com erros menores de previsão.

O terceiro método avaliado foi o SARIMA que é uma extensão do tradicional modelo ARIMA (autoregressivo integrado de média móvel), porém com a adição de componentes sazonais. O modelo capta o comportamento da demanda utilizando dados históricos da série temporal, sendo o método mais utilizado em previsões relacionadas à área da saúde (MARCILIO et al., 2013;. KAM et al, 2010; WARGON et al., 2010). O modelo SARIMA é descrita por sete parâmetros:  $(p, d, q) (P, D, Q)_s$ , em que  $p$  representa o fator autoregressivo (AR),  $d$  representa a ordem de diferenciação requerida para reduzir dados não estacionários (I), e o  $q$  representa a média móvel dos erros (MA). Os parâmetros de  $P$ ,  $D$  e  $Q$  são análogos aos  $p$ ,  $d$  e  $q$ , no entanto descrevem a porção sazonal do modelo. Finalmente,  $s$  representa ordem da sazonalidade dos dados (BOX et al., 1994). A definição dos melhores

valores para os parâmetros do modelo podem ser avaliados através função de autocorrelação (FAC) e a função de autocorrelação parcial (FACP). Os modelos que apresentaram o melhor ajuste para o período de teste da série temporal da procura por atendimento na EH foram:  $(1,0,4) (0,1,1)_7$ , quando todos os pacientes foram considerados,  $(0,0,4) (1,0,1)_7$  considerando apenas os pacientes categoria MU, e  $(1,0,2) (1,0,1)_7$  considerando apenas os pacientes categoria U.

Uma extensão do SARIMA, o modelo MSARIMA, também foi avaliado para prever a demanda da procura por atendimento na EH. O MSARIMA incorpora variáveis independentes (explicativas) ao modelo SARIMA, em busca de uma melhor caracterização da série de tempo de demanda (SUN et al., 2009; KAM et al., 2010). Em nosso estudo a demanda da EH do HCPA foi utilizada como variável dependente, e os fatores climáticos e de calendário como variáveis independentes. Além das variáveis climáticas apresentadas na Tabela 1, foi testada a influência dessas mesmas variáveis com a defasagem de 1 a 7 dias. Assim, um total de 64 variáveis climáticas e 2 variáveis de calendário foram testadas como variáveis independentes no modelo MSARIMA; apenas aqueles que apresentam valores de  $p \leq 0,05$  foram mantidas.

A precisão dos modelos de previsão foi medida através da comparação entre os valores reais e previstos durante o período de teste. Para isso, foi calculado o erro médio absoluto percentual (MAPE - *mean absolute prediction error*) para cada horizonte de previsão (1, 7, 14, 21 e 30 dias). Sendo uma medida que independe da escala, o MAPE permite a comparação direta dos resultados de diferentes modelos aplicados a diferentes séries temporais. A estatística representa a média das diferenças absolutas entre os valores previstos e os observados, apresentado de forma percentual; um valor pequeno de MAPE indica um modelo bem ajustado aos dados. Considera-se uma série de  $m$  valores previstos  $(\hat{y}_1, \hat{y}_2, \dots)$ .

., $\hat{y}_m$ ) e os valores observados correspondentes ( $y_1, y_2, \dots, y_m$ ); a estatística MAPE é calculado como se segue:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (1)$$

### 2.3 Resultados

Durante o intervalo considerado neste estudo 57128 pacientes procuraram atendimento médico na EH do HCPA, sendo 51046 durante os 755 dias que compreendem o período de treino, e 6082 durante os 90 dias que compreendem o período de teste. Em média, 68 pacientes procuraram atendimento médico por dia, variando entre 26 e 119. Durante o mesmo intervalo a temperatura média foi de 21,08°C, variando de 0°C a 40,6°C, com uma gama média diária de 9,68°C.

O gráfico de dispersão da demanda diária de atendimento médico na EH (Figura 1) mostra uma mudança no nível de série por volta do dia 165 (14 de Julho de 2013). Essa data corresponde ao início de um novo programa de triagem chamado "paciente certo no lugar certo", que direciona os pacientes não urgentes para unidades de cuidados primários. Depois que o novo programa foi adotado de forma consistente a demanda permaneceu estacionária, sem tendências visíveis.

A Figura 2 apresenta as variações da demanda durante a semana (painel superior) e o ano (painel inferior) na forma de *box-plots*. ANOVA *one-way* foi utilizada para detectar as diferenças entre os dias de semana e meses do ano, obtendo-se os resultados na Figura 2. A demanda possui um pico na segunda-feira, seguido por diminuição até a quarta-feira; na quinta-feira ele sobe novamente, diminuindo progressivamente até o domingo. No entanto,

diferenças estatisticamente significativas só foram constatadas entre os dias de semana e finais de semana.

Para analisar as variações da procura por atendimento na EH ao longo do ano (painel superior) utilizou-se os dados a partir de agosto de 2013, quando a série estabiliza após a introdução do programa "paciente certo no cuidado certo". Foi removido da análise o mês de Outubro de 2014, quando uma manutenção foi realizada no sistema de ar condicionado do departamento o que gerou uma redução atípica na demanda. Não houve diferenças significativas durante os meses, exceto para outubro, atribuindo isso ao fato de apenas 2013 ter sido utilizado para analisar este mês. Avaliou-se ainda a diferença entre a procura por atendimento em dias de feriados e dias normais; não foi encontrada diferença significativa.

A Tabela 2 apresenta o valor MAPE para cada modelo, considerando-se todos os pacientes (total), e os classificados como muito urgente (MU) e urgentes (U), para os 5 horizontes de previsão (1, 7, 14, 21 e 30 dias). Em geral, quanto mais curto o horizonte mais precisa a previsão. O poder de predição dos modelos variou de acordo com a classificação do paciente, sendo o SS a melhor escolha quando todos os pacientes foram examinados, e o SARIMA foi o mais preciso para modelar demandas de pacientes MU e U. O modelo MSARIMA, que incorporou os fatores climáticos, não melhorou o desempenho dos modelos SARIMA, independente da classificação dos pacientes. O apêndice I apresenta os  $p$ -valores para todos os fatores climáticos incluídos nos modelos, considerando as defasagens de até 7 dias para todos os fatores.

## 2.4 Discussão

Neste estudo nós avaliamos o desempenho de 4 modelos de previsão da procura por atendimento médico em uma EH, verificando a influência de fatores climáticos e de



calendário no comportamento da demanda. De acordo com nossas pesquisas, nosso estudo inova ao estratificar a série temporal de acordo com a classificação do paciente, conforme a STM.

No que diz respeito à precisão do modelo, o SS produziu os menores valores MAPE, independente do horizonte de previsão escolhido, quando todos os pacientes foram considerados. Para um horizonte de 1 dia o SS produziu um MAPE de 2,91%, considerado muito bom quando comparado com os resultados em Jones et al. (2008); para os outros horizontes investigados o modelo produziu um MAPE média de 11%, o que está alinhado com os resultados descritos em trabalhos semelhantes (JONES et al., 2008; MARCILIO et al., 2013). Apesar da sua complexidade, os modelos ARIMA apresentaram o pior desempenho nas previsões da demanda da EH, quando todos os pacientes foram considerados. Como relatado por Marcilio et al. (2013), Tandberg & Qualls (1994), e Jones et al. (2002), dependendo das características da série temporal analisada modelos mais simples podem gerar resultados mais consistentes do que modelos mais complexos.

Como esperado, os modelos de previsão da procura por atendimento na EH de pacientes classificados como MU e U obtiveram valores MAPE maiores, pois possuem menor número de pacientes e maiores variabilidades. Para essas categorias o modelo com o melhor desempenho foi o SARIMA, exceto para a previsão dos pacientes classificados como UM para o horizonte de previsão de 7 dias; nesse caso, SHWM produziu o menor erro (ver Tabela 2). Para o horizonte de previsão de 1 dia, obtivemos valor MAPE de 7,19% para os pacientes MU, e 3,98% para os pacientes U, que são consideradas aceitáveis e úteis para apoiar as decisões gerenciais da EH. Para horizontes de previsão maiores (7 a 30 dias) os valores MAPE foram maiores, variando de 16,82% a 17,21% para os pacientes MU, e 12,79% a 15,21% para os pacientes U. Considerando que esses pacientes são os que demandam maiores

recursos ED e mais frequente requerem leitos, focar as análises nessas categorias de pacientes, como feito aqui, é extremamente relevante para tomadas de decisões na prática. É importante notar que os resultados acima foram semelhantes aos relatados em outros estudos de previsão realizadas utilizando dados de EH que atendem casos complexos (SUN et al., 2009; MARCILIO et al., 2013).

Com relação às informações externas analisadas e incorporadas aos modelos, apenas o dia da semana apresentou um efeito sistemático sobre a procura por atendimento na EH, independente da classificação dos pacientes considerada. Como apresentado na Figura 2, os dias da semana tem um efeito sobre a demanda, enquanto os meses do ano não têm. O efeito de feriados e dias seguintes a feriados na demanda da EH também não foram significativos. Picos de demanda foram verificados nas segundas-feiras, e vales nos finais de semana, o que estão alinhados com resultados relatados por vários estudos disponíveis na literatura sobre a demanda em EH (MARCILIO et al., 2013; SUN et al., 2009; BATAL et al., 2001; JONES et al., 2002). Há uma forte diminuição da procura nos finais de semana; esse fato pode contribuir para a otimização dos recursos disponíveis na EH e para o gerenciamento da equipe de profissionais.

Conforme apresentado no Apêndice I, alguns fatores climáticos demonstraram correlação significativa com a demanda de pacientes, para todas as classificações. No entanto, quando se compara o desempenho MAPE dos modelos MSARIMA (que consideram esses fatores) e os modelos SARIMA (que não tomam), este último superou sistematicamente o primeiro. Atribuiu-se a isso o fato da EH sob análise só prestar assistência médica a casos complexos, que não parecem ser afetadas por condições climáticas.

Sabe-se que a utilização de técnicas de previsão de demanda para prever a procura em por atendimento em EH, pode contribuir diretamente para a redução do número de

pacientes que deixam o hospital sem receber atendimento e o número de reclamações feitas pelos pacientes (BATAL et al., 2001). No presente estudo, observou-se que os modelos que consideram todos os pacientes apresentaram erros de predição menores do que os que estratificam os pacientes conforme sua classificação no STM. Além disso, verificou-se que o modelo com melhores resultados para todos os pacientes (SS) não é o mesmo do que quando a classificação dos pacientes é considerada (SARIMA). É importante ressaltar que os modelos SS de fácil implementação na prática, e que o seu bom desempenho na previsão de demanda em EH tem sido relatado em estudos anteriores (CHAMPION et al., 2007).

Finalizando, os resultados deste estudo não suportam a crença comum de que a demanda diária de procura por atendimento em EH é influenciada por fatores climáticos (MARCILIO et al., 2013; SUN et al., 2009; KAM et al., 2010). A comparação entre métodos de previsão aqui apresentada indica que, em EH que tratam pacientes de alta complexidade, os modelos SARIMA fornecem previsões da procura por atendimento mais precisas para os pacientes classificados como MU e U. Em outras palavras, a inclusão de fatores climáticos como variáveis independentes no modelo de previsão não aumentou sua precisão.

## **2.5 Limitações**

Este estudo indica que os fatores climáticos não influenciam a demanda de procura por atendimento em uma EH dedicada a casos complexos; no entanto, nós utilizamos dados de um único hospital localizado em uma região específica do Brasil. Assim, nossos resultados são válidos para a EH dedicadas a casos complexos, localizadas na mesma região ou em regiões com características climáticas semelhantes. Para resultados mais gerais o estudo deve ser reaplicado em regiões com diferentes características climáticas. A mesma recomendação aplica-se à amostra de pacientes.

## 2.6 Conclusões

Nosso estudo confirma que a demanda diária para atendimentos em EH é caracterizado por padrões sazonais semanais. Além disso, ele indica que modelos de previsão baseados puramente na série temporal podem ser usados para fornecer previsões precisas de em EH de alta complexidade, especialmente para previsões de curto prazo. A precisão da previsão depende do modelo utilizado, horizonte de previsão e classificação dos pacientes no STM. Em nossas análises, SS produziu os menores valores MAPE, independente do horizonte de previsão escolhido, quando todas as classes de pacientes foram consideradas na série. Para os pacientes classificados como MU e U, o modelo com o melhor desempenho foi o SARIMA, exceto para a previsão dos pacientes classificados como MU para o horizonte de previsão de 7 dias; nesse caso, SHWM produziu o menor erro. Alguns fatores climáticos demonstraram correlação significativa com a demanda, mas não aumentaram a precisão da previsão quando incorporados ao modelo.

## 2.7 Referências

- ABRAHAM, G.; BYRNES, G. B.; BAIN, C. A. Short-term forecasting of emergency inpatient flow. **Information Technology in Biomedicine, IEEE Transactions on**, v. 13, n. 3, p. 380-388, 2009.
- ARMSTRONG, J. S.; FILDES, R. Making progress in forecasting. **International Journal of Forecasting**, v. 22, n. 3, p. 433-441, 2006.
- BATAL, H.; TENCH, J.; MCMILLAN, S.; ADAMS, J.; MEHLER, P. S. Predicting patient visits to an urgent care clinic using calendar variables. **Academic Emergency Medicine**, v. 8, n. 1, p. 48-53, 2001.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis: forecasting and control**, revised ed. Holden-Day, 1976.

BOYLE, J.; JESSUP, M.; CRILLY, J.; GREEN, D.; LIND, J.; WALLIS, M.; MILLER, P.; FITZGERALD, G. Predicting emergency department admissions. **Emergency Medicine Journal**, v. 29, n. 5, p. 358-365, 2012.

CHAMPION, R.; KINSMAN, L. D.; LEE, G. A.; MASMAN, K. A.; MAY, E. A.; MILLS, T. M.; TAYLOR, M. D. THOMAS, P. R.; WILLIAMS, R. J. Forecasting emergency department presentations. **Australian Health Review**, v. 31, n. 1, p. 83-90, 2007.

DAVIDSON, S. J.; KOENIG, K. L.; CONE, D. C. Daily patient flow is not surge: "management is prediction". **Academic Emergency Medicine**, v. 13, n. 11, p. 1095-1096, 2006.

DE GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. **International journal of forecasting**, v. 22, n. 3, p. 443-473, 2006.

DERLET, R. W.; RICHARDS, J. R. Overcrowding in the nation's emergency departments: complex causes and disturbing effects. **Annals of emergency medicine**, v. 35, n. 1, p. 63-68, 2000.

FATOVICH, D. M.; NAGREE, Y.; SPRIVULIS, P. Access block causes emergency department overcrowding and ambulance diversion in Perth, Western Australia. **Emergency Medicine Journal**, v. 22, n. 5, p. 351-354, 2005.

FORERO, R.; HILLMAN, K. M.; MCCARTHY, S.; FATOVICH, D.M.; JOSEPH, A. P.; RICHARDSON, D. B. Access block and ED overcrowding. **Emergency Medicine Australasia**, v. 22, n. 2, p. 119-135, 2010.

GENTILE, S.; VIGNALLY, P.; DURAND, A. C.; GAINOTTI, S.; SAMBUC, R.; GERBEAUX, P. Nonurgent patients in the emergency department? A French formula to prevent misuse. **BMC health services research**, v. 10, n. 1, p. 1, 2010.

HOOT, N. R.; ARONSKY, D. Systematic review of emergency department crowding: causes, effects, and solutions. **Annals of emergency medicine**, v. 52, n. 2, p. 126-136.e1, 2008.

INMET, **Instituto Nacional de Meteorologia**. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesConvencionais>> Acesso em: 30/07/2015.

JONES, S. A.; JOY, M. P.; PEARSON, J. Forecasting demand of emergency care. **Health care management science**, v. 5, n. 4, p. 297-305, 2002.

JONES, S. S.; THOMAS, A.; EVANS, R. S.; WELCH, S. J.; HAUG, P. J.; SNOW, G. L. Forecasting daily patient volumes in the emergency department. **Academic Emergency Medicine**, v. 15, n. 2, p. 159-170, 2008.

KADRI, F.; HARROU, F.; CHAABANE, S.; TAHON, C. Time series modelling and forecasting of emergency department overcrowding. **Journal of medical systems**, v. 38, n. 9, p. 1-20, 2014.

KAM, H. J.; SUNG, J. O.; PARK, R. W. Prediction of daily patient numbers for a regional emergency medical center using time series analysis. **Healthcare informatics research**, v. 16, n. 3, p. 158-165, 2010.

KOEHLER, A. B.; SNYDER, R. D.; ORD, J. K. Forecasting models and prediction intervals for the multiplicative Holt–Winters method. **International Journal of Forecasting**, v. 17, n. 2, p. 269-286, 2001.

KOLKER, A. Process modeling of emergency department patient flow: Effect of patient length of stay on ED diversion. **Journal of Medical Systems**, v. 32, n. 5, p. 389-401, 2008.

LITVAK, E.; LONG, M. C.; COOPER, A. B.; MCMANUS, M. L. Emergency department diversion: causes and solutions. **Academic emergency medicine: official journal of the Society for Academic Emergency Medicine**, v. 8, n. 11, p. 1108-1110, 2001.

MACKWAY-JONES K. ed. Emergency triage. London: Manchester Triage Group/**BMJ Books**, 1997.

MARCILIO, I.; HAJAT, S.; GOUVEIA, N. Forecasting daily emergency department visits using calendar variables and ambient temperature readings. **Academic emergency medicine**, v. 20, n. 8, p. 769-777, 2013.

RABIN, E.; KOCHER, K.; MCCLELLAND, M.; PINES, J.; HWANG, U.; RATHLEV, N.; ASPLIN, B.; TRUEGER N. S.; WEBER, E. Solutions to emergency department ‘boarding’ and crowding are underused and may need to be legislated. **Health Affairs**, v. 31, n. 8, p. 1757-1766, 2012.

RICHARDSON, D. B.; MOUNTAIN, D. Myths versus facts in emergency department overcrowding and hospital access block. **Medical Journal of Australia**, v. 190, n. 7, p. 369, 2009.

ROTSTEIN, Z.; WILF-MIRON, R.; LAVI, B.; SHAHAR, A.; GABBAY, U.; NOY, S. The dynamics of patient visits to a public hospital ED: a statistical model. **The American journal of emergency medicine**, v. 15, n. 6, p. 596-599, 1997.

SCHMIDT, M. I.; DUNCAN, B. B.; SILVA, G. A.; MENEZES, A. M.; MONTEIRO, C. A.; BARRETO, S. M.; CHOR, D.; MENEZES, P. R. Chronic non-communicable diseases in Brazil: burden and current challenges. **The Lancet**, v. 377, n. 9781, p. 1949-1961, 2011.

SCHWEIGLER, L. M.; DESMOND, J. S.; MCCARTHY, M. L.; BUKOWSKI, K. J.; IONIDES, E. L.; YOUNGER, J. G. Forecasting models of emergency department crowding. **Academic Emergency Medicine**, v. 16, n. 4, p. 301-308, 2009.

SUN, Y.; HENG, B.; SEOW, Y.; SEOW, E. Forecasting daily attendances at an emergency department to aid resource planning. **BMC emergency medicine**, v. 9, n. 1, p. 1, 2009.

TANDBERG, D.; QUALLS, C. Time series forecasts of emergency department patient volume, length of stay, and acuity. **Annals of emergency medicine**, v. 23, n. 2, p. 299-306, 1994.

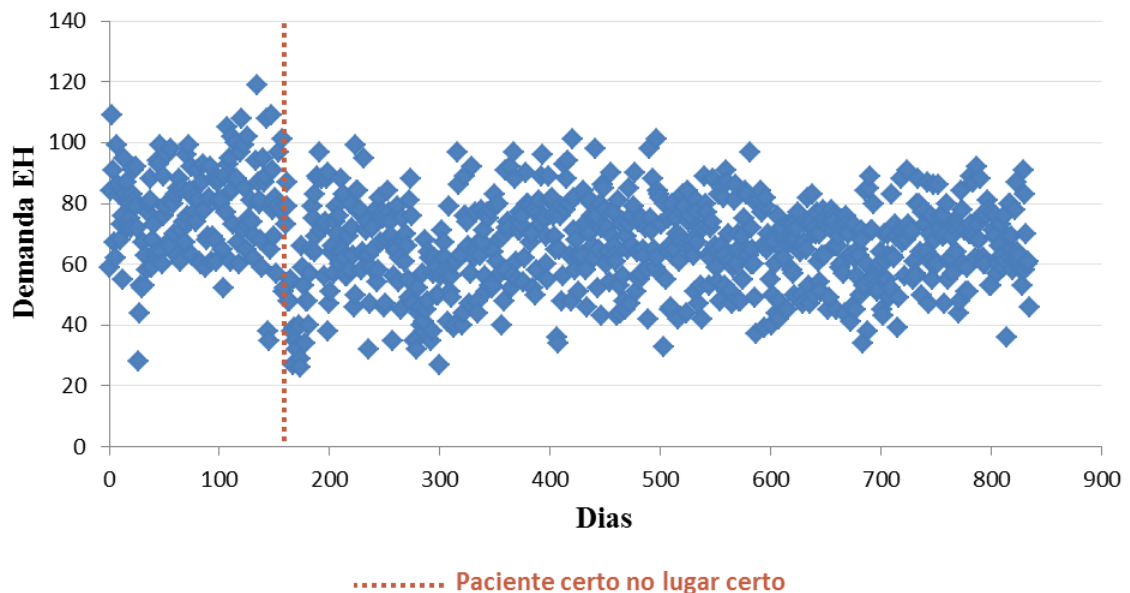
WARGON, M.; GUIDET, B.; HOANG, T. D.; HEJBLUM, G. A systematic review of models for forecasting the number of emergency department visits. **Emergency Medicine Journal**, v. 26, n. 6, p. 395-399, 2009.

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

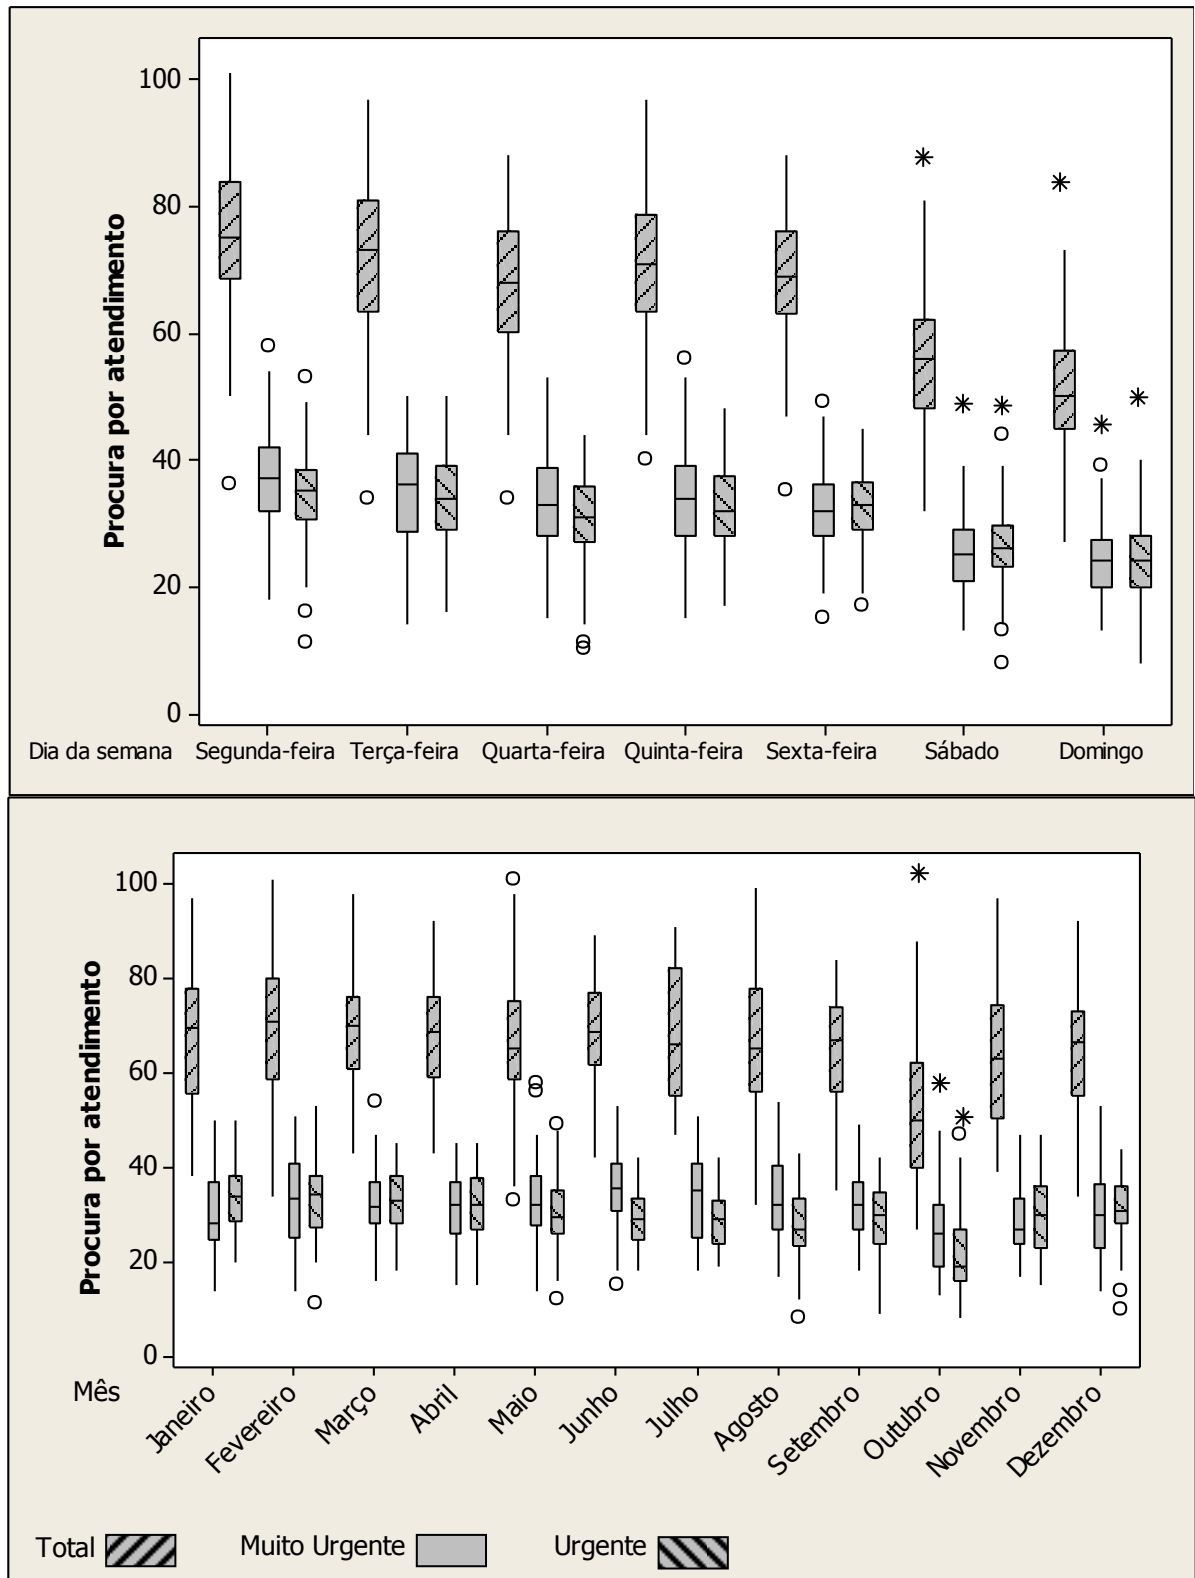
ZIBNERS, L. M., BONSU, B. K., HAYES, J. R., COHEN, D. M. Local weather effects on emergency department visits: a time series and regression analysis. **Pediatric emergency care**, v. 22, n. 2, p. 104-106, 2006.

**Tabela 2.1:** Variáveis explanatórias utilizadas no MSARIMA

	<b>Variáveis</b>	<b>Detalhamento</b>
Calendário	Meses	Janeiro, Fevereiro, Março, Abril, Maio, Junho, Julho, Agosto, Setembro, Outubro, Novembro, Dezembro
	Dias da semana	Segunda-feira, Terça-feira, Quarta-feira, Quinta-feira, Sexta-feira, Sábado, Domingo
Climáticas	Temperatura média	Celcius
	Temperatura mínima	Celcius
	Temperatura máxima	Celcius
	Amplitude térmica	Celcius
	Precipitação	Milímetros
	Velocidade do vento	Metros/segundo
	Umidade relativa	Percentual
	Insolação	Horas

**Figura 2.1.** Gráfico de dispersão da procura por atendimento na emergência do Hospital de Clínicas de Porto Alegre





\* $p \leq 0,05$  (ANOVA)

**Figure 2.2.** Variação da demanda na semana (estratificado por dia) e no ano (estratificado por mês)

**Tabela 2.2:** Valores MAPE para cada método e para os 5 horizontes de previsão

		1	7	14	21	30
TOTAL	MVSARIMA	6,23%	12,01%	11,79%	12,29%	11,51%
	SARIMA	6,23%	12,01%	11,79%	12,29%	11,51%
	SS	2,91%	10,67%	10,67%	11,35%	11,07%
	HWM	3,02%	10,80%	10,85%	11,54%	11,11%
MU	MVSARIMA	7,19%	17,65%	16,89%	17,23%	17,21%
	SARIMA	7,19%	17,65%	16,89%	17,23%	17,21%
	SS	11,16%	17,79%	17,36%	18,13%	19,14%
	HWM	9,40%	16,82%	16,89%	17,56%	18,18%
U	MVSARIMA	3,98%	12,79%	15,71%	14,74%	14,54%
	SARIMA	3,98%	12,79%	15,71%	14,74%	14,54%
	SS	7,18%	15,72%	18,04%	16,41%	16,60%
	HWM	5,57%	14,24%	16,56%	15,50%	15,57%

Modelos com melhor ajuste

**Apêndice 2.1:** Significância das variáveis climáticas pela classificação dos pacientes e diferentes defasagens de tempo

	Total	MU	U		Total	MU	U
Temperatura média (0)	0,293	0,379	0,183	Temperatura média (4)	0,652	0,613	0,080
Temperatura mínima (0)	0,007	0,640	0,000	Temperatura mínima (4)	0,522	0,024	0,000
Temperatura máxima (0)	0,048	0,441	0,000	Temperatura máxima (4)	0,518	0,018	0,000
Amplitude térmica (0)	0,098	0,100	0,260	Amplitude térmica (4)	0,861	0,602	0,464
Precipitação (0)	0,178	0,534	0,001	Precipitação (4)	0,761	0,063	0,005
Velocidade do vento (0)	0,060	0,462	0,000	Velocidade do vento (4)	0,771	0,004	0,000
Umidade relativa (0)	0,593	0,309	0,020	Umidade relativa (4)	0,461	0,016	0,072
Insolação (0)	0,477	0,243	0,458	Insolação (4)	0,884	0,863	0,753
Temperatura média (1)	0,828	0,888	0,876	Temperatura média (5)	0,657	0,779	0,436
Temperatura mínima (1)	0,016	0,903	0,000	Temperatura mínima (5)	0,652	0,058	0,000
Temperatura máxima (1)	0,010	0,611	0,000	Temperatura máxima (5)	0,262	0,030	0,000
Amplitude térmica (1)	0,618	0,423	0,902	Amplitude térmica (5)	0,487	0,847	0,204
Precipitação (1)	0,942	0,627	0,248	Precipitação (5)	0,767	0,268	0,039
Velocidade do vento (1)	0,031	0,490	0,000	Velocidade do vento (5)	0,678	0,011	0,000
Umidade relativa (1)	0,359	0,144	0,719	Umidade relativa (5)	0,876	0,237	0,094
Insolação (1)	0,211	0,079	0,388	Insolação (5)	0,677	0,884	0,634
Temperatura média (2)	0,818	0,809	0,948	Temperatura média (6)	0,788	0,791	0,211
Temperatura mínima (2)	0,096	0,453	0,000	Temperatura mínima (6)	0,485	0,034	0,000
Temperatura máxima (2)	0,061	0,149	0,000	Temperatura máxima (6)	0,374	0,036	0,000
Amplitude térmica (2)	0,819	0,533	0,555	Amplitude térmica (6)	0,964	0,544	0,674
Precipitação (2)	0,829	0,547	0,266	Precipitação (6)	0,468	0,360	0,019
Velocidade do vento (2)	0,169	0,081	0,000	Velocidade do vento (6)	0,786	0,005	0,000
Umidade relativa (2)	0,272	0,033	0,755	Umidade relativa (6)	0,570	0,164	0,009
Insolação (2)	0,773	0,346	0,426	Insolação (6)	0,891	0,779	0,798
Temperatura média (3)	0,480	0,796	0,077	Temperatura média (7)	0,059	0,067	0,235
Temperatura mínima (3)	0,392	0,078	0,000	Temperatura mínima (7)	0,191	0,116	0,000
Temperatura máxima (3)	0,349	0,042	0,000	Temperatura máxima (7)	0,744	0,011	0,000
Amplitude térmica (3)	0,885	0,862	0,732	Amplitude térmica (7)	0,119	0,441	0,133
Precipitação (3)	0,699	0,496	0,100	Precipitação (7)	0,152	0,888	0,004
Velocidade do vento (3)	0,591	0,010	0,000	Velocidade do vento (7)	0,679	0,006	0,000
Umidade relativa (3)	0,639	0,236	0,410	Umidade relativa (7)	0,913	0,134	0,022
Insolação (3)	0,356	0,335	0,445	Insolação (7)	0,774	0,857	0,549

(x) Dias de defasagem   p<0.05

### **3. Artigo 2: Previsão do tempo de permanência em emergências hospitalares utilizando regressão por mínimos quadrados parciais**

Rafael Calegari<sup>1</sup>, Flavio S. Fogliatto<sup>1</sup>, Filipe R. Lucini<sup>1</sup>, Jeruza Neyeloff<sup>2</sup>,

Beatriz D. Schaan<sup>2</sup>

<sup>1</sup>Departamento de Engenharia de Produção, Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil;

<sup>2</sup>Divisão de Endocrinologia, Hospital de Clínicas de Porto Alegre/Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil;

## Resumo

**Objetivos:** O presente estudo tem o objetivo de aplicar e avaliar um modelo de previsão do TPEH em uma EH com alto grau de congestionamento, utilizando como variáveis independentes fatores relacionados ao funcionamento do hospital e como variáveis dependentes quatro indicadores relacionados ao TPEH.

**Métodos:** O estudo testou a eficácia da previsão do TPEH, utilizando quatro indicadores: 1) soma total dos TPEH de todos os pacientes presentes no dia em análise (TT); 2) soma do TPEH somente dos pacientes que entraram e saíram no mesmo dia (TTSC); 3) TPEH médio de todos os pacientes presentes no dia em análise (TM); e 4) TPEH médio somente de pacientes que não permaneceram o dia completo (TMSC). O estudo foi conduzido no Hospital de Clínicas de Porto Alegre (HCPA), que é um hospital escola localizado no Brasil. Os dados diários foram coletados de 1º de janeiro de 2014 a 31 de dezembro de 2014, sendo 90% utilizados para treino dos modelos e o restante para teste e validação. Os modelos de previsão foram criados a partir da regressão por mínimos quadrados parciais (PLS, *partial least squares*), utilizando como variáveis independentes o número diário de exames, profissionais, taxas de ocupação e pacientes triados.

**Resultados:** Durante o período analisado 21918 pacientes foram atendidos, com TPEH médio de 2928 minutos, variando entre 3 e 13182 minutos. Observou-se diferença significativa nas variáveis independentes em dias de semana e finais de semana. Dentre os quatro indicadores avaliados, o TM foi o que alcançou os menores erros na previsão, tanto para dias de semana quanto para finais de semana. No referido indicador, utilizando-se somente dois componentes principais atingiu-se um erro médio percentual (MAPE) de 5,68% (dias de semana) e 8,34% (finais de semana).

**Conclusões:** Este estudo confirma que o número de exames realizados no hospital, número de funcionários, taxas de ocupação e número de pacientes triados, atuam de forma distinta sobre o TPEH, se analisadas em dias de semana ou finais de semana. Além disso, conclui-se que a utilização do PLS em modelos de previsão do TPEH pode gerar bons resultados em emergências hospitalares (EH) com alto grau de congestionamento.

### 3.1 Introdução

Os serviços de emergências hospitalares (EH) desempenham um papel fundamental no sistema de saúde, servindo de porta de entrada para hospitais e fornecendo cuidados para pacientes com lesões e doenças graves. No entanto, as EH em todo o mundo sofrem com o aumento da demanda e superlotação (DERLET & RICHARDS, 2000; FORERO et al., 2010). Múltiplos fatores convergem simultaneamente para resultar na superlotação das EH: o envelhecimento da população, aumento da incidência de doenças crônicas, aumento da procura por atendimento, aumento da complexidade dos cuidados, visitas não urgentes, profissionais não capacitados e escassez de leitos (SCHMIDT et al., 2011; FATOVICH et al., 2005; HOOT & ARONSKY, 2008; LITVAK et al., 2001; GENTILE et al., 2010). É importante ressaltar que o congestionamento nas EH tem implicações sobre a qualidade do atendimento oferecido aos pacientes, sobre a eficiência e eficácia das operações internas e na satisfação de funcionários e pacientes (RICHARDSON & MOUNTAIN, 2009; HOOT & ARONSKY, 2008). Soluções comumente estudadas para a superlotação incluem o aumento de profissionais de saúde e de leitos hospitalares; no entanto, a melhoria do fluxo de pacientes com a gestão otimizada dos recursos disponíveis também pode ser uma abordagem eficaz para combater o problema (KOLKER, 2008; RABIN et al., 2012; KADRI et al., 2014; SCHWEIGLER et al., 2009).

A utilização da capacidade das EH é função direta do tempo de permanência dos pacientes na emergência hospitalar (TPEH). Definido como o tempo do registro do paciente na triagem até sua transferência para outra área, internação ou alta (GARDNER et al., 2007), o TPEH já é um indicador amplamente utilizado e consolidado para a comparação da eficiência no gerenciamento do fluxo dos pacientes (ASPLIN, 2006; RATHLEV et al., 2007). Dessa forma, a previsão do TPEH pode contribuir fortemente para o planejamento dos

recursos necessários para uma gestão adequada desse fluxo de pacientes (GUL & GUNERI, 2015). Por exemplo, previsões para horizontes longos podem ser úteis para reformulações estruturais e da equipe de profissionais (BATAL et al., 2001), enquanto previsões de curto prazo podem auxiliar no planejamento operacional diário dos recursos disponíveis (ABRAHAM et al., 2009).

Estudos tratam do TPEH na literatura; entretanto, apenas uma pequena parcela deles propõe ou aplica modelos de previsão (GUL & GUNERI, 2015). De forma geral, tais estudos utilizam como técnicas de previsão redes neurais artificiais (RNA's), além de modelos criados a partir de variações desta técnica. Gul e Guneri (2015) aplicaram um modelo de RNA para previsão do TPEH em um hospital na Turquia; porém, encontraram resultados com menor acurácia do que os obtidos por Li et al. (2013), que aplicaram RNA para o hospital de uma forma geral, não focando na EH. Wrenn et al. (2005) também aplicaram RNA para a previsão do TPEH em uma EH nos Estados Unidos, não alcançando resultados com alta acurácia, porém concluíram que os resultados foram promissores para estudos futuros, devido ao reconhecimento de padrões complexos proporcionados pelo modelo. Constata-se, a partir desses estudos, que a literatura carece de modelos de previsão que alcancem uma acurácia maior do que as já reportadas até o momento.

O Brasil possui 1,63 leitos/mil habitantes (DATASUS, 2015), quando o recomendado pela Organização Mundial da Saúde é de 3 leitos/mil habitantes (OMS, 2010). Essa escassez de leitos hospitalares no país aumenta o congestionamento das EH e, conseqüentemente, eleva o TPEH. Por essa razão, muitos pacientes permanecem mais de 24 horas na EH aguardando leitos. Tendo em vista que muitas informações referentes ao hospital são armazenadas de forma diária, ocorre uma diferença de escala entre o TPEH e essas informações. Isso dificulta a utilização de modelos de previsão anteriormente apresentados,

que utilizam informações diárias do hospital como variáveis independentes e o TPEH como variável dependente. Uma forma de abordar esse problema é a utilização de indicadores diários relacionados ao TPEH. Nesse contexto, o presente estudo tem o objetivo de aplicar um modelo de previsão do TPEH em uma EH com alto grau de congestionamento, utilizando como variáveis independentes fatores relacionados ao funcionamento do hospital e como variáveis dependentes quatro indicadores relacionados ao TPEH. O estudo se justifica por abordar a previsão do TPEH em uma EH com grau de congestionamento muito maior do que as utilizadas em estudos anteriores. Além disso, não encontramos na literatura trabalhos que avaliassem a utilização do PLS em EH com os indicadores e as covariáveis utilizadas no presente estudo.

## **3.2 Método**

### **3.2.1 Planejamento do estudo e cenário**

Trata-se de um estudo retrospectivo, que utiliza dados históricos de procura por atendimento médico na EH, para aplicar um modelo de previsão do TPEH. O estudo foi conduzido no Hospital de Clínicas de Porto Alegre (HCPA), que é um hospital escola localizado na região sul do Brasil e que conta com 843 leitos e aproximadamente 32.000 admissões/ano. A EH do HCPA opera 24 horas por dia, 7 dias por semana ao longo de todo o ano e trata pacientes do Sistema Único de Saúde (SUS). Recebe pacientes da cidade de Porto Alegre e da região metropolitana, totalizando uma população de aproximadamente 4 milhões. O comitê de ética do HCPA aprovou o estudo e os autores cumpriram as recomendações da declaração de Helsinki. Os dados de entrada foram os TPEH dos pacientes atendidos na EH.



### 3.2.2 Protocolo do estudo

Todas as informações sobre o hospital e os pacientes, foram extraídas da base de dados corporativa do hospital. Foram selecionadas as informações entre 1º de janeiro de 2014 a 31 de dezembro de 2014, sendo removido das análises o mês de outubro, período que a ED passou por reformas, o que restringiu temporariamente o número de atendimentos. Os dados referentes ao hospital foram processados de forma diária, das 00:00:00 hora às 23:59:59 horas de cada dia. Já as informações referentes ao TPEH foram trabalhadas de forma individual, pois grande parte dos pacientes permaneceu mais de um dia na EH, o que impossibilita uma segregação diária dessas informações.

Estudos anteriores já propuseram modelos matemáticos relacionando o TPEH com variáveis internas e externas de hospitais (WILER et al., 2012; RATHLEV et al., 2007; GARDNER et al., 2007). Esses estudos fazem uma relação do TPEH médio diário, com fatores, também diários, que possam influenciá-lo. Porém, hospitais em países em desenvolvimento possuem, de uma forma geral, TPEH muito superiores aos apresentados nesses estudos (MATTA & PEPE, 2008). Esse fato gera uma diferença de escalas entre as variáveis dependentes e independentes, dificultando a aplicação desses modelos matemáticos. Além disso, considerando que muitos pacientes permanecem mais de um dia em observação na EH em função da limitação de ofertas de leitos nas unidades hospitalares, para análises que objetivam auxiliar as tomadas de decisão gerenciais é importante identificar e separar esses pacientes daqueles que ingressam e saem da EH no mesmo dia. Para isso, serão propostos e avaliados quatro indicadores relacionados ao TPEH, para a aplicação de modelos de previsão em hospitais em países em desenvolvimento. São eles: (i) soma total dos TPEH de todos pacientes presentes na EH no dia em análise (TT); (ii) soma do TPEH somente dos pacientes que entraram e saíram no mesmo dia, além de contabilizar os que tiveram alta ou foram

admitidos na EH no dia em análise (TTSC), não contabilizando assim os pacientes que permaneceram o dia completo, sem alta ou internação; (iii) TPEH médio de todos os pacientes (TM); (iv) TPEH médio somente daqueles que não permaneceram o dia completo (TMSC). Estas abordagens estão ilustradas na Figura 1. No exemplo, são mostrados quatro pacientes que receberam atendimento no intervalo de três dias. Selecionando o dia 2 como referência, o cálculo do TT seria a soma dos TPEH dos quatro pacientes presentes na EH neste dia conforme eq. (1), o que resultaria em um TT de 48 horas (2880 minutos). Para calcular o TTSC, dado na eq. (2), exclui-se da análise o paciente 2, que permaneceu o dia completo na EH, obtendo-se, assim, um TTSC de 24 horas (1440 minutos). O cálculo do TM [eq. (3)] e do TMSC [eq. (4)] seguem a mesma lógica, porém trabalhando-se com o operador de média ao invés do operador de soma, e obtendo-se como resultado um TM de 12 horas (720 minutos) e um TMSC de 8 horas (480 minutos).

$$TT = TPEH_{paciente\ 1} + TPEH_{paciente\ 2} + TPEH_{paciente\ 3} + TPEH_{paciente\ 4} \quad (1)$$

$$TTSC = TPEH_{paciente\ 1} + TPEH_{paciente\ 3} + TPEH_{paciente\ 4} \quad (2)$$

$$TM = \frac{TPEH_{paciente\ 1} + TPEH_{paciente\ 2} + TPEH_{paciente\ 3} + TPEH_{paciente\ 4}}{4} \quad (3)$$

$$TMSC = \frac{TPEH_{paciente\ 1} + TPEH_{paciente\ 3} + TPEH_{paciente\ 4}}{3} \quad (4)$$

### 3.2.3 Análise dos dados

Para a previsão do TPEH, a técnica que mais se adequou ao propósito do estudo foi a regressão por mínimos quadrados parciais (PLS - *partial least squares*). A regressão PLS é recomendada para modelar situações onde existe um alto grau de colinearidade entre variáveis independentes e o modelo de regressão deve considerar mais de uma variável dependente simultaneamente, as quais também podem estar correlacionadas (DUDEK, 2015). Todas as modelagens apresentadas neste estudo foram conduzidas no MATLAB R2012b e Minitab 14.

A regressão PLS é uma ferramenta amplamente utilizada na modelagem de relações lineares entre dados multivariados, modelando conjuntos de variáveis observadas por meio de variáveis latentes (ROSIPAL & NICOLE, 2006). Assim como em outros modelos de regressão, o PLS tem como objetivo principal construir um modelo linear do tipo  $\mathbf{Y} = \mathbf{XB} + \mathbf{E}$ , onde  $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_M]$  é uma matriz ( $N \times M$ ) de variáveis dependentes ou de resposta,  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_K]$  é uma matriz ( $N \times K$ ) de variáveis independentes ou preditoras,  $\mathbf{B}$  é uma matriz ( $K \times M$ ) de coeficientes de regressão, e  $\mathbf{E}$  é a matriz de resíduos, que tem a mesma dimensão de  $\mathbf{Y}$  (WOLD et al., 2001). O PLS cria novas variáveis independentes, chamadas de componentes principais, que são combinações lineares das variáveis originais. Por serem ortogonais entre si, os componentes principais são não correlacionados e são capazes de capturar as principais direções de variabilidade presentes nos dados, mesmo com um número de componentes inferiores ao número de variáveis originais (CHATTERJEE & HALI, 2006). Com relação ao número de componentes principais retidos no modelo, a literatura aponta os critérios de Kaiser-Guttman e o de Jolliffe como os mais utilizados (CANGELOSI & GORIELY, 2007). O critério de Kaiser-Guttman, quando trabalhado com a matriz de covariância, retém os componentes principais com autovalores associados maiores do que a média dos autovalores. Para o caso da utilização da matriz de correlação, são retidos os

componentes principais com autovalor maior ou igual a 1 (JACKSON, 1991). Baseando-se em estudos de simulação, Jolliffe (2002) propôs um critério que retém componentes com autovalores iguais ou superiores a 0,7; porém, tal critério, em alguns casos, pode reter componentes principais não essenciais ao modelo.

Foram consideradas no modelo de regressão PLS quatro variáveis dependentes e dezesseis variáveis independentes. As variáveis dependentes são TT ( $y_1$ ), TTSC ( $y_2$ ), TM ( $y_3$ ) e TMSC ( $y_4$ ). As variáveis independentes, todas medidas diariamente, são: número de exames de tomografias ( $x_1$ ), ecografias ( $x_2$ ) e ressonâncias magnéticas ( $x_3$ ); número de cirurgias eletivas no bloco ( $x_4$ ), de urgência no bloco ( $x_5$ ), eletivas no centro cirúrgico ambulatorial (CCA) ( $x_6$ ) e de urgência no CCA ( $x_7$ ); quantidade de médicos ( $x_8$ ), enfermeiros ( $x_9$ ) e técnicos em enfermagem ( $x_{10}$ ); taxa de ocupação do centro de terapia intensiva (CTI) ( $x_{11}$ ), taxa de ocupação nas enfermarias clínicas e cirúrgicas (ECC) ( $x_{12}$ ); número total de pacientes triados ( $x_{13}$ ), pacientes classificados como emergência ( $x_{14}$ ), muito urgente ( $x_{15}$ ) e urgente ( $x_{16}$ ).

O número de exames, cirurgias e funcionários se referem aos valores diários de todo hospital. As taxas de ocupação são calculadas dividindo o número de pacientes presentes às 00:01 horas do dia em análise pelo número de leitos do setor. Já a classificação dos pacientes, definida na triagem, segue os critérios do Sistema de Triagem de Manchester (STM) (MACKWAY-JONES, 1997). Este sistema organiza os critérios de atendimento em cinco níveis de prioridade. As categorias são identificadas por cores, descrição do caso e tempos estimados de atendimento (TEA); são elas: (i) vermelho – emergência (EM), necessita atendimento imediato, TEA = 0 minutos; (ii) laranja – muito urgente (MU), necessita atendimento com urgência, TEA  $\leq$  10 minutos; (iii) amarelo – urgente (U), paciente possui condições clínicas para aguardar atendimento, TEA  $\leq$  60 minutos; (iv) verde – pouco urgente

(PU), paciente pode ser direcionado para o serviço ambulatorial, TEA  $\leq 120$  minutos; (v) azul – não urgente (NU), paciente deve ser direcionado para o serviço ambulatorial, TEA  $\leq 240$  minutos; e (vi) branco – não classificado. Como 96% dos pacientes são classificados como EM, MU e U, apenas estes foram incluídos na análise.

### 3.2.4 Validação e avaliação do modelo

Para que a estabilidade do modelo fosse avaliada, foram realizadas 1000 iterações nas previsões. Em cada iteração modificava-se aleatoriamente a composição dos intervalos de treino e teste, porém sempre mantendo a proporção de 90% para treino e 10% para teste. O resultado final corresponde à média das 1000 iterações. Esse procedimento visa impedir que os resultados sejam tendenciosos, já que com um grande número de iterações o modelo de previsão se torna mais estável, independentemente da ordem com que os dados sejam apresentados.

A acurácia dos modelos de previsão foi medida através da comparação entre os valores previstos e os observados, durante o período de teste. Para isso, foi utilizado o indicador MAPE (do inglês *mean absolute prediction error*), que calcula o erro percentual médio absoluto. Pelo fato do MAPE não depender da escala dos dados, torna-se uma medida adequada para a verificação de acurácia das previsões feitas para diferentes variáveis dependentes, além de possuir a vantagem de permitir a comparação direta dos resultados obtidos. O MAPE representa a média das diferenças absolutas entre os valores previstos e observados, expressa em termos percentuais; quanto menor o MAPE, melhor o modelo se ajusta aos dados observados. Sendo  $(\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n)$  a série de  $n$  valores previstos e  $(y_1, y_2, \dots, y_n)$  a série de  $n$  valores observados correspondentes, o MAPE é calculado conforme a eq. (5).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{(y_t - \hat{y}_t)}{y_t} \right| \quad (5)$$

### 3.3 Resultados

Durante o período analisado nesse estudo, 21918 pacientes foram atendidos na EH, com TM de 2928 minutos, variando entre 3 e 13182 minutos. As médias e intervalos diários das variáveis são apresentados na Tabela 1. Esses valores referem-se somente aos pacientes que foram triados, não considerando os que desistiram do atendimento ou que foram encaminhados para atendimento em outros locais. Observou-se diferente comportamento das variáveis dos dias de semana e finais de semana, conforme esperado e já verificado em estudos anteriores (WILER et al., 2012; RATHLEV et al., 2007).

Os histogramas de frequência das variáveis dependentes e independentes, considerando valores observados em dias da semana e finais de semana conjuntamente, apresentaram comportamento bimodal (com exceção do indicador de TM). Sendo assim, o banco de dados foi dividido em dois (dias de semana e finais de semana), e os modelos de previsão foram ajustados às duas partes. Feriados nacionais, assim como os dias que os precedem e os que os sucedem, apresentaram comportamentos semelhantes aos dos finais de semana, sendo incorporados àquele banco de dados. Para validar a estratificação dos dados, realizaram-se testes de hipóteses para as médias das variáveis em dias da semana e finais de semana, com resultados apresentados na Tabela 2. Considerando intervalo de confiança de 95%, as médias das variáveis em cada divisão do banco de dados apresentaram diferenças significativas, com exceção da taxa de ocupação da CTI e o número de pacientes classificados como EM.

Com relação à acurácia das previsões, a Tabela 3 apresenta o MAPE dos modelos em função do número de componentes principais retidos na regressão PLS, a variância explicada, de forma acumulada, pelo número de componentes retidos e os autovalores associados a cada componente. O MAPE é apresentado separadamente para os modelos considerando os bancos de dados de dias de semana e de finais de semana. Dos quatro indicadores de TPEH avaliados, TM foi o que apresentou os menores erros na previsão, tanto para os dias de semana quanto para os finais de semana; utilizando dois componentes principais, os modelos geraram MAPEs de 5,68% e 8,34%, respectivamente. Os menores MAPEs alcançados para TT, TTSC e TMSC foram de 8,41%, 9,30% e 8,75% para os dias da semana, e de 16,02%, 12,96% e 11,31% para os finais de semana. Claramente, os modelos de previsão para os dias da semana são mais precisos do que os de finais de semana. Atribui-se a isso a maior flutuação das variáveis dependentes e independentes em finais de semana e feriados. O *scree plot* dos autovalores da matriz de correlação pelo número de componentes principais retidos na regressão PLS é apresentado na Figura 2. O ponto de inflexão da curva se dá no autovalor de aproximadamente 1,5, quando 2 componentes principais são retidos na regressão.

### **3.4 Discussão**

Nesse estudo foi analisado o desempenho de um modelo de previsão para o TPEH baseado em regressão PLS. A modelagem foi aplicada considerando quatro indicadores derivados do TPEH, identificando em cada caso o modelo mais adequado para estimar o tempo de permanência de pacientes em uma EH com alto grau de congestionamento. Devido à diferença no comportamento das variáveis independentes em dias de semana e finais de semana, o banco de dados considerado foi estratificado nesse sentido.

Muitos estudos tratam do TPEH, porém poucos abordam o tema de previsão (GUL & GUNERI, 2015). Alguns trabalhos elaboram modelos para o tempo de permanência no hospital, não focando no TPEH. Li et al. (2013), utilizando uma modelagem através de RNAs treinadas mediante retro-propagação dos erros alcançaram aproximadamente 80% de acurácia no modelo de previsão do tempo de permanência em um hospital da China, identificando 5 fatores preditores significativos: dias no hospital antes da realização da cirurgia, gravidade dos ferimentos, tipos de cirurgias realizadas, formas de pagamentos e volume de admissões do hospital durante o período de internação. Já Gul e Guneri (2015) aplicaram a modelagem através de RNA para prever o TPEH em uma EH na Turquia, não encontrando resultados tão significativos como os de Li et al., (2013), o que pode ser explicado pelo número insuficiente de variáveis explicativas consideradas na modelagem. Wrenn et al. também estimaram o TPEH de uma EH utilizando um modelo baseado em RNA, utilizando fatores relacionados à gravidade da doença do paciente e o número de exames realizados. Apesar de não obterem previsões com boa acurácia, os autores concluíram que o estudo foi importante por ter capturado a complexidade dos dados relacionados à EH, podendo ser explorado em futuros estudos. Apesar de vastamente utilizado como medida de desempenho de modelos preditivos em diversas áreas do conhecimento (DE GOOIJER & HYNDMAN, 2006), em nenhum dos trabalhos sobre previsão do TPEH disponíveis na literatura o MAPE foi utilizado como indicador de desempenho. De uma forma geral, é possível afirmar que os modelos obtidos no presente estudo são relevantes e que quando comparados a outros estudos, mesmo os que aplicam modelos mais complexos de previsão, possuem uma boa capacidade preditiva.

Quanto ao critério de retenção de componentes principais no modelo de previsão, o MAPE das previsões direciona para a adoção de um critério ainda mais rigoroso que os de Kaiser-Guttman e Jolliffe. Em geral, as melhores previsões foram obtidas ao utilizarem-se 2 componentes principais no modelo, correspondendo ao ponto de inflexão do *scree plot* da



Figura 2. Baseando-se no critério de Kaiser-Guttman, seriam retidos 3 componentes principais, explicando 65,47% da variância total dos dados. Já o critério de Jolliffe reteria 6 componentes principais, com MAPEs inferiores aqueles obtidos ao utilizar-se um número menor de componentes. Essa análise corrobora a ideia de que, em alguns casos, os métodos de Kaiser-Guttman e Jolliffe podem reter componentes não essenciais ao modelo de previsão. Analisando-se a Tabela 3, verifica-se que, com o aumento do número de componentes principais retidos (e, conseqüentemente, a variância nos dados por eles explicada), a acurácia do modelo de previsão não aumenta. Conclui-se com isso que a porção da variância explicada a partir da terceira componente principal não se deve às variáveis independentes testadas nos modelos, o que acaba por agregar ruído aos modelos.

Finalmente, os resultados do presente estudo demonstram que a regressão PLS apresenta boa acurácia nas previsões do TPEH de hospitais com alto grau de congestionamento. Além disso, mostram que em países em desenvolvimento, onde de uma forma geral as EH apresentam TPEH muito superior aos de países desenvolvidos, o TM de pacientes é um indicador que representa de forma adequada e previsível a ocupação das EH.

### **3.5 Limitações**

Este estudo indica que o PLS é recomendado para a previsão do TPEH de hospitais com alto grau de congestionamento, porém foram utilizados dados de somente um hospital. Dessa forma, as análises podem ser consideradas como generalizáveis somente a hospitais com características semelhantes as do presente estudo. Para resultados definitivos, recomenda-se a aplicação do estudo em hospitais com características diferentes, ou até mesmo em países com características diferentes.

### 3.6 Conclusões

Este estudo confirma que o TPEH, número de exames realizados no hospital, número de funcionários, taxas de ocupação e número de pacientes procurando atendimento nos hospitais, possuem comportamento com diferenças significativas nos dias da semana e finais de semana. Além disso, aborda quatro formas diferentes de trabalhar com o TPEH para hospitais localizados em países em desenvolvimento, demonstrando que TM de permanência dos pacientes gera resultados mais previsíveis do que o TT, TTSC e TMSC. Indica também, que modelos de previsão do TPEH baseados em regressão PLS podem gerar ótimos resultados, até mesmo quando comparado com modelos mais complexos propostos em estudos anteriores, tais como as RNAs.

### 3.7 Referências

- ABRAHAM, G.; BYRNES, G. B.; BAIN, C. A. Short-term forecasting of emergency inpatient flow. **Information Technology in Biomedicine, IEEE Transactions on**, v. 13, n. 3, p. 380-388, 2009.
- ASPLIN, B. R. Measuring crowding: time for a paradigm shift. **Academic Emergency Medicine**, v. 13, n. 4, p. 459-461, 2006.
- BATAL, H.; TENCH, J.; MCMILLAN, S.; ADAMS, J.; MEHLER, P. S. Predicting patient visits to an urgent care clinic using calendar variables. **Academic Emergency Medicine**, v. 8, n. 1, p. 48-53, 2001.
- CANGELOSI, R.; GORIELY, A. Component retention in principal component analysis with application to cDNA microarray data. **Biology direct**, v. 2, n. 2, p. 1-21, 2007.
- CHATTERJEE, S.; HADI, A. S. **Regression analysis by example**. John Wiley & Sons, 2015.

DATASUS, 2015. Available in: <[http://cnes.datasus.gov.br/Mod\\_Ind\\_Tipo\\_Leito.asp](http://cnes.datasus.gov.br/Mod_Ind_Tipo_Leito.asp) >  
Accessed in: 15/02/2015

DE GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. **International journal of forecasting**, v. 22, n. 3, p. 443-473, 2006.

DERLET, R. W.; RICHARDS, J. R. Overcrowding in the nation's emergency departments: complex causes and disturbing effects. **Annals of emergency medicine**, v. 35, n. 1, p. 63-68, 2000.

DUDEK, Grzegorz. Pattern-based local linear regression models for short-term load forecasting. **Electric Power Systems Research**, v. 130, p. 139-147, 2016.

FATOVICH, D. M.; NAGREE, Y.; SPRIVULIS, P. Access block causes emergency department overcrowding and ambulance diversion in Perth, Western Australia. **Emergency Medicine Journal**, v. 22, n. 5, p. 351-354, 2005.

FORERO, R.; HILLMAN, K. M.; MCCARTHY, S.; FATOVICH, D.M.; JOSEPH, A. P.; RICHARDSON, D. B. Access block and ED overcrowding. **Emergency Medicine Australasia**, v. 22, n. 2, p. 119-135, 2010.

GARDNER, R. L.; SARKAR, U.; MASELLI, J. H.; GONZALES, R. Factors associated with longer ED lengths of stay. **The American journal of emergency medicine**, v. 25, n. 6, p. 643-650, 2007.

GENTILE, S.; VIGNALLY, P.; DURAND, A. C.; GAINOTTI, S.; SAMBUC, R.; GERBEAUX, P. Nonurgent patients in the emergency department? A French formula to prevent misuse. **BMC health services research**, v. 10, n. 1, p. 1, 2010.

GUL, M.; GUNERI, A. F. Forecasting patient length of stay in an emergency department by artificial neural networks. **Journal of Aeronautics & Space Technologies/Havacilik ve Uzey Teknolojileri Dergisi**, v. 8, n. 2, 2015.

HOOT, N. R.; ARONSKY, D. Systematic review of emergency department crowding: causes, effects, and solutions. **Annals of emergency medicine**, v. 52, n. 2, p. 126-136.e1, 2008.

JACKSON, J. Edward. **A user's guide to principal components**. John Wiley & Sons, 2005.

JOLLIFFE, Ian. **Principal component analysis**. John Wiley & Sons, Ltd, 2002.

KADRI, F.; HARROU, F.; CHAABANE, S.; TAHON, C. Time series modelling and forecasting of emergency department overcrowding. **Journal of medical systems**, v. 38, n. 9, p. 1-20, 2014

KOLKER, A. Process modeling of emergency department patient flow: Effect of patient length of stay on ED diversion. **Journal of Medical Systems**, v. 32, n. 5, p. 389-401, 2008.

KRALL, S. P.; CORNELIUS, A. P.; ADDISON, J. B. Hospital factors impact variation in emergency department length of stay more than physician factors. **Western Journal of Emergency Medicine**, v. 15, n. 2, p. 158, 2014.

LI, J. S.; TIAN, Y.; LIU, Y. F.; SHU, T.; LIANG, M. H. Applying a BP neural network model to predict the length of hospital stay. In: **Health Information Science**. Springer Berlin Heidelberg, 2013. p. 18-29.

LITVAK, E.; LONG, M. C.; COOPER, A. B.; MCMANUS, M. L. Emergency department diversion: causes and solutions. **Academic emergency medicine: official journal of the Society for Academic Emergency Medicine**, v. 8, n. 11, p. 1108-1110, 2001.

MACKWAY-JONES K. ed. Emergency triage. London: Manchester Triage Group/**BMJ Books**, 1997.

MATTA, I. E. A. D.; PEPE, V. L. E. Evaluation of emergency hospital services in the state of Rio de Janeiro. **Ciência & Saúde Coletiva**, v. 13, n. 5, p. 1637-1648, 2008.

OMS, Organização Mundial da Saúde. Financiamento dos Sistemas de Saúde: o caminho para a cobertura universal. **Relatório Mundial da Saúde – Comunidade dos Países de Língua Portuguesa**, 2010. Disponível em: <[http://www.who.int/whr/2010/whr10\\_pt.pdf](http://www.who.int/whr/2010/whr10_pt.pdf)> Acesso em: 15/02/2015

RABIN, E.; KOCHER, K.; MCCLELLAND, M.; PINES, J.; HWANG, U.; RATHLEV, N.; ASPLIN, B.; TRUEGER N. S.; WEBER, E. Solutions to emergency department ‘boarding’ and crowding are underused and may need to be legislated. **Health Affairs**, v. 31, n. 8, p. 1757-1766, 2012.

RATHLEV, N. K.; CHESSARE, J.; OLSHAKER, J.; OBENDORFER, D.; MEHTA, S. D.; ROTHENHAUS, T.; CRESPO, S.; MAGAURAN, B.; DAVIDSON, K.; SHEMIN, R.; LEWIS, K.; BECKER, J. M.; FISHER, L.; GUY, L.; COOPER, A.; LITVAK, E. Time series analysis of variables associated with daily mean emergency department length of stay. **Annals of emergency medicine**, v. 49, n. 3, p. 265-271, 2007.

RICHARDSON, D. B.; MOUNTAIN, D. Myths versus facts in emergency department overcrowding and hospital access block. **Medical Journal of Australia**, v. 190, n. 7, p. 369, 2009.

ROSIPAL, R.; KRÄMER, N. Overview and recent advances in partial least squares. In: **Subspace, latent structure and feature selection**. Springer Berlin Heidelberg, 2006. p. 34-51.

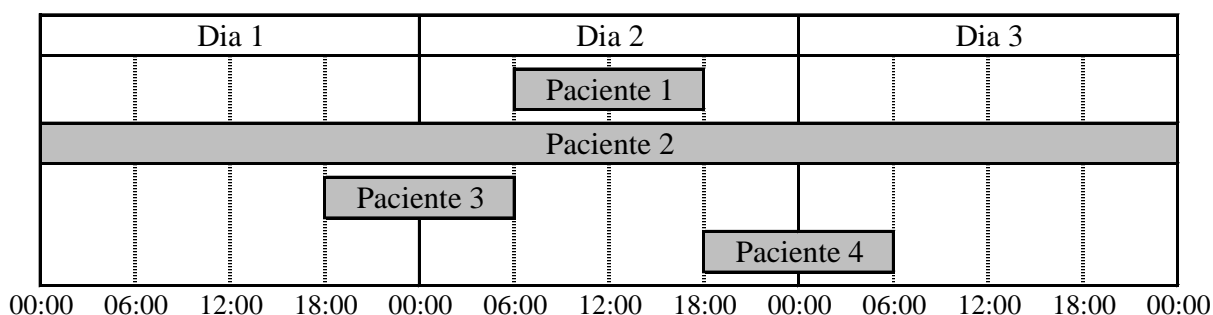
SCHMIDT, M. I.; DUNCAN, B. B.; SILVA, G. A.; MENEZES, A. M.; MONTEIRO, C. A.; BARRETO, S. M.; CHOR, D.; MENEZES, P. R. Chronic non-communicable diseases in Brazil: burden and current challenges. **The Lancet**, v. 377, n. 9781, p. 1949-1961, 2011.

SCHWEIGLER, L. M.; DESMOND, J. S.; MCCARTHY, M. L.; BUKOWSKI, K. J.; IONIDES, E. L.; YOUNGER, J. G. Forecasting models of emergency department crowding. **Academic Emergency Medicine**, v. 16, n. 4, p. 301-308, 2009.

WILER, J. L.; HANDEL, D. A.; GINDE A. A.; ARONSKY, D.; GENES, N. G.; HACKMAN, J. L.; HILTON, J. A.; HWANG, U.; KAMALI, M.; PINES, J. M.; POWELL, E.; SATTARIAN, M.; FU, R. Predictors of patient length of stay in 9 emergency departments. **The American journal of emergency medicine**, v. 30, n. 9, p. 1860-1864, 2012.

WOLD, S.; SJÖSTRÖM, M.; ERIKSSON, L. PLS-regression: a basic tool of chemometrics. **Chemometrics and intelligent laboratory systems**, v. 58, n. 2, p. 109-130, 2001.

WRENN, J.; JONES, I.; LANAGHAN, K.; CONGDON, C. B.; ARONSKY, D. Estimating patient's length of stay in the emergency department with an artificial neural network. In: **AMIA Annual Symposium Proceedings**. American Medical Informatics Association, 2005. p. 1155.

**Figura 3.1:** Exemplo de TPEH em função do número de dias e horários de entrada e saída**Tabela 3.1:** Médias, desvios-padrão, e valores mínimos e máximos das variáveis dependentes e independentes, estratificados conforme o intervalo de observação

Variáveis dependentes e independentes	Dias da semana			Finais de semana		
	Média	Desvio	Mín - Max	Média	Desvio	Mín - Max
TT	117904	13708	75537 - 152390	103535	20573	37362 - 148648
TTSC	63790	8134	42353 - 97619	49127	9132	20460 - 73644
TM	964	73	766 - 1169	992	113	623 - 1241
TMSC	613	67	458 - 793	549	81	401 - 785
Tomografias	95	18	50 - 143	27	20	5 - 119
Ecografias	62	14	25 - 124	11	17	0 - 81
Ressonâncias magnéticas	18	6	4 - 43	3	5	0 - 24
Cirurgias eletivas no bloco	33	5	10 - 46	7	9	0 - 43
Cirurgias de urgência no bloco	6	2	1 - 11	4	2	0 - 11
Cirurgias eletivas no CCA	89	15	27 - 119	10	23	0 - 102
Cirurgias de urgência no CCA	6	4	1 - 23	3	2	0 - 8
Médicos	279	21	222 - 315	88	56	43 - 315
Enfermeiros	181	16	150 - 218	91	28	64 - 207
Técnicos em enfermagem	438	25	374 - 498	305	44	239 - 453
Taxa de ocupação CTI	88	5	70 - 98	89	5	73 - 98
Taxa de ocupação ECC	90	3	78 - 96	86	4	72 - 93
Total pacientes triados	74	12	34 - 101	56	12	33 - 97
Pacientes EM	1	1	0 - 5	1	1	0 - 5
Pacientes MU	37	8	14 - 58	26	7	14 - 48
Pacientes U	33	7	11 - 53	26	6	10 - 45

TT: Soma total dos TPEH de todos os pacientes presentes no dia em análise; TTSC: Soma do TPEH somente dos pacientes que entraram e saíram no mesmo dia, além de contabilizar os que tiveram alta ou foram admitidos na EH no dia em análise; TM: TPEH médio de todos os pacientes; TMSC: TPEH médio somente daqueles que não permaneceram o dia completo. CCA: centro cirúrgico ambulatorial. CTI: centro de tratamento intensivo. ECC: enfermarias clínicas e cirúrgicas. EM: emergência; MU: muito urgente; U: urgente

**Tabela 3.2:** Testes de hipóteses para as médias das variáveis observadas em dias da semana e em finais de semana, com intervalo de confiança de 95%


Variáveis dependente e independentes	Dias da semana vs finais de semana	
	CI (95%)	valor <i>p</i>
TT	9.957,90 / 18.779,90	p<0,01
TTSC	12.523,20 / 16.802,80	p<0,01
TM	-52,50 / -4,40	p<0,01
TMSC	45,43 / 82,45	p<0,01
Tomografias	63,88 / 73,20	p<0,01
Ecografias	47,25 / 54,96	p<0,01
Ressonâncias Magnéticas	14,41 / 17,18	p<0,01
Cirurgias eletivas no bloco	24,56 / 28,47	p<0,01
Cirurgias de urgência no bloco	1,86 / 2,89	p<0,01
Cirúrgias eletivas no CCA	73,68 / 83,45	p<0,01
Cirurgias de urgência no CCA	2,08 / 3,42	p<0,01
Médicos	180,17 / 202,00	p<0,01
Enfermeiros	83,51 / 95,02	p<0,01
Técnicos em enfermagem	123,66 / 142,06	p<0,01
Taxa de ocupação CTI	-2,52 / 0,13	p=0,078
Taxa de ocupação ECC	2,31 / 4,16	p<0,01
Total pacientes triados	15,35 / 21,12	p<0,01
Pacientes EM	-0,01 / 0,57	p=0,078
Pacientes VU	8,93 / 12,42	p<0,01
Pacientes U	15,35 / 21,12	p<0,01

TT: Soma total dos TPEH de todos pacientes presentes no dia em análise; TTSC: Soma do TPEH somente dos pacientes que entraram e saíram no mesmo dia, além de contabilizar os que tiveram alta ou foram admitidos na EH no dia em análise; TM: TPEH médio de todos os pacientes; TMSC: TPEH médio somente daqueles que não permaneceram o dia completo. CCA: centro cirúrgico ambulatorial. CTI: centro de tratamento intensivo. ECC: enfermarias clínicas e cirúrgicas. EM: emergência; MU: muito urgente; U: urgente

**Tabela 3.3:** MAPE da previsão do TPEH pelo número de componentes principais incluídas no modelo, variância explicada e autovalores da matriz de correlação

CP	Variância explicada	Dias da semana				Finais de semana			
		TT	TTSC	TM	TMSC	TT	TTSC	TM	TMSC
1	55,80%	8,45%	9,34%	5,76%	8,75%	17,95%	14,21%	8,63%	11,78%
2	65,47%	8,41%	9,30%	5,68%	8,81%	16,64%	13,19%	8,34%	11,66%
3	72,52%	8,48%	9,35%	5,83%	8,80%	16,45%	13,10%	8,36%	11,94%
4	78,36%	8,52%	9,36%	5,82%	8,85%	16,06%	12,96%	8,38%	11,40%
5	83,95%	8,68%	9,40%	5,84%	8,88%	16,02%	12,97%	8,43%	11,31%
6	88,35%	8,78%	9,41%	5,83%	8,89%	16,20%	13,06%	8,52%	11,33%
7	92,10%	8,78%	9,42%	5,86%	8,89%	16,83%	13,18%	8,89%	11,42%
8	95,34%	8,76%	9,41%	5,87%	8,87%	16,83%	13,23%	8,93%	11,38%
9	97,20%	8,79%	9,46%	5,88%	8,89%	17,04%	13,44%	9,03%	11,46%
10	98,01%	8,80%	9,47%	5,88%	8,90%	17,08%	13,41%	9,08%	11,53%
11	98,66%	8,81%	9,53%	5,90%	8,97%	17,31%	13,43%	9,21%	11,59%
12	99,24%	8,86%	9,66%	5,92%	9,04%	17,48%	13,48%	9,37%	11,72%
13	99,64%	8,86%	9,61%	5,93%	8,99%	17,56%	13,56%	9,39%	11,79%
14	99,87%	8,84%	9,57%	5,93%	8,98%	17,54%	13,60%	9,39%	11,86%
15	99,95%	8,84%	9,57%	5,93%	8,98%	17,79%	13,74%	9,54%	11,95%
16	100,00%	8,84%	9,57%	5,93%	8,98%	17,76%	13,82%	9,45%	12,02%

**Figura 3.2:** Scree plot dos autovalores associados aos componentes principais obtidos a partir da matriz de correlações das variáveis independentes





**4. Artigo 3: Impacto dos processos internos do hospital no tempo de permanência dos pacientes na emergência hospitalar**

Rafael Calegari<sup>1</sup>, Flavio S. Fogliatto<sup>1</sup>, Filipe R. Lucini<sup>1</sup>, Jeruza Neyeloff<sup>2</sup>,

Beatriz D. Schaan<sup>2</sup>

<sup>1</sup>Departamento de Engenharia de Produção, Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil;

<sup>2</sup>Divisão de Endocrinologia, Hospital de Clínicas de Porto Alegre/Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil;

## Resumo

**Objetivos:** O presente estudo tem o objetivo de identificar e quantificar os fatores que, de forma independente, influenciam o tempo de permanência dos pacientes em uma emergência hospitalar (EH) com alto grau de congestionamento.

**Métodos:** O estudo foi conduzido no Hospital de Clínicas de Porto Alegre (HCPA), que é um hospital escola localizado no Brasil. Os dados diários foram coletados de 1 de janeiro de 2014 a 31 de dezembro de 2014. Foram realizadas simulações em um modelo de regressão baseado em mínimos quadrados parciais (PLS – *partial least squares*), utilizando como variáveis independentes números diários de exames, profissionais, taxas de ocupação e número de pacientes triados.

**Resultados:** Durante o período analisado 21918 pacientes foram atendidos na EH, com tempo de permanência na emergência (TPEH) médio de 2928 minutos, variando entre 3 e 13182 minutos. Observou-se diferente comportamento das variáveis dos dias de semana e finais de semana. Para os dias da semana a variável que demonstrou maior influência no TPEH médio foi o número de tomografias realizadas, o aumento do número de exames acarretou um aumento no TPEH. Nos finais de semana a taxa de ocupação nas enfermarias clínicas e cirúrgicas (ECC) foi a que apresentou a maior influência, de modo que o aumento da ocupação também acarretou um aumento no TPEH.

**Conclusões:** Nosso estudo analisou a influência de dezesseis variáveis independentes, todas relacionadas a fatores internos do hospital, no TPEH, em uma EH de alto grau de congestionamento. Variáveis que apareceram como estatisticamente significativas são discutidas neste trabalho; no entanto, outras de difícil mensuração não puderam ser contempladas em nossa modelagem, tais como a habilidade e conhecimentos dos funcionários, estão abertas para investigação em estudos futuros.

## 4.1 Introdução

A superlotação em emergências hospitalares (EH) é um problema que afeta hospitais no mundo inteiro (FATOVICH et al., 2003). Já existem fortes evidências apoiando a relação entre a superlotação de EH e (i) pacientes que saem sem receber atendimento (POLEVOI et al., 2004), (ii) redução da qualidade do atendimento a pacientes com doenças graves (PINES et al., 2006) e (iii) aumento da mortalidade de pacientes (RICHARDSON, 2009). Muitos estudos propuseram formas de superar esse problema através da revisão dos processos operacionais (PARK et al., 2008; HOLM & DAHL, 2009; KUO et al., 2012; BATARSEH et al., 2013); porém quando uma mudança nos processos não é viável, o correto gerenciamento do fluxo dos pacientes surge como a alternativa mais efetiva (KOLKER, 2008; RABIN et al., 2012; KADRI et al., 2014; SCHWEIGLER et al., 2009). Lim et al. (2012) definem o fluxo de pacientes na EH como o intervalo que compreende a entrada do paciente na triagem, seguido pelo registro, alocação em um leito da EH, avaliação clínica, tratamento, e o encaminhamento do paciente. Pela grande importância do gerenciamento desse fluxo no bom funcionamento do hospital, um grande volume de estudos vem tentando identificar formas de auxiliar os gestores das EH (RUOHONEN et al., 2006; KHURMA et al., 2008; BECK et al., 2009; WENG et al., 2011; KUO et al., 2012; BATARSEH et al., 2013; KADRI et al., 2014).

Definido como o tempo entre o registro do paciente após a triagem até sua transferência para outra área, internação ou alta (GARDNER et al., 2007), o tempo de permanência na EH (TPEH) já é uma ferramenta amplamente utilizada e consolidada de comparação de eficiência no fluxo dos pacientes (ASPLIN, 2006; RATHLEV et al., 2007). Entender o que influi nesse tempo de permanência e qual a contribuição das áreas do hospital, é um ponto fundamental na melhoria desse fluxo (KRALL et al., 2014). Analisando dados obtidos em uma EH nos Estados Unidos, Rathlev et al. (2007) utilizaram auto-regressão

integrado de média móvel (ARIMA - *autoregressive integrated moving average*), para identificar que o número de cirurgias eletivas, número de admissões na EH e ocupação do hospital, estavam de forma independente associados com o aumento do TPEH em uma EH específica. Já Wiler et al. (2012) analisaram dados de nove diferentes EH também nos Estados Unidos, concluindo que o aumento no TPEH se dava em dias com alto volume de admissão, utilização das ambulâncias em distâncias mais longas e durante os dias da semana. Gardner et al. (2006) identificaram que os fatores que de forma independente influenciavam o TPEH são: etnia hispânica (20 minutos), ocasionados pela dificuldade de comunicação entre línguas diferentes; exames de tomografias ou ressonâncias magnéticas (36 minutos), relacionado ao tempo necessário para preparo dos pacientes, transporte e análise dos resultados; e localização do hospital em uma área metropolitana (32 minutos). É importante ressaltar que nos estudos acima os TPEH observado foram 241, 324 e 255 minutos, claramente não refletem a realidade dos países em desenvolvimento nos quais são observados valores muito superiores (MATTA & PEPE, 2008).

Outros estudos utilizam simulação para identificar fatores que afetam o TPEH. De uma forma geral, analisam a influência da alocação de recursos disponíveis (WENG et al., 2011; BECK et al., 2009; RUOHONEN et al., 2006), de alterações nos métodos de triagem (BATARSEH et al., 2013; KUO et al., 2012) e alterações na equipe de profissionais (KHURMA et al., 2008) no TPEH. Beck et al. (2009), simularam a influência de alterações na alocação de recursos no TPEH, considerando número de leitos e funcionários, para diferentes níveis de chegada de pacientes. Em uma EH na Noruega, Holm & Dahl (2009) aplicaram uma simulação para identificar se a alteração nos processos de triagem reduziriam o TPEH, identificando que a substituição das enfermeiras por médicos em horários de pico reduziram 4,6% o TPEH. Park et al. (2008) aplicaram um modelo de previsão para o número de pacientes que procuraram atendimento em uma EH nos Estados Unidos, simulando em

seguida a influência do número de enfermeiros, leitos, e médicos no TPEH. Sendo assim, a utilização de simulação em EH já é uma ferramenta bastante utilizada e que pode auxiliar fortemente a tomada de decisões em hospitais (GUL & GUNERI, 2015).

Em geral, a literatura aponta para excesso de demanda e recursos escassos como os responsáveis pelo alto TPEH. Considerando o modelo de fluxo de pacientes composto por entrada/transporte/saída, que fornece uma estrutura para examinar os fatores que afetam o acesso à EH, qualidade e resultados dos tratamentos, uma questão crítica que deve ser avaliada é se o hospital possui os sistemas e capacidade para mover os pacientes mais doentes da EH para unidades de cuidados críticos ou outras unidades de internação (WILSON et al., 2005). Questiona-se então se determinados fatores internos, como recursos humanos disponíveis, realização de exames e cirurgias, e a própria taxa de ocupação de leitos hospitalares, teriam impacto no TPEH. Sendo assim, o presente estudo tem como objetivo identificar e quantificar os fatores, internos e externos à EH, que de forma independente contribuem para o aumento do TPEH. A identificação desses fatores é de suma importância, pois baseado neles é possível localizar os gargalos do fluxo, concentrando esforços em futuras mudanças operacionais e estruturais.

## **4.2 Métodos**

### **4.2.1 Planejamento do estudo e cenário**

Trata-se de um estudo retrospectivo, que utiliza dados históricos de procura por atendimento médico na EH, para aplicar um modelo de previsão do TPEH. O estudo foi conduzido no Hospital de Clínicas de Porto Alegre (HCPA), que é um hospital escola localizado na região sul do Brasil e que conta com 843 leitos e aproximadamente 32000 admissões/ano. A EH do HCPA opera 24 horas por dia, 7 dias por semana ao longo de todo o

ano e trata pacientes do Sistema Único de Saúde (SUS). Recebe pacientes da cidade de Porto Alegre e da região metropolitana, totalizando uma população de aproximadamente 4 milhões. O comitê de ética do HCPA aprovou o estudo e os autores cumpriram as recomendações da declaração de Helsinki. Os dados de entrada foram os TPEH dos pacientes atendidos na EH.

#### 4.2.2 Protocolo do estudo

As informações sobre o hospital e o TPEH foram extraídas da base de dados corporativa do hospital, compreendendo atendimentos entre 1 de janeiro a 31 de dezembro de 2014, sendo removido das análises o mês de outubro, período que a EH passou por reformas e restringiu temporariamente o número de atendimentos. Os dados foram processados de forma diária, das 00:00:00 hora às 23:59:59 horas de cada dia. Dados sobre o TPEH dos pacientes foram trabalhados individualmente, tendo em vista que grande parte dos pacientes permaneceu mais de um dia na EH.

Considerando que muitos pacientes permanecem mais de um dia em observação na EH, em função da limitação da oferta de leitos, para critérios gerenciais é importante separar esses pacientes daqueles que entram e saem no mesmo dia. Para isso, no presente estudo abordou-se o TPEH de quatro formas: *(i)* soma total dos TPEH de todos pacientes presentes no dia em análise (TT); *(ii)* soma do TPEH somente dos pacientes que entraram e saíram no mesmo dia, além de contabilizar os que tiveram alta ou foram admitidos no dia em análise (TTSC), i.e., não contabiliza os pacientes que permaneceram o dia completo; *(iii)* TPEH médio de todos os pacientes (TM); *(iv)* TPEH médio somente daqueles que não permaneceram o dia completo (TMSC).

### 4.2.3 Análise dos dados

Utilizamos regressão baseada em mínimos quadrados parciais (PLS - *partial least square*) para modelar a influência das variáveis independentes sobre a TPEH dos pacientes na EH em análise. A escolha do PLS é justificada por duas razões principais. Primeiro, ele explica a alta multicolinearidade entre as variáveis independentes observadas em nossa amostra; segundo, permite a modelagem simultânea de variáveis dependentes altamente correlacionadas. O PLS maximiza a correlação entre os conjuntos de variáveis dependentes e independentes, que são primeiro ortogonalizados para remover multicolinearidade (DUDEK, 2015). Quatro variáveis dependentes e dezesseis variáveis independentes foram consideradas em nossa modelagem. As variáveis dependentes são: TT ( $y_1$ ), TTSC ( $y_2$ ), TM ( $y_3$ ) e TMSC ( $y_4$ ). As variáveis independentes são: número de exames de tomografias ( $x_1$ ), ecografias ( $x_2$ ) e ressonâncias magnéticas ( $x_3$ ); número de cirurgias eletivas no bloco ( $x_4$ ), de urgência no bloco ( $x_5$ ), eletivas no centro cirúrgico ambulatorial (CCA) ( $x_6$ ) e de urgência no CCA ( $x_7$ ); quantidade de médicos ( $x_8$ ), enfermeiros ( $x_9$ ) e técnicos em enfermagem trabalhando ( $x_{10}$ ); taxa de ocupação do centro de terapia intensiva (CTI) ( $x_{11}$ ), taxa de ocupação nas enfermarias clínicas e cirúrgicas (ECC) ( $x_{12}$ ); número total de pacientes acolhidos no EH ( $x_{13}$ ), pacientes classificados como emergência ( $x_{14}$ ), muito urgente ( $x_{15}$ ) e urgente ( $x_{16}$ ). Todas as modelagens foram realizadas no MATLAB R2012b e Minitab 14.

O número de exames, cirurgias e funcionários se referem aos valores diários de todo hospital. As taxas de ocupação são calculadas dividindo o número de pacientes presentes às 00:01 horas do dia em análise, pela capacidade de leitos do setor. Já a classificação dos pacientes, definida na triagem, segue os critérios do Sistema de Triagem de Manchester (STM) (MACKWAY-JONES, 1997). Este sistema organiza os critérios de atendimento em cinco níveis de prioridade. As categorias são identificadas por cores, descrição do caso e

tempos estimados de atendimento (TEA); são elas: (i) vermelho – emergência (EM), necessita atendimento imediato, TEA = 0 minutos; (ii) laranja – muito urgente (MU), necessita atendimento com urgência, TEA  $\leq$  10 minutos; (iii) amarelo – urgente (U), paciente possui condições clínicas para aguardar atendimento, TEA  $\leq$  60 minutos; (iv) verde – pouco urgente (PU), paciente pode ser direcionado para o serviço ambulatorial, TEA  $\leq$  120 minutos; (v) azul – não urgente (NU), paciente deve ser direcionado para o serviço ambulatorial, TEA  $\leq$  240 minutos; e (vi) branco – não classificado. Como 96% dos pacientes são classificados como EM, MU e U, apenas estes foram incluídos na análise.

As rotinas de regressão do PLS padronizam as variáveis antes da determinação do modelo, com o intuito de remover os efeitos de escala, além de permitir a comparação direta dos coeficientes de regressão. O modelo PLS é construído regredindo as variáveis dependentes em componentes principais obtidos da ortogonalização da matriz de correlação das variáveis independentes. Para avaliar a importância das variáveis independentes, um mapeamento dos coeficientes deve ser executado considerando os coeficientes de regressão associados com componentes principais e as cargas das variáveis originais dentro de cada componente (CHATTERJEE & HADI, 2006). No entanto, a comparação direta dos coeficientes resultantes do mapeamento pode não ser intuitivo devido à padronização das variáveis originais. Além disso, o significado estatístico do efeito das variáveis independentes originais sobre a variável dependente não podem ser avaliados, uma vez que a modelagem PLS utiliza componentes principais, e não as variáveis originais. Uma alternativa é usar os modelos PLS num estudo de simulação, variando os níveis de variáveis independentes individualmente e analisando o efeito correspondente sobre a variável dependente. Foi realizada tal simulação analisando os impactos do aumento do valor de cada variável independente em 1,5 desvios-padrão. Detalhes sobre a simulação são fornecidos na próxima seção.



#### 4.2.4 Validação e avaliação do modelo

Para garantir a estabilidade do modelo PLS, foram realizadas 1000 iterações na rotina de ajuste do modelo. Em cada iteração, os dias incluídos nos intervalos de treino e teste foram aleatoriamente variados, mantendo sempre a proporção de 9:1 entre os intervalos. Os modelos PLS finais são indicados pelas médias dos coeficientes de regressão obtidas nas iterações.

Ao testar a precisão dos modelos de previsão e executar a simulação mencionada na seção anterior, foram considerados os 1000 modelos resultantes das iterações. A precisão da previsão dos modelos foi medida comparando os valores do TPEH observados com aqueles previstos por cada modelo PLS durante o intervalo de testes do conjunto de dados, utilizando o erro médio percentual absoluto (MAPE - *mean absolute prediction error*). Sendo uma medida que não é afetada pelo efeito de escala, o MAPE permite a comparação direta dos resultados de diferentes modelos. A estatística dá a média das diferenças absolutas entre os valores previstos e os observados, expressos em percentagens; quanto menor o valor MAPE, mais precisas são as previsões obtidas a partir do modelo.

No presente estudo todas as 1000 saídas geradas pelo modelo PLS foram consideradas. Foi realizada a comparação das médias dos resultados com o cenário de referência, no qual todas as variáveis eram mantidas em seus respectivos valores médios, e o cenário alternativo, no qual as variáveis independentes sofriam um incremento de 1,5 desvios-padrão.

### 4.3 Resultados

Durante o período analisado nesse estudo, 21918 pacientes foram atendidos na EH, resultando em TPEH médio de 2928 minutos, variando entre 3 e 13182 minutos. As médias e intervalos diários das variáveis dependentes e independentes são mostrados na Tabela 1. Esses valores se referem somente aos pacientes que foram triados, não considerando os que desistiram do atendimento ou que foram encaminhados para atendimento em outros locais. Como esperado, observou-se comportamento diferente das variáveis dos dias de semana para os finais de semana.

A maioria das variáveis dependentes e independentes apresentou um comportamento bimodal durante toda a semana com dois picos de frequência, a maior observada durante a semana. Feriados nacionais e os dias seguintes e anteriores a eles apresentaram um comportamento semelhante ao observado nos fins de semana, e foi tratado como tal. Para validar o comportamento bimodal das variáveis, e estratificar a amostra adequadamente, realizou-se um teste de hipóteses sobre os valores médios de todas as variáveis, resultando em  $p$ -valores demonstrados na Tabela 1. Considerando um nível de significância de 5%, todas as variáveis apresentaram diferenças entre os dias de semana e finais de semana, com exceção de duas: taxa de ocupação da unidade de tratamento intensiva (UTI) ( $x_{11}$ ), e o número de pacientes classificados como de emergência ( $x_{14}$ ). Levando em consideração estes resultados, o banco de dados foi dividido em dias de semana e finais de semana, e os modelos de regressão foram aplicados separadamente.

Entre as quatro abordagens consideradas no cálculo do TPEH dos pacientes, TM foi a que apresentou o melhor ajuste, tanto para dias de semana quanto para os finais de semana: os valores de MAPE de 5,68% e 8,34%, respectivamente, foram obtidos utilizando apenas dois componentes principais na regressão. Os menores valores de MAPE obtidos para as

variáveis dependentes TT, TTSC, e TSMC foram 8,41%, 9,30% e 8,75% (dias de semana), e 16,02%, 12,96% e 11,31% (finais de semana). Modelos obtidos utilizando os dias de semana do conjunto de dados foram claramente mais precisos, o que pode ser explicado pela maior variância observada em variáveis dependentes e independentes durante finais de semana e feriados.

Os resultados das simulações são apresentados na Tabela 2. Nós testamos o efeito de um aumento de 1,5 desvios-padrão dos valores de cada variável independente sobre os indicadores do TPEH, em dias de semana e finais de semana. Os resultados variam de acordo com o indicador do TPEH e o conjunto de dados (dias de semana e finais de semana). Considerando a variável dependente TM, que produziu os modelos de regressão com menores valores de MAPE, a variável independente com maior impacto no TPEH durante a semana foi o número de tomografias realizadas: um aumento de 27 unidades em  $x_1$  (ou seja, realizar 27 tomografias acima da média de 95, durante a semana) leva a um aumento de 17,6 minutos no TM. Outras variáveis independentes com impacto significativo na TM (em ordem decrescente de importância) foram o número de cirurgias eletivas no bloco cirúrgico ( $x_4$ ), número de médicos ( $x_8$ ), e o número de enfermeiros ( $x_9$ ). Considerando-se o modelo de regressão para o TM nos finais de semana, a variável independente com maior impacto no TPEH foi a taxa de ocupação das enfermarias clínicas e cirúrgicas (ECC): um aumento de 6% no  $x_{12}$  acima da média diária de 86% nos finais de semana, gera um aumento de 60 minutos no TM. Outras variáveis independentes com impacto significativo sobre TM foram o número de cirurgias eletivas no bloco cirúrgica e o número de tomografias realizadas.

#### 4.4 Discussão

Análises preliminares realizadas no banco de dados demonstraram uma diferença significativa no comportamento da maioria das variáveis em dias de semana e finais de semana. Os mesmos resultados foram relatados por Wiler et al. (2012), e Rathlev et al. (2007) ao analisar dados semelhantes. Além disso, as análises direcionadas ao TPEH demonstraram valores médios maiores do que os observados em países desenvolvidos; veja Rathlev et al. (2007) e Wiler et al. (2012), entre outros. Dado o número limitado de estudos que analisam TPEH de pacientes nas emergências dos países em desenvolvimento, os nossos resultados e os relatados por Matta & Pepe (2008) podem servir como base para futuras pesquisas sobre o tema. Dada a falta de estudos sobre o TPEH em emergências de países em desenvolvimento, optamos por explorar o indicador em quatro abordagens diferentes, contribuindo para ampliar o conhecimento sobre o assunto na literatura. Os melhores resultados da modelagem foram obtidos quando se utilizou a abordagem TM como variável dependente. Acreditamos que em EH com características similares à investigada aqui, o TM diário pode ser usado como indicador para avaliar a melhoria do fluxo do paciente.

Pelo melhor ajuste ao modelo de regressão, TM é a variável dependente mais abordada na discussão. A maioria dos resultados obtidos está alinhada tanto com a observação empírica quanto com os resultados disponíveis na literatura. Esse é o caso, por exemplo, do impacto das tomografias realizadas diariamente na TM (cada 27 exames realizados gera um aumento de 17,6 minutos no TM, e 14,8 no TMSC). Este resultado está alinhado com os publicados por Gardner et al. (2007), que também verificaram uma relação positiva entre o número de tomografias diárias realizadas e o TPEH, com base em uma amostra de 360 EH nos Estados Unidos. A relação positiva entre o número de tomografias e o TPEH também vai ao encontro das opiniões dos médicos que trabalham na EH do HCPA; eles relatam que em

dias com alta demanda de tomografias as análises dos exames de pacientes menos urgentes são postergadas, o que tem um impacto direto no TPEH.

Como esperado, a taxa de ocupação nas ECC foi a variável com maior influência sobre o TPEH, entre todas as variáveis investigadas. Nos finais de semana 6% de aumento na taxa de ocupação leva a um aumento de 60 minutos no TM. O número de cirurgias eletivas nos dias de semana também apresentou influência na TM: o aumento de 7 cirurgias no bloco cirúrgico leva a um aumento de 16,5 minutos em TM. Em relação ao número de profissionais no hospital, sabe-se que o número de médicos, enfermeiros e técnicos de enfermagem de plantão tem um impacto sobre o fluxo de pacientes. Esses profissionais estão ativamente envolvidos em todas as atividades hospitalares, influenciando diretamente no tempo de admissão e alta dos pacientes. No HCPA dados apontam para um aumento no TPEH com o aumento do número de médicos e enfermeiros de plantão. Isso pode ser explicado pelo redirecionamento dos funcionários do hospital em dias de mais movimento na EH; aumentando o número de funcionários temporários na EH aumenta a sua capacidade de admissões, como demonstrado nos resultados da regressão.

O número de pacientes que procuram atendimento médico em EH é frequentemente utilizado como variável explicativa em modelos em que o TPEH é a variável dependente; veja Rathlev et al. (2007), Lucas et al. (2009) e Wiler et al. (2012). Utilizando dados de um centro de traumas nível 1, Rathlev et al. (2007) concluíram que cada admissão na EH gerou um aumento de 2,19 minutos no TPEH médio. Analisando dados de 5 hospitais em diferentes locais nos Estados Unidos, Lucas et al. (2009) também descobriram que a única variável que poderia explicar significativamente o TPEH dos pacientes foi o número de admissões na EH. Nossos resultados, por outro lado, não apontam como significativa a relação entre o número de admissões e o TPEH. Os mesmos resultados foram encontrados por Wiler et al. (2012) ao

analisar dados de 9 EH também nos Estados Unidos. A explicação para isto é que o número de entradas na EH é relativamente constante ao longo do tempo.

Alguns resultados do presente estudo são de difíceis explicações, e devem ser o objeto de estudos em pesquisas futuras. Por exemplo, não há nenhuma explicação trivial para o fato de que algumas variáveis independentes impactam positivamente o TPEH durante a semana, e negativamente nos fins de semana. Esse é o caso de tomografias realizadas, que apresentam um impacto altamente positivo no TM nos dias de semana, e impacto altamente negativo em fins de semana. Outra situação de difícil explicação é o fato de algumas variáveis possuírem um impacto significativo quando analisadas sob o ponto de vista de um determinado indicador, mas não em outro muito semelhante ao anterior. Esse é o caso do número de cirurgias eletivas no centro cirúrgico, que são significativos no TM, mas não TT. Essas são algumas possíveis explicações para tais resultados inesperados. Em primeiro lugar, a operação de EH em dias de semana e finais de semana são sabidamente diferentes. Assim, outras variáveis independentes não investigadas aqui podem ser capazes de explicar um pouco melhor o que acontece nos finais de semana. Em segundo lugar, a modelagem PLS não considera as interações entre as variáveis independentes. Não é incomum que alguns efeitos não intuitivos em fatores principais são compensados por termos de interação significativos. Isso não pode ser avaliado no modelo de regressão PLS, mas poderia ser a explicação de alguns resultados aparentemente inconsistentes.

#### **4.5 Limitações**

A principal limitação do estudo é o fato de que somente uma EH foi utilizada para as análises. Dessa forma, os resultados podem ser considerados somente para hospitais com características semelhantes as do presente estudo. Para resultados definitivos, recomenda-se a

aplicação do estudo em hospitais com características diferentes, ou até mesmo em países com características diferentes.

#### 4.6 Conclusões

Sabe-se que os hospitais possuem estruturas organizais complexas e que a qualidade do serviço prestado depende de muitos fatores. Estudos anteriores apontam muitas variáveis, internas e externas do hospital, que podem influenciar o TPEH. Nosso estudo analisou a influência de dezesseis fatores internos do hospital no TPEH em uma EH de alto grau de congestionamento. Através de uma simulação, identificou-se que, dentre as dezesseis variáveis abordadas, o número de exames de tomografias é a que mais influencia o TPEH nos dias de semana e a taxa de ocupação nas ECC nos finais de semana. Algumas variáveis demonstraram ser significativas, porém, pela falta de resultados mais expressivos, acredita-se que fatores não avaliados possam ter maior influência sobre o TPEH. Até mesmo variáveis de difícil mensuração, como a habilidade e conhecimento dos funcionários, por exemplo, devem de alguma maneira ser adicionados em futuros trabalhos.

#### 4.7 Referências

ABRAHAM, G.; BYRNES, G. B.; BAIN, C. A. Short-term forecasting of emergency inpatient flow. **Information Technology in Biomedicine, IEEE Transactions on**, v. 13, n. 3, p. 380-388, 2009.

ASPLIN, B. R. Measuring crowding: time for a paradigm shift. **Academic Emergency Medicine**, v. 13, n. 4, p. 459-461, 2006.

BATAL, H.; TENCH, J.; MCMILLAN, S.; ADAMS, J.; MEHLER, P. S. Predicting patient visits to an urgent care clinic using calendar variables. **Academic Emergency Medicine**, v. 8, n. 1, p. 48-53, 2001.

BATARSEH, O. G.; GOLDLUST, E. J.; DAY, T. E. SYSML for conceptual modelling and simulation for analysis: A case example of a highly granular model of an emergency department. In: **Winter simulation conference**. Winter Simulation Conference, 2013. p. 2398–2409.

BECK, E.; BALASUBRAMANIAN, H.; HENNEMAN, P. L. Resource management and process change in a simplified model of the emergency department. In: **Winter simulation conference**. Winter Simulation Conference, 2009. p. 1887-1895.

CHATTERJEE, S.; HADI, A. S. **Regression analysis by example**. John Wiley & Sons, 2015.

DERLET, R. W.; RICHARDS, J. R. Overcrowding in the nation's emergency departments: complex causes and disturbing effects. **Annals of emergency medicine**, v. 35, n. 1, p. 63-68, 2000.

DUDEK, Grzegorz. Pattern-based local linear regression models for short-term load forecasting. **Electric Power Systems Research**, v. 130, p. 139-147, 2016.

FATOVICH, D. M.; NAGREE, Y.; SPRIVULIS, P. Access block causes emergency department overcrowding and ambulance diversion in Perth, Western Australia. **Emergency Medicine Journal**, v. 22, n. 5, p. 351-354, 2005.

FORERO, R.; HILLMAN, K. M.; MCCARTHY, S.; FATOVICH, D.M.; JOSEPH, A. P.; RICHARDSON, D. B. Access block and ED overcrowding. **Emergency Medicine Australasia**, v. 22, n. 2, p. 119-135, 2010.

GARDNER, R. L.; SARKAR, U.; MASELLI, J. H.; GONZALES, R. Factors associated with longer ED lengths of stay. **The American journal of emergency medicine**, v. 25, n. 6, p. 643-650, 2007.

GENTILE, S.; VIGNALLY, P.; DURAND, A. C.; GAINOTTI, S.; SAMBUC, R.; GERBEAUX, P. Nonurgent patients in the emergency department? A French formula to prevent misuse. **BMC health services research**, v. 10, n. 1, p. 1, 2010.



GUL, M.; GUNERI, A. F. Forecasting patient length of stay in an emergency department by artificial neural networks. **Journal of Aeronautics & Space Technologies/Havacilik ve Uzay Teknolojileri Dergisi**, v. 8, n. 2, 2015.

HOLM, L. B.; DAHL, F. A. Simulating the effect of physician triage in the emergency department of Akershus University Hospital. In: **Winter Simulation Conference**. Winter Simulation Conference, 2009. p. 1896-1905.

HOOT, N. R.; ARONSKY, D. Systematic review of emergency department crowding: causes, effects, and solutions. **Annals of emergency medicine**, v. 52, n. 2, p. 126-136.e1, 2008.

KADRI, F.; HARROU, F.; CHAABANE, S.; TAHON, C. Time series modelling and forecasting of emergency department overcrowding. **Journal of medical systems**, v. 38, n. 9, p. 1-20, 2014

KHURMA, N.; BACIOIU, G. M.; PASEK, Z. J. Simulation-based verification of lean improvement for emergency room process. In: **Winter simulation conference**. Winter Simulation Conference, 2008. p. 1490–1499.

KOLKER, A. Process modeling of emergency department patient flow: Effect of patient length of stay on ED diversion. **Journal of Medical Systems**, v. 32, n. 5, p. 389-401, 2008.

KRALL, S. P.; CORNELIUS, A. P.; ADDISON, J. B. Hospital factors impact variation in emergency department length of stay more than physician factors. **Western Journal of Emergency Medicine**, v. 15, n. 2, p. 158, 2014.

KUO, Y. H.; LEUNG, J. M.; GRAHAM, C. A. Simulation with data scarcity: Developing a simulation model of a hospital emergency department. In: **Winter simulation conference**. Winter Simulation Conference, 2012. p. (pp. 1–12).

LI, J. S.; TIAN, Y.; LIU, Y. F.; SHU, T.; LIANG, M. H. Applying a BP neural network model to predict the length of hospital stay. In: **Health Information Science**. Springer Berlin Heidelberg, 2013. p. 18-29.

LITVAK, E.; LONG, M. C.; COOPER, A. B.; MCMANUS, M. L. Emergency department diversion: causes and solutions. **Academic emergency medicine: official journal of the Society for Academic Emergency Medicine**, v. 8, n. 11, p. 1108-1110, 2001.

LUCAS, R.; FARLEY, H.; TWANMOH, J.; URUMOV, A.; OLSEN, N.; EVANS, B.; KABIRI, H. Emergency department patient flow: the influence of hospital census variables on emergency department length of stay. **Academic Emergency Medicine**, v. 16, n. 7, p. 597-602, 2009.

MACKWAY-JONES K. ed. Emergency triage. London: Manchester Triage Group/**BMJ Books**, 1997.

MATTA, I. E. A. D.; PEPE, V. L. E. Evaluation of emergency hospital services in the state of Rio de Janeiro. **Ciência & Saúde Coletiva**, v. 13, n. 5, p. 1637-1648, 2008.

PARK, E. H.; PARK, J.; NTUEN, C.; KIM, D.; JOHNSON, K. Forecast driven simulation model for service quality improvement of the emergency department in the Moses H. Cone Memorial Hospital. **Asian Journal on Quality**, 2008 p. 1-14.

PINES, J. M.; HOLLANDER, J. E.; LOCALIO, A. R.; METLAY, J. P. The association between emergency department crowding and hospital performance on antibiotic timing for pneumonia and percutaneous intervention for myocardial infarction. **Acad Emerg Med**, v. 13, n. 8, p. 873-878, 2006.

POLEVOI, S. K.; QUINN, James V.; KRAMER, N. R. Factors associated with patients who leave without being seen. In: **Presented at the SAEM annual meeting**. 2004.

RABIN, E.; KOCHER, K.; MCCLELLAND, M.; PINES, J.; HWANG, U.; RATHLEV, N.; ASPLIN, B.; TRUEGER N. S.; WEBER, E. Solutions to emergency department 'boarding' and crowding are underused and may need to be legislated. **Health Affairs**, v. 31, n. 8, p. 1757-1766, 2012.

RATHLEV, N. K.; CHESSARE, J.; OLSHAKER, J.; OBENDORFER, D.; MEHTA, S. D.; ROTHENHAUS, T.; CRESPO, S.; MAGAURAN, B.; DAVIDSON, K.; SHEMIN, R.; LEWIS, K.; BECKER, J. M.; FISHER, L.; GUY, L.; COOPER, A.; LITVAK, E. Time series analysis of variables associated with daily mean emergency department length of stay. **Annals of emergency medicine**, v. 49, n. 3, p. 265-271, 2007.

RICHARDSON, D. B.; MOUNTAIN, D. Myths versus facts in emergency department overcrowding and hospital access block. **Medical Journal of Australia**, v. 190, n. 7, p. 369, 2009.

ROSIPAL, R.; KRÄMER, N. Overview and recent advances in partial least squares. In: **Subspace, latent structure and feature selection**. Springer Berlin Heidelberg, 2006. p. 34-51.

RUOHONEN, T.; NEITTAANMAKI, P.; TEITTINEN, J. Simulation model for improving the operation of the emergency department of special health care. In: **Winter simulation conference**. Winter Simulation Conference 2006. p. 453–458

SCHMIDT, M. I.; DUNCAN, B. B.; SILVA, G. A.; MENEZES, A. M.; MONTEIRO, C. A.; BARRETO, S. M.; CHOR, D.; MENEZES, P. R. Chronic non-communicable diseases in Brazil: burden and current challenges. **The Lancet**, v. 377, n. 9781, p. 1949-1961, 2011.

SCHWEIGLER, L. M.; DESMOND, J. S.; MCCARTHY, M. L.; BUKOWSKI, K. J.; IONIDES, E. L.; YOUNGER, J. G. Forecasting models of emergency department crowding. **Academic Emergency Medicine**, v. 16, n. 4, p. 301-308, 2009.

WENG, S. J.; CHENG, B. C.; KWONG, S. T.; WANG, L. M.; CHANG, C. Y. Simulation optimization for emergency department resources allocation. In: **Winter simulation conference**. Winter Simulation Conference 2006. p. 1231–1238.

WILER, J. L.; HANDEL, D. A.; GINDE A. A.; ARONSKY, D.; GENES, N. G.; HACKMAN, J. L.; HILTON, J. A.; HWANG, U.; KAMALI, M.; PINES, J. M.; POWELL, E.; SATTARIAN, M.; FU, R. Predictors of patient length of stay in 9 emergency departments. **The American journal of emergency medicine**, v. 30, n. 9, p. 1860-1864, 2012.

WILSON, M. J.; SIEGEL, B.; WILLIAMS, M. Perfecting patient flow: America's safety net hospitals and emergency department crowding. *National Association of Public Hospitals and Health Systems* 2005. 1(1): 1-39.

WOLD, S.; SJÖSTRÖM, M.; ERIKSSON, L. PLS-regression: a basic tool of chemometrics. *Chemometrics and intelligent laboratory systems*, v. 58, n. 2, p. 109-130, 2001.

**Tabela 4.1:** Média, desvio padrão, valores mínimos e máximos e significância das variáveis dependentes e independentes

Variáveis dependentes e independentes	Dias da semana			Finais de semana			p-valor
	Média	DP	MIN - MAX	Média	DP	MIN - MAX	
TT	117904	13708	75537 - 152390	103535	20573	37362 - 148648	p<0.001
TTSC	63790	8134	42353 - 97619	49127	9132	20460 - 73644	p<0.001
TM	964	73	766 - 1169	992	113	623 - 1241	p<0.001
TMSC	613	67	458 - 793	549	81	401 - 785	p<0.001
Tomografias	95	18	50 - 143	27	20	5 - 119	p<0.001
Ecografias	62	14	25 - 124	11	17	0 - 81	p<0.001
Ressonâncias Magnéticas	18	6	4 - 43	3	5	0 - 24	p<0.001
Cirurgias eletivas no bloco	33	5	10 - 46	7	9	0 - 43	p<0.001
Cirurgias de urgência no bloco	6	2	1 - 11	4	2	0 - 11	p<0.001
Cirurgias eletivas no CCA	89	15	27 - 119	10	23	0 - 102	p<0.001
Cirurgias de urgência no CCA	6	4	1 - 23	3	2	0 - 8	p<0.001
Médicos	279	21	222 - 315	88	56	43 - 315	p<0.001
Enfermeiros	181	16	150 - 218	91	28	64 - 207	p<0.001
Técnicos em enfermagem	438	25	374 - 498	305	44	239 - 453	p<0.001
Taxa de ocupação CTI	88	5	70 - 98	89	5	73 - 98	p=0.078
Taxa de ocupação ECC	90	3	78 - 96	86	4	72 - 93	p<0.001
Total pacientes triados	74	12	34 - 101	56	12	33 - 97	p<0.001
Pacientes EM	1	1	0 - 5	1	1	0 - 5	p=0.078
Pacientes MU	37	8	14 - 58	26	7	14 - 48	p<0.001
Pacientes U	33	7	11 - 53	26	6	10 - 45	p<0.001

TT: Soma total dos TPEH de todos pacientes presentes no dia em análise; TTSC: Soma do TPEH somente dos pacientes que entraram e saíram no mesmo dia, além de contabilizar os que tiveram alta ou foram admitidos na EH no dia em análise; TM: TPEH médio de todos os pacientes; TMSC: TPEH médio somente daqueles que não permaneceram o dia completo. CCA: centro cirúrgico ambulatorial. CTI: centro de tratamento intensivo. ECC: enfermarias clínicas e cirúrgicas. EM: emergência; MU: muito urgente; U: urgente; DP: desvio-padrão; MIN: mínimo; MAX: máximo.

**Tabela 4.2:** Efeito do aumento de 1,5 desvios padrão das variáveis independentes nos indicadores do TPEH

Variáveis	Dias de semana				Finais de semana			
	TT	TTSC	TM	TMSC	TT	TTSC	TM	TMSC
Tomografias	NS	NS	17,6	14,8	NS	-886,0	-22,0	NS
Ecografias	NS	NS	NS	NS	NS	857,0	NS	5,0
Ressonâncias Magnéticas	-1845,7	-1281,3	NS	NS	NS	12,0	NS	NS
Cirurgias eletivas no bloco	NS	NS	16,5	NS	NS	-1006,0	-25,0	NS
Cirurgias de urgência no bloco	NS	NS	NS	NS	NS	NS	NS	NS
Cirurgias eletivas no CCA	NS	NS	NS	NS	NS	2031,0	NS	11,0
Cirurgias de urgência no CCA	NS	NS	NS	NS	NS	NS	NS	NS
Médicos	2414,6	NS	12,1	NS	NS	1149,0	1,0	6,0
Enfermeiros	2809,5	NS	10,8	NS	NS	710,0	-4,0	3,0
Técnicos em enfermagem	1646,2	NS	NS	NS	NS	1811,0	NS	NS
Taxa de ocupação CTI	NS	1822,1	NS	13,6	NS	NS	NS	NS
Taxa de ocupação ECC	1584,1	1170,0	NS	NS	15575,0	6470,0	60,0	NS
Total pacientes triados	-2220,7	-1868,0	NS	NS	NS	NS	NS	NS
Pacientes EM	NS	NS	NS	NS	NS	NS	NS	NS
Pacientes MU	NS	-1079,2	NS	NS	NS	NS	NS	NS
Pacientes U	-1710,6	-1343,1	NS	NS	NS	1541,0	NS	NS

$p < 0,05$

NS: não significativo; TT: Soma total dos TPEH de todos pacientes presentes no dia em análise; TTSC: Soma do TPEH somente dos pacientes que entraram e saíram no mesmo dia, além de contabilizar os que tiveram alta ou foram admitidos na EH no dia em análise; TM: TPEH médio de todos os pacientes; TMSC: TPEH médio somente daqueles que não permaneceram o dia completo. CCA: centro cirúrgico ambulatorial. CTI: centro de tratamento intensivo. ECC: enfermarias clínicas e cirúrgicas. EM: emergência; MU: muito urgente; U: urgente; DP: desvio-padrão; MIN: mínimo; MAX: máximo.

## 5. Considerações Finais

### 5.1 Conclusões

A presente dissertação teve como objetivo geral avaliar os fatores que influenciam a procura por atendimento e o TPEH em EH com alto grau de congestionamento. Para atingir o objetivo geral, ele foi dividido em 5 objetivos específicos, apresentados em 3 artigos.

O primeiro artigo teve como objetivos: avaliar a influência de fatores climáticos e de calendário na procura por atendimento em uma EH com alto grau de congestionamento; e identificar os modelos de previsão que possuem maior acurácia na previsão da procura por atendimentos no HCPA, para pacientes estratificados conforme o STM. O estudo confirmou que a demanda diária para atendimentos na EH é caracterizado por padrões sazonais e semanais. Alguns fatores climáticos demonstraram correlação significativa com a procura por atendimento na EH, porém não aumentaram a precisão da previsão. Além disso, o artigo indica que os modelos de previsão baseados em séries temporais podem ser utilizados para previsões precisas em EH de alta complexidade, especialmente previsões para curto prazo. A precisão da previsão depende do modelo utilizado, horizonte de previsão e classificação do paciente no STM. Nas análises realizadas para o número total de pacientes, a suavização exponencial simples (SES) produziu os menores erros, independentemente do horizonte de previsão. Em geral, para os pacientes classificados como muito urgente (MU) e urgente (U), o modelo com o melhor desempenho foi o SARIMA.

O segundo artigo teve como objetivos: avaliar quatro indicadores relacionados ao TPEH para identificar qual a forma mais adequada para trabalhar com o fluxo de pacientes em EH com alto grau de congestionamento; e aplicar um modelo de previsão do TPEH baseado em regressão PLS. O artigo confirmou que o TPEH, número de exames realizados no hospital, número de funcionários, taxas de ocupação e número de pacientes procurando atendimento nos hospitais, possuem comportamento com diferenças significativas nos dias da semana e finais de semana. Além disso, aborda quatro formas diferentes de trabalhar com o TPEH para hospitais localizados em países em desenvolvimento, demonstrando que o TM de permanência dos pacientes gera resultados mais precisos do que o TT, TTSC e TMSC. Indica também que modelos de previsão do TPEH baseados em regressão PLS podem gerar bons resultados, até mesmo quando comparado com modelos mais complexos propostos em estudos anteriores.

O terceiro artigo teve como objetivo avaliar os fatores internos do hospital que, de forma independente, influenciam no TPEH. O artigo analisou a influência de dezesseis variáveis internas do hospital no TPEH em uma EH de alto grau de congestionamento. Através de uma simulação, identificou-se que dentre as dezesseis variáveis abordadas, o número de exames de tomografias é a variável que mais influencia o TPEH nos dias de semana e a taxa de ocupação nas ECC nos finais de semana. Algumas variáveis demonstraram ser significativas, porém, pela falta de resultados mais expressivos, acredita-se que fatores não avaliados possam ter maior influência sobre o TPEH.

Portanto, as considerações acima permitem afirmar que a dissertação foi coerente com o tema proposto e que os objetivos desta pesquisa, tanto geral como específicos, foram atingidos.

## **5.2 Sugestões para trabalhos futuros**

De uma forma geral, os artigos que aplicam modelos de previsão da procura por atendimentos em EH não estratificam os pacientes conforme a gravidade. De acordo com nossas pesquisas, o primeiro artigo da presente dissertação inovou ao avaliar modelos de previsão da procura por atendimento em pacientes classificados conforme a STM, porém utilizou os dados de somente uma EH. Acreditamos que quanto mais estratificada essa previsão, mais ela pode auxiliar os gestores das EH na otimização do fluxo dos pacientes. Dessa forma, sugere-se para trabalhos futuros aplicar outros modelos de previsão da procura por atendimento em outras EH que possuam o STM.

Apesar da complexidade da utilização de modelos de previsão baseados em PLS, eles são descritos na literatura como modelos com alto poder de predição. Nosso segundo artigo demonstrou que o PLS possui boa acurácia ao prever o TPEH em EH com alto grau de congestionamento, inclusive quando comparado com modelos mais complexos. Uma contribuição importante para a literatura seria a consolidação desse método no ambiente hospitalar, mais especificamente em EH. Por essa razão, sugere-se para trabalhos futuros a utilização da regressão PLS utilizando dados de outras EH. Além disso, no mesmo artigo, foram propostos quatro indicadores relacionados ao TPEH para EH onde os pacientes permanecem mais de um dia. Sugere-se também, que trabalhos futuros utilizem esses indicadores em outras EH ou proponham novos indicadores.

O terceiro artigo avaliou a influência de dezesseis fatores do hospital no TPEH no HCPA. Esses fatores eram relacionados aos números de exames, cirurgias, profissionais, pacientes atendidos e taxas de ocupação. Verificou-se que ainda há um número grande de fatores, não avaliados em nosso estudo, que podem influenciar esse TPEH. Alguns fatores de fácil mensuração, como os abordados em nosso estudo, e outros de difícil mensuração, como habilidade e conhecimento dos profissionais. Dessa forma, sugere-se para futuros trabalhos avaliar a influência de outros fatores no TPEH do HCPA, incluindo fatores de difícil mensuração. O principal desafio para esses futuros trabalhos será identificar a melhor forma de mensurar e modelar essas variáveis.