



ANÁLISE ESTATÍSTICA DOS FATORES QUE AFETAM O *NO-SHOW* DE PACIENTES EM AGENDAMENTOS CLÍNICOS

Luísa Moncorvo de Mattos

Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)
Rua Marquês de São Vicente, 225 – Gávea, Rio de Janeiro – RJ, 22451-900
luisa.moncorvo@gmail.com

Leila Figueiredo Dantas

Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)
Rua Marquês de São Vicente, 225 – Gávea, Rio de Janeiro – RJ, 22451-900
leilaffdantas@gmail.com

Fernando Luiz Cyrino Oliveira

Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)
Rua Marquês de São Vicente, 225 – Gávea, Rio de Janeiro – RJ, 22451-900
cyrino@puc-rio.br

RESUMO

O não comparecimento dos pacientes aos seus compromissos médicos reduz a produtividade do provedor, aumenta os custos com cuidados médicos e diminui a capacidade efetiva da clínica. Portanto, o objetivo deste trabalho é identificar quais fatores estão associados ao *no-show* de pacientes em uma clínica de cirurgia bariátrica no Rio de Janeiro através de um estudo retrospectivo dos agendamentos durante um período de 17 meses. Análises estatísticas foram realizadas através da regressão logística simples e múltipla para identificação das variáveis estatisticamente significativas, e em seguida, um modelo preditivo foi desenvolvido. Os resultados indicam que pacientes com alta taxa de *no-show* anterior e um horário tarde de atendimento são os mais suscetíveis a perderem seus agendamentos. O artigo foi escrito pela aluna de Iniciação Científica Luísa Moncorvo, tendo como segunda autora a doutoranda e co-orientadora Leila Dantas e foi orientado pelo Prof. Fernando Cyrino, do Departamento de Engenharia Industrial da PUC-Rio.

PALAVRAS CHAVE. *No-show*; agendamentos; regressão logística.
Tópicos do artigo: EST, SA, SE.

ABSTRACT

Patients who schedule clinic appointments and fail to keep them reduce provider's productivity, increase health care costs and reduce health clinic effective capacity. This study aims to identify factors associated with non-attendance at a bariatric surgery clinic in Rio de Janeiro. To achieve this, a retrospective study was conducted during a period of 17 months. Statistical analyses were performed using simple and multiple logistic regression to identify variables statistically significant, and then, a predictive model was developed. The results showed that patients with high history of *no-show* and later scheduled appointments are the most likely to miss their appointments. The article was written by the student Luísa Moncorvo, having as second author the doctoral student and co-adviser Leila Dantas and was advised by Prof. Fernando Cyrino, from the Department of Industrial Engineering of PUC-Rio.

KEYWORDS. *No-show*; appointments; logistic regression.
Paper topics: EST, SA, SE.



1. Introdução

O não comparecimento (*no-show*) dos pacientes a suas consultas agendadas é um problema comum na área da saúde, e representa um custo bastante significativo para o setor. Segundo a *World Health Organization* [WHO 2014], as despesas de saúde per capita total é de US\$947,43, correspondente a 8,32% do Produto Interno Bruto (PIB) brasileiro.

O *no-show* reduz a produtividade do provedor e limita o acesso de outros pacientes ao sistema de saúde, diminuindo assim a receita da clínica e sua capacidade efetiva [Lehmann et al. 2007] [Daggy et al. 2010] [Menendez e Ring 2015]. Além disso, esses agendamentos perdidos trazem consequências também para os pacientes, pois, com a possibilidade de um paciente faltar, os provedores agendam mais consultas em um mesmo horário, podendo aumentar consideravelmente o tempo de espera para o atendimento e diminuir a qualidade do serviço [Giunta et al. 2013].

Assim sendo, alguns estudos têm como intuito analisar os fatores que afetam o *no-show* nos sistemas de saúde, e suas descobertas afirmam que o comportamento do paciente pode influenciar a taxa de *no-show* e que modelos podem ser previstos para estimar a probabilidade de cada paciente em faltar, com base em características demográficas e informações do agendamento. Técnicas estatísticas e de *data science* são utilizadas para a formulação desses modelos preditivos [Huang e Hanauer 2014]. Dessa forma, sistemas de agendamento mais eficientes consideram a predição do comportamento do paciente no momento em que a consulta é marcada, aprimorando o desempenho organizacional do sistema, uma vez que melhora consideravelmente o tempo de espera, reduz o tempo ocioso do médico e aumenta o número de pacientes atendidos em determinado intervalo de tempo.

Posto isto, o presente estudo tem como objetivo analisar os fatores que estão associados significativamente com o *no-show* de pacientes em uma clínica de cirurgia bariátrica do Rio de Janeiro e desenvolver um modelo estatístico para prever a probabilidade de *no-show* de cada paciente.

Este artigo está estruturado da seguinte forma: a Seção 2 compreende uma revisão da literatura das principais variáveis que podem afetar o *no-show*. Em seguida, na Seção 3, é apresentada a metodologia da pesquisa. Os resultados são discutidos na Seção 4, e por fim, a conclusão do estudo é apresentada na Seção 5.

2. Revisão da literatura

Entender os fatores que afetam o *no-show* é essencial para aplicar intervenções que levem em consideração a probabilidade dos pacientes de não comparecerem ao seu agendamento. Com isso, estudos anteriores utilizaram análises estatísticas com o intuito de identificar quais fatores estão associados significativamente com o *no-show*. Esses determinantes estão relacionados com os dados demográficos do paciente e com informações do agendamento, tais como: gênero, idade, distância entre a residência e o local da consulta, *lead time*, histórico de *no-show* anterior, quantidade de consultas marcadas, tipo de agendamento, forma de pagamento, mês, dia e hora da consulta, dentre outros.

O período entre a data marcada da consulta e a data em que o agendamento foi feito, conhecido como *lead time*, é o fator que mais contribui para o *no-show* do paciente [Norris et al. 2014]. Diversos trabalhos encontraram que tempos mais curtos de *lead time* se correlacionam com taxas de comparecimento mais elevadas [Lee et al. 2005] [Cohen et al. 2008] [Cohen et al. 2008] [Goldbart et al. 2009] [Daggy et al. 2010] [Giunta et al. 2013] [Cronin et al. 2013] [Huang e Hanauer 2014] [Norris et al. 2014] [Peng et al. 2016].

A idade do paciente é um fator significativo nos estudos de Lee et al. [2005], Lehmann et al. [2007], Tseng [2010], Daggy et al. [2010], Traeger et al. [2012], Kaplan-Lewis e Percac-Lima [2013], Cronin et al. [2013], Lalloo e McDonald [2013], Menendez e Ring [2015] e Peng et al. [2016]. Esses autores afirmam que os mais jovens perdem os agendamentos mais



frequentemente do que os pacientes mais velhos. Além disso, Huang e Hanauer [2014], em clínicas pediátricas, concluíram que quanto mais velha a criança maior a probabilidade de *no-show*, enquanto Cohen et al. [2008] e Norris et al. [2014] analisaram que a taxa de não comparecimento era mais elevada entre os pacientes adultos. Já Goldbart et al [2009] e Giunta et al. [2013] não encontraram evidências estatísticas para idade.

O tipo de agendamento está relacionado com o propósito da consulta, como por exemplo, pacientes de primeira visita e pacientes de retorno (*follow-up*). Lehmann et al. [2007] e Giunta et al. [2013] encontraram que este foi o fator mais significativo, com maior taxa de *no-show* para pacientes de retorno comparados aos pacientes de primeira visita. Este resultado contrasta o estudo de Tseng [2010], o qual afirma serem os novos pacientes a faltarem mais as consultas, e o de Cronin et al. [2013], que não encontraram significância para esta variável.

Com relação ao gênero, Cohen et al. [2008] e Peng et al. [2016] encontraram diferenças estatisticamente significativas: os primeiros afirmam que os homens são mais propensos a perderem uma consulta, enquanto que, no segundo trabalho, o *no-show* é mais comum entre as mulheres. Lee et al. [2005], Lehmann et al. [2007], Goldbart et al. [2009], Tseng [2010], Kaplan-Lewis e Percac-Lima [2013], Giunta et al. [2013], Cronin et al. [2013], Huang e Hanauer [2014] e Menendez e Ring [2015] também abordaram esse fator em sua análise, mas não encontraram influência significativa de gênero no comportamento do não comparecimento.

Para Daggy et al. [2010], o histórico de *no-show* anterior foi um dos fatores mais fortes para prever o comportamento do paciente. Esse preditor analisa a proporção de consultas perdidas anteriormente e alguns artigos [Lee et al. 2005] [Daggy et al 2010] [Cronin et al. 2013] [Giunta et al. 2013] afirmam que esta variável tem um efeito significativo sobre as taxas de frequência, pacientes que faltaram consultas passadas tendem a manter este comportamento. Além disso, para Daggy et al. [2010] quanto mais consultas marcadas, maior a probabilidade de não comparecimento.

A forma de pagamento é um fator significativo para Traeger et al. [2012], Kaplan-Lewis e Percac-Lima [2013], Cronin et al. [2013], Norris et al. [2014] e Peng et al. [2016]. Os autores concordam que pacientes que pagam sua própria consulta são mais propensos a não comparecerem do que aqueles com seguro de saúde. Já para Lehmann et al. [2007] e para Daggy et al. [2010], possuir ou não plano de saúde não é fator de significância.

Com relação ao dia da semana em que a consulta foi agendada, Cronin et al. [2013], Norris et al. [2014] e Menendez e Ring [2015], afirmam que a taxa de não comparecimento às segundas-feiras é mais elevada, em contraste com Huang e Hanauer [2014], que encontraram a sexta-feira como o dia da semana com maior taxa de *no-show*. Lehmann et al. [2007], Goldbart et al. [2009], Daggy et al. [2010], Tseng [2010], Giunta et al. [2013], Lalloo e McDonald [2013] e Cronin et al. [2013], não encontraram evidências significativas para essa variável.

Quanto ao mês do agendamento, Lalloo e McDonald [2013] encontraram que fevereiro é o mês com menor probabilidade de *no-show*, enquanto Giunta et al. [2013] afirmam que nos meses de férias (junho, julho e dezembro) os índices de não comparecimentos são mais elevados.

De acordo com Norris et al. [2014] e Peng et al. [2016], pacientes com horários de agendamento pela tarde têm menores riscos de faltarem a consulta comparados com os da manhã. Já para Cohen et al. [2008], Goldbart et al. [2009], Giunta et al. [2013] e Huang e Hanauer [2014], horários à tarde possuem maior taxa de *no-show*. Lehmann et al. [2007], Daggy et al. [2010], Tseng [2010], Cronin et al. [2013] e Lalloo e McDonald [2013] não encontraram significância entre o *no-show* e o turno do dia.

Em relação à distância, alguns estudos afirmam que quanto maior a distância da casa do paciente para a clínica, maior é a probabilidade do paciente em faltar a consulta [Lee et al. 2005] [Daggy et al. 2010] [Huang e Hanauer 2014]. Já Lalloo e McDonald [2013] e Menendez e Ring [2015] foram contrários a esta afirmação, e Peng et al. [2016] não encontraram evidências estatísticas para esse fator.

Para um entendimento mais amplo de todos os fatores que são abordados na literatura e sua significância, quatro revisões encontradas na literatura identificam e analisam em seus estudos, além desses aqui citados, outros fatores que podem influenciar o *no-show* de pacientes



nos agendamentos ambulatoriais [Deyo e Inui 1980] [Bean e Talaga 1992] [Garuda et al. 1998] [Dantas 2016]. Ao analisa-las, conclui-se que o *lead time* e o histórico de agendamento perdido são os fatores estatisticamente mais significativos.

Embora esses estudos revisados concordem que o problema do *no-show* pode ser previsto, diferentes conclusões acerca da significância de cada variável e sua correlação com a taxa de não comparência aparecem entre as pesquisas. Os resultados dos estudos estão sujeitos a variações locais, uma vez que a especialidade da clínica e o país onde o fato é observado podem influenciar no comportamento do paciente. Dantas [2016] analisou 105 estudos em diversas especialidades clínicas, dos quais apenas um foi realizado no sistema de saúde brasileiro e nenhum realizado em uma clínica especializada em cirurgia bariátrica.

3. Metodologia

Os dados aqui utilizados foram obtidos de uma clínica especializada em cirurgia bariátrica no Rio de Janeiro, durante um período de 17 meses, entre 05/01/2015 e 27/05/2016. Ao todo, 3012 registros de agendamento foram analisados, referentes ao atendimento do principal cirurgião bariátrico. Para manipulação dos dados, os registros de agendamento foram divididos aleatoriamente em coortes de desenvolvimento e validação (80% e 20% dos dados, respectivamente). O coorte de desenvolvimento foi utilizado para desenvolver o modelo de predição da probabilidade de *no-show* de cada paciente, e o coorte de validação para encontrar a precisão do modelo, comparando o número esperado ao número real de *no-shows*.

As características dos pacientes e informações do agendamento foram agrupadas em 11 variáveis explicativas e divididas em categorias: idade (16-30 anos, 31-40 anos, 41-50 anos, >50 anos); gênero (feminino e masculino); dia da semana (segunda-feira e quarta-feira); mês (dez-jan-fev, mar-abr-mai, jun-jul-ago e set-out-nov); horário da consulta (08:30-11:30, 11:30-14:30, 14:30-16:30 e 16:30-18:30); *lead time* (0-6 dias, 7-13 dias, 14-20 dias e >20 dias); distância (≤ 10 km, 10-30km, 30-40km e >40km); tipo de agendamento (primeira consulta, retorno não operado, marcação de cirurgia e retorno operado); forma de pagamento (plano de saúde e *selfpay*); histórico de *no-show* anterior (0-10%, 10-30%, 30-50% e >50%); e quantidade de agendamentos anteriores (0-1 vez, 2-4 vezes e ≥ 5 vezes). A variável resposta, chamada também de variável dependente, corresponde ao status do agendamento: *show/no-show*.

Para determinar o histórico de *no-show*, foram necessários dados anteriores dos pacientes, calculando a quantidade total de agendamentos marcados e analisando a proporção de agendamentos perdidos. O fator distância foi calculado a partir de um algoritmo desenvolvido pelo *software MS Excel*, o qual interage com o Google Maps e retorna a distância entre dois CEP's, em quilômetros.

Para avaliar quais os fatores que afetam o *no-show* e prever casos futuros, foi desenvolvido um modelo de regressão logística, cuja forma geral é dada pela seguinte equação:

$$\ln\left(\frac{p(x)}{1-p(x)}\right) = \beta_0 + \beta \cdot X \quad (1)$$

Onde $p(x)$ é a probabilidade de *no-show*, β_0 é uma constante, β é o vetor de coeficientes correspondentes a X , e X é o vetor de variáveis explicativas.

O termo $\frac{p(x)}{1-p(x)}$ da equação (1) é denominado razão de chances (*odds ratio*) e representa a razão entre a chance de um evento ocorrer e a chance, ou probabilidade, desse evento não ocorrer. Em termos gerais, o *OR* indica a probabilidade relativa que um indivíduo tem de comparecer ao agendamento.

Testes estatísticos permitem testar hipóteses quanto a relação entre as variáveis independentes (X), e a variável resposta (Y). A hipótese nula é que não existe relação entre X e Y , e matematicamente corresponde dizer que o coeficiente é nulo ($H_0: \beta = 0$). A hipótese alternativa é que existe relação entre X e Y , e portanto o coeficiente não é nulo ($H_1: \beta \neq 0$). Nesse sentido, ao rejeitar H_0 entende-se que o fator influencia no *no-show*.



Para o objetivo deste trabalho, inicialmente foi realizada uma regressão logística simples para todas as 11 variáveis [Lee et al. 2005] [Cronin et al. 2013] [Lalloo e McDonald 2013] [Giunta et al. 2013], com nível de significância de $\alpha = 0,25$ como limiar de inclusão [Hosmer e Lemeshow 2000].

A partir das variáveis significativas da análise univariada, foi realizada uma análise multivariada, utilizando um modelo de regressão logística múltipla para desenvolvimento do modelo preditivo [Lee et al. 2005] [Tseng 2010] [Daggy et al. 2010] [Traeger et al. 2012] [Giunta et al. 2013] [Huang e Hanauer 2014] [Menendez e Ring 2015] [Peng et al. 2016], e para a determinação de um modelo de regressão logística reduzida, considerou-se apenas as variáveis cujos p-valores de sua análise multivariada fossem menores que o nível de significância de 5%.

Todos os testes estatísticos foram realizados com auxílio do *Software R* versão 3.3.2 [R 2016] e o pacote ISLR [James et al. 2013].

4. Resultados e discussões

Dos 3012 registros analisados nesta pesquisa, 842 (27,9%) foram avaliados como *no-show*. No total, havia 2103 mulheres e 773 homens, com idade média de 40 anos (em um intervalo de 16 a 77 anos).

A partir de uma análise descritiva dos dados, apresentada na Tabela 1, observou-se que as taxas de *no-show* foram maiores entre os homens (28,1%) em comparação com as mulheres (27,4%), assim como para pacientes mais jovens (32,4%), pacientes de 1ª visita (28,5%) e para aqueles que pagavam sua própria consulta (47,9%). Nos agendamentos marcados no final da tarde (40,5%), às segundas-feiras (28,5%) e nos meses setembro, outubro ou novembro (30,0%) a taxa de não comparecimento também foi mais elevada. Além disso, o *no-show* foi menor para agendamentos com tempo de espera mais curtos, entre 0 e 6 dias (24,0%), em pacientes que possuíam um histórico de *no-show* inferior a 10% (20,6%) e para os que moravam a uma distância inferior a 10km da clínica (25,1%).

Tabela 1 – Análise descritiva dos dados

Variáveis independentes	No-Show N (%)	Show N (%)	Total N (%)	Variáveis independentes	No-Show N (%)	Show N (%)	Total N (%)
Idade				Lead time			
16 a 30 anos	167 (32,4%)	349 (67,6%)	516 (17,1%)	0 - 6 dias	206 (24,0%)	654 (76,0%)	860 (28,6%)
31 a 40 anos	341 (30,7%)	769 (69,3%)	1110 (36,9%)	7 - 13 dias	231 (32,4%)	483 (67,6%)	714 (23,7%)
41 a 50 anos	187 (26,0%)	533 (74,0%)	720 (23,9%)	14 - 20 dias	203 (27,9%)	525 (72,1%)	728 (24,2%)
≥ 50 anos	119 (20,5%)	462 (79,5%)	581 (19,3%)	> 20 dias	201 (28,3%)	508 (71,7%)	709 (23,5%)
Gênero				Distância			
Feminino	577 (27,4%)	1526 (72,6%)	2103 (69,8%)	≤ 10km	171 (25,1%)	509 (74,9%)	680 (22,6%)
Masculino	217 (28,1%)	556 (71,9%)	773 (25,7%)	10 - 30km	238 (26,4%)	662 (73,6%)	900 (29,9%)
Tipo de agendamento				30 - 40km	184 (29,8%)	434 (70,2%)	618 (20,5%)
1ª vez	330 (28,5%)	827 (71,5%)	1157 (38,4%)	> 40km	165 (29,9%)	386 (70,1%)	551 (18,3%)
Retorno não operado	98 (19,2%)	413 (80,8%)	511 (17,0%)	Horário da consulta			
Marcação de cirurgia	16 (20,8%)	61 (79,2%)	77 (2,6%)	08:30 - 11:30	147 (18,8%)	635 (81,2%)	782 (25,9%)
Retorno operado	69 (22,8%)	234 (77,2%)	303 (10,1%)	11:30 - 14:30	117 (22,2%)	410 (77,8%)	527 (17,5%)
Forma de Pagamento				14:30 - 16:30	186 (25,3%)	548 (74,7%)	734 (24,4%)
Plano de saúde	727 (26,2%)	2045 (73,8%)	2772 (92,0%)	16:30 - 18:30	392 (40,5%)	577 (59,5%)	969 (32,2%)
Selfpay	115 (47,9%)	125 (52,1%)	240 (8,0%)	Dia da consulta			
Quantidade de agendamentos				Segunda	419 (28,5%)	1050 (71,5%)	1469 (48,8%)
0 ou 1 vez	668 (28,8%)	1650 (71,2%)	2318 (77,0%)	Quarta	417 (27,6%)	1096 (72,4%)	1513 (50,2%)
2 a 4 vezes	158 (24,6%)	485 (75,4%)	643 (21,3%)	Mês da consulta			
≥ 5 vezes	16 (31,4%)	35 (68,6%)	51 (1,7%)	dez - jan - fev	176 (25,8%)	507 (74,2%)	683 (22,7%)
Histórico de no-show anterior				mar - abr - mai	364 (29,8%)	857 (70,2%)	1221 (40,5%)
0 i- 10%	185 (20,6%)	712 (79,4%)	897 (29,8%)	jun - jul - ago	136 (24,5%)	419 (75,5%)	555 (18,4%)
10 i- 30%	11 (23,9%)	35 (76,1%)	46 (1,5%)	set - out - nov	166 (30,0%)	387 (70,0%)	553 (18,4%)
30 i- 50%	20 (24,1%)	63 (75,9%)	83 (2,8%)				
≥ 50%	122 (33,2%)	246 (66,8%)	368 (12,2%)				

Na análise estatística univariada com nível de significância de $\alpha = 0,25$, as variáveis idade, tipo de agendamento, forma de pagamento, quantidade de agendamentos anteriores, histórico de *no-show*, *lead time*, distância, horário e mês da consulta foram associadas significativamente com o não comparecimento. Apenas os fatores gênero e dia da consulta não



mostraram evidências estatísticas significativas, e portanto não foram considerados na análise multivariada.

O modelo de regressão logística múltipla foi construído com as variáveis significativas da análise univariada, e as variáveis que se mantiveram significativas para um p -valor $< 0,05$ na análise multivariada foram apenas o histórico de *no-show* anterior e o horário da consulta, considerados na construção do modelo reduzido.

Na construção desses modelos preditivos foram realizadas cinco repetições diferentes, uma vez que os cortes de desenvolvimento e validação são aleatórios e, portanto, a cada vez que o programa é rodado, um novo resultado é computado. Os resultados com melhor acuracidade foi o considerado para construção dos modelos. Das cinco repetições do modelo completo de regressão logística múltipla, obteve-se em média uma acuracidade de 80% e para o modelo reduzido a média foi de 77%.

Os resultados das análises estatísticas são apresentados na Tabela 2, na qual pode-se analisar os coeficientes, os p -valores, os OR's e os OR's com intervalos de confiança de 95%. O nível de referência está indicado entre parênteses ao lado do nome da variável. No modelo de regressão logística reduzido, pode-se observar que pacientes agendados nos últimos horários disponíveis para atendimento têm 3,23 vezes mais chances de faltar do que os pacientes agendados no período de 08:30h às 11:30h. Da mesma forma, pacientes com histórico de *no-show* anterior maior que 50% são os mais suscetíveis a perderem seus agendamentos.

Tabela 2 – Resultados das análises estatísticas

Variáveis independentes	Univariada				Multivariada				Multivariada Reduzida			
	β	OR	OR 95% CI	p-valor	β	OR	OR 95% CI	p-valor	β	OR	OR 95% CI	p-valor
<i>Intercept</i>					-1,585				-1,220			
Idade (≥ 50 anos)												
16 a 30 anos	0,601	1,82	(1,35 - 2,46)	<0,001	0,200	1,22	(0,62 - 2,38)	0,557				
31 a 40 anos	0,467	1,59	(1,23 - 2,08)	<0,001	-0,002	1,00	(0,56 - 1,78)	0,996				
41 a 50 anos	0,233	1,26	(0,95 - 1,68)	0,110	-0,185	0,83	(0,44 - 1,55)	0,557				
Gênero (Feminino)												
Masculino	0,009	1,01	(0,82 - 1,24)	0,929								
Tipo de agendamento (1ª vez)												
Retorno não operado	-0,559	0,57	(0,43 - 0,76)	<0,001	0,059	1,06	(0,66 - 1,68)	0,801				
Marcação de cirurgia	-0,758	0,47	(0,22 - 0,89)	<0,001	-0,172	0,84	(0,29 - 2,10)	0,727				
Retorno operado	-0,322	0,72	(0,52 - 0,99)	0,053	-0,019	0,98	(0,47 - 1,96)	0,959				
Forma de Pagamento (Plano de saúde)												
Selfpay	1,105	3,02	(2,24 - 4,08)	<0,001	-0,264	0,77	(0,24 - 2,01)	0,618				
Quantidade de agendamentos (0 ou 1 vez)												
2 a 4 vezes	-0,193	0,82	(0,66 - 1,03)	0,087	-0,203	0,82	(0,52 - 1,27)	0,373				
≥ 5 vezes	0,287	1,33	(0,63 - 2,67)	0,428	0,159	1,17	(0,31 - 3,97)	0,804				
Histórico de no-show anterior ($\geq 50\%$)												
0 10%	-0,649	0,52	(0,39 - 0,71)	<0,001	-0,695	0,50	(0,32 - 0,78)	<0,001	-0,623	0,54	(0,39 - 0,73)	<0,001
10 30%	-0,508	0,60	(0,125 - 1,27)	0,206	-0,098	0,91	(0,25 - 2,77)	0,870	-0,490	0,61	(0,26 - 1,33)	0,235
30 50%	-0,415	0,66	(0,35 - 1,20)	0,187	-0,079	0,92	(0,32 - 2,40)	0,876	-0,402	0,67	(0,35 - 1,24)	0,214
Lead time (> 20 dias)												
0 - 6 dias	-0,203	0,82	(0,63 - 1,05)	0,117	-0,661	0,52	(0,25 - 1,03)	0,067				
7 - 13 dias	0,185	1,20	(0,93 - 1,55)	0,153	-0,073	0,93	(0,49 - 1,74)	0,818				
14 - 20 dias	0,023	1,02	(0,79 - 1,32)	0,859	0,075	1,08	(0,61 - 1,93)	0,797				
Distância (≤ 10 km)												
10 - 30km	0,095	1,10	(0,85 - 1,42)	0,464	0,134	1,14	(0,64 - 2,07)	0,654				
30 - 40km	0,283	1,33	(1,01 - 1,74)	<0,001	0,452	1,57	(0,86 - 2,91)	0,144				
> 40 km	0,254	1,29	(0,97 - 1,71)	0,077	0,511	1,67	(0,88 - 3,19)	0,119				
Horário da consulta (08:30 - 11:30)												
11:30 - 14:30	0,231	1,26	(0,93 - 1,70)	0,135	0,527	1,69	(0,94 - 3,29)	0,076	0,305	1,36	(0,83 - 2,18)	0,211
14:30 - 16:30	0,354	1,42	(1,08 - 1,87)	<0,001	0,068	1,07	(0,62 - 1,84)	0,806	0,177	1,19	(0,77 - 1,86)	0,432
16:30 - 18:30	1,023	2,78	(2,18 - 3,56)	<0,001	0,791	2,20	(1,26 - 3,88)	<0,001	1,172	3,23	(2,22 - 4,75)	<0,001
Dia da consulta (Segunda)												
Quarta	-0,066	0,94	(0,78 - 1,12)	0,469								



Variáveis independentes	Univariada				Multivariada				Multivariada Reduzida				
	β	OR	OR 95% CI	p-valor	β	OR	OR 95% CI	p-valor	β	OR	OR 95% CI	p-valor	
Mês da consulta													
(dez - jan - fev)													
mar - abr - mai	0,189	1,21	(,96 - 1,53)	0,114	0,521	1,68	(0,93 - 3,12)	0,089					
jun - jul - ago	-0,015	0,99	(0,74 - 1,31)	0,918	0,291	1,34	(0,70 - 2,59)	0,380					
set - out - nov	0,147	1,16	(0,87 - 1,53)	0,306	0,009	1,01	(0,47 - 2,17)	0,982					

Ao contrário de muitos estudos, o *lead time* não foi estatisticamente significativo para predizer o *no-show* nas consultas. Porém, vale notar que se fosse considerado um nível de significância de 10% na análise multivariada, o *lead time* e o mês de agendamento seriam outras duas variáveis candidatas ao modelo preditivo reduzido.

Assim como nos estudos de Giunta et al. [2013] e Huang e Hanauer [2014], verificou-se que a proporção de *no-show* aumenta durante as últimas horas de atendimento. Além disso, o histórico de *no-show* anterior é um fator determinante para predizer o comportamento do paciente. Aqueles com maior probabilidade de não comparecerem ao agendamento têm maior porcentagem de *no-show* anterior, concordando com os trabalhos de Lee et al. [2005], Daggy et al [2010], Cronin et al. [2013], Giunta et al. [2013], Huang e Hanauer [2014] e Norris et al. [2014].

Para exemplificar o uso do modelo preditivo, indicado na Tabela 2, supõe-se que um paciente homem irá marcar sua cirurgia, tem 32 anos, com plano de saúde, *lead time* de 10 dias, e está agendado às 17h na quarta-feira no mês de abril, possui histórico de 33% de consultas perdidas, 5 marcações feitas e mora a uma distância de 7 km da clínica. O cálculo da taxa de *no-show* para este paciente, considerando a equação (1), é o seguinte:

$$\ln\left(\frac{p(x)}{1-p(x)}\right) = -1,585 - 0,002 - 0,172 + 0 + 0,159 - 0,079 - 0,073 + 0 + 0,791 + 0,521 = -0,440.$$

Logo, $\frac{p(x)}{1-p(x)} = e^{-0,440} = 0,644 \rightarrow p(x) = 0,644(1-p(x)) \rightarrow p(x) = 0,3917$, ou seja, a probabilidade do referido paciente faltar é de 39,17%.

Considerando o modelo reduzido com apenas as variáveis significativas no modelo multivariado, de forma análoga, tem-se para o mesmo paciente:

$$\ln\left(\frac{p(x)}{1-p(x)}\right) = -1,220 - 0,402 + 1,172 = -0,45 \rightarrow e^{-0,45} = 0,6379 \rightarrow p(x) = 0,6379(1-p(x)) \rightarrow p(x) = 0,3895 = 38,95\%.$$

Como foi obtido valores próximos, com diferença de apenas 0,22 pontos percentuais, observa-se que o modelo preditivo reduzido tem desempenho tão bom quanto o modelo multivariado, podendo ser utilizado de forma mais prática pelo cirurgião, uma vez que considera menor número de variáveis e as informações necessárias para a predição estão facilmente a disposição da clínica.

5. Conclusão

Este estudo mostrou que modelos estatísticos podem ser desenvolvidos para prever a probabilidade de um paciente não comparecer a consulta agendada. Para isso, foi realizada uma aplicação em uma clínica de cirurgia bariátrica no Rio de Janeiro, onde analisou-se quais características demográficas do paciente e informações do agendamento podem influenciar na taxa de *no-show* dos pacientes. Após a análise multivariada, observou-se que pacientes agendados nos últimos horários disponíveis para atendimento e pacientes com histórico de *no-show* anterior maior que 50% são os mais suscetíveis a perderem seus agendamentos.

Para melhorar a eficiência do setor de saúde, os resultados desta pesquisa podem ser usados para aplicar métodos de intervenção de agendamento avançado, otimizando o número de pacientes atendidos e a utilização dos recursos, simultaneamente. Sistemas de agendamento que levem em consideração a probabilidade de *no-show* de cada paciente no momento em que uma consulta é agendada, como políticas de dupla marcação (*overbooking*), é uma prática que pode ser adotada. Dessa forma, ao incorporar os modelos preditivos, predições serão fornecidas em tempo real, podendo orientar as secretárias na possibilidade de marcação ou não de dois pacientes em mesmo horário.



Além disso, para direcionar o comportamento do paciente, outras práticas de gestão podem ser incorporadas, como o envio de lembretes, a fim de evitar que pacientes esqueçam de seus compromissos médicos.

Referências

- Bean, A. G.; Talaga, J. (1992) Appointment breaking: causes and solutions. *Marketing Health Services*, 12(4):14-25.
- Cohen, A. D.; Dreiher, J.; Vardy, D. A.; Weitzman, D. (2008). Nonattendance in a dermatology clinic—a large sample analysis. *Journal of the European Academy of Dermatology and Venereology*, 22(10):1178-1183.
- Cronin, P. R.; Decoste, L.; Kimball, A. B. (2013). A multivariate analysis of dermatology missed appointment predictors. *JAMA Dermatology*, 149(12):1435-1437.
- Daggy, P.; Lawley, M.; Willis, D.; Thayer, D.; Suelzer, C.; Delaurentis, P. C.; Turkcan, A.; Chakraborty, S.; Sands, L. (2010). Using no-show modeling to improve clinic performance. *Health Informatics Journal*, 16(4):246-259.
- Dantas, L. F. (2016). Revisão sistemática da literatura sobre *no-show* em agendamento de consultas. Dissertação (Mestrado em Engenharia Industrial). Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro.
- Deyo, R. A.; Inui, T. S. (1980). Dropouts and broken appointments: a literature review and agenda for future research. *Medical Care*, 18(11):1146-1157.
- James, G.; Witten, D.; Hastie, T.; Tibshirani, R. (2013). ISLR: Data for An Introduction to Statistical Learning with Applications in R. R package version 1.0. <https://CRAN.R-project.org/package=ISLR>
- Garuda, S. R.; Javalgi, R. G.; Talluri, V. S. (1998). Tackling no-show behavior: a market-driven approach. *Health Marketing Quarterly*, 15(4):25-44.
- Ginta, D.; Briatore, A.; Baum, A.; Luna, D.; Waisman, G.; Quiros, F. G. B. (2013). Factors associated with nonattendance at clinical medicine scheduled outpatient appointments in a university general hospital. *Patient Preference & Adherence*, 7.
- Goldbart, A. D.; Dreiher, J.; Vardy, D. A.; Alkrinawi, S.; Cohen, A. D. (2009). Nonattendance in pediatric pulmonary clinics: an ambulatory survey. *BMC Pulmonary Medicine*, 9(1):1-6.
- Hosmer, D. W.; Lemeshow, S. (2000). *Applied logistic regression*. New York: Wiley.
- Huang, Y.; Hanauer, D. A. (2014). Patient no-show predictive model development using multiple data sources for an effective overbooking approach. *Applied Clinical Informatics*, 5(3):836-860.
- Kaplan-Lewis, E.; Percac-Lima, S. (2013). No-show to primary care appointments why patients do not come. *Journal of Primary Care & Community Health*, 4(4):251-255.
- Laloo, R.; McDonald, J. M. (2013). Appointment attendance at a remote rural dental training facility in Australia. *BMC Oral Health*, 13(1):1-8.
- Lee, V. J.; Earnest, A.; Chen, M. I.; Krishnan, B. (2005). Predictors of failed attendance in a multi-specialty outpatient centre using electronic databases. *BMC Health Services Research*, 5(1):1-8.
- Lehmann, T. N. O.; Aebi, A.; Lehmann, D.; Olivet, M. B.; Stalder, H. (2007). Missed appointments at a Swiss university outpatient clinic. *Public Health*, 121(10):790-799.



Menendez, M. E.; Ring, D. (2015). Factors associated with non-attendance at a hand surgery appointment. *Hand*, 10(2):221-226.

Norris, J. B.; Kumar, C.; Chang, S.; Moskowitz, H.; Shade, S. A.; Willis, D. R. (2014). An empirical investigation into factors affecting patient cancellations and no-show at outpatient clinics. *Decision Support Systems*, 57:428-443.

Peng, Y.; Erdem, E.; Shi, J.; Masek, C.; Woodbridge, P. (2016). Large-scale assessment of missed opportunity risks in a complex hospital setting. *Informatics for Health and Social Care*, 41(2):112-127.

R Core Team (2016). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. Web page. <https://www.R-project.org/>.

Traeger, L.; O'Cleirigh, C.; Skeer, M. R.; Mayer, K. H.; Safren, S. A. (2012). Risk factors for missed HIV primary care visits among men who have sex with men. *Journal of Behavioral Medicine*, 35(5):548-556.

Tseng, F. Y. (2010). Non-attendance in endocrinology and metabolism patients. *Journal of the Formosan Medical Association*, 109(12):895-900.

WHO – World Health Organization (2014). Web Page. <http://apps.who.int/gho/data/view.main.HEALTHEXPCAPBRA?lang=en> e <http://apps.who.int/gho/data/view.main.HEALTHEXPRATIOBRA?lang=en>. Acessado: 2017-03-09.