

IZABEL OLIVA MARCILIO DE SOUZA

**Previsão do volume diário de atendimentos no
serviço de pronto socorro de um hospital geral:
comparação de diferentes métodos**

Tese apresentada à Faculdade de Medicina
da Universidade de São Paulo para obtenção
do título de Doutor em Ciências

Programa de Medicina Preventiva

Orientador: Prof. Dr. Nelson da Cruz Gouveia

São Paulo

2013

Dados Internacionais de Catalogação na Publicação (CIP)

Preparada pela Biblioteca da
Faculdade de Medicina da Universidade de São Paulo

©reprodução autorizada pelo autor

Marcilio de Souza, Izabel Oliva

Previsão do volume diário de atendimentos no serviço de pronto socorro de um hospital geral : comparação de diferentes métodos / Izabel Oliva Marcilio de Souza. -- São Paulo, 2013.

Tese(doutorado)--Faculdade de Medicina da Universidade de São Paulo.
Programa de Medicina Preventiva.

Orientador: Prof. Dr. Nelson da Cruz Gouveia.

Descritores: 1.Estudos de séries temporais 2.Previsões/métodos 3.Modelos estatísticos 4.Necessidades e demandas de serviços de saúde/tendências 5.Serviços médicos de emergência/organização & administração 6.Serviços médicos de emergência/estatística & dados numéricos 7.Epidemiologia dos serviços de saúde 8.Modelos lineares

USP/FM/DBD-214/13

AGRADECIMENTOS

Aos meus Pai e Mãe, todo o meu reconhecimento e agradecimento. Amo vocês, e sem o exemplo e o apoio, não teria chegado aqui.

Ao meu orientador Nelson Gouveia, que tem me apoiado e me proporcionado oportunidades únicas de aprendizado e crescimento acadêmico desde a época da residência médica (e já se passaram 10 anos), culminando com este Doutorado e o estágio na London School of Hygiene and Tropical Medicine. Nelson: muito obrigada por tudo, de coração.

To Shak Hajat who has kindly accepted to be my tutor and has given me invaluable advices and led me throughout my time series struggle at the London School of Hygiene and Tropical Medicine.

Aos meus irmãos queridos e às cunhadas também tão queridas: muito obrigada pelo apoio e companheirismo sempre. E agradecimento maior pelos sobrinhos, que são sempre razão para um sorriso fácil.

Aos professores participantes da banca de qualificação, Prof. Dr. Paulo Rossi Menezes, Prof. Dr. Antônio Ponce de Leon e Profa. Dra. Denise Schout, pela leitura cuidadosa e crítica e pelas importantes observações.

Aos demais Professores do Departamento de Medicina Preventiva da FMUSP, que muito me ensinaram ao longo do tempo em que estive aqui. Em particular, agradeço à Professora Maria Novaes, que me apoiou no processo de seleção para a bolsa Capes-Sandúiche e a bolsa do Erasmus Summer Programme em Rotterdam, e que me lançou em mais um desafio na minha chegada de volta ao Brasil.

Aos meus colegas do Núcleo Técnico de Informação em Saúde da COVISA, particularmente ao meu chefe José Olímpio Moura de Albuquerque, que muito me ensinou sobre vigilância e informação em saúde e que, principalmente, foi quem me deu a ideia inicial para a pergunta desta Tese, quando discutíamos

os números e tendência temporal da epidemia por Influenza A H1N1 em 2009 no Município de São Paulo.

Aos meus colegas do Núcleo de Vigilância Epidemiológica do HCFMUSP, que me receberam tão bem e têm sido ótimos parceiros nessa reta final de trabalho na Tese.

E repetindo o agradecimento da minha Dissertação de Mestrado: muito obrigada a Lílian Santos, sempre sorridente e com todas as informações e orientações necessárias. Um apoio inestimável a todos os alunos da Pós-Graduação do Departamento de Medicina Preventiva da FMUSP.

SUMÁRIO

Lista de siglas

Lista de tabelas

Lista de figuras

Resumo

Summary

1 INTRODUÇÃO	1
1.1 Os estudos de séries temporais e os modelos de previsão	2
1.2 Avaliação da acurácia da previsão nos modelos de séries temporais	3
1.3 Características dos dados em uma série temporal	4
1.4 Autocorrelação	6
1.5 Alguns métodos de séries temporais utilizados em epidemiologia	7
1.5.1 Modelo sazonal autorregressivo integrado de média móvel	8
1.5.2 Modelos lineares generalizados	9
1.5.3 Equações de estimação generalizadas.....	10
1.6 Aplicação de métodos de previsão em serviços de pronto socorro	11
1.6.1 Demanda nos serviços de pronto socorro.....	12
1.6.2 A previsão da demanda e o planejamento dos serviços de pronto socorro.....	14
1.6.3 Revisão de literatura: estudos de previsão aplicados aos serviços de pronto socorro.....	16
1.7 Justificativa	21
2 OBJETIVOS	23
2.1 Geral	23
2.2 Específicos	23

3 MATERIAL E MÉTODO	24
3.1 Desenho do estudo	24
3.2 Local do estudo e população estudada	24
3.3 Fonte de dados	26
3.4 Protocolo do estudo	26
3.5 Aplicação dos métodos de séries temporais e modelos de previsão	27
3.6 Medidas de efeito e avaliação da acurácia dos modelos de previsão	30
3.7 Considerações éticas	31
4 RESULTADOS	32
4.1 Volume diário de pacientes no pronto socorro e temperatura média observada ao longo da série	32
4.2 Definição dos modelos de previsão de acordo com o melhor ajuste	34
4.2.1 Modelos lineares generalizados.....	34
4.2.2 Equações de estimação generalizadas.....	35
4.2.3 SARIMA.....	35
4.3 Quantificação do efeito das variáveis independentes no volume diário de pacientes no pronto socorro	39
4.4 Medidas de acurácia e comparação dos modelos de previsão	39
5 DISCUSSÃO.....	43
5.1 Limitações metodológicas e aplicação do estudo	46
6 CONCLUSÕES	48
7 ANEXO	49
8 REFERÊNCIAS.....	72

LISTA DE SIGLAS

AIC	Critério de Informação de Akaike
AR	Autorregressão
ARIMA	Autorregressão integrada de média móvel
CFM	Conselho Federal de Medicina
DP	Desvio padrão
EUA	Estados Unidos da América
FAC	Função de autocorrelação
FACP	Função de autocorrelação parcial
FMUSP	Faculdade de Medicina da Universidade de São Paulo
GEE	Equação de estimação generalizada
GLM	Modelo linear generalizado
HCFMUSP	Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo
ICHC	Instituto Central do Hospital das Clínicas
MAPE	Erro médio percentual absoluto
NIS	Núcleo de Informação em Saúde
PS	Pronto socorro
QIC	Critério de quase-verossimilhança sob modelo de independência
RMSE	Raiz do erro quadrático médio
RR	Risco relativo
SARIMA	Autorregressão integrada de média móvel sazonal

LISTA DE TABELAS

Tabela 1	Características dos estudos que realizaram a previsão do volume diário de pacientes em serviços de pronto socorro.....	20
Tabela 2	Número de pacientes no pronto socorro e temperatura média diária no Município de São Paulo – Pronto Socorro do ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010.....	32
Tabela 3	Efeito das variáveis independentes em termos de mudança percentual no volume diário de pacientes no pronto socorro – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010.....	40
Tabela 4	Erro médio percentual absoluto dos modelos para previsão do volume diário de pacientes no pronto socorro nos três horizontes de previsão - ICHC-FMUSP, 1° de outubro a 30 de dezembro de 2010.....	42

LISTA DE FIGURAS

- Figura 1 Total de atendimentos mensais no pronto socorro – ICHC-FMUSP, 2008 a 2012.....13
- Figura 2 Volume diário de pacientes no pronto socorro por dia do atendimento – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010.....33
- Figura 3 Distribuição do volume diário de pacientes no pronto socorro de acordo com o dia da semana – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010.....33
- Figura 4 Distribuição do volume diário de pacientes no pronto socorro de acordo com o mês – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 201034
- Figura 5 Função de autocorrelação (acima) e função de autocorrelação parcial (abaixo) do volume diário de pacientes no pronto socorro – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010.....37
- Figura 6 Função de autocorrelação (acima) e função de autocorrelação parcial (abaixo) após diferenciação de ordem $d(1)$ do volume diário de pacientes no pronto socorro – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010..... 38
- Figura 7 Comparação dos valores reais observados e valores previstos para o volume diário de pacientes no pronto socorro de acordo com os modelos lineares generalizados e modelos SARIMA, sem incluir termos para o efeito da temperatura (a) e incluindo termos para o efeito da temperatura (b) - ICHC-FMUSP, 1° de outubro a 31 de dezembro de 2010.....41

RESUMO

Marcilio de Souza IO. *Previsão do volume diário de atendimentos no serviço de pronto socorro de um hospital geral: comparação de diferentes métodos* [Tese]. São Paulo: Faculdade de Medicina, Universidade de São Paulo; 2013.

OBJETIVOS: O estudo explorou diferentes métodos de séries temporais visando desenvolver um modelo para a previsão do volume diário de pacientes no Pronto Socorro do Instituto Central do Hospital das Clínicas da Faculdade de Medicina da USP. **MÉTODOS:** Foram explorados seis diferentes modelos para previsão do número diário de pacientes no pronto socorro de acordo com algumas variáveis relacionadas ao calendário e à temperatura média diária. Para a construção dos modelos, utilizou-se a contagem diária de pacientes atendidos no pronto socorro entre 1º de janeiro de 2008 a 31 de dezembro de 2010. Os primeiros 33 meses do banco de dados foram utilizados para o desenvolvimento e ajuste dos modelos, e os últimos três meses foram utilizados para comparação dos resultados obtidos em termos da acurácia de previsão. A acurácia foi medida a partir do erro médio percentual absoluto. Os modelos foram desenvolvidos utilizando-se três diferentes métodos: modelos lineares generalizados, equações de estimação generalizadas e modelos sazonais autorregressivos integrados de média móvel (SARIMA). Para cada método, foram testados modelos que incluíram termos para controlar o efeito da temperatura média diária e modelos que não incluíram esse controle. **RESULTADOS:** Foram atendidos, em média, 389 pacientes diariamente no pronto socorro, número que variou entre 166 e 613. Observou-se uma sazonalidade semanal marcante na distribuição do volume de pacientes ao longo do tempo, com maior número de pacientes às segundas feiras e tendência linear decrescente ao longo da semana. Não foi observada variação significativa no volume de pacientes de acordo com os meses do ano. Os modelos lineares generalizados e equações de estimação generalizada resultaram em melhor acurácia de previsão que os modelos SARIMA. No primeiro horizonte de previsão (outubro), por exemplo, os erros médios percentuais absolutos dos modelos lineares generalizados e de equação de estimação generalizada foram ambos 11,5% e 10,8% (modelos que incluíram e

que não incluíram termo para controlar o efeito da temperatura, respectivamente), enquanto os erros médios percentuais absolutos para os modelos SARIMA foram 12,8% e 11,7% (modelos que incluíram e que não incluíram termo para controlar o efeito da temperatura, respectivamente). Para todos os modelos, incluir termos para controlar o efeito da temperatura média diária não resultou em melhor acurácia de previsão. A previsão a curto prazo (7 dias) em geral resultou em maior acurácia do que a previsão a longo prazo (30 dias). CONCLUSÕES: Este estudo indica que métodos de séries temporais podem ser aplicados na rotina do serviço de pronto socorro para a previsão do provável volume diário de pacientes no serviço. A previsão realizada para o curto prazo tem boa acurácia e pode ser incorporada à rotina do serviço, de modo a subsidiar seu planejamento e colaborar com a adequação de recursos materiais e humanos. Os modelos de previsão baseados unicamente em variáveis relacionadas ao calendário foram capazes de prever a variação no volume diário de pacientes, e os métodos aqui aplicados podem ser automatizados para gerar informações com antecedência suficiente para decisões de planejamento do serviço de pronto socorro.

Descritores: Estudos de séries temporais; Previsões/métodos; Modelos estatísticos; Necessidades e demandas de serviços de saúde/tendências; Serviços médicos de emergência/organização & administração; Serviços médicos de emergência/estatística & dados numéricos; Epidemiologia dos serviços de saúde; Modelos lineares

SUMMARY

Marcilio de Souza IO. *Forecasting daily emergency department visits using calendar variables and ambient temperature readings: comparison of different models applied to a setting in Sao Paulo – Brazil* [Thesis]. São Paulo: Faculdade de Medicina, Universidade de São Paulo; 2013.

OBJECTIVES: This study aims to develop different models to forecast the daily number of patients seeking emergency department (ED) care in a general hospital according to calendar variables and ambient temperature readings and to compare the models in terms of forecasting accuracy. **METHODS:** We developed and tested six different models of ED patient visits using total daily counts of patient visits to the *Instituto Central do Hospital das Clínicas* Emergency Department from January 1, 2008 to December 31, 2010. We used the first 33 months of the dataset to develop the ED patient visits forecasting models (the training set), leaving the last 3 months to measure each model's forecasting accuracy by the mean absolute percentage error. Forecasting models were developed using 3 different time series analysis methods: generalized linear models, generalized estimating equations and seasonal autoregressive integrated moving average (SARIMA). For each method, we explored models with and without the effect of mean daily temperature as a predictive variable. **RESULTS:** Daily mean number of ED visits was 389, ranging from 166 to 613. Data showed a weekly seasonal distribution, with highest patient volumes on Mondays and lowest patient volumes on weekends. There was little variation in daily visits by month. Generalized linear models and generalized estimating equation models showed better forecasting accuracy than SARIMA models. For instance, the mean absolute percentage errors from generalized linear models and generalized estimating equations models at the first month of forecasting (October, 2012), were 11.5% and 10.8% (models with and without control for the temperature effect, respectively), while the mean absolute percentage errors from SARIMA models were 12.8% and 11.7% (models with and without control for the temperature effect, respectively). For all models, controlling for the effect of temperature resulted in worse or similar

forecasting ability than models with calendar variables alone, and forecasting accuracy was better for the short term horizon (7 days in advance) than for the longer term (30 days in advance). CONCLUSIONS: Our study indicates that time series models can be developed to provide forecasts of daily ED patient visits, and forecasting ability was dependent on the type of model employed and the length of the time-horizon being predicted. In our setting, generalized linear models and generalized estimating equation models showed better accuracy, and including information about ambient temperature in the models did not improve forecasting accuracy. Forecasting models based on calendar variables alone did in general detect patterns of daily variability in ED volume, and thus could be used for developing an automated system for better planning of personnel resources.

Descriptors: Time series studies; Forecasting/methods; Models, statistical; Health services needs and demand/trends; Emergency medical services/organization & administration; Emergency medical services/statistics & numerical data; Health service epidemiology; Linear models.

1 INTRODUÇÃO

A aplicação de métodos estatísticos para a previsão de eventos futuros é bastante comum em diferentes disciplinas e áreas do conhecimento científico, seja para a compreensão dos fenômenos estudados, seja para embasar o planejamento de serviços e modelos de tomada de decisão.¹ São exemplos aplicados de modelos de previsão: o estudo de fenômenos geológicos e astronômicos, a análise do comportamento de mercado e a previsão da demanda por setores de serviços ou da produção industrial.¹

No campo da saúde, há um esforço ainda incipiente no sentido de utilizar as informações coletadas rotineiramente no serviço para a previsão de eventos futuros. Na Inglaterra, uma publicação do Escritório Nacional de Auditorias (National Audit Office) atesta que os fundos que administram os serviços de saúde poderiam fazer uso de seu conhecimento acerca dos padrões de admissão nos serviços de emergência para fazer a previsão da provável demanda de recursos humanos e materiais.² Nos Estados Unidos, um recente relatório do Instituto de Medicina comenta o paradoxo de que, ao mesmo tempo em que as ciências médicas são consideradas altamente avançadas em relação a outros campos do saber, a organização dos serviços de saúde representa um atraso em relação a outros setores de serviço no que diz respeito ao uso das tecnologias da informação para o planejamento e gestão.³ Nesse sentido, os estudos de séries temporais aplicados ao serviço de saúde para a previsão de eventos, embora ainda pouco explorados, representam uma importante ferramenta para o planejamento em saúde, a definição de prioridades e a reorientação de práticas.

1.1 Os estudos de séries temporais e os modelos de previsão

Define-se uma série temporal como um conjunto de observações previamente obtidas e ordenadas no tempo.^{1,4} Inicialmente, os estudos de séries temporais eram executados tão somente para a análise gráfica e a descrição dos fenômenos observados, mas, a partir do desenvolvimento dos métodos estatísticos de análise, têm sido bastante utilizados para a construção de modelos explicativos.¹ Esses modelos são chamados de modelos univariados quando a ocorrência do fenômeno é avaliada unicamente como função do tempo e sua previsão é feita com base no comportamento observado no passado. Outra possibilidade são os modelos explicativos multivariados, em que outras variáveis independentes, além do tempo, são incluídas na equação.¹ O ajuste de modelos multivariados no estudo de séries temporais permite a compreensão dos fatores que influenciam o comportamento da variável estudada.¹

Os estudos de séries temporais também podem ser utilizados para a previsão de valores futuros, um processo que consiste em utilizar métodos estatísticos para avaliar dados históricos e identificar um padrão na ocorrência do evento estudado, definir um modelo matemático que expresse essa ocorrência e, a partir da extrapolação do modelo proposto para um momento futuro (i.e., um período posterior à série de dados utilizada para o ajuste do modelo), prever a ocorrência desse evento.¹

A aplicação dos métodos de séries temporais para a previsão envolve dois momentos distintos: o primeiro consiste na identificação do padrão de ocorrência do evento e a definição do modelo matemático subjacente a esse padrão. Essa etapa geralmente é realizada a partir de dados do primeiro período da série temporal, anterior ao horizonte que se pretende prever, e é comumente chamado de '*ante-post*', ou 'período de treinamento'. O segundo momento corresponde à extrapolação do modelo para realizar a previsão dos valores em um momento posterior ao período de treinamento, que em geral é chamado de '*ex post*' ou 'período de validação'.

É preciso se levar em conta, no entanto, que a extrapolação de um modelo estatístico para a previsão de valores no período de validação é feita sob o pressuposto que os mecanismos influenciando a ocorrência dos dados históricos vão permanecer os mesmos no período futuro. Além disso, as incertezas inerentes a qualquer processo de estimativa de parâmetros de um modelo estatístico são refletidas na previsão dos novos valores e, mais que isso, são ampliadas à medida que a previsão se estende para períodos mais distantes no futuro.⁵ Assim, previsões feitas a curto prazo geralmente apresentam melhor acurácia que aquelas feitas a longo prazo.^{4,5} A acurácia da previsão deve sempre ser monitorada através da comparação dos valores previstos aos valores reais observados, tão logo o banco de dados seja completado com os mesmos.

1.2 Avaliação da acurácia da previsão nos modelos de séries temporais

Uma particularidade da avaliação do sucesso da aplicação de um método estatístico para a previsão de valores futuros em uma série temporal é que, para além de avaliar o grau de ajuste do modelo na representação dos dados observados, é necessário mensurar a acurácia da previsão realizada. Medir a acurácia da previsão consiste em avaliar a extensão do erro de previsão, ou seja, mensurar o quanto os valores previstos no modelo se distanciam do valor real observado,^{1,6,7} e sua importância nesse tipo de estudo se dá porque diferentes modelos podem ter ajustes semelhantes, mas resultarem em valores de previsão bastante diferentes.^{4,5} Mais que isso, não raro o modelo de melhor ajuste resulta em previsões de menor acurácia.^{4,5}

Para a avaliação da acurácia de um modelo de previsão, é fundamental a análise gráfica comparando a distribuição dos valores obtidos no modelo com os valores reais observados no período de validação. Essa comparação permite observar quão próximas essas duas curvas permanecem ao longo do tempo. Além disso, é possível avaliar se os modelos de previsão são capazes de prever os pontos de inflexão das

curvas e as mudanças no padrão de ocorrência da variável de interesse.¹ É também importante a análise da distribuição gráfica dos erros de previsão: uma vez que em um modelo ideal teórico os erros de previsão resultam de flutuações erráticas dos dados, causadas por fatores externos e não previsíveis, a soma de todos os erros observados deve ter um valor próximo a zero, e a representação gráfica desses erros ao longo da série deve ter um padrão aleatório, não uniforme.¹

Dentre as possíveis formas para a quantificação do erro de previsão, o cálculo do erro médio percentual absoluto (MAPE, de acordo com seu nome em inglês*) é o mais comum. O MAPE, como já explicitado pelo nome, representa a média da diferença entre os valores observados e os valores previstos na série, expressa em termos de porcentagem do valor observado. Por ser um valor em porcentagem, ou seja, não escalar, o uso do MAPE para medir a acurácia do modelo é vantajoso ao tornar possível a comparação da acurácia da previsão entre diferentes modelos e diferentes séries temporais.^{1,6}

Outra medida de acurácia utilizada nos modelos de previsão é a raiz do erro quadrático médio (RMSE, do nome em inglês), que corresponde à raiz da média dos quadrados dos erros do modelo. Por incluir o quadrado do erro de cada observação em sua fórmula de cálculo, o RMSE superdimensiona valores aberrantes, o que é uma desvantagem para a sua aplicação.¹

1.3 Características dos dados em uma série temporal

Tipicamente, o padrão de variação observado nos dados de uma série temporal pode ser decomposto em um ou mais dos seguintes elementos: tendência, sazonalidade e flutuação aleatória. A compreensão desses elementos é parte fundamental no estudo de séries temporais.^{1,4}

* Para facilidade de leitura, algumas siglas utilizadas neste documento, por se referirem a termos de estatística já consagrados e utilizados amplamente em língua inglesa, serão grafadas nessa língua.

Tendência pode ser definida como uma variação de longo termo na média da variável de interesse, e essa tendência pode ser de aumento ou de queda. A definição do que seja longo termo vai depender do número de observações e do tamanho da série a ser estudada⁴. A análise da tendência de ocorrência de fenômenos de saúde é bastante frequente na literatura epidemiológica, sendo usualmente denominada de “tendência secular”. A série temporal apresentada na Figura 1 é um exemplo de série com tendência secular de aumento da variável estudada (total de atendimentos mensais no serviço de pronto socorro). Por outro lado, uma série é dita “estacionária” quando não se observa uma tendência na variável de interesse, ou seja, sua média permanece estável ao longo do tempo.

Sazonalidade se refere a qualquer padrão repetitivo ocorrendo de maneira regular e conhecida, a exemplo do padrão semanal típico da variação do número de atendimentos no serviço de pronto socorro. Mais comumente, no entanto, a sazonalidade se refere a repetições cíclicas acontecendo no intervalo de um ano,⁴ características de alguns acometimentos em saúde, a exemplo do aumento de casos de pneumonia nos meses de inverno, ou de dengue durante o verão.

O ajuste de uma série temporal geralmente inclui a aplicação de processos matemáticos para o controle da tendência e da sazonalidade existentes, de maneira a transformar a série de dados em uma série aparentemente estacionária. Chama-se de flutuação aleatória o que permanece na série após o controle dessas variações. Ou seja, ao se ajustar uma série temporal a um modelo estatístico com controle para a sazonalidade e a tendência observadas, o resíduo (diferença entre o valor observado e o ajustado) provavelmente apresentará ainda alguma variação aleatória.⁴ Além da flutuação aleatória, que pode ser decorrente de erros de mensuração ou outros fatores externos à série ou não previsíveis,¹ os resíduos de uma série temporal podem apresentar variações aparentemente aleatórias, mas que podem ser explicadas a partir de alguns modelos

probabilísticos, como o modelo de média móvel ou o modelo de autorregressão.⁴

1.4 Autocorrelação

Outra característica de grande relevância nos dados de uma série temporal é a autocorrelação. Muito da teoria estatística é desenvolvida pressupondo o emprego de amostras aleatórias de observações independentes entre si. As séries temporais, no entanto, apresentam a peculiaridade de que observações coletadas sucessivamente ao longo do tempo geralmente não são independentes. Essa dependência, ou correlação, entre um valor da série e seus valores vizinhos é conhecida como autocorrelação.¹

A autocorrelação pode ser intrínseca à variável estudada, como ocorre em uma série de casos de uma doença infecto-contagiosa de rápida transmissão, ou pode ser decorrente da correlação de variáveis explicativas do desfecho. Em uma série temporal avaliando a relação entre temperatura e mortalidade, por exemplo, a autocorrelação observada é decorrente da correlação da temperatura em dias consecutivos e não um resultado da correlação direta da mortalidade em dias seguidos. Uma vez que a modelagem de dados para inferências estatísticas pressupõe sua independência, a autocorrelação traz implicações importantes para a análise das séries temporais e deve ser controlada no ajuste do modelo.¹

Nas séries em que a autocorrelação é uma consequência da correlação de uma ou mais variáveis explicativas ao longo do tempo, a inclusão dessas variáveis no modelo tende a controlar, ou reduzir, a autocorrelação existente. A análise gráfica dos resíduos do modelo permite verificar se o controle da autocorrelação após o ajuste foi adequado. Se o ajuste foi suficiente, os resíduos são independentes entre si e o gráfico de sua dispersão ao longo do tempo deve apresentar uma flutuação aleatória, e não um padrão óbvio de distribuição.¹

Por outro lado, quando a autocorrelação é intrínseca à variável estudada, ou quando algum grau de autocorrelação persiste no modelo mesmo após a inclusão de variáveis de controle, o diagnóstico e a estimativa da autocorrelação dos dados de uma série podem ser feitos através da Função de Autocorrelação e Função de Autocorrelação Parcial (FAC e FACP, respectivamente).^{1,4} A FAC mede a autocorrelação de uma variável em um intervalo de defasagem do tempo, enquanto a FACP mede a autocorrelação de uma variável entre dois momentos de defasagem controlando para as defasagens intermediárias.⁴

Uma vez diagnosticada a presença de autocorrelação na série, a inspeção dos gráficos da FAC e da FACP em relação ao tempo permite também a identificação do processo subjacente a ela. Assim, os gráficos da FAC e da FACP dos dados da série ou de seus resíduos em relação ao tempo são utilizados para o diagnóstico da estrutura de correlação existente nos dados quando o modelo a ser aplicado na série temporal pressupõe essa definição. Mais especificamente, a análise desses gráficos possibilita a estimativa da ordem de autorregressão (AR) e da média móvel a serem empregadas em alguns métodos, como as equações de estimação generalizadas e o modelo autorregressivo integrado de média móvel (GEE e ARIMA, respectivamente, a partir dos nomes em inglês).⁴

1.5 Alguns métodos de séries temporais utilizados em epidemiologia

O estudo de séries temporais deve sempre começar com uma análise exploratória dos dados, que necessariamente inclui a análise gráfica de sua dispersão ao longo do tempo. A partir do padrão observado no gráfico, é possível identificar quais métodos estatísticos são mais adequados para o ajuste da série.¹ A seleção do método a ser utilizado na análise da série também é definida pelo objetivo do estudo, pelas variáveis disponíveis para análise, além da periodicidade e do intervalo de tempo a ser estudado.^{1,4}

Existem diferentes métodos para o estudo de séries temporais e a escolha daquele mais adequado para explicar e/ou prever um determinado fenômeno é uma tarefa crucial na modelagem dos dados. Uma mesma série de dados pode ser explicada por diferentes modelos e argumenta-se que nenhum método de análise é incontestavelmente superior ao outro.⁴ É prática comum nesse tipo de estudo, portanto, que diferentes modelos sejam testados e comparados a fim de se escolher aquele que apresenta o melhor ajuste dos dados.⁴

Diversas estatísticas foram desenvolvidas para a comparação de modelos quanto ao ajuste dos dados. Dentre essas, o Critério de Informação de Akaike (AIC, do nome em inglês) é uma das mais utilizadas.⁴ O AIC apresenta a vantagem de incluir em sua fórmula de cálculo um termo para penalização relativo ao número de parâmetros incluídos no modelo, ou seja, o AIC permite a preservação do princípio de parcimônia ao qualificar o ajuste do modelo a uma série de dados.⁴ Outra vantagem de se utilizar o AIC é que ele possibilita a comparação de modelos com diferentes números de parâmetros em sua fórmula ou, mais que isso, a comparação de modelos não aninhados, como, por exemplo, a comparação de um modelo ARIMA com um modelo linear generalizado (GLM, do nome em inglês).^{4,6}

1.5.1 Modelo sazonal autorregressivo integrado de média móvel

Os modelos ARIMA descrevem o comportamento atual (e futuro) da variável de interesse em relação a seus valores no passado e são um dos mais utilizados em análises de séries temporais.^{4,8} Os modelos sazonais ARIMA (SARIMA) são uma extensão dos modelos ARIMA com a possibilidade de incorporação de padrões de sazonalidade.^{4,6}

Modelos SARIMA são tradicionalmente representados como (p, d, q) $(P, D, Q)_s$, em que p representa a ordem de autoregressão (AR), d é a ordem de diferenciação (i.e.: o processo de transformação dos dados da série para torná-la estacionária. A diferenciação consiste no cálculo da

diferença entre dois valores observados numa defasagem d de tempo), e q é a ordem da média móvel (MA, do nome em inglês). P , D , e Q são seus correspondentes sazonais, e s é o termo que define a sazonalidade.^{1,4}

A aplicação de um modelo SARIMA deve começar a partir da especificação da ordem de diferenciação capaz de remover a tendência da série, transformando-a em um processo aparentemente estacionário.^{1,4} A partir daí, as especificações das ordens da AR e da média móvel do modelo são feitas de acordo com a inspeção dos gráficos da FACP e FAC, respectivamente. Em processos estacionários, a FACP geralmente apresenta uma diminuição súbita de seus valores na defasagem p , de modo que o valor p do processo $AR(p)$ do modelo é definido como a última defasagem da FACP com valor significativamente diferente de zero. De modo semelhante, a FAC do processo de $MA(q)$ geralmente apresenta o corte na defasagem q , sendo, de maneira análoga ao $AR(p)$, utilizada para definição do valor q do processo $MA(q)$. A definição dos parâmetros sazonais P e Q é feita a partir das FACP e FAC nas datas correspondentes às defasagens sazonais.^{1,4}

Após a identificação do modelo apropriado, os parâmetros da série são estimados por máxima verossimilhança. A aplicação de modelos SARIMA consiste em um processo iterativo com três estágios: identificação, estimação e verificação.^{1,4} A identificação é feita a partir da comparação de possíveis modelos lineares com os dados existentes, seguida de um teste de acurácia atingida. Se o modelo especificado não for considerado satisfatório, o processo é repetido até que um modelo seja definido.¹ Esse caráter iterativo da modelagem SARIMA demanda bastante tempo computacional, mas que tem sido diminuído com o desenvolvimento dos pacotes estatísticos e com o avanço das máquinas computadoradas.

1.5.2 Modelos lineares generalizados

Análises de regressão são utilizadas com frequência em estudos epidemiológicos de séries temporais e, nesses casos, é necessário se levar

em conta as particularidades do padrão de variação e a autocorrelação desse tipo de dado.⁹ Os GLM foram desenvolvidos como uma extensão das regressões lineares para comportar o ajuste de funções não lineares¹⁰ e representam uma possibilidade para a modelagem de séries temporais.

Os GLM apresentam, ainda, a vantagem de permitir a modelagem de variáveis com distribuições outras que não a distribuição normal, como a distribuição de Poisson. A distribuição de Poisson expressa a probabilidade de ocorrência de um determinado número de eventos em um intervalo de tempo e, portanto, é utilizada para descrever modelos em que a variável de interesse é um agregado, uma contagem do fenômeno estudado.¹⁰ O número total de internações diárias ou o total de nascimentos em um mês são exemplos de variáveis que representam uma contagem. No modelo teórico da distribuição de Poisson, a média e a variância se equivalem. Processos de contagem reais, no entanto, frequentemente apresentam uma variância mais ampla, fenômeno chamado de superdispersão, e o modelo ajustado deve ser adaptado para corrigir essa questão.¹⁰

Assim, os GLM com distribuição de Poisson e corrigidos para superdispersão têm sido usados extensivamente em estudos epidemiológicos de séries temporais que investigam a associação entre eventos de saúde em um nível agregado, como mortalidade ou internações hospitalares, e alguns fatores de risco, a exemplo de variáveis climáticas ou níveis de poluição.^{9,11-14}

1.5.3 Equações de estimação generalizadas

Com o intuito de estender as funções dos GLM e permitir o controle para a autocorrelação de variáveis em uma série temporal, Liang e Zeger¹⁵ descreveram, em 1986, os modelos de equações de estimação generalizadas. A aplicação das GEE permite a regressão da variável dependente nas variáveis independentes e, ao mesmo tempo, o controle para a autocorrelação entre medidas repetidas no mesmo sujeito ao longo

do tempo, ou ainda, como acontece usualmente nos estudos de séries temporais, o controle para a autocorrelação de medidas da mesma variável feitas em sequência na série.¹⁶ Por essa razão, os modelos GEE têm sido utilizados com crescente frequência nos estudos de séries temporais para o estudo do efeito de variações meteorológicas e de poluição do ar na saúde.^{15,17-19} O controle para autocorrelação nos modelos GEE, ao contrário dos modelos GLM, prescinde dos valores dos dados que compõem a série, podendo ser incluído nos modelos de previsão de valores futuros.

O método das GEE, ao contrário dos GLM, que se baseiam na teoria de máxima verossimilhança, está baseado na teoria de quase-verossimilhança e, portanto, a estatística AIC não pode ser aplicada para avaliar o ajuste do modelo à série de dados estudada. Uma solução para essa questão foi proposta em 2001, com a modificação do AIC para criar um critério de avaliação do ajuste de modelos do tipo GEE, chamado de Critério de Quase-verossimilhança sob modelo de Independência (QIC, do nome em inglês) e que já está incorporado na maioria dos programas de computador para análises estatísticas.^{16,17}

1.6 Aplicação de métodos de previsão em serviços de pronto socorro

A análise da distribuição temporal de eventos para formular modelos de previsão que possam embasar a adequação do serviço à demanda esperada pode ser particularmente importante nos serviços de pronto socorro (PS).² É notável o aumento no número de pacientes que buscam esse tipo de serviço, tanto no Brasil como mundialmente, e essa demanda excessiva acarreta na superlotação dos serviços, no aumento do tempo de espera por atendimento e na conseqüente queda da qualidade da assistência prestada. O quadro resultante desse processo é reconhecido como um problema de grande importância para os sistemas de saúde e tem suscitado um número crescente de pesquisas sobre o tema.^{3,20-22}

1.6.1 Demanda nos serviços de pronto socorro

O aumento na demanda por atendimentos em serviços de PS tem sido relatado por autores de diversos países. Em 2006, um relatório do Instituto de Medicina, nos Estados Unidos, afirmou que enquanto a população americana cresceu 12% entre os anos de 1993 e 2003, o número de internações hospitalares teve crescimento de 13% e os atendimentos em PS aumentaram 26% no mesmo período. Esses números correspondem a um total de 114 milhões de atendimentos em serviços de PS por ano.³ De acordo com Wargon et al.,²² em 1994 se estimava um aumento de 3 a 5% ao ano na demanda de atendimentos de emergências no Reino Unido. Além disso, 40% do total de admissões hospitalares era feito a partir de serviços de emergência.

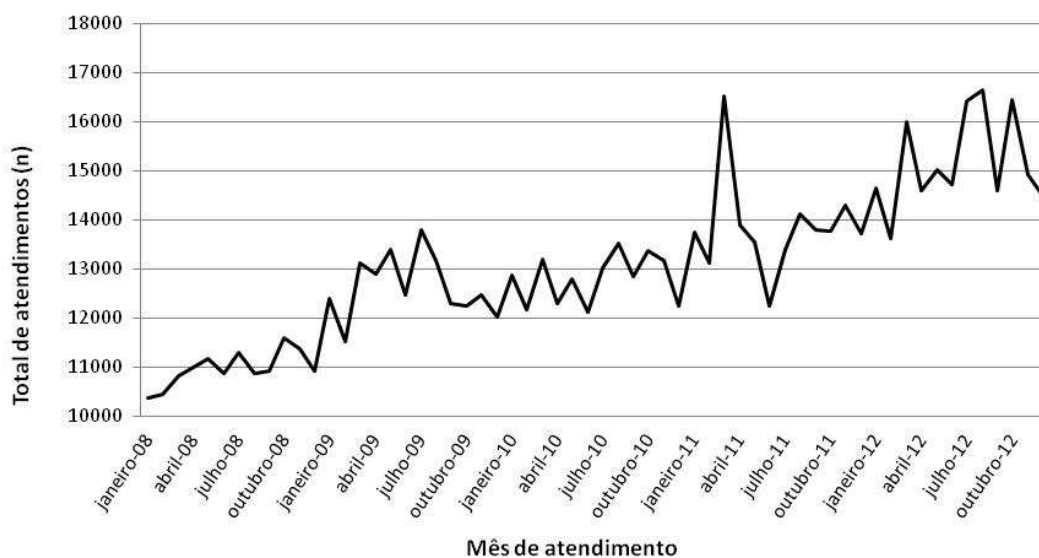
Situação semelhante é observada no Brasil. O poder público, em suas instâncias municipais, estaduais e federal, reconhece o aumento na demanda por atendimentos nos PS, e os serviços de atendimentos a urgência e emergência são descritos como uma das “mais problemáticas áreas do Sistema de Saúde” em uma recente Portaria do Ministério da Saúde.²⁰ Assim, esforços têm sido empreendidos para a efetiva organização e estruturação das redes assistenciais nessa área. O governo federal lançou uma série de portarias que orientam e regulamentam os serviços de atendimento às urgências e emergências no país, e em 2003 implementou a Política Nacional de Urgência e Emergência.²¹

Os dados referentes ao número de atendimentos no PS do Instituto Central do Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo (ICHC-FMUSP) também evidenciam o aumento na demanda desse serviço ao longo do tempo (Figura 1). Destaca-se, por exemplo, que entre 2008 e 2012 a média mensal de atendimentos no serviço passou de 10.965 para 15.178.

O aumento no número de atendimentos nos PS, tanto no Brasil como mundialmente, pode ser explicado, em parte, pela mudança no perfil

epidemiológico da população. O crescimento rápido e desordenado das cidades aliado ao envelhecimento populacional contribuem para o aumento de enfermidades relacionadas a situações de urgência, como algumas doenças cardiovasculares e os agravos por causas externas.^{3,20,21} No Brasil, por exemplo, as doenças cardiovasculares são a principal causa de mortalidade, além de serem responsáveis pelo maior custo relacionado a intervenções hospitalares no sistema de saúde nacional.²³ As causas externas, por sua vez, representam a terceira maior causa de mortalidade no país e a sexta maior causa de hospitalizações.²⁴ Percebe-se, assim, que duas das três principais causas de morte estão diretamente relacionadas a atendimentos de urgência e emergência, demonstrando a importância desse setor para o sistema de assistência à saúde.²⁵

Figura 1 Total de atendimentos mensais no pronto socorro – ICHC-FMUSP, 2008 a 2012



*Fonte: Relatório de indicadores de produção do HCFMUSP, informados pelo Núcleo de Informação em Saúde (NIS) do Hospital

Outra explicação para o número crescente de pacientes que procuram atendimento no PS é o uso inadequado desse serviço, ou seja, pacientes que chegam ao serviço com quadros clínicos que prescindem de cuidados

de urgência ou emergência. A literatura mundial aponta diferentes razões para esse fenômeno: reconhece-se, por exemplo, que o PS funciona como porta de entrada para o sistema para aqueles pacientes que não têm fácil acesso a equipamentos de atenção primária e secundária à saúde.^{3,21,26} Mais que isso, em geral esses pacientes chegam ao PS para cuidar de situações que se agravaram como consequência da falta de acompanhamento regular na atenção primária.³ Há ainda, por parte da população, o pressuposto que o atendimento no PS é feito por profissionais mais bem preparados e com acesso a equipamentos de ponta, possibilitando o manejo de situações complexas e a realização de exames secundários no mesmo tempo e local de atendimento.^{3,26}

1.6.2 A previsão da demanda e o planejamento dos serviços de pronto socorro

A procura por atendimentos de urgência e emergência caracteriza-se pela demanda espontânea e os serviços de PS são definidos como de grande complacência, não oferecendo restrições ao atendimento de pacientes. De acordo com o disposto na Resolução do Conselho Federal Medicina (CFM) nº 1451/95, o “estabelecimento de pronto socorro deverá permanecer à disposição da população em funcionamento ininterrupto”.²⁷ Esse aspecto representa um desafio para a gestão e planejamento dos serviços de PS. Somam-se a esse outros fatores complicadores, como a complexidade crescente dos casos manejados no PS, a insuficiência no número de leitos hospitalares disponíveis e a instituição de tratamentos agressivos com o intuito de diminuir o volume de admissões e o tempo de permanência no hospital.²²

O grande volume de pacientes e a dificuldade de se organizar a demanda levam à superlotação dos PS, à espera prolongada pelo atendimento e à percepção de uma baixa qualidade no serviço prestado.^{22,28,29} A demora em ser atendido é citada como a maior razão para insatisfação dos pacientes^{29,30} e quanto maior o tempo de espera, maior a

probabilidade dos pacientes abandonarem o PS antes de serem atendidos. Essa situação é ainda agravada pelo fato de que mais de um quarto dos pacientes que abandonam o PS antes de serem atendidos retorna ao serviço buscando novo atendimento.³⁰

Compreender a distribuição temporal da demanda em um PS é uma etapa fundamental para sua organização, colaborando com o bom funcionamento de toda a rede de assistência. O relatório do Comitê para o Futuro do Atendimento de Urgência do Instituto de Medicina dos Estados Unidos (Institute of Medicine Committee on the Future of Emergency Care in the U.S. Health System) em 2006 recomendava que pesquisadores da área de medicina de emergência deveriam explorar novos métodos para aprimorar o fluxo dos pacientes e, dentre as medidas propostas, incluía o conhecimento do volume de chegada de pacientes ao serviço.³ A previsão do volume diário de atendimentos representa um dos aspectos que podem contribuir para esse aprimoramento ao permitir a otimização no planejamento, com a adaptação dos recursos humanos e materiais à variação diária do número provável de pacientes.^{7,30-33}

Uma análise de série temporal do volume diário de atendimentos em um PS em Israel, por exemplo, observou um número muito maior de pacientes aos domingos. Esse achado levou a administração do hospital a alocar um médico a mais na equipe de atendimento aos domingos, o que resultou no alívio do congestionamento do PS nesses dias.³³ Batal et al.,³⁰ em 2001, relataram a diminuição em 18,5% dos pacientes que abandonaram o PS antes de serem atendidos, além da diminuição em 30% das reclamações, ao aplicarem um modelo de previsão do número diário de pacientes para a adequação da equipe de atendimento em um hospital público no Colorado, Estados Unidos.

Embora habitualmente as decisões para o dimensionamento das equipes de atendimento no PS sejam feitas com base na experiência pessoal dos profissionais envolvidos,³⁴⁻³⁶ é de grande importância para

esses serviços a busca por um enfoque racional com modelos objetivos para subsidiar sua organização.^{3,6,7,22,28,30,37}

1.6.3 Revisão de literatura: estudos de previsão aplicados aos serviços de pronto socorro

Diferentes métodos de séries temporais têm sido utilizados por alguns autores para realizar a previsão do volume de pacientes que buscam atendimento no PS.^{6,7,22} Os estudos têm demonstrado que a demanda enfrentada nesses serviços, embora bastante variável se comparada dia a dia, apresenta no longo prazo um padrão cíclico e previsível,^{35,38} influenciado pelo dia da semana, período do ano e ocorrência de feriados.^{6,7,28,30,33,39,40} No entanto, a revisão da literatura especializada mostra que ainda são poucos os estudos (e serviços) que exploraram a possibilidade da previsão do volume diário de pacientes para o planejamento do serviço.^{6,22,36}

Rotstein et al.,³³ em 1997, aplicaram um modelo linear generalizado incluindo variáveis para o dia da semana, mês e ocorrência de feriados para realizar a previsão de atendimentos diários em um PS em Israel. Os autores relataram que o erro médio da previsão correspondeu a 10% da média de visitas diárias e recomendaram que a previsão de atendimentos no serviço de emergência a partir de estudos de séries temporais fosse utilizada rotineiramente para o melhor planejamento do PS.

Batal et al.³⁰ usaram regressão linear múltipla para prever as admissões em um PS nos Estados Unidos (EUA). A equação para a previsão incluiu variáveis para controlar o efeito do dia da semana, mês, feriados, períodos de inverno e a média móvel do volume de pacientes nos 7 dias anteriores. Também foram testadas variáveis climáticas (temperatura máxima, média e mínima e índice pluviométrico). Os autores relataram que o dia da semana foi o fator de maior impacto na previsão, com maior número de pacientes às segundas-feiras e tendência decrescente ao longo da semana. As variáveis climáticas pouco acrescentaram ao modelo. Para

avaliar a qualidade da previsão realizada, os autores aplicaram na prática do serviço os valores previstos no estudo, adequando o tamanho da equipe de assistência de acordo com o número provável de pacientes. Foi relatada uma melhora substancial na organização da equipe de profissionais no serviço, associada à melhora dos indicadores de satisfação por parte dos pacientes.

Reis e Mandl,⁴¹ em 2003, utilizaram um modelo ARIMA univariado para fazer a previsão do número de atendimentos diários em um PS pediátrico nos EUA. A maior demanda no PS foi observada aos fins de semana. Os resultados mostraram um MAPE de 9,4% e os autores concluíram que os modelos gerados foram capazes de prever com boa acurácia a demanda no PS, podendo ser utilizados para gerar um sistema de alarme para quando um aumento inesperado da demanda for observado. Os autores incluíram no estudo sugestões para se por em prática esse sistema de alarme, como o disparo de mensagens com informações do tipo: “O número de pacientes no serviço hoje está significativamente maior do que seria esperado para este dia da semana e esta estação do ano. Além disso, o número de pacientes hoje está significativamente maior do que seria esperado a partir dos números observados nos últimos dias”.

Jones et al.,⁶ em 2008, compararam diferentes métodos para realizar a previsão do volume diário de pacientes em três PS dos EUA. Os métodos testados foram: alisamento exponencial (uso de médias móveis exponencialmente ponderadas, em que os dados mais recentes da série têm maior peso), um modelo SARIMA, um modelo de regressão linear múltipla incluindo variáveis para o dia da semana, mês, ocorrência de feriado e algumas variáveis climáticas, um modelo de regressão semelhante mas incluindo também a interação entre seus termos, além de uma análise de redes neurais artificiais. O número diário de pacientes no PS esteve associado ao dia da semana e à ocorrência de feriado em todos os serviços estudados, embora a magnitude da associação tenha sido diferente entre eles. Também foi encontrada uma associação positiva entre o número de

pacientes e a temperatura máxima no mesmo dia do atendimento, e uma associação negativa em relação à temperatura máxima no dia anterior. Os MAPEs relatados para os diferentes métodos variaram entre 8,5% e 15,5%, sendo que o método que apresentou melhor acurácia, no geral, foi o método de regressão linear múltipla sem interação entre os termos.

Sun et al.,⁷ em 2009, realizaram a previsão de atendimentos em um PS em Singapura utilizando um modelo SARIMA que incluiu como variáveis independentes: dia da semana, mês, ocorrência de feriados, temperatura média diária, umidade relativa do ar e nível de poluição atmosférica. O modelo mostrou que o volume diário de pacientes variava de acordo com o dia da semana, com maior número de casos às segundas-feiras, e de acordo com o período do ano, com mais casos nos meses de maio a julho. Além disso, a demanda era maior nos feriados e estava associada positivamente com temperaturas mais elevadas. A previsão do número de atendimentos no PS foi feita separadamente para três categorias de gravidade dos pacientes e os MAPEs encontrados variaram entre 6,7% e 16,8%.

Kam et al.,⁴² em 2010, fizeram a previsão de atendimentos diários em um PS na Coreia do Sul comparando um modelo SARIMA univariado e um modelo SARIMA com a inclusão de variáveis para o dia da semana, mês, estação do ano, ocorrência de feriados e nove variáveis climáticas (temperatura máxima, temperatura mínima, temperatura média, amplitude de temperatura, ocorrência de chuva, ocorrência de neve, umidade relativa do ar, velocidade do ar e ocorrência de tempestade de areia). Foi encontrada uma forte sazonalidade semanal, com maior número de atendimentos durante os fins de semana. Além disso, a temperatura média diária e a ocorrência de chuva também apresentaram efeito importante no número de atendimentos no PS. O modelo multivariado apresentou acurácia ligeiramente mais alta na previsão dos eventos, com MAPE de 7,4%, comparado a 7,8% do modelo univariado. Os autores concluíram que os dois modelos foram capazes de prever com boa acurácia o número diário de

pacientes no PS e podem ser utilizados como ferramenta para o planejamento do serviço.

Boyle et al.,³⁹ em 2011, realizaram um estudo que tinha como objetivo desenvolver e testar um programa de computação para realizar a previsão do número de pacientes buscando atendimento em serviços de PS na Austrália. O modelo de previsão proposto levava em conta apenas as variáveis relacionadas ao calendário (dia da semana e feriado). Para cada dia do período de treinamento, o programa identificava os dias com as mesmas características (mesmo dia da semana e ocorrência ou não de feriado) em uma janela de 4 semanas, sendo duas anteriores e duas posteriores ao dia de interesse. O programa então aplicava uma fórmula para a suavização da série obtida nesse procedimento e gerava os valores previstos para o número de pacientes. O MAPE para a previsão diária foi de 7%.

A Tabela 1 resume as características dos estudos encontrados na revisão bibliográfica que utilizaram métodos de séries temporais para realizar previsão do número diário de atendimentos no PS. Além desses, outros estudos realizaram a previsão da demanda mensal,^{43,44} anual,⁴⁵ ou a cada hora^{31,37,46,47} em serviços de PS.

Tabela 1 Características dos estudos que realizaram a previsão do volume diário de pacientes em serviços de pronto socorro

Autores	Ano de publicação	Local do estudo	Número médio de pacientes/dia	Objetivos	Método para previsão	Variáveis independentes	Medida da acurácia
Rotstein et al.	1997	Israel	240	Adequar a equipe de atendimento à demanda	Modelo linear generalizado	Dia da semana, feriado, mês	RMSE: 22,1
Batal et al.	2001	EUA	101	Adequar a equipe de atendimento à demanda e diminuir o número de pacientes que deixam o PS antes de serem atendidos	Regressão linear múltipla	Dia da semana, feriado, mês, período de inverno, temperatura e precipitação	-
Reis e Mandl*	2003	EUA	137	Determinar o padrão da demanda no PS para subsidiar a vigilância sindrômica para gerar alerta de epidemias	ARIMA	-	MAPE: 9,4%
Jones et al.	2008	EUA	PS 1: 33; PS 2: 108; PS 3: 69	Comparar a acurácia de diferentes métodos para previsão do número diário de pacientes no PS	Regressão linear múltipla, SARIMA, alisamento exponencial, redes neurais artificiais	Dia da semana, feriado, mês, estação, temperatura, precipitação e neve	MAPEs variaram entre 8,5% e 15,5%
Sun et al.	2009	Singapura	400	Identificar fatores locais relacionados à demanda no PS e fazer previsões baseadas nesses fatores	SARIMA	Dia da semana, feriado, mês, temperatura, umidade relativa e poluição atmosférica	MAPEs variaram entre 6,7% e 16,8%
Kam et al.	2010	Coreia do Sul	232	Fazer a previsão do número diário de pacientes em um serviço de emergência	SARIMA (univariado e multivariado)	Dia da semana, feriado, mês, estação, temperatura, precipitação, neve, velocidade do vento e tempestade de areia	MAPEs: 7,4% (modelo multivariado) e 7,8% (modelo univariado)
Boyle et al.	2011	Austrália	(não reportado)	Desenvolver e validar um pacote estatístico para realizar a previsão do número diário de pacientes em serviços de emergência	Modelos de médias móveis baseado na sazonalidade mensal e semanal	Dia da semana, mês	MAPE: 7,0%

PS: pronto socorro, MAPE: erro médio percentual absoluto, RMSE: raiz do erro médio quadrático, ARIMA: modelo autorregressivo integrado de média móvel, SARIMA: modelo autorregressivo integrado de média móvel sazonal

* O estudo foi realizado em um pronto socorro pediátrico

1.7 Justificativa

O aumento da demanda nos serviços de PS é uma realidade reconhecida pelo poder público no Brasil, que tem lançado mão de diferentes estratégias e ações para a solução desse problema.²¹ Identificar os fatores que influenciam a demanda diária de atendimentos e, a partir deles, realizar a previsão do número provável de pacientes no PS diariamente possibilita a melhor organização do serviço ao dar subsídios para seu planejamento.³⁰⁻³³ A utilização de dados coletados na rotina do serviço para realizar essa previsão é uma recomendação de relatórios recentes de comissões que avaliaram a eficiência e a qualidade da assistência a pacientes em situação de urgência e emergência.^{2,3}

A aplicação de modelos matemáticos para antecipar o volume diário de pacientes e ajustar a disponibilidade de recursos humanos e materiais é uma maneira de aprimorar a qualidade da assistência prestada e melhorar a relação custo-efetividade nos serviços de PS uma vez que, apesar de dinâmico e flutuante, o volume diário de pacientes nesses serviços pode ser antecipado.^{30-33,35} Por outro lado, é reconhecido o fato de que as decisões relativas ao planejamento do PS geralmente são feitas de acordo com a experiência dos profissionais do serviço, com base em suas vivências e opiniões pessoais, tornando difícil a avaliação a longo prazo dos efeitos das medidas tomadas.^{35,36} A literatura revisada aponta um número reduzido de estudos que utilizaram séries temporais para realizar a previsão da demanda diária nos PS.^{6,7,30,33,39,40,42}

Os resultados de estudos prévios mostraram um padrão cíclico no volume diário de pacientes em serviços de PS, influenciado principalmente por variáveis relacionadas ao calendário, como o dia da semana, os meses do ano e a ocorrência de feriados.^{6,7,28,30,33,39,40} Algumas variáveis climáticas, principalmente a temperatura média diária, também foram testadas nos modelos de previsão, uma vez que diversos estudos demonstraram a associação entre essa variável e a ocorrência de hospitalizações e aumento

de mortalidade.^{11,12,13,14} No Reino Unido, por exemplo, o Serviço Nacional de Meteorologia mantém um programa que alerta os pacientes com Doença Pulmonar Obstrutiva Crônica em dias que sua saúde pode ser afetada pelo clima.⁴⁸

O impacto dos níveis de temperatura média na previsão do volume diário de pacientes no PS, no entanto, ainda não está bem compreendido na literatura científica: enquanto alguns estudos mostraram uma associação entre essas duas variáveis,^{6,7,38,42,49,50} outros autores argumentam que a inclusão de variáveis para controlar o efeito da temperatura aumenta a incerteza do modelo de previsão e não aumenta sua acurácia de modo significativo.^{6,30,51} Tendo em vista que o efeito das variações climáticas depende em grande parte da localização geográfica e das características da população e do serviço de saúde estudado, o efeito da temperatura média diária para melhorar a acurácia do modelo de previsão deve ser testado localmente.

Considerando o acima exposto, este estudo objetiva construir um modelo para a previsão do volume diário de pacientes em um serviço de PS de acordo com variáveis do calendário e com medidas da temperatura média diária. Além disso, como diferentes métodos de estudos de séries temporais podem ser empregados para realizar essa previsão, e como a literatura especializada argumenta que não há uma supremacia de um método em relação aos outros,⁴⁻⁶ diferentes métodos para análise de séries temporais serão comparadas em termos da acurácia da previsão.

2 OBJETIVOS

2.1 Geral

Construir um modelo para a previsão do volume diário de pacientes no Pronto Socorro do Instituto Central do Hospital das Clínicas da Faculdade de Medicina da USP (ICHC-FMUSP).

2.2 Específicos

2.2.1 Analisar o padrão de distribuição temporal do volume diário de pacientes atendidos no PS do ICHC-FMUSP no período de 2008 a 2010;

2.2.2 Identificar e quantificar os efeitos da temperatura média diária e das características do dia de visita ao PS em relação ao calendário associados ao volume diário de pacientes nesse PS;

2.2.3 Explorar e comparar a acurácia da previsão de diferentes métodos para análise de séries temporais;

2.2.4 Avaliar o impacto da inclusão de variáveis para o controle do efeito da temperatura média diária na acurácia da previsão do volume diário de pacientes no PS.

3 MATERIAL E MÉTODO

3.1 Desenho do estudo

Foi realizado um estudo de séries temporais baseado em dados retrospectivos para avaliar a relação entre a demanda de atendimentos no PS e algumas variáveis independentes e, a partir dele, alguns modelos para previsão dessa demanda foram propostos e comparados quanto a sua acurácia.

3.2 Local do estudo e população estudada

O Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo (HCFMUSP) é um hospital universitário, considerado o maior hospital de nível terciário no Brasil. O complexo HCFMUSP inclui 7 institutos hospitalares, sendo 5 hospitais de agudos (Instituto Central, Instituto da Criança, Instituto do Coração, Instituto de Ortopedia e Trauma e Instituto de Psiquiatria), além de dois hospitais de retaguarda (Hospital Auxiliar de Suzano e Hospital Auxiliar de Cotoxó).

O Instituto Central do Hospital das Clínicas (IHC) é o maior desses institutos. Em 2012, o número mensal médio de leitos comuns instalados no IHC foi de 944, para uma média de 810 leitos operacionais (i.e., leitos em utilização ou passíveis de serem utilizados). No mesmo ano, observou-se a média mensal de 110 leitos operacionais de UTI. O número total de internações em todo o IHC nesse ano foi de 34.959 pacientes. O Pronto Socorro do IHC, com funcionamento 24 horas, é um dos maiores PS do país, onde são atendidos cerca de 160.000 pacientes ao ano.

Fundado na década de 40 do século passado, o HCFMUSP sempre realizou atendimentos de urgência e emergência, tendo papel de destaque

na organização do fluxo de atendimento a urgências na grande São Paulo. O PS do HCFMUSP está estabelecido como a referência para atendimentos de alta complexidade para parte da zona centro-oeste e a totalidade da zona sul do Município de São Paulo, o que compreende 9 subprefeituras (Lapa, Butantã, Pinheiros, Santo Amaro, Cidade Ademar, Campo Limpo, M'Boi Mirim, Capela do Socorro, Parelheiros). Além disso, é também referência para atendimentos de alta complexidade para 14 municípios da região metropolitana de São Paulo, e municípios dos Departamentos Regionais de Saúde (DRS) de Registro (DRS XII) e de Sorocaba (DRS XVI).

A inserção do PS do HCFMUSP como parte formalmente integrada ao sistema estadual de urgências e emergências constitui um dos pré requisitos para a contratualização do hospital como Hospital de Ensino de acordo com a Portaria Interministerial nº 2.400 de 2007. Também é preconizado pela contratualização que os hospitais de ensino aumentem os procedimentos de média e alta complexidade e que diminuam os procedimentos de atenção básica. Assim, a partir de janeiro de 2008 ocorreu a reorganização do fluxo de pacientes no PS do ICHC da FMUSP, com o objetivo de atender as regras da contratualização, além de colaborar com a racionalização da oferta dos serviços e promover a melhor qualidade da assistência prestada. O PS passou então a trabalhar sob um regime que pode ser caracterizado como um PS de porta “semi fechada”, o que significa que a entrada do paciente no serviço deve ocorrer a partir do encaminhamento pela rede de referência e contra-referência. Quando não há esse encaminhamento, o paciente passa inicialmente pelo setor de Acolhimento Inicial do PS (AIPS), onde é atendido por profissionais de enfermagem para a triagem e classificação de risco de acordo com um protocolo estabelecido e preenchimento de uma ficha impressa (Ficha de Acolhimento com Classificação de Risco). Só entram efetivamente no PS aqueles pacientes classificados como de risco moderado ou grave.

Para este estudo, foi utilizada a contagem diária do total de pacientes atendidos no Pronto Socorro do ICHC-FMUSP entre 1º de janeiro de 2008 a

31 de dezembro de 2010. Foram excluídos da amostra apenas os casos relacionados a gestação, parto e puerpério (CID-10 O00-O99), os eventos relacionados ao período perinatal (P00-P96) e anomalias congênitas (Q00-Q99), uma vez que pacientes com esses diagnósticos, apesar de entrarem no PS pelo mesmo local que os demais, são encaminhados diretamente ao serviço de ginecologia e obstetrícia do hospital.

3.3 Fonte de dados

As informações referentes ao número diário de pacientes atendidos no PS do ICHC-FMUSP foram obtidas diretamente do sistema de informação do hospital mediante solicitação formal ao setor responsável, o Núcleo de Informação em Saúde (NIS).

O banco de dados com a temperatura média diária no Município de São Paulo foi obtido junto à Companhia Ambiental do Estado de São Paulo (CETESB). Essas informações são coletadas a cada hora em 12 estações automáticas de monitoramento distribuídas pela cidade. A temperatura média diária foi calculada como a média das medidas de 24 horas nas 12 estações.

3.4 Protocolo do estudo

O banco de dados foi dividido em dois períodos. O primeiro, de 1° de janeiro de 2008 a 30 de setembro de 2010, foi utilizado para análise exploratória da distribuição temporal das variáveis, ajuste dos modelos estatísticos, quantificação do efeito das variáveis independentes no número diário de atendimentos no PS e, por fim, definição da equação para a previsão do volume diário de pacientes no serviço. Esse primeiro período será doravante chamado de 'período de treinamento'.

O segundo período, de 1° de outubro a 31 de dezembro de 2010, foi utilizado para a validação do modelo de previsão e será chamado de

‘período de validação’. Neste, os volumes de pacientes no PS previstos a partir dos modelos definidos no período de treinamento foram comparados, através de gráficos e do cálculo dos MAPEs, com o volume real de pacientes observado diariamente no PS.

O período de validação foi ainda subdividido em três horizontes de previsão de 30 dias, referentes aos meses de outubro, novembro e dezembro de 2010. Assim, após a realização da previsão e medida da acurácia no primeiro horizonte de previsão (outubro), os dados desse mês foram incorporados ao período de treinamento e o modelo re-estimado para realizar a previsão do número de atendimentos no segundo horizonte (novembro). O mesmo procedimento foi repetido para o terceiro horizonte (dezembro). A acurácia dos modelos foi testada para a previsão de intervalos de 7 e de 30 dias em prospectivo em cada um desses horizontes. O objetivo dessa abordagem foi se aproximar de um cenário de prática real, em que o modelo de previsão pudesse ser atualizado continuamente com a incorporação dos valores reais observados ao longo do tempo e, assim, que novos valores de previsão pudessem ser gerados.

3.5 Aplicação dos métodos de séries temporais e modelos de previsão

Este estudo se propôs a testar diferentes métodos de análise de séries temporais para a previsão da demanda diária no PS, a fim de definir o mais adequado para a realidade estudada. Foram explorados os seguintes métodos: modelos lineares generalizados, equações de estimação generalizadas e modelo SARIMA. A escolha desses três métodos para comparação baseou-se na revisão da literatura e teve a seguinte motivação: os modelos GLM e GEE, por possibilitarem o ajuste de dados com distribuição de Poisson e permitirem a inclusão de termos para o controle de algumas variações típicas de séries temporais, como tendência, sazonalidade e autocorrelação, têm sido largamente empregados em estudos epidemiológicos de séries temporais,^{9,11-15,17-19} mas foram pouco explorados para estudos de previsão. Modelos SARIMA, de maneira

contrária, são descritos como os mais amplamente usados em estudos de previsão de eventos de saúde.^{6,7,22}

Os modelos GLM e GEE foram ajustados assumindo-se uma distribuição de Poisson com correção para a superdispersão dos dados. A definição da ordem da AR e da média móvel para o modelo SARIMA foi feita a partir dos gráficos da FAC e FACP.

Todos os modelos incluíram um termo linear referente ao dia de admissão no PS para controle da tendência secular nos atendimentos. O controle da sazonalidade foi feito a partir da inclusão de termos de Fourier, uma modelagem matemática para alisamento de dados. Sua aplicação consiste no uso de funções de seno e cosseno para controlar padrões de repetições cíclicas em uma série de dados,⁴ sendo amplamente utilizada em estudo de séries temporais.⁵²⁻⁵⁴ O uso de termos de Fourier para controle da sazonalidade é particularmente vantajoso em modelos de previsão de valores no período posterior ao intervalo utilizado para ajuste do modelo, uma vez que a definição dos termos é baseada exclusivamente em funções matemáticas, portanto prescindindo dos valores reais da série estudada. Por esse motivo, foi o método utilizado neste estudo, e a estrutura dos termos de Fourier escolhida incluiu 12 harmônicas na série. O número de harmônicas foi escolhido de forma a criar ciclos de repetição a cada 4 semanas,⁵² possibilitando o controle da sazonalidade de médio e de longo prazo, uma vez que o controle de curto prazo foi feito diretamente com a inclusão de variáveis independentes no modelo (i.e., dias da semana e temperatura média diária).

Todos os modelos aplicados incluíram termos indicadores para variáveis relacionadas ao calendário: os dias da semana, a ocorrência de feriados e dias anteriores e posteriores aos feriados. Foram considerados 'feriados' os dias 1º de janeiro, 25 de janeiro (aniversário do Município de São Paulo), o sábado e a terça feira de carnaval, 21 de abril, Sexta feira Santa, Domingo de Páscoa, 1º de maio, Corpus Christi, 9 de Julho, 7 de

setembro, 12 de outubro, 2 de novembro, 15 de novembro e 25 de dezembro.

Além desses, como a inspeção visual do gráfico de admissões no PS de acordo com a data de admissão mostrou valores discrepantes para os dias 1º de janeiro e 31 de dezembro (menor número de pacientes), foi criada uma variável *dummy* para controlar essa variação. Também baseado na inspeção visual dos dados, foi incluído um termo correspondente ao período de epidemia de influenza A H1N1 em 2009 (13 de julho a 12 de agosto), quando houve um aumento desproporcional no volume diário de pacientes no PS.

Como a literatura mostra resultados controversos em relação à importância de se incluir variáveis climáticas para a previsão da demanda no PS,^{6,38,51} todos os métodos de previsão foram testados, cada um, com um modelo que incluía e outro que não incluía variáveis para controlar o efeito da temperatura média diária. A inclusão da temperatura média se deu por essa ser a variável climática que mais consistentemente apresenta associação com eventos de morbidade e mortalidade.^{7,12,13,38} Esses desfechos de saúde ocorrem nos dois extremos de temperatura, calor e frio. Assim, o efeito da temperatura média no volume diário de pacientes foi estimado como um aumento log linear no risco para admissão no PS para cada 1°C acima ou abaixo de limiares de calor e de frio, respectivamente. A identificação desses valores limiares foi feita através do ajuste reiterado de modelos, cada um incluindo um valor inteiro de temperatura dentre todos os valores observados no banco de dados durante o período do estudo. Os valores de temperatura que resultaram no modelo de melhor ajuste (menor AIC) foram identificados como os limiares de calor e de frio para a amostra estudada. Mais ainda, como a literatura mostra que os efeitos da temperatura média diária na saúde podem ocorrer com uma defasagem de tempo, que é mais curta para o calor e pode persistir por semanas para o frio,¹¹⁻¹³ o efeito da temperatura na demanda do PS foi estimado em relação à temperatura no mesmo dia da visita ao PS e em um intervalo de dias de

defasagem em relação a este. A extensão do intervalo de dias de defasagem utilizado foi decidida a partir da visualização gráfica das estimativas dos riscos associados a ultrapassagens do valor limiar da temperatura nas defasagens de 0 a 20 dias, sendo selecionado o intervalo de dias em que o risco estimado era significativamente maior que zero.¹³

Todas as análises foram desenvolvidas utilizando-se o pacote estatístico Stata (Stata Corp. College Station, TX).

3.6 Medidas de efeito e avaliação da acurácia dos modelos de previsão

O efeito de cada variável independente no número diário de pacientes no PS foi estimado a partir dos modelos GLM e GEE e, para facilitar sua comunicação, será apresentado em termos da variação esperada no volume diário de pacientes no PS em termos percentuais. Essa medida de efeito é uma conversão do risco relativo de acordo com a fórmula:

$$(Risco\ Relativo - 1) \times 100$$

cujo resultado informa a variação esperada no volume de pacientes associada a cada variável independente em relação a sua categoria de referência.

Os modelos multivariados SARIMA não foram utilizados na estimativa de efeito das variáveis independentes, por não fornecerem informações globais do efeito de cada parâmetro na variável dependente.

A avaliação da acurácia e a comparação dos modelos de previsão foram realizadas através da inspeção de gráficos comparando os valores previstos e os valores reais observados, além do cálculo do erro médio percentual absoluto (MAPE) através da fórmula:

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

onde y_t é o valor real observado, \hat{y}_t corresponde ao valor estimado a partir do modelo de previsão e n é o número total de observações.

3.7 Considerações éticas

O estudo foi baseado em dados secundários e agregados, prescindindo de informações de identificação dos casos. O projeto foi submetido e aprovado pelo Comitê de Ética em Pesquisa da Faculdade de Medicina da Universidade de São Paulo (Protocolo de Pesquisa nº 327/10).

4 RESULTADOS

4.1 Volume diário de pacientes no PS e temperatura média observada ao longo da série

A Tabela 2 apresenta um sumário dos dados acerca do número diário de pacientes e da temperatura média observada durante o período de treinamento, que compreendeu 1.004 dias. Observou-se a média de 389 pacientes atendidos por dia no PS, número que variou de 166 a 613.

Tabela 2 Número de pacientes no pronto socorro e temperatura média diária no Município de São Paulo – Pronto Socorro do ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010

	Média	DP	5° percentil	95° percentil
Número diário de pacientes (n)	388,6	85,5	248	520
Temperatura média (°C)	19,5	3,4	13,7	24,5

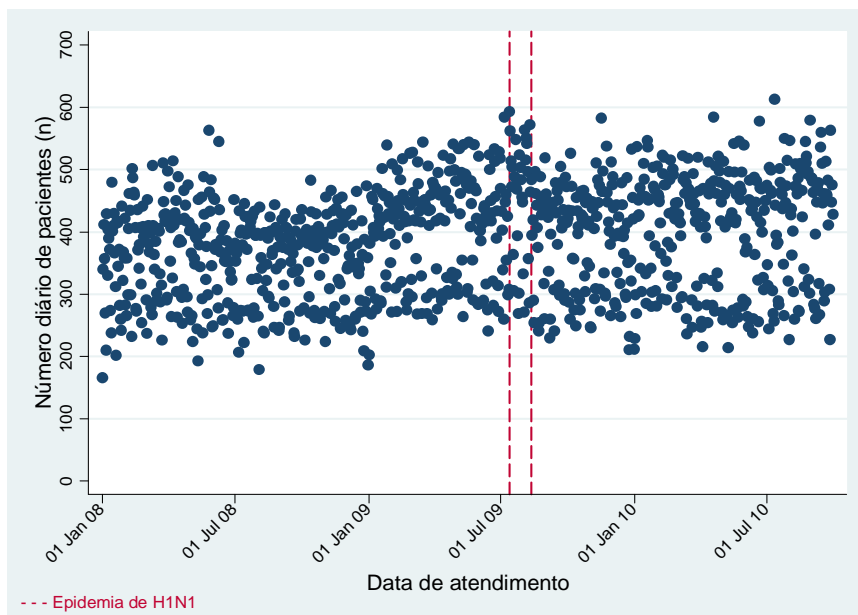
ICHC-FMUSP: Instituto Central do Hospital das Clínicas da Faculdade de Medicina da USP; DP: desvio padrão

A análise do gráfico de dispersão do volume diário de pacientes no PS em relação à data de admissão mostrou uma tendência de aumento dos casos no período, mais marcante a partir de janeiro de 2009. Além disso, a dispersão dos dados seguiu um padrão com duas faixas distintas e demarcadas ao longo do período, evidenciando a diferença observada na demanda enfrentada em dias úteis (maior volume de pacientes) e nos finais de semana (menor volume) (Figura 2). Também se observou o efeito da epidemia de influenza A H1N1 ocorrida em 2009, que reconhecidamente acarretou uma maior demanda aos PS do município (Figura 2).

O gráfico tipo Box-plot com a distribuição da demanda diária de acordo com o dia da semana mostrou o maior volume de pacientes na segunda-feira, com uma tendência linear decrescente ao longo da semana,


e os menores números ocorrendo no final de semana (Figura 3). Por outro lado, não foi observada uma variação significativa no número diário de atendimentos de acordo com os meses do ano (Figura 4).

Figura 2 Volume diário de pacientes no pronto socorro por dia do atendimento – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010




ICHC-FMUSP: Instituto Central do Hospital das Clínicas da Faculdade de Medicina da USP

Figura 3 Distribuição do volume diário de pacientes no pronto socorro de acordo com o dia da semana – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010



ICHC-FMUSP: Instituto Central do Hospital das Clínicas da Faculdade de Medicina da USP

Figura 4 Distribuição do volume diário de pacientes no pronto socorro de acordo com o mês – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010



ICHC-FMUSP: Instituto Central do Hospital das Clínicas da Faculdade de Medicina da USP

4.2 Definição dos modelos de previsão de acordo com o melhor ajuste

4.2.1 Modelos lineares generalizados

Os modelos GLM foram ajustados incorporando-se as variáveis independentes já explicitadas, além do controle da sazonalidade e da tendência secular.

O limiar para efeito da temperatura foi de 16° C, tanto para o frio como para o calor, e a defasagem que apresentou associação com o aumento no volume de pacientes no PS foi de zero a 5 dias para o calor, e zero a 20 dias para o frio. Esses mesmos valores foram aplicados nos modelos GEE e SARIMA.

4.2.2 Equações de estimação generalizadas

Após o primeiro ajuste dos dados com um modelo GEE, a análise do gráfico da FACP dos resíduos mostrou a presença de autocorrelação dos dados, determinada principalmente pelo padrão de sazonalidade semanal observada na demanda de atendimentos no PS. Tentou-se, então, o ajuste do modelo com estruturas de autorregressão que variaram de 1 a 7 dias de defasagem. Os modelos de séries temporal com autorregressão são modelos de regressão múltipla em que a variável dependente é função de seus valores num período passado. Na série temporal aqui estudada, o melhor ajuste (menor QIC) foi encontrado no modelo com um termo para autorregressão de um dia de defasagem (AR(1)), o que significa que o volume de pacientes atendidos no PS em um determinado dia era influenciado pelo número de pacientes no PS no dia anterior.

4.2.3 SARIMA

A definição da ordem da AR e da média móvel para o modelo SARIMA foi feita a partir da plotagem dos gráficos da FAC e FACP do volume diário de pacientes no PS.

Observou-se a presença de autocorrelação significativamente diferente de zero nas defasagens de 1 e 2 dias. Além disso, apesar de não apresentarem tendência nos termos de defasagem mais próximos, os dois gráficos mostraram um padrão de sazonalidade e tendência nos termos de defasagem relacionados à variação semanal, com autocorrelação positiva e significativamente diferente de zero nas defasagens de 7, 14, 21 dias e assim por diante (Figura 5).

Após a diferenciação dos dados na ordem $d(1)$, que tornou a série aparentemente estacionária, o gráfico da FAC ainda apresentava autocorrelação nas defasagens de 1 e 2 dias, tanto nos termos locais (i.e., os termos imediatamente anteriores ao dia estudado), como nos intervalos sazonais (ou seja, a cada intervalo de sete dias). O gráfico da FACP mostrou

autocorrelação na defasagem de 1 dia, também nos termos locais e sazonais (Figura 6). Além disso, observou-se um padrão de autocorrelação parcial em todos os termos da primeira semana, o que, de acordo com Chatfield,⁴ pode ser considerado como um padrão “sem explicações físicas óbvias” e que não deve ser levado em consideração.

Os resultados encontrados sugeriram a utilização de um modelo SARIMA (1,0,2) (1,1,2)₇. Como a interpretação de gráficos da FAC e da FACP envolve um aspecto bastante subjetivo,^{4,5} foram testadas outras possibilidades de modelos SARIMA (derivadas de outras possibilidades de interpretação dos mesmos gráficos), que foram comparadas de acordo com o AIC. De todos os modelos testados, e após a inclusão das variáveis independentes já descritas na seção **3. Material e Métodos**, o modelo com melhor ajuste permaneceu sendo o SARIMA (1,0,2) (1,1,2)₇.

O processo de identificação do modelo foi repetido para a previsão nos segundo e terceiro horizontes. Os gráficos da FAC e da FACP foram bastante similares, portanto o mesmo modelo SARIMA foi empregado.

Figura 5 Função de autocorrelação (acima) e função de autocorrelação parcial (abaixo) do volume diário de pacientes no pronto socorro – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010




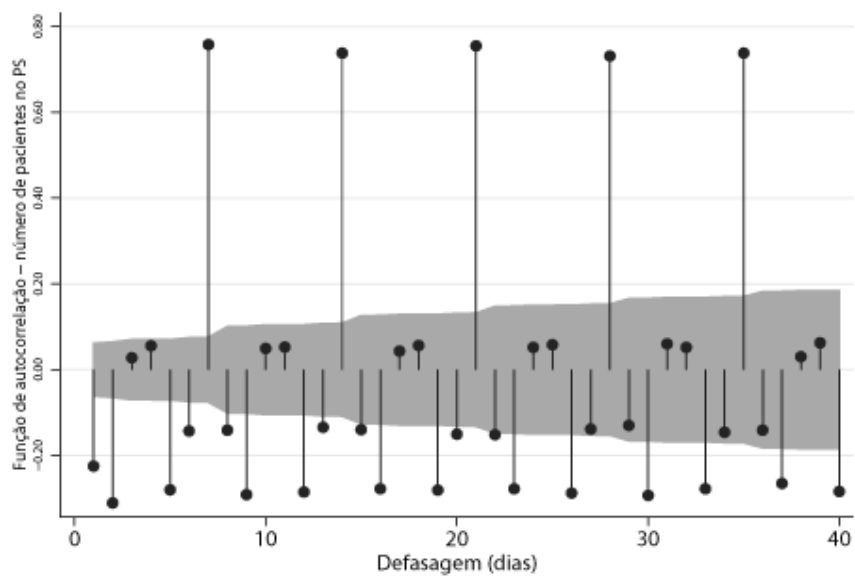


Figura 6 Função de autocorrelação (acima) e função de autocorrelação parcial (abaixo) após diferenciação de ordem $d(1)$ do volume diário de pacientes no pronto socorro – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010



4.3 Quantificação do efeito das variáveis independentes no volume diário de pacientes no PS

A Tabela 3 apresenta o efeito estimado das variáveis independentes no número diário de pacientes atendidos no PS durante o período de treinamento, em termos percentuais e de acordo com o modelo GLM. São apresentados os resultados do modelo que incluiu e do que não incluiu termos para controlar o efeito da temperatura média diária.

Embora a temperatura média tenha apresentado uma associação estatisticamente significativa com o volume diário de pacientes no PS, que foi maior para os extremos de frio do que de calor, a estimativa dos parâmetros aponta que os maiores efeitos observados estiveram associados a variáveis relacionadas ao calendário, principalmente ao dia da semana.

Além disso, a inclusão de termos para temperatura não afetou de maneira significativa os resultados do modelo, exceção feita ao efeito da epidemia de influenza A H1N1 (que coincide com os dias mais frios do ano de 2009 e que foi, também, o inverno mais frio de todo o período estudado).

Os resultados obtidos a partir dos modelos GEE foram bastante similares e, portanto, não são mostrados aqui.

4.4 Medidas de acurácia e comparação dos modelos de previsão

A Figura 7 mostra a comparação dos volumes diários de pacientes no PS previstos a partir dos modelos GLM e SARIMA com o volume real observado no período de validação. Como os modelos GLM e GEE tiveram resultados bastante semelhantes, as curvas obtidas com o modelo GEE foram omitidas dos gráficos para a melhor visualização dos dados.

Pode-se observar na Figura 7 que todos os modelos testados se aproximaram dos valores reais observados e, principalmente, foram capazes

de detectar os pontos de inflexão da curva, ou seja, momentos de mudança na sua direção. A comparação dos gráficos com modelos que incluíram e que não incluíram o controle para o efeito da temperatura não mostra diferenças significativas.

Tabela 3 Efeito das variáveis independentes em termos de mudança percentual no volume diário de pacientes no pronto socorro – ICHC-FMUSP, 1° de janeiro de 2008 a 30 de setembro de 2010

Variável independente	GLM (não inclui termos para efeito da temperatura média)		GLM (inclui termos para efeito da temperatura média)	
	Varição no volume de pacientes ^a (%)	IC 95%	Varição no volume de pacientes ^a (%)	IC 95%
Segunda-feira (referência)	-	-	-	-
Terça-feira	-9,3	(-11,2 a -7,4)	-9,3	(-11,1 a -7,5)
Quarta-feira	-12,2	(-14,0 a -10,3)	-12,2	(-13,9 a -10,4)
Quinta-feira	-13,1	(-14,9 a -11,3)	-13,1	(-14,9 a -11,3)
Sexta-feira	-14,1	(-15,9 a -12,3)	-14,2	(-15,9 a -12,4)
Sábado	-37,4	(-38,8 a -36,0)	-37,4	(-38,8 a -36,0)
Domingo	-43,4	(-44,8 a -42,1)	-43,5	(-44,8 a -42,1)
Feriado	-28,5	(-31,2 a -25,8)	-28,5	(-31,2 a -25,8)
Véspera de feriado	-6,5	(-9,2 a -3,7)	-6,5	(-9,2 a -3,7)
Dia posterior a feriado	0,6	(-2,7 a 4,0)	0,6	(-2,6 a 4,0)
Epidemia de influenza A H1N1	18,1	(13,7 a 22,7)	13,4	(8,6 a 18,4)
31 dezembro/1° janeiro	-37,9	(-45,2 a -29,7)	-38,3	(-45,4 a -30,1)
Efeito do calor* ^β	-	-	1,1	(0,6 a 1,6)
Efeito do frio** ^β	-	-	5,3	(2,8 to 7,8)
Data de admissão	0	(0,0 a 0,0)	0	(0,0 to 0,0)

ICHC-FMUSP: Instituto Central do Hospital das Clínicas da Faculdade de Medicina da USP; GLM: modelo linear generalizado; IC 95%: Intervalo de 95% de Confiança

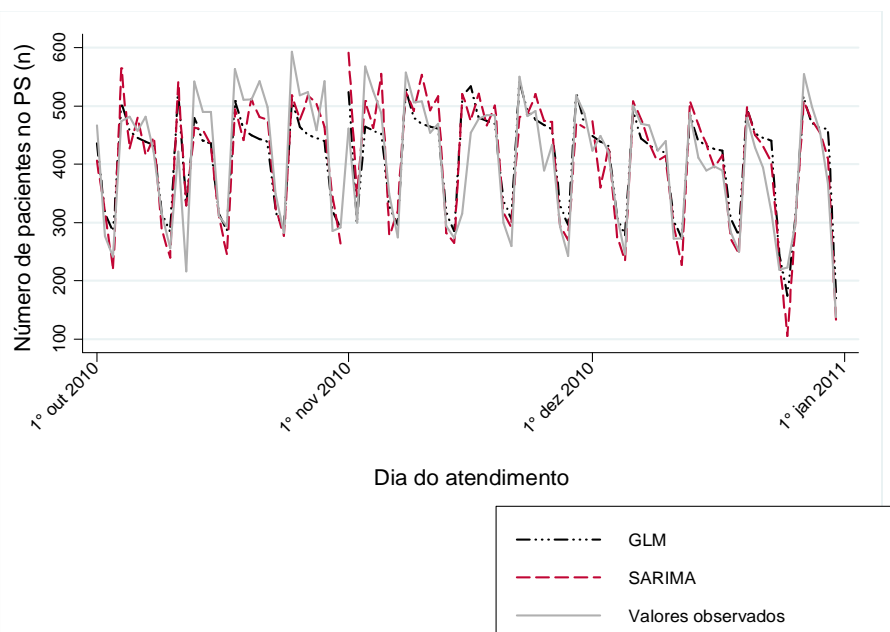
^a Varição no volume de pacientes: (risco relativo – 1) * 100

^β O efeito do calor e do frio foram calculados como um aumento log linear para cada 1°C acima ou abaixo dos valores limiares para o calor e para o frio, respectivamente

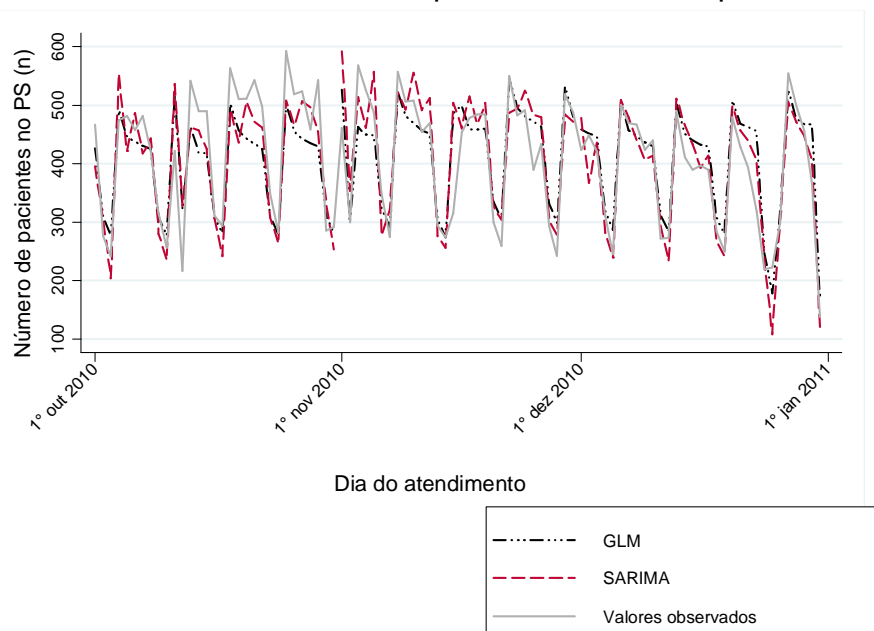
* A temperatura limiar para o efeito do calor foi de 16°C no dia do atendimento ou nos 5 dias anteriores

** A temperatura limiar para o efeito do frio foi de 16°C no dia do atendimento ou nos 20 dias anteriores

Figura 7 Comparação dos valores reais observados e valores previstos para o volume diário de pacientes no pronto socorro de acordo com os modelos lineares generalizados e modelos SARIMA, sem incluir termos para o efeito da temperatura (a) e incluindo termos para o efeito da temperatura (b) - ICHC-FMUSP, 1° de outubro a 31 de dezembro de 2010



(a) Modelos sem inclusão de termos para o efeito da temperatura



(b) Modelos incluindo termos para o efeito da temperatura

A Tabela 4 mostra o erro médio percentual absoluto de cada um dos modelos para os três horizontes de previsão, com e sem a inclusão de termos para o efeito da temperatura. Os MAPEs calculados para os primeiros 7 dias de cada horizonte de previsão também são mostrados. De maneira geral, os MAPEs para o horizonte de 7 dias de previsão foram menores que os MAPEs para 30 dias. Além disso, os valores dos MAPEs mostraram uma tendência de queda do primeiro para o terceiro horizonte de previsão. MAPEs resultantes dos modelos GLM e GEE foram bastante semelhantes e, em geral, menores que os obtidos com os modelos SARIMA.

A inclusão de termos para controlar o efeito da temperatura nos modelos não resultou em maior acurácia da previsão, e os MAPEs calculados a partir desses modelos foram piores ou similares aos modelos que não incluíram termos para controle do efeito da temperatura.

Tabela 4 Erro médio percentual absoluto dos modelos para previsão do volume diário de pacientes no pronto socorro nos três horizontes de previsão - ICHC-FMUSP, 1° de outubro a 30 de dezembro de 2010

Modelos sem inclusão de termos para o efeito da temperatura						
	1° horizonte de previsão*		2° horizonte de previsão*		3° horizonte de previsão*	
	7 dias	30 dias	7 dias	30 dias	7 dias	30 dias
	MAPE (%)		MAPE (%)		MAPE (%)	
GLM	8,8	10,8	9,5	9,6	4,5	8,7
GEE	8,9	10,8	8,9	9,3	4,6	8,9
SARIMA	12,4	11,7	16,7	11,4	7,5	9,0
Modelos incluindo termos para o efeito da temperatura						
	1° horizonte de previsão*		2° horizonte de previsão*		3° horizonte de previsão*	
	7 dias	30 dias	7 dias	30 dias	7 dias	30 dias
	MAPE (%)		MAPE (%)		MAPE (%)	
GLM	8,8	11,5	9,9	9,2	5,4	10,0
GEE	8,8	11,5	9,4	9,1	5,4	10,2
SARIMA	12,9	12,8	17,1	11,8	7,2	9,3

*1° horizonte de previsão: 1 a 30 de outubro de 2010, 2° horizonte de previsão: 1 a 30 de novembro de 2010, 3° horizonte de previsão: 1 a 30 de dezembro de 2010; GLM: modelo linear generalizado; GEE: equação de estimação generalizada; MAPE: erro médio percentual absoluto

5 DISCUSSÃO

Este estudo testou a aplicação de três métodos de análise de séries temporais para a previsão do volume diário de pacientes em um PS e comparou a acurácia entre modelos que incluíram e que não incluíram termos para controlar o efeito da temperatura média diária. Os resultados mostram que as variáveis relacionadas ao calendário exercem maior influência na previsão do número de pacientes no PS que a temperatura média diária, e esses achados estão de acordo com publicações prévias.^{6,7,30} Além disso, na série temporal estudada a sazonalidade semanal era preponderante em relação à sazonalidade mensal na distribuição do volume diário de pacientes no PS, e segundas-feiras eram os dias mais cheios, enquanto os fins de semana eram mais vazios. Esses resultados estão de acordo com estudos anteriores, que também relataram maior número de pacientes durante a semana em relação aos fins de semana, principalmente no primeiro dia útil.^{6,7,30,33,34,37}

Todos os modelos testados permitiram a previsão dos padrões de demanda no PS. Os modelos GLM e GEE geraram resultados bastante semelhantes e, em geral, de maior acurácia do que os modelos SARIMA. Os modelos da classe ARIMA têm sido extensivamente utilizados na previsão de eventos de saúde,^{6,7,22} embora publicações prévias confirmem nossos achados de que outros métodos de séries temporais resultam em previsões com nível de acurácia semelhante ou melhor.^{6,31}

Tandberg e Qualls³¹ compararam 5 diferentes métodos de previsão de visitas ao PS por hora, incluindo um modelo ARIMA, e os resultados mostraram que um modelo mais simples de média móvel gerava a maior qualidade de previsão. A acurácia dos modelos foi comparada a partir da análise gráfica das previsões. Jones et al.⁶ compararam a acurácia de modelos SARIMA, de regressão linear múltipla, de regressão de séries

temporais, alisamento exponencial, e um modelo de rede artificial neural para a previsão do volume diário de pacientes em 3 PS dos EUA e concluíram que o modelo de série temporal levava a resultados mais consistentes e de maior acurácia (menor MAPE) entre todos os modelos testados. Não é explicitado no estudo, no entanto, qual o método de regressão de séries temporais utilizado.

Além de resultarem em maior acurácia neste estudo, os modelos GLM e GEE apresentam-se como mais vantajosos que os modelos SARIMA para a previsão em um cenário real de prática, uma vez que o ajuste de modelos SARIMA é um processo iterativo e as estruturas de autorregressão e de média móvel precisam ser reespecificadas a cada vez que dados atualizados são incluídos na série de dados, dificultando a automação do processo.

Em estudos anteriores, o controle da sazonalidade foi geralmente feito por intermédio da inclusão de variáveis categóricas para estratificações pré-selecionadas de intervalos de tempo, a exemplo do uso de indicadores para os meses do ano. Essa abordagem traz as desvantagens de não permitir o controle da sazonalidade ocorrendo dentro de um mês, além de assumir uma mudança do tipo categórica (*step-wise*) de um mês para o outro. Neste estudo, optou-se pelo uso de termos de Fourier para fazer o controle da sazonalidade, o que permite a modelagem de repetições cíclicas e regulares em diferentes frequências. Dessa forma, buscou-se atingir um controle da sazonalidade mais suave e mais próximo do que é observado na distribuição dos dados. Apesar dessa abordagem diferente, os MAPEs aqui obtidos, que variaram entre 4,5% e 17,1%, foram semelhantes aos MAPEs publicados em outros estudos. Reis e Mandl⁴¹ fizeram a previsão de visitas diárias em um PS pediátrico utilizando modelos ARIMA e obtiveram o MAPE de 9,4%. Jones et al.,⁶ no estudo descrito previamente, encontraram MAPEs que variaram entre 8,5% e 15,5%. Sun et al.⁷ utilizaram um modelo SARIMA incluindo termos para controlar efeitos climáticos e de poluição do ar para a previsão do volume diário de pacientes em 3 PS de Singapura, e

os MAPEs resultantes foram de 6,7%, 8,6% e 16,9%. Kam et al.⁴² realizaram a previsão de pacientes atendidos diariamente em um PS da Coreia do Sul comparando um modelo SARIMA univariado e um modelo SARIMA múltiplo que incluía variáveis climáticas. Foram reportados MAPEs de 7,8% e 7,4%, respectivamente. Boyle et al.³⁹ reportaram um MAPE de 7,0% em um estudo para previsão do volume diário de pacientes em dois PS na Austrália.

A análise dos MAPEs encontrados neste estudo aponta que os modelos GLM e GEE tiveram boa acurácia na previsão do volume diário de pacientes no PS do ICHC-FMUSP. Embora a teoria estatística não estabeleça valores limites para determinar modelos de previsão com boa acurácia, alguns autores citam como ponto de corte desejável MAPEs abaixo de 20%,^{1,7} limite que está acima do pior resultado obtido neste estudo.

Os resultados obtidos para os horizontes de previsão mais curtos (7 dias) foram melhores que a previsão para os horizontes de 30 dias, fato que está de acordo com a literatura especializada.^{4,5} Além disso, em geral, os MAPEs do terceiro horizonte de previsão (dezembro) foram menores que os do segundo e primeiro horizontes (novembro e outubro). Esse achado pode ter se dado pelo fato que o terceiro horizonte de previsão incluiu mais dados para a regressão no período de treinamento, resultando em uma estimativa de previsão mais precisa. Outra explicação possível é que o terceiro horizonte seja de fato mais previsível, uma vez que o mês de dezembro corresponde às férias escolares e uma parcela significativa da população deixa a cidade para férias e nos feriados de Natal e Ano Novo. Foi possível observar, por exemplo, que dezembro foi o mês com o menor volume de pacientes no PS nos 3 anos da série.

Os resultados deste estudo não apoiam a inclusão de termos para controlar o efeito da temperatura média na previsão do volume diário de pacientes no PS. Modelos mais simples, ou seja, modelos baseados unicamente em variáveis relacionadas ao calendário apresentaram resultados similares ou melhores do que os modelos mais complexos. Além

de não melhorarem a acurácia da previsão de atendimentos, as variáveis meteorológicas não podem ser previstas com 100% de acerto, principalmente em horizontes de previsão acima de 3 dias em prospectivo, fato que aumenta a incerteza dos modelos de previsão do volume de pacientes. Mais que isso, um modelo de previsão que utilize apenas variáveis relacionadas ao calendário pode ser mais facilmente implementado como um processo automatizado e, assim, ser gerado com uma antecedência suficiente para embasar decisões de gerenciamento do serviço.

Embora pudesse ser esperado que os modelos para a previsão do volume diário de pacientes no PS que incluíram termos para o efeito da temperatura média gerassem previsões de acurácia ao menos similar aos modelos que não incluíram essas variáveis, os resultados deste estudo mostram o contrário, fato que tem respaldo na literatura. Chatfield⁴ mostra que, embora os modelos mais complexos geralmente apresentem melhor ajuste aos dados (o que de fato aconteceu na série de dados deste estudo), a acurácia da previsão desses modelos não necessariamente é melhor, e é comum que modelos mais simples sejam melhores.

5.1 Limitações metodológicas e aplicação do estudo

O objetivo final deste estudo foi o de explorar modelos para previsão do número diário de pacientes no PS que pudessem ser utilizados no planejamento do serviço e adequação dos recursos à demanda esperada. Para explorar tal proposição, o modelo final encontrado deveria ser testado no cenário real. Embora os modelos utilizados tenham sido capazes de fazer a previsão da demanda no PS e, mais que isso, tenham sido capazes de prever os momentos de inflexão no gráfico do volume de pacientes ao longo do tempo, em alguns dias específicos o erro absoluto observado foi bastante alto, o que pode dificultar seu uso aplicado ao planejamento do serviço de emergência. Por outro lado, estudos que apresentaram acurácia de previsão similares relataram resultados positivos ao aplicarem na prática os modelos

de previsão para a adequação da equipe do PS à demanda esperada. Batal et al.,³⁰ por exemplo, encontraram uma diminuição de 18,5% no número de pacientes que abandonam o serviço antes do atendimento, além da redução em 30% das reclamações após utilizarem os modelos de previsão para dimensionamento da equipe no PS. Rotstein et al.³³ relataram a melhora no congestionamento do PS ao aumentarem a equipe de assistência nos domingos, em adequação ao resultado obtido em um estudo de previsão.

Uma limitação deste estudo é o fato de que a previsão foi feita apenas para meses fora do período de inverno. Será importante estender as análises para incluir outros meses e entender como a série se comporta em relação a acurácia da previsão. Por outro lado, é improvável que os resultados sejam muito diferentes do que os apresentados aqui, uma vez que o volume de pacientes atendidos diariamente no PS do ICHC-FMUSP não teve grande variação de acordo com os meses do ano, como pode ser observado na Figura 4.

Procurou-se incluir nos modelos as variáveis independentes que já foram relacionadas em estudos anteriores como variáveis que influenciam o volume diário de pacientes no PS. É possível, no entanto, que existam outros fatores que afetem essa demanda e que não puderam ser incluídos neste estudo, inclusive por não poderem ser facilmente quantificáveis, como a capacidade de funcionamento de outros serviços de saúde da rede de referência e contrarreferência.³³ Outras variáveis climáticas não incluídas nos modelos também poderiam influenciar o comportamento e a acurácia das previsões realizadas.

6 CONCLUSÕES

Os resultados encontrados indicam que métodos de séries temporais podem ser aplicados na rotina do serviço de PS para realizar a previsão do provável volume diário de pacientes no serviço. A previsão realizada para o curto prazo tem boa acurácia e pode ser incorporada à rotina do serviço, de modo a subsidiar o seu planejamento e colaborar com a adequação de recursos materiais e humanos, facilitando sua organização e melhorando a qualidade da assistência prestada.

A acurácia da previsão realizada variou de acordo com o modelo utilizado e com o horizonte de previsão incluído na análise. Para os dados do PS do ICHC-FMUSP, os modelos GLM e GEE levaram a melhores resultados que os modelos SARIMA. A inclusão de variáveis para controlar o efeito da temperatura média no número diário de pacientes não aumentou a acurácia da previsão. Embora em alguns dias o erro de previsão tenha sido relativamente alto, de uma maneira geral os modelos de previsão baseados unicamente em variáveis relacionadas ao calendário foram capazes de prever a variação no volume diário de pacientes.

Este estudo representou um exemplo de aplicação da metodologia de séries temporais para o planejamento de um serviço de saúde, de acordo com recomendações de câmeras técnicas sobre o assunto e de acordo com o que já é realizado em outros setores de produção de serviços. Os métodos aqui aplicados podem ser automatizados de forma a gerar informações com antecedência suficiente para decisões de gestão e planejamento. Embora os profissionais atuando no serviço trabalhem com o senso comum dos dias em que geralmente há uma maior lotação do PS, trabalhar com os dados de maneira objetiva para ajustar as equipes de assistência pode trazer importante benefício para o serviço e para os pacientes.

7 ANEXO

Artigo aceito para publicação na revista Academic Emergency Medicine.

Marcilio I, Hajat S, Gouveia N. Forecasting daily emergency department visits using calendar variables and ambient temperature readings. Acad Emerg Med. [In press]

Title of Manuscript

Forecasting daily emergency department visits using calendar variables and ambient temperature readings

Abstract

Objectives: This study aims to develop different models to forecast the daily number of patients seeking emergency department (ED) care in a general hospital according to calendar variables and ambient temperature readings and to compare the models in terms of forecasting accuracy.

Methods: We developed and tested six different models of ED patient visits using aggregated daily counts of patient visits to an ED in Sao Paulo, Brazil from January 1, 2008 to December 31, 2010. We used the first 33 months of the dataset to develop the ED patient visits forecasting models (the training set), leaving the last 3 months to measure each model's forecasting accuracy by means of the mean absolute percentage error. Forecasting models were developed using 3 different time series analysis methods: generalized linear models, generalized estimating equations and seasonal autoregressive integrated moving average. For each method, we explored models with and without the effect of mean daily temperature as a predictive variable.

Results: Daily mean number of ED visits was 389, ranging from 166 to 613. Data showed a weekly seasonal distribution, with highest patient volumes on Mondays and lowest patient volumes on weekends. There was little variation in daily visits by month. Generalized linear models and generalized estimating equation models showed better forecasting accuracy than seasonal autoregressive integrated moving average (SARIMA) models. For instance, the mean average percentage errors from generalized linear models and generalized estimating equations models at the first month of forecasting (October, 2012), were 11.5% and 10.8% (models with and without control for the temperature effect, respectively), while the mean average percentage errors from SARIMA models were 12.8% and 11.7% (models with and without control for the temperature effect, respectively). For all models, controlling for the effect of temperature resulted in worse or similar forecasting ability than models with calendar variables alone, and forecasting accuracy was better for the short term horizon (7 days in advance) than for the longer term (30 days in advance).

Conclusions: Our study indicates that time series models can be developed to provide forecasts of daily ED patient visits, and forecasting ability was dependent on the type of model employed and the length of the time-horizon being predicted. In our setting, generalized linear models and generalized estimating equation models showed better accuracy, and including information about ambient temperature in the models did not improve forecasting accuracy. Forecasting models based on calendar variables alone did in general detect patterns of daily variability in ED volume, and thus could be used for developing an automated system for better planning of personnel resources.

Introduction

Reports from different countries, including the United States, the United Kingdom, and Brazil, have shown an increase in demand for emergency department (ED) care, resulting in frequently overcrowded EDs, lengthy waiting times for assistance, and an overall perception by patients of a poor health care¹⁻⁴. Prolonged waiting times are described as a major factor for dissatisfaction with ED care^{5,6}, and patients are more likely to leave without being seen as waiting time increases⁵. While common practice is to divert patients from EDs in times of overcrowding², using data on daily patient volume for better planning of personnel resources might increase the service's efficiency as well as improve ED patient care quality^{5,7-9}. A report from the National Audit Office on inpatient admissions from acute hospitals in England has stated that the trusts could make more effective use of their knowledge of patterns of ED admissions in order to assess the likely demand of their resources¹⁰.

A time series is a set of chronologically ordered observations, and forecasting methods uses past values of any given time series to predict its future behavior¹¹. Time series models can be used to forecast future ED patient visits based on the estimated effect of predictor variables, and such forecasts can be used for proactive bed and staff management and for facilitating patient flow^{12,13}. For example, the finding that Sundays had a much higher volume of patients in the ED at a hospital in Israel led to the decision of allocating an additional physician to staff every Sunday, thus alleviating ED congestion⁹. Batal et al. (2001) have reported an 18.5% decrease in patients leaving without being seen in an ED and a 30% decrease in complaints after adjusting staff in accordance to the results of an applied ED patient visits forecasting model⁵. Although decisions on staffing are commonly based on personal experience¹⁴⁻¹⁶, a rational approach to allocation of resources

would be of great importance for improving the quality of care delivered at ED settings^{1-3,5,17}.

A number of factors can influence daily ED visits, and a patient visits forecasting model should include those factors. Previous studies have shown that ED visits present cyclical variations according to day of the week, time of the year, and the occurrence of public holidays^{1,5,9,12,13,17}. Temperature variables have also been included in some patient visits forecasting models^{14,17-20}, since many studies have demonstrated the association of climate factors, temperature in particular, with the occurrence of mortality and morbidity outcomes²¹⁻²⁴. For instance, weather forecasts in the United Kingdom have been used for warning chronic obstructive pulmonary disease patients when their health is likely to be affected²⁵. The predictive effect of temperature on daily ED visits, however, is still uncertain. While some studies have shown there is an association between these variables^{12,17-20,26}, other authors advocate that including temperature adds uncertainty to the model in exchange for little improvement on forecasting accuracy^{5,12,27}. Because the temperature effect depends on the geographical location and on characteristics of the ED²⁶, the relevance of including weather variables for improving the overall prediction accuracy should be tested when developing a particular forecasting model for daily ED visits.

Our study aims to develop models to forecast the daily number of patients seeking ED care in a busy general hospital in a major world city (Sao Paulo, Brazil) according to calendar variables and ambient temperature. Different time series approaches can be employed to develop forecast models, and the relevant literature indicates that there is no obvious supremacy of one method over others¹¹. We thus explored three different analytic approaches to develop daily ED patient visits forecasting models as well as the contribution of ambient temperature, and compared the models in terms of forecasting accuracy.

Methods

Study design

In order to develop and compare accuracy of forecast models of ED patient visits using different time-series analysis methods, we evaluated records of daily ED visits to a tertiary hospital in Sao Paulo, Brazil. The study was approved by the Ethical Committee Review Board of the University of Sao Paulo Clinics Hospital.

Study setting and population

The study was conducted in Sao Paulo, Brazil, a city of approximately 11 million people. The ED is the main referral hospital for high-complexity emergency clinical, surgery and trauma cases occurring in the south and west region of the city. Operating 7 days per week, 24 hours a day, the ED treats approximately 180,000 patients per year.

Data collection

Data on daily ED patient visits, including date and time of arrival and main diagnosis, were extracted from a computerized tracking system at the hospital's Information and Health Department. We extracted aggregated daily counts of all patients that presented to the ED from January 1, 2008 to December 31, 2010.

Daily mean temperature and air pollution data were obtained from the Sao Paulo Environmental Agency. Air pollution was assessed by measuring the ambient levels of particulate matter (PM₁₀) and ozone (O₃), since these pollutants have shown consistent and independent associations with adverse health effects²⁸. These environmental data are collected hourly at several fully automated monitoring stations throughout Sao Paulo (there are 12 monitoring stations for temperature and PM₁₀, and 8 stations for O₃). Daily mean temperature, PM₁₀ and O₃ were calculated as an average of all 24 hour measurements at the 12 stations.

Study Protocol

The database of daily ED visits, temperature, and air pollution was divided into two periods. The first period, from January 1, 2008 to September 30, 2010, was used for initial data analysis and model development (the 'training set'). The second period, from October 1, 2010 to December 31, 2010, was used to apply the ED patient visits forecasting models and test their accuracy (the 'post-sample forecasting set'). The post-sample forecasting set was further divided into three forecasting horizons of one month each (October, November, and December 2010), and forecast accuracy was assessed at horizons of 7 and 30 days in advance. After forecasting daily ED visits for the 1st horizon (October) and measuring the model's accuracy, the observed values of ED visits were incorporated into the training set and the model reestimated, with the resulting outputs being used to forecast ED visits for the 2nd horizon (November). The process was then repeated for the 3rd horizon (December). This 30-day horizon approach was chosen as we wanted to simulate a real case scenario in which the forecasting model could be updated with the observed values as time went by, and new forecasting values would be generated for future dates.

Data analysis

We explored models of ED patient visits using the following 3 forecasting methods: generalized linear models (GLM), generalized estimating equations (GEE), and seasonal autoregressive integrated moving average (SARIMA) models. All analyses were conducted in Stata 12.0 (Stata Corp., College Station, TX).

GLMs have been used widely in time series regression studies of health outcomes in relation to environmental variables^{21-24,29}. GEEs are an extension of GLMs that have been increasingly used for time-series analysis as well³⁰⁻³³, and provide the advantage of allowing for autocorrelation (non-independence of ED patient visits on proximate days) to be taken

into account in the post-sample forecasting set^{30,31}. We thus applied Poisson GLM and GEE models allowing for over-dispersion to quantify effects of the predictor variables on daily ED visits and to forecast the number of ED visits in the post-sample forecasting set. For the GEE, we considered autoregressive structures up to 7 days lag, finally choosing an autoregressive structure of one-day lag based on best model fit. An autoregressive time-series model is a multiple regression model in which the outcome variable is regressed on its past values¹¹, and the chosen one-day lag means that the number of ED visits in one given day is mostly affected by the previous day patient volume. Goodness of fit was assessed through comparison of quasilielihood under the independence model criterion (QIC)³⁴.

The third forecasting method we examined was a SARIMA model. Autoregressive integrated moving average (ARIMA) models describe current (and future) behavior of variables in terms of their past values, and has been described as the most widely used in health events forecasting^{3,12,17}. Seasonal autoregressive integrated moving average (SARIMA) models extend basic ARIMA models and allow for the incorporation of seasonal patterns. In time-series analysis, seasonality refers to any repetitive pattern that occurs with a known periodicity, such as the weekly pattern observed in ED daily visits. A SARIMA model is typically represented by $(p, d, q) (P, D, Q)_s$ where p represents the order of autoregression (AR), d is the order of differencing (i.e., data transformation through calculating differences among pairs of observations at a d lag in order to make a nonstationary series stationary), and q is the order of the moving average (MA). P , D , and Q are their seasonal counterparts, and s is the seasonal lag¹¹. Model identification was achieved by examining correlogram plots of the autocorrelation function (ACF) and partial autocorrelation function (PACF) of the data. These plots indicated that a SARIMA model of order $(1,0,2) (1,1,2)_7$ had the best fit for our database, indicating an autoregressive

structure of a one-day lag, a moving average of a two-day lag, and a weekly seasonality (a 7-day lag). Because there is some subjectivity in the interpretation of such plots¹¹, we compared alternative models based on AIC (Akaike Information Criterion), and the model described here was the model with the best fit.

All ED patient visits forecasting models included calendar variables as predictors of ED visits. These were: day-of-week, public holidays (a total of 12 days per year) and the days before and after a holiday, since ED activity on such days can be affected by a rebound effect of the holiday. Because the H1N1 flu epidemic of 2009 produced an abnormal peak in ED visits in Sao Paulo due to respiratory causes³⁵, an indicator term for that period (July 13 to August 12, 2009) was included in the models. Moreover, because exceptionally low numbers of visits for the 31st of December and 1st of January of each year were also identified, a term for these dates was also included in the models.

Year-round seasonality was controlled for in all models by including Fourier terms, a data smoothing technique that uses sine-cosine functions for controlling of regular cyclical patterns in the data. Fourier terms were chosen because their specification does not depend on the actual data and thus can be used in the post-sample forecasting equation. Long term trend was accounted for by means of a linear term for date of admission.

For each of the three forecasting methods, we tested one model with and one without temperature as a predictor of daily ED visits. Temperature has been shown to be the climate factor most consistently related to health outcomes^{17,22,23,26}. Because health outcomes are associated with extremes of both heat and cold weather, temperature effect was modeled as a log linear increase below cold and above heat identified thresholds. Threshold values were determined by fitting models over all observed values in the temperature range, and then selecting values with best model fit (lowest AIC).

When assessing the effect of each independent variable on the daily number of ED patient visits, we included daily mean levels of air pollution in the model, since air pollution is known to be associated with ED visits. However, when modeling the training set for developing the forecasting equation, air pollution data were not included, because in a real-case scenario air pollution concentrations are not readily forecastable.

Outcome measure and model evaluation

For ease of interpretation, the effect of each independent variable on the daily number of ED patient visits was expressed as the percentage change in risk of an ED patient visit. This measure of association is a conversion of the relative risk obtained from GLM and GEE models and represents the increase or decrease in the number of daily ED visits associated with each variable in relation to the reference category. Multivariate SARIMA models do not provide information on the overall effect of each parameter and thus was not used for effect estimation.

Forecast accuracy was measured through comparison of plots showing the forecasted and observed values of daily ED visits, and through calculation of the mean average percentage error (MAPE) in each horizon (7 days and 30 days in advance) of the post-sample forecasting set. MAPE is the mean of the absolute differences between forecasted and observed values expressed in terms of a percentage of the observed values, thus a lower MAPE reflects better forecasting accuracy. Being a scale independent measure, MAPE can be used to compare forecasting results of different time series models and with other studies.

Results

ED patient volume, ambient temperature and air pollution data

We observed 390,192 ED patient visits during the training set period (1004 days). Daily mean number of ED visits was 389, ranging from 166 to 613. During the same period, daily mean ambient temperature was 19.5°C (5th centile was 13.7°C, 95th centile was 24.5°C), daily mean PM₁₀ was 36.4µg/m³ (5th centile was 16.5µg/m³, 95th centile was 75.2µg/m³), and daily mean O₃ was 47.1µg/m³ (5th centile was 15.9µg/m³, 95th centile was 85.7µg/m³).

The scatter plot of ED patient volume according to date of ED visit (Figure 1) across the study period shows an upward trend in visits over time, more evident from January 2009 onwards. The plot also shows the different patterns of weekdays (higher patient volume) and weekend (lower patient volume) ED daily visits as evidenced by the two distinctive bands on the scatter plot throughout the study period. Box plots of the distribution of data by day-of-week and month (Figure 2) showed higher patient volumes on Mondays and lower volumes on weekends. However, there was little variation in daily visits by month.

Estimated effects of calendar variables and ambient temperature on daily ED patient visits

Table 1 shows the estimated effect of each predictor variable on daily ED visits obtained from the GLMs with and without terms for temperature, and expressed in terms of percentage change in risk. Threshold values for cold and heat effects were both 16°C, and optimum lags were up to 20 and 5 days respectively. Although temperature was associated with daily ED visits, with the cold effect being stronger than the heat effect, controlling for temperature did not change the estimated impact of the calendar variables.

The effects obtained through modeling with GEE were very similar and therefore are omitted here.

Forecasting accuracy

Figure 3 shows the observed and forecasted values of daily ED visits in the post-sample forecasting set for the GLM and SARIMA models. As GLM and GEE results were almost identical, the latter was omitted for better visualization. The plots show that forecasted values successfully predicted the observed levels, as the lines representing each of those values follow a similar pattern, and there is an overlapping of values in the curves. Furthermore, all tested models could forecast major turning points in patient volume, i.e. the times at which upward and downward changes in observed values occurred were in agreement with changes in forecasted values. Comparison of graphs including and without including temperature values did not show significant differences.

We calculated the MAPE of each model in order to compare their accuracy and decide which would be the most useful in our setting. **Table 2** shows the calculated MAPE of all tested models in the 3 post sample 30-days forecasting horizons. MAPEs are also shown for the first 7 days of each horizon. In general, MAPEs for the 7-days horizons were lower than for the 30 days horizons. Also, MAPEs reduced from first to third horizon. Calculated MAPE from GLM and GEE were very similar and gave better results than SARIMA. Controlling for the effect of temperature did not improve ED patient visit forecasting accuracy. The calculated MAPEs from models including temperature values resulted in worse or similar forecasting ability.

Discussion

This study assessed different methods for forecasting daily ED visits, and compared the accuracy of models with and without consideration of ambient temperature effects. We found that calendar variables were more important forecasting factors than ambient temperature. Moreover, our results showed that weekly seasonality was more dominant than monthly seasonality on daily ED patient visits variation throughout the study period, and Mondays presented the highest ED patient volume while weekends presented the lowest. These results are in accordance with previous results^{5,9,12,14,17}.

Our models could reliably predict patterns of daily ED visits. GLM and GEE models gave very similar results, and both showed better forecasting accuracy than SARIMA models. ARIMA models have been extensively used for health events forecasting purposes^{3,12,17}, although previous studies confirm our findings that other time series methods perform equally or better than ARIMA^{7,12}. Tandemberg et al. (1994) compared 5 different methods for forecasting hourly ED visits, including ARIMA, and found that a less complex moving average model had the best forecasting power⁷. Jones et al. (2008) compared SARIMA, multiple linear regression, times series regression, exponential smoothing, and artificial neural network models accuracy in forecasting daily ED volume at 3 facilities in the United States and found that time series regression had the best and most consistent accuracy of all tested models¹². Besides their better accuracy in our study, we believe that for practical purposes GLM and GEE are advantageous over SARIMA, since fitting a SARIMA model is an iterative process and the autoregressive and moving average structures need to be reidentified as updated data are included in the training series, making it difficult to use it as an automated process.

Seasonal control in previous studies was mostly done by the inclusion of categorical variables within selected time stratifications, e.g. indicator terms for each month of the

year. This approach is disadvantageous as it fails to control for seasonal changes within a month as well assuming a step change in events at the end of each period. We controlled for annual seasonal patterns using Fourier terms, which model regularly repeating seasonal cycles of different frequencies. Despite using this different approach, the overall MAPEs obtained from our models were in accordance with MAPEs published in previous studies. Reis et al. (2003) forecasted daily ED pediatric visits with ARIMA models and found a MAPE of 9.4%³⁶. Jones et al. (2008), in the study described previously, found MAPE results that ranged from 8.5% to 15.5%¹². Sun and al (2009) used a SARIMA model including terms for weather and air pollution to forecast daily ED visits at 3 Singapore health facilities and found MAPEs of 6.7%, 8.6% and 16.9%¹⁷. Kam et al. (2010) forecasted daily ED visits in a Korean hospital using both a univariate and a multivariate SARIMA model including weather variables, with resulting MAPEs of 7.8% and 7.4% respectively²⁰. Boyle et al. (2011) forecasted daily ED presentations in two hospitals in Australia and obtained a MAPE of 7%¹³.

Per the MAPEs, the GLM and GEE were accurate and both models were better for the 7-day than the 30-day horizon. Moreover, MAPEs at the 3rd horizon (December 2010) were lower than the 2nd (November 2010) and 1st (October 2010) horizons. This could possibly be due to the fact that the 3rd horizon included a greater amount of data in the training set being regressed, thus resulting in more accurate forecasting of ED patient visits. Another possible explanation for such result is that the 3rd horizon may be in fact a more predictable one, as December corresponds to school holidays, and a significant amount of people leave the city for summer vacations, Christmas and New Year's Eve holidays. In all three years of the dataset December had the lowest number of observed ED visits.

Our findings do not support including terms for ambient temperature effects in ED patient visit forecasting models. Simpler models based upon calendar variables, i.e., models

that did not include temperature variables for forecasting ED daily visits, performed equally or better than the more complex ones. Besides not improving ED demand forecast accuracy, weather conditions cannot, of course, be forecast with 100% accuracy, especially for horizons of more than three days in advance, thus adding further inaccuracies to an ED patient visit forecast model. Moreover, ED patient visit forecasting models based solely on calendar variables are more easily set up as an automated process and can be provided well in advance, leaving enough time for administrative decisions.

Although it may be expected that forecasting models of ED patient visits including terms for temperature effects would perform at least as well as those that did not include such terms, our results showing the contrary are not unusual. Chatfield (2005)¹¹ argues that even though complex forecasting models in general give a better fit than simpler models (and this was actually true for our models), the resulting forecast is not necessarily more accurate, and simpler models are often better.

The ultimate goal of this study is to explore models for predicting ED patient volume that healthcare managers can employ for better planning and resource allocation. In order to fulfill this, such models should be tested in practice. Although our models could successfully forecast the pattern of daily ED visits, there were some days that were associated with high absolute errors, which could hinder use of the forecasting method in real case scenarios. On the other hand, previous studies with similar accuracy to our models reported promising results when used for managerial decisions. For instance, Batal et al. (2001) found an 18.5% decrease in patients leaving without being seen and a 30% decrease in complaints after applying their model to inform staffing levels⁵.

Limitations

The evaluation dataset included only months of the warmest season in Brazil (October-December), so we could not evaluate how the model would perform during the winter period. Extending the database in order to forecast daily ED visits during the winter or other seasons to assess any changes in the models' forecast accuracy could be of great importance. On the other hand, the volume of ED daily visits in our setting did not show monthly seasonality, as can be observed in **Figure 2**.

Our models included those predictive variables that could be measured readily in our setting, but there may be other factors affecting daily ED visits that could not be evaluated in this study, such as the availability of other primary care facilities and their workload⁹. Other environmental factors not considered here also have the potential to make a contribution to model performance.

Conclusions

Our study indicates that time series models can be developed to provide accurate short range forecasts of ED patient visits, which might inform future ED staffing choices. Forecasting ability was dependent on the type of model employed and the length of the time-horizon being predicted. In our setting, GLMs and GEEs models showed better accuracy than SARIMA models, and including information about ambient temperature did not improve forecasting accuracy. Although there were occasional days with relatively high forecast errors, forecasting models based on calendar variables alone did in general detect patterns of daily variability in ED volume, and thus could be used for developing an automated system for better planning of personnel resources.

References

- 1 Asplin BR, Flottemesch TJ, Gordon BD. Developing models for patient flow and daily surge capacity research. *Acad Emerg Med* 2006;13:1109–13.
- 2 Institute of Medicine Committee on the Future of Emergency Care in the U.S. Health System. *Hospital-Based Emergency Care: At the Breaking Point*. Washington, DC: National Academies Press, 2006.
- 3 Wargon M, Guidet B, Hoang TD, Hejblum G. A systematic review of models for forecasting the number of emergency department visits. *Emerg Med J* 2009;26:395–9.
- 4 Brasil. Ministério da Saúde. Política nacional de atenção às urgências. Brasília (DF): Ministério da Saúde; 2003.
- 5 Batal H, Tench J, McMillan S, Adams J, Mehler PS. Predicting patient visits to an urgent care clinic using calendar variables. *Acad Emerg Med* 2001;8(1):48–53.
- 6 Green L, et al. Using queuing theory to increase effectiveness of ED provider staffing. *Acad Emerg Med* 2007;14(Suppl 1):S85.
- 7 Tandberg D, Qualls C. Time series forecasts of emergency department patient volume, length of stay, and acuity. *Ann Emerg Med* 1994;23:299–306.
- 8 Holleman DR, Bowling RL, Gathy C. Predicting daily visits to a walk-in clinic and emergency department using calendar and weather data. *J Gen Intern Med* 1996;11:237–9.
- 9 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. *Am J Emerg Med* 1997; 15:596–8.
- 10 National Audit Office, *Inpatient Admissions and Bed Management in NHS Acute Hospitals*. The Stationery Office, London, 2000.
- 11 Chatfield C. *The analysis of time series: an introduction*. 6th ed. Boca Raton, FL: Chapman and Hall/CRC; 2003.
- 12 Jones SS, Thomas A, Evans RS, Welch SJ, Haug PJ, Snow GL. Forecasting daily patient volumes in the emergency department. *Acad Emerg Med* 2008;15(2):159–70.
- 13 Boyle J, Jessup M, Crilly J, et al. Predicting emergency department admissions. *Emerg Med J* 2012;29(5):358–65.

- 14 Jones SA, Joy MP, Pearson J. Forecasting demand of emergency care. *Health Care Manag Sci* 2002;5:297–305.
- 15 Davidson SJ, Koenig KL, Cone DC. Daily Patient Flow Is Not Surge: “Management Is Prediction”. *Acad Emerg Med* 2006;13(11):1095-6.
- 16 Abraham G, Byrnes GB, Bain BA. Short-term forecasting of emergency inpatient flow. *IEEE Trans Inf Technol Biomed* 2009;13(3):380-8.
- 17 Sun Y, Heng BH, Seow YT, Seow E. Forecasting daily attendances at an emergency department to aid resource planning. *BMC Emerg Med* 2009;9:1.
- 18 Alberdi JC, Diaz J, Lage MB, et al. Model for forecasting emergency hospital admissions: effect of environmental variables. *J Environ Health* 2001;64:9–15.
- 19 Rising WR, O’Daniel JA, Roberts CS. Correlating weather and trauma admissions at a level I trauma center. *J Trauma* 2006;60(5):1096–100.
- 20 Kam HJ, Sung JO, Park RW. Prediction of daily patient numbers for a regional emergency medical center using time series analysis. *Health Inform Res* 2010;16(3):158–65.
- 21 Kovats RS, Hajat S, Wilkinson P. Contrasting patterns of mortality and hospital admissions during hot weather and heat waves in Greater London, UK. *Occup Environ Med* 2004;61:893–8.
- 22 Schwartz J, Samet JM, Patz JA. Hospital Admissions for heart disease: the effects of temperature and humidity. *Epidemiology* 2004;15:755–61.
- 23 Armstrong B. Models for the relationship between ambient temperature and daily mortality. *Epidemiology* 2006;17: 624–31.
- 24 Muggeo VM, Hajat S. Modelling the non-linear multiple-lag effects of ambient temperature on mortality in Santiago and Palermo: a constrained segmented distributed lag approach. *Occup Environ Med* 2009;66:584–91.
- 25 United Kingdom’s National Weather Service. COPD forecast alert service. The United Kingdom’s National Weather Service (Accessed October 12, 2012, at <http://www.metoffice.gov.uk/health/public/copd>).
- 26 Friede KA, Osborne MC, Erickson DJ, et al. Predicting Trauma Admissions: The Effect of Weather, Weekday, and Other Variables. *Minn Med* 2009;92(11):47-9.
- 27 Zibners LM, Bonsu BK, Hayes JR, Cohen DM. Local weather effects on emergency department visits: a time series and regression analysis. *Pediatr Emerg Care* 2006;22(2):104–6.

- 28 Bell ML, Davis DL, Gouveia N, Borja-Aburtod VH, Cifuentes LA. The avoidable health effects of air pollution in three Latin American cities: Santiago, Sao Paulo, and Mexico City. *Environ Res* 2006;100:431–40.
- 29 Zeger SL, Irizarry R, Peng RD. On time series analysis of public health and biomedical data. *Annu Rev Pub Health* 2006;27:57–79.
- 30 Liang KY, Zeger SL. Longitudinal data analysis using generalized linear models. *Biometrika* 1986;73:13–22.
- 31 Pan W, Connett JE. Selecting the working correlation structure in generalized estimating equations with application to the lung health study. *Statistica Sinica* 2002;12:475-90.
- 32 Hanley JA, Negassa A, Edwardes MDB, Forrester JE. Statistical analysis of correlated data using generalized estimating equations: an orientation. *Am J Epidemiol* 2003;157:364–75.
- 33 Hajat S, Armstrong B, Baccini M, et al. Impact of high temperatures on mortality: is there an added heat wave effect? *Epidemiology* 2006;17:632–8.
- 34 Pan, W. Akaike's information criterion in generalized estimating equations. *Biometrics* 2001;57:120-5.
- 35 Schout D, Hajjar ILA, Galas RFBG, et al. Epidemiology of human infection with the novel virus Influenza A (H1N1) in the Hospital das Clinicas, Sao Paulo, Brazil - June-September 2009. *CLINICS* 2009;64(10):1025–30.
- 36 Reis BY, Mandl KD. Time series modelling for syndromic surveillance. *BMC Med Inform Decis Mak* 2003;23(3):2.

Tables

Table 1 Effect of predictors on total daily emergency department visits, training set (January 1, 2008 –September 30, 2010)

Predictor variable	GLM without control for temperature effect		GLM controlling for temperature effect	
	Change in risk ^a (%)	95% CI	Change in risk ^a (%)	95% CI
Monday (reference)	-	-	-	-
Tuesday	-9.8	(-11.6 to -7.9)	-9.8	(-11.6 to -8.0)
Wednesday	-12.6	(-14.4 to -10.8)	-12.6	(-14.3 to -10.8)
Thursday	-13.6	(-15.4 to -11.8)	-13.6	(-15.4 to -11.9)
Friday	-14.5	(-16.2 to -12.7)	-14.5	(-16.2 to -12.8)
Saturday	-37.3	(-38.7 to -35.8)	-37.3	(-38.7 to -35.9)
Sunday	-43.0	(-44.3 to -41.6)	-43.0	(-44.3 to -41.6)
Holiday	-27.6	(-30.2 to -24.8)	-27.6	(-30.2 to -24.9)
Day before a holiday	-6.7	(-9.4 to -4.0)	-6.7	(-9.3 to -4.0)
Day after a holiday	1.1	(-2.2 to 4.4)	1.0	(-2.2 to 4.4)
H1N1 flu epidemic (2009)	19.7	(15.3 to 24.3)	14.2	(9.4 to 19.2)
December 31/ January 1	-37.8	(-45.0 to -29.6)	-38.0	(-45.1 to -30.0)
Heat threshold* (lags 0 to 5)	-	-	0.7	(0.2 to 1.2)
Cold threshold* (lags 0 to 20)	-	-	5.7	(3.2 to 8.2)
PM ₁₀ (µg/m ³) [£]	0.1	(0.1 to 0.2)	0.1	(0.1 to 0.2)
O ₃ (µg/m ³) [£]	0.0	(0.0 to 0.0)	0.0	(0.0 to 0.0)
Date (trend term)	0.0	(0.0 to 0.0)	0.0	(0.0 to 0.0)

GLM: generalized linear model; PM₁₀: particulate matter; O₃: ozone

^aPercentage change in risk: (relative risk – 1) * 100

*Heat and cold thresholds were at 16°C and the percentage change in risk was calculated for each °C above (heat) or below (cold) threshold values

[£]24 hour average, percentage change in risk was calculated for each 1 unit change in ambient concentration

Table 2 Mean absolute percentage error of forecasting models in the 3 post-sample forecasting horizons (October 1 to December 31, 2010)

Models without control for temperature effect						
	1st forecasting horizon*		2nd forecasting horizon*		3rd forecasting horizon*	
	7 days	30 days	7 days	30 days	7 days	30 days
	MAPE (%)		MAPE (%)		MAPE (%)	
GLM	8.8	10.8	9.5	9.6	4.5	8.7
GEE	8.9	10.8	8.9	9.3	4.6	8.9
SARIMA	12.4	11.7	16.7	11.4	7.5	9.0
Models controlling for temperature effect						
	1st forecasting horizon*		2nd forecasting horizon*		3rd forecasting horizon*	
	7 days	30 days	7 days	30 days	7 days	30 days
	MAPE (%)		MAPE (%)		MAPE (%)	
GLM	8.8	11.5	9.9	9.2	5.4	10.0
GEE	8.8	11.5	9.4	9.1	5.4	10.2
SARIMA	12.9	12.8	17.1	11.8	7.2	9.3

GLM: generalized linear models; GEE: generalized estimating equations; SARIMA: seasonal autoregressive integrated moving average

*1st forecasting horizon: 1st to 31st October, 2010; 2nd forecasting horizon: 1st to 30th November, 2010, 3rd forecasting horizon: 1st to 31st December, 2010.

Figure 1 Scatter plot of total emergency department visits by date of visit, training set (January 1, 2008 – September 30, 2010)

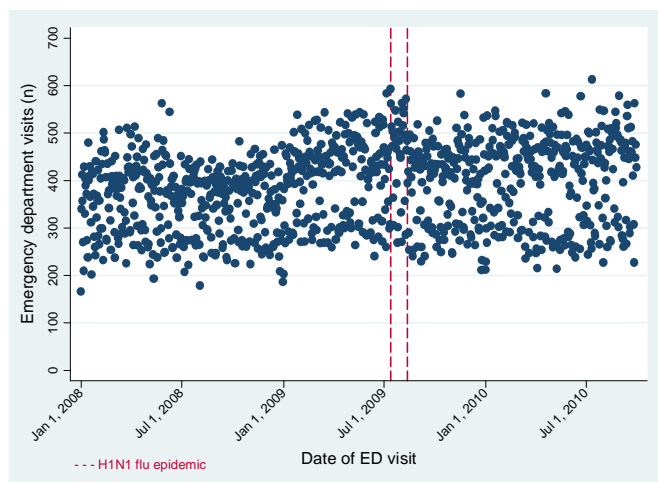


Figure 2 Box-plot of total emergency department visits by day of the week and month of the year, training set (January 1, 2008 – September 30, 2010)


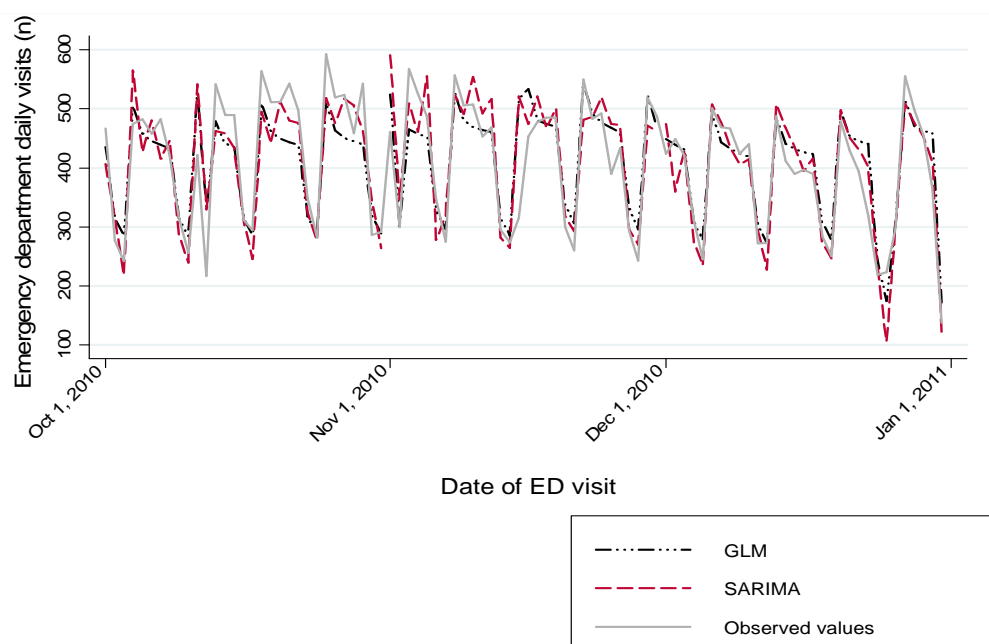
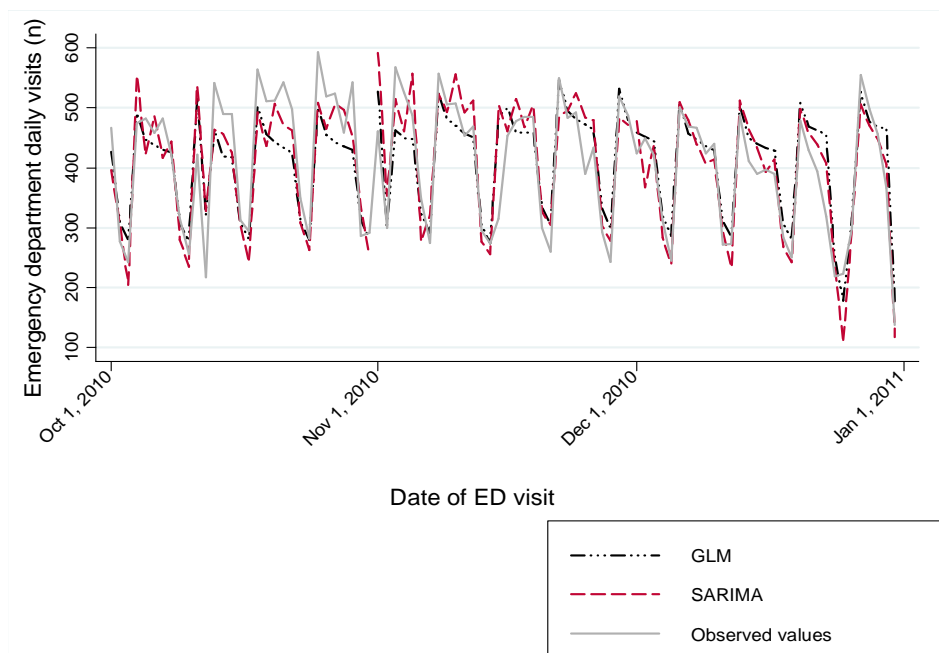


Figure 3 Observed and forecasted emergency department daily visits by GLM and SARIMA models without (a) and with (b) control for the temperature effect – post-sample forecasting set (October 1, 2010 – December 31, 2010)



(a) Models without control for temperature effect



(b) Models controlling for temperature effect

8 REFERÊNCIAS

- 1 Gaynor PE, Kirkpatrick RC. *Introduction to Time-Series Modelling and Forecasting in Business and Economy*. New York: Mc Graw-Hill; 1994.
- 2 National Audit Office. *Inpatient Admissions and Bed Management in NHS Acute Hospitals*. London: The Stationery Office; 2000.
- 3 Institute of Medicine. Committee on the Future of Emergency Care in the U.S. Health System. *Hospital-Based Emergency Care: At the Breaking Point*. Washington, DC: National Academies Press; 2006.
- 4 Chatfield C. *The analysis of time series: an introduction*. 6th ed. Boca Raton, FL: Chapman and Hall/CRC; 2003.
- 5 Diggle PJ. *Time series: a biostatistical introduction*. New York: Oxford University Press; 1990.
- 6 Jones SS, Thomas A, Evans RS, Welch SJ, Haug PJ, Snow GL. Forecasting daily patient volumes in the emergency department. *Acad Emerg Med*. 2008;15(2):159-70.
- 7 Sun Y, Heng BH, Seow YT, Seow E. Forecasting daily attendances at an emergency department to aid resource planning. *BMC Emerg Med*. 2009;9:1.
- 8 Weisang G, Awazu Y. Vagaries of the euro: an introduction to ARIMA modelling. *CS-BIGS*. 2008;2(1):45-55.
- 9 Zeger SL, Irizarry R, Peng RD. On time series analysis of public health and biomedical data. *Annu Rev Pub Health*. 2006;27:57–79.
- 10 Dobson AJ, Barnett AG. *Introduction to Generalized Linear Models*. 3rd ed. Boca Raton, FL: Chapman and Hall/CRC; 2008.
- 11 Kovats RS, Hajat S, Wilkinson P. Contrasting patterns of mortality and hospital admissions during hot weather and heat waves in Greater London, UK. *Occup Environ Med*. 2004;61:893–8.

- 12 Schwartz J, Samet JM, Patz JA. Hospital admissions for heart disease: the effects of temperature and humidity. *Epidemiology*. 2004;15:755–61.
- 13 Armstrong B. Models for the relationship between ambient temperature and daily mortality. *Epidemiology*. 2006;17:624–31.
- 14 Muggeo VM, Hajat S. Modelling the non-linear multiple-lag effects of ambient temperature on mortality in Santiago and Palermo: a constrained segmented distributed lag approach. *Occup Environ Med*. 2009;66:584–91.
- 15 Liang KY, Zeger SL. Longitudinal data analysis using generalized linear models. *Biometrika*. 1986;73:13-22.
- 16 Cui J. QIC program and model selection in GEE analyses. *Stata J*. 2007;7(2):209-20.
- 17 Pan W, Connett JE. Selecting the working correlation structure in generalized estimating equations with application to the lung health study. *Stat Sin*. 2002;12:475-90.
- 18 Hanley JA, Negassa A, Edwardes MDB, Forrester JE. Statistical analysis of correlated data using generalized estimating equations: an orientation. *Am J Epidemiol*. 2003;157:364–75.
- 19 Hajat S, Armstrong B, Baccini M, Biggeri A, Bisanti L, Russo A, Paldy A, et al. Impact of high temperatures on mortality: is there an added heat wave effect? *Epidemiology*. 2006;17:632–8.
- 20 Brasil. Ministério da Saúde. Portaria GM/MS n.º 2048, de 5 de novembro de 2002. Brasília (DF): Ministério da Saúde; 2002.
- 21 Brasil. Ministério da Saúde. *Política nacional de atenção às urgências*. Brasília (DF): Ministério da Saúde; 2003.
- 22 Wargon M, Guidet B, Hoang TD, Hejblum G. A systematic review of models for forecasting the number of emergency department visits. *Emerg Med J*. 2009;26:395–9.
- 23 Schmidt MI, Duncan BB, Silva GA, Menezes AM, Monteiro CA, Barreto SM, et al. Doenças crônicas não transmissíveis no Brasil: carga e desafios atuais. *Lancet*. 2011;377(9781):1949-61.

- 24 Reichenheim ME, Souza ER, Moraes CL, Jorge MHPM, Silva CMFP, Minayo MCS. Violência e lesões no Brasil: efeitos, avanços alcançados e desafios futuros. *Lancet*. 2011;377(9781):1962-75.
- 25 Avanzi MP, Silva CRG. Diagnósticos mais frequentes em serviço de emergência para adulto de um hospital universitário. *Rev de Ciências Médicas (Campinas)*. 2005;14(2):175-85.
- 26 Carret MLV, Fassa AG, Kawachi I. Demand for emergency health service: factors associated with inappropriate use. *BMC Health Serv Res*. 2007;7:131.
- 27 Conselho Federal de Medicina. Resolução CFM nº 1451/95. Brasília (DF): CFM; 1995.
- 28 Asplin BR, Flottemesch TJ, Gordon BD. Developing models for patient flow and daily surge capacity research. *Acad Emerg Med*. 2006;13:1109–13.
- 29 Green LV, Soares J, Giglio JF, Green RA.. Using queuing theory to increase effectiveness of emergency department provider staffing. *Acad Emerg Med*. 2006;13(1):61-8.
- 30 Batal H, Tench J, McMillan S, Adams J, Mehler PS. Predicting patient visits to an urgent care clinic using calendar variables. *Acad Emerg Med*. 2001;8(1):48-53.
- 31 Tandberg D, Qualls C. Time series forecasts of emergency department patient volume, length of stay, and acuity. *Ann Emerg Med*. 1994;23:299–306.
- 32 Holleman DR, Bowling RL, Gathy C. Predicting daily visits to a walk-in clinic and emergency department using calendar and weather data. *J Gen Intern Med*. 1996;11:237–9.
- 33 Rotstein Z, Wilf-Miron R, Lavi B, Shahar A, Gabbay U, Noy S. The dynamics of patient visits to a public hospital emergency department: a statistical model. *Am J Emerg Med*. 1997;15:596–8.
- 34 Jones SA, Joy MP, Pearson J. Forecasting demand of emergency care. *Health Care Manag Sci*. 2002;5:297–305.
- 35 Davidson SJ, Koenig KL, Cone DC. Daily patient flow is not surge: “management is prediction”. [editorial]. *Acad Emerg Med*. 2006;13(11):1095-6.

- 36 Abraham G, Byrnes GB, Bain BA. Short-term forecasting of emergency inpatient flow. *IEEE Trans Inf Technol Biomed.* 2009;13(3):380-8.
- 37 McCarthy ML, Zeger SL, Ding R, Aronsky D, Hoot NR, Kelen GD. The challenge of predicting demand for emergency department services. *Acad Emerg Med.* 2008;15:337–346.
- 38 Friede KA, Osborne MC, Erickson DJ, Roesler JS, Azam A, Croston JK, et al. Predicting trauma admissions: the effect of weather, weekday, and other variables. *Minn Med.* 2009;92(11):47-9.
- 39 Boyle J, Jessup M, Crilly J, Green D, Lind J, Wallis M, et al. Predicting emergency department admissions. *Emerg Med J.* 2012;29(5):358–65.
- 40 Boutsioli Z. Forecasting the stochastic demand for inpatient care: the case of the Greek national health system. *Health Serv Man Res.* 2010;23:116–20.
- 41 Reis BY, Mandl KD. Time series modelling for syndromic surveillance. *BMC Med Inform Decis Mak.* 2003;23(3):2.
- 42 Kam HJ, Sung JO, Park RW. Prediction of daily patient numbers for a regional emergency medical center using time series analysis. *Health Inform Res.* 2010;16(3):158–65.
- 43 Champion R, Kinsman LD, Lee GA, Masman KA, May EA, Mills TM, et al. Forecasting emergency department presentations. *Aust Health Rev.* 2007;31(1):83-90.
- 44 Abdel-Aal RA, Mangoud AM. Modeling and forecasting monthly patient volume at a primary health care clinic using univariate time-series analysis. *Comp Methods and Programs Biomed.* 1998;56:235–47.
- 45 Milner PC. Ten-year follow-up of ARIMA forecasts of attendances at accident and emergency departments in the Trent Region. *Stat Med.* 1997;16:2117-25.
- 46 Morzuch BJ, Allen PG. Forecasting hospital emergency department arrivals. In: 26th Annual Symposium on Forecasting; 2006; Santander. [citado em 13 de abril de 2013]. Disponível em <http://www.umass.edu/resec/faculty/morzuch/index.html>.

- 47 Jones SS, Evans RS, Allen TL, Thomas A, Haug PJ, Welch SJ, et al. A multivariate time series approach to modelling and forecasting demand in the emergency department. *J Biomed Inform.* 2009;42:123–39.
- 48 Met office: United Kingdom's National Weather Service. COPD forecast alert service. The United Kingdom's National Weather Service. [citado em 12 de outubro de 2012]. Disponível em <http://www.metoffice.gov.uk/health/public/copd>.
- 49 Díaz J, Alberdi JC, Pajares MS, López C, Lopes R, Lage MB, et al. Model for forecasting emergency hospital admissions: effect of environmental variables. *J Environ Health.* 2001;64:9–15.
- 50 Rising WR, O'Daniel JA, Roberts CS. Correlating weather and trauma admissions at a level I trauma center. *J Trauma.* 2006;60(5):1096–100.
- 51 Zibners LM, Bonsu BK, Hayes JR, Cohen DM. Local weather effects on emergency department visits: a time series and regression analysis. *Ped Emerg Care.* 2006;22(2):104-6.
- 52 Atchison CJ, Tam CC, Hajat S, van Pelt W, Cowden JM, Lopman BA. Temperature-dependent transmission of rotavirus in Great Britain and The Netherlands. *Proc Biol Sci.* 2010;277(1683):933-42.
- 53 Leonardi GS, Hajat S, Kovats RS, Smith GE, Cooper D, Gerard E. Syndromic surveillance use to detect the early effects of heat-waves: an analysis of NHS Direct data in England. *Soz Präventivmed.* 2006;51(4):194-201.
- 54 Bhaskaran K, Hajat S, Armstrong B, Haines A, Herrett E, Wilkinson P, et al. The effects of hourly differences in air pollution on the risk of myocardial infarction: case crossover analysis of the MINAP database. *BMJ.* 2011;343:d5531.