



UM MODELO PARA CLASSIFICAÇÃO DO COMPORTAMENTO DE RECLAMAÇÃO EM PRONTO ATENDIMENTO NA SAÚDE SUPLEMENTAR

¹Charles Ferreira de Souza

²André Silva De Carvalho

³Aimã Ibrahim Mourad

⁴Maria Carolina Conejero

RESUMO

Objetivo: Avaliar se o tempo de espera e outras variáveis associadas ao atendimento e ao perfil do paciente aumentam a probabilidade de ocorrência de reclamações em serviços de pronto atendimento de uma operadora de saúde suplementar.

Método: Utilizou-se regressão logística binária com inflação de zeros aplicada a uma base com mais de 600 mil atendimentos. Foram consideradas variáveis sociodemográficas, assistenciais e contextuais. Testes de desempenho e validação do modelo incluíram curva ROC, AUC, coeficiente de Gini e modelos comparativos como árvore de decisão e random forest.

Resultados: Fatores como tempo porta-médico, retorno em até 48h, alta por evasão e diagnóstico CID capítulo XX aumentam a chance de reclamação. Fatores como plano individual, histórico de asma e atendimentos em maio foram protetores. O modelo apresentou bom ajuste estatístico, mas baixa sensibilidade e proporção de verdadeiros positivos.

Conclusão: Apesar de estatisticamente significativo, o modelo não apresenta desempenho preditivo satisfatório para eventos raros como reclamações em saúde. A inclusão de novas variáveis, outras abordagens de modelagem e técnicas de machine learning mais robustas são recomendadas.

Palavras-chave: Reclamações de Pacientes. Satisfação do Cliente em Saúde. Serviços de Urgência Médica. Regressão Logística com Inflação de Zeros. Modelagem Preditiva. Avaliação da Qualidade em Saúde.

Rev. FAPAD

e-ISSN: 2764-2313

Recebido: 21.12.24

Aprovado: 26.03.25

<https://doi.org/10.37497/revistafapad.v5id.article.95>

¹ Escola Superior de Agricultura “Luiz de Queiroz” da Universidade de São Paulo - ESALQ/USP, São Paulo, (Brasil).

² Centro Universitário FEI, São Paulo, (Brasil). Orcid id: <https://orcid.org/0000-0001-7724-1097>

³ Centro Universitário FEI, São Paulo, (Brasil). Orcid id: <http://orcid.org/0000-0003-0247-232X>

⁴ Centro Universitário FEI, São Paulo, (Brasil). Orcid id: <https://orcid.org/0000-0001-7082-3545>

A MODEL FOR CLASSIFYING COMPLAINT BEHAVIOR IN EMERGENCY CARE WITHIN SUPPLEMENTARY HEALTH SERVICES

ABSTRACT

Objective: To assess whether waiting time and other patient and service-related variables increase the likelihood of complaints in emergency care services within a supplementary health operator.

Method: A zero-inflated binary logistic regression model was applied to a dataset of over 600,000 records. Demographic, clinical, and contextual predictors were analyzed. Model performance was evaluated using ROC curve, AUC, Gini coefficient, and comparison with decision tree and random forest models.

Results: Risk factors included door-to-physician time, 48-hour return, discharge due to patient withdrawal, and diagnoses under ICD Chapter XX. Protective factors were individual plan contracts, asthma history, and visits in May. Despite good statistical fit, the model showed low sensitivity and true positive rates.

Conclusion: Although statistically significant, the model does not perform well for predicting rare events such as healthcare complaints. Enhancing the model with additional variables and advanced machine learning techniques is suggested.

Keywords: Patient Complaints. Customer Satisfaction in Healthcare. Emergency Medical Services. Zero-Inflated Logistic Regression. Predictive Modeling. Healthcare Quality Assessment.

UN MODELO PARA LA CLASIFICACIÓN DEL COMPORTAMIENTO DE QUEJAS EN LA ATENCIÓN DE URGENCIAS EN LA SALUD SUPLEMENTARIA

RESUMEN

Objetivo: Evaluar si el tiempo de espera y otras variables asociadas al perfil del paciente y del servicio aumentan la probabilidad de quejas en unidades de atención de urgencias de una operadora de salud suplementaria.

Método: Se aplicó un modelo de regresión logística binaria con inflación de ceros a una base de datos con más de 600 mil registros. Se consideraron variables sociodemográficas, asistenciales y contextuales. La validación del modelo incluyó curva ROC, AUC, coeficiente de Gini y comparación con modelos de árbol de decisión y random forest.

Resultados: Factores de riesgo fueron: tiempo puerta-médico, retorno en 48h, alta por evasión y diagnósticos del Capítulo XX del CID. Los factores protectores incluyeron: contrato individual, historial de asma y atenciones en el mes de mayo. El modelo mostró buen ajuste estadístico, pero baja sensibilidad y tasa de verdaderos positivos.

Conclusión: Aunque estadísticamente significativo, el modelo no presenta un buen rendimiento para predecir eventos raros como quejas en salud. Se recomienda incluir nuevas variables y técnicas avanzadas de aprendizaje automático.

Palabras clave: Quejas de Pacientes. Urgencias Médicas. Modelado Predictivo. Salud Suplementaria. Regresión Logística con Inflación de Ceros.

INTRODUÇÃO

A revolução da tecnologia da informação tem se intensificado no Brasil nas últimas décadas, por meio da ampliação do acesso à internet, popularização dos dispositivos móveis, disseminação das mídias sociais e digitalização. Esses avanços têm transformado significativamente a maneira como as pessoas se expressam, potencializando o alcance e o impacto das opiniões individuais na sociedade (Peixoto, 2021; Pinheiro & Castells, 1999).

De acordo com a Pesquisa Nacional por Amostra de Domicílios Contínua (PNAD) 2021, a internet já era utilizada em 90,0% dos domicílios do Brasil naquele ano. O telefone móvel foi o equipamento mais utilizado para acessar a rede (99,5%) e “enviar ou receber mensagens de texto, voz ou imagens por aplicativos diferentes de e-mail” foi um dos principais motivos para acesso à internet (94,9%).

A experiência do consumidor é um fator crucial nas relações comerciais entre empresas e indivíduos. Atualmente, as pessoas buscam informações detalhadas sobre produtos e serviços, frequentemente consultando experiências de outros consumidores e compartilhando suas próprias recomendações ou críticas em espaços públicos de debate, principalmente nas mídias sociais (Peixoto, 2021; Sharma, 2014).

No setor de saúde suplementar, esse comportamento adquire ainda mais relevância. O registro frequente de reclamações por parte dos beneficiários pode resultar em processos administrativos pela Agência Nacional de Saúde Suplementar (ANS), gerando multas ou até a suspensão temporária da comercialização de planos por parte das operadoras. Apesar de ser um tema monitorado de perto nos fóruns de estratégia, ainda não há um estudo que trate do assunto sob perspectiva multivariada.

Este estudo foi realizado em uma operadora de planos de saúde que possui sua própria rede de hospitais e unidades de pronto atendimento, as quais apresentam elevados índices de reclamação de clientes quando comparadas a outros serviços da instituição. Com isso, busca-se responder: em serviços de urgência, um maior tempo de espera para atendimento médico aumenta a chance de registro de reclamação por parte do cliente? E mais: características do indivíduo, do atendimento e da unidade de saúde também podem influenciar a ocorrência de reclamação?

REFERENCIAL TEÓRICO

A Agência Nacional de Saúde Suplementar (ANS) é uma autarquia vinculada ao Ministério da Saúde, instituída pela Lei nº 9.961, de 28 de janeiro de 2000, com a finalidade de regular o setor de planos de saúde no Brasil. Sua missão inclui a defesa do interesse público na assistência suplementar à saúde,

assegurando que as operadoras cumpram as normas estabelecidas e promovam um atendimento de qualidade aos beneficiários.

De acordo com dados divulgados pela ANS, entre janeiro e setembro de 2022, foram registradas mais de 170 mil Notificações de Intermediação Preliminar (NIP), das quais 80,2% possuíam natureza assistencial. Dentre essas, os subtemas mais recorrentes foram "Gerenciamento das Ações de Saúde pela Operadora" (39,7%) e "Prazos Máximos para Atendimento" (17,7%). A NIP atua como um mecanismo extrajudicial que facilita a comunicação entre operadoras e beneficiários, permitindo que as operadoras prestem esclarecimentos sobre as reclamações apresentadas.

Além dos canais regulatórios tradicionais, as operadoras de planos de saúde têm investido em plataformas digitais para aprimorar o relacionamento com os clientes. A implementação de sistemas de Resolução Online de Disputas (Online Dispute Resolution - ODR) tem se mostrado uma estratégia eficaz nesse contexto. Fernandes et al. (2018) discutem a expansão do ODR no Brasil, destacando os desafios legislativos e culturais para sua implementação, mas também ressaltando os benefícios potenciais na resolução de conflitos de forma mais ágil e acessível.

A experiência do paciente nos serviços de saúde é influenciada por diversos fatores, incluindo o tempo de espera e a qualidade do atendimento recebido. Estudos internacionais têm demonstrado que a implementação de sistemas eficazes de triagem pode reduzir significativamente a mortalidade nos departamentos de emergência. Por exemplo, Sabry *et al.* (2023) evidenciaram que a introdução de um sistema de triagem de cinco níveis resultou em uma diminuição nas taxas de mortalidade e no tempo de permanência no departamento de emergência.

Em serviços de pronto atendimento, a adoção da classificação de risco é uma prática comum para priorizar casos mais graves, garantindo atendimento rápido a quem mais necessita. Essa triagem é realizada por profissionais de saúde e, geralmente, segue sistemas que atribuem cores ou números aos pacientes. Embora a classificação de risco não implique desatenção aos casos menos graves, ela apresenta desafios, especialmente em hospitais gerais, onde atendimentos com prioridade "pouco urgente" são frequentes. Silva *et al.* (2019) observaram que, em um hospital público de grande porte no sudeste brasileiro, 33,4% dos atendimentos foram classificados como "pouco urgentes", o que pode contribuir para a insatisfação dos pacientes e aumento das reclamações, mesmo quando a triagem é realizada corretamente.

A percepção dos pacientes sobre o tempo de espera e a qualidade do atendimento está diretamente relacionada à satisfação geral com os serviços de saúde. Tempos de espera prolongados e comunicação ineficaz podem levar a uma diminuição na satisfação do paciente e na confiança nos serviços prestados. Portanto, estratégias que visam melhorar a comunicação e reduzir o tempo de espera são essenciais para aprimorar a experiência do paciente.

Além disso, a integração de tecnologias digitais, como aplicativos móveis e plataformas online, tem sido explorada como solução para melhorar a comunicação entre pacientes e serviços de saúde, fornecer atualizações em tempo real sobre tempos de espera e permitir o agendamento de consultas, potencialmente reduzindo a insatisfação dos pacientes. Fernandes et al. (2018) discutem a expansão da resolução de disputas online no Brasil, destacando o papel da tecnologia nos serviços de saúde e os desafios para sua implementação eficaz.

Em suma, a gestão eficaz do tempo de espera, a implementação adequada da classificação de risco e o uso estratégico de tecnologias digitais são fundamentais para melhorar a experiência do paciente nos serviços de urgência e emergência. Investimentos em treinamento de profissionais, infraestrutura adequada e inovações tecnológicas são essenciais para alcançar esses objetivos.

MATERIAIS E MÉTODOS

Este estudo foi conduzido em uma operadora de planos de saúde que mantém rede própria de hospitais e unidades de pronto atendimento. Essas unidades registram índices significativamente mais elevados de reclamações por parte dos clientes quando comparadas a outros serviços da mesma instituição. Embora o tema seja acompanhado de forma sistemática nos fóruns internos de estratégia, não foram encontrados estudos anteriores que abordem a questão sob uma perspectiva analítica multivariada, especialmente com foco em variáveis associadas ao perfil do atendimento e do paciente.

Para a análise dos dados, utilizou-se o modelo de regressão logística, uma técnica estatística amplamente empregada para prever a probabilidade de ocorrência de um evento binário a partir de um conjunto de variáveis explicativas. Essa abordagem é particularmente útil em estudos que buscam compreender os fatores associados à ocorrência de determinado desfecho, como o registro de uma reclamação formal por parte do cliente.

Nesta seção, apresentam-se os principais aspectos da técnica de regressão logística, bem como a forma de operacionalização das variáveis utilizadas e os critérios adotados para construção do modelo preditivo no contexto específico deste estudo.

1.1 Base de Dados

A análise de regressão logística binária foi realizada utilizando uma base de dados privada, composta por atendimentos realizados entre janeiro de 2022 e julho de 2023 em um serviço de urgência de operadora de plano de saúde que atua no estado de Minas Gerais, além dos registros de reclamação dos clientes atendidos no referido estabelecimento de saúde. Essa base de dados contém informações relevantes para o problema em questão e é composta por uma variável resposta binária (variável dependente) e um conjunto de variáveis preditoras.

Antes de aplicar a regressão logística binária realizamos o processo de pré- processamento dos dados. Isso incluiu a remoção de valores ausentes, tratamento de outliers e transformação das variáveis preditoras qualitativas em variáveis indicadoras, conforme necessário.

A primeira etapa consistiu em unir as bases de dados de atendimento e o registro de reclamações, utilizando o código identificador único do cliente presente em ambas as bases. Levando em consideração que nem sempre o cliente registra reclamação sobre o atendimento no mesmo dia em que o serviço de urgência foi prestado, optou-se por considerar todos os registros de reclamação realizados pelo cliente em um período de até três dias após a realização do atendimento.

Foram adotadas medidas para aprimorar a qualidade das informações do banco de dados. Inicialmente, foram excluídos quaisquer registros com informações ausentes, bem como atendimentos em que a alta do serviço estava relacionada a óbito. Dentro do contexto dos serviços de urgência, não é incomum que os clientes permaneçam sob cuidados médicos por um período prolongado, aguardando internação em um leito hospitalar adequado ao seu estado clínico. Por este motivo os atendimentos com duração de até vinte e quatro horas foram mantidos na análise.

A análise estatística e a construção do modelo de regressão logística binária foram realizadas utilizando o software R.

A base de dados possui 600.971 linhas/atendimentos e 28 colunas, sendo 01 variável dependente e 27 preditoras (09 de cliente e 18 de atendimento), todas elas descritas na tabela a seguir. Na tabela 1 é possível observar a variável dependente.

1.2 Pré-processamento de Dados

1.3 Software e Ferramentas

1.4 Caracterização da base de dados

Tabela 1: Descrição da variável dependente

Variável	Descrição
ind_rec	Variável binária que indica se o cliente registrou reclamação em até 03 dias após o atendimento recebido

Em seguida são apresentadas as variáveis explicativas / preditoras de cliente na tabela 2.

Tabela 2: Descrição das variáveis explicativas/preditoras (de cliente)

Variável	Descrição
ds_faixa_etária	Faixa etária do cliente atendido
ds_sexo	Sexo do cliente
ds_tipo_produto	Descrição do tipo de produto do cliente contratado junto a operadora
ds_tipo_contratacao	Descrição do tipo de contratação do produto do cliente
ds_util_prev	Descrição do tipo que é mais frequente no histórico de utilização do cliente
ind_asma	Variável indicadora para cliente que possui asma como condição de saúde
ind_mais_urgentes	Variável indicador para atendimentos classificados como amarelos, laranja ou vermelhos
ind_exp_onl	Variável indicadora para cliente que possui histórico de utilização do serviço de atendimento on-line para pequenas urgências
score_reclamacao	Razão entre o número de reclamações registradas e o tempo de exposição dele nos 12 meses anteriores ao atendimento de urgência atual. A exposição considerada foi o tempo de permanência no plano de saúde expresso em meses

Por fim apresentamos as variáveis explicativas / preditoras de atendimento na tabela 3.

Tabela 3: Descrição das variáveis explicativas/preditoras (de atendimento)

(continua)

Variável	Descrição
atend_med_24h	Número de atendimentos realizados pelo(a) médico(a) nas 24 horas anteriores ao atendimento atual
atend_enf_24h	Número de classificações de risco realizadas pelo(a) enfermeiro(a) nas 24 horas anteriores ao atendimento atual
atend_vistos	Número de atendimentos em que outros clientes tiveram etapa de classificação de risco finalizada depois e que o atendimento médico iniciou antes do cliente atual
cod_capitulo_cid_agr	Código do capítulo do Cid (Classificação internacional de doenças) atribuído ao final do atendimento
ds_ano	Ano do atendimento realizado
ds_cor	Descrição da cor que simboliza a classificação de risco atribuída ao cliente pela equipe de enfermagem
ds_dia_semana	Dia da semana do atendimento realizado
ds_mes	Mês do atendimento realizado
ds_unidade_tipo	Descrição do tipo de unidade de saúde em que foi realizado o atendimento de urgência
ind_alta_evasao	Variável indicador para atendimento resultado/alta por evasão por parte do cliente

Variável	Descrição
ind_pediatria	Variável indicadora para atendimento realizado em alguma das especialidades ou filas de atendimento para clientes pediátricos
ind_presc_medica	Variável indicadora para cliente com utilização de medicação durante o atendimento
ind_presc_exalab	Variável indicadora para cliente com realização de exame laboratorial durante o atendimento
ind_presc_exaimg	Variável indicadora para cliente com realização de exame de imagem durante o atendimento
ind_retorno_48hs	Variável indicadora para cliente com atendimento de urgência anterior no período de 48 horas
ind_udc	Variável indicadora para atendimento em que o cliente teve passagem por unidade de decisão clínica
tempo_porta_medico_min	Tempo entre o cliente retirar a senha no totem de autoatendimento até o médico iniciar o atendimento de urgência
tempo_inicio_fim_medico_min	Tempo de duração em minutos da etapa entre o médico iniciar e finalizar o atendimento do cliente

1.5 Modelo de regressão logística binário

O modelo de regressão logística binária foi utilizado com a finalidade de estudar quais variáveis (de cliente e atendimento) têm significância estatística para modificar a probabilidade de reclamação. Sendo assim, a variável binária que indica se o cliente atendido registrou reclamação foi utilizada como variável dependente, enquanto as demais variáveis foram utilizadas como preditoras.

A regressão logística binária é uma extensão da regressão linear, que é adequada para variáveis dependentes contínuas. No entanto, ao lidar com variáveis dependentes binárias, a regressão logística binária se torna uma escolha mais apropriada, pois permite modelar a relação entre as variáveis explicativas e a probabilidade de ocorrência do evento. Como mencionado anteriormente, o evento de interesse (registro de reclamação de clientes) ocorre a uma taxa muito baixa em relação ao volume de atendimentos realizados. A análise de eventos desta natureza (eventos raros) apresenta desafios estatísticos, pois a baixa incidência desses eventos pode resultar em amostras desbalanceadas e dificuldade na estimativa de parâmetros. Por este motivo foi feita opção por utilizar a regressão logística com inflação de zeros, que é uma extensão do modelo de regressão logística binária que lida com a presença de excesso de zeros na variável dependente.

Ao contrário do modelo de regressão logística binária tradicional, que assume que todos os zeros na variável dependente refletem a ausência do evento de interesse, o modelo de

regressão logística com inflação de zeros considera que os zeros podem ter origens diferentes: zeros verdadeiros, que representam a ausência do evento; e zeros inflacionados, que ocorrem por razões distintas do fenômeno em estudo.

A regressão logística com inflação de zeros (zero-inflated) combina dois componentes, um para modelar a probabilidade dos zeros (ausência do evento) e outra para modelar a probabilidade dos uns (ocorrência do evento). Desta maneira a equação para modelagem das probabilidades é:

$$\begin{cases} p(Y_i = 0) = \frac{1}{1+e^{-Z_i}} + \left(1 - \frac{1}{1+e^{-Z_i}}\right) \cdot e^{-C_i} \\ p(Y_i = 1) = \left(1 - \frac{1}{1+e^{-Z_i}}\right) \cdot \left(\frac{1}{1+e^{-C_i}}\right) \end{cases} \quad (1)$$

$$Z_i = \delta_0 + \delta_1 \cdot W_{1i} + \delta_2 \cdot W_{2i} \dots + \delta_q \cdot W_{qi} \quad (\text{modelo para inflação de zeros}) \quad (2)$$

$$C_i = \beta_0 + \beta_1 \cdot X_{1i} + \beta_2 \cdot X_{2i} \dots + \beta_k \cdot X_{ki} \quad (\text{modelo condicional}) \quad (3)$$

onde, $p(Y_i = 0)$ é a probabilidade de não ocorrência do evento de interesse; $p(Y_i = 1)$ é a probabilidade de ocorrência do evento de interesse; $\delta_0 + \delta_1 + \delta_2 \dots + \delta_q$ são os coeficientes e $W_{1i} \cdot W_{2i} + \dots + W_{qi}$ as q variáveis explicativas do modelo *zero-inflated*; $\beta_0 + \beta_1 + \beta_2 \dots + \beta_k$ são os coeficientes e $X_{1i} \cdot X_{2i} + \dots + X_{ki}$ as k variáveis explicativas do modelo condicional.

Essa abordagem permitiu estimar simultaneamente os parâmetros relacionados à probabilidade de ocorrência do evento e os parâmetros associados à inflação de zeros. Assim, foi possível entender não apenas a influência das variáveis explicativas na presença/ausência das reclamações, mas também nos zeros inflacionados.

1.6 Adequação do modelo

Para avaliar a adequação do modelo utilizamos o teste *Hosmer e Lemeshow*. Para este teste, os dados são divididos de acordo com as probabilidades previstas em 10 grupos iguais, sendo que os números previstos e os reais são comparados com a estatística do qui- quadrado. A hipótese nula H_0 deste teste é a de que as proporções observadas e esperadas são as mesmas ao longo da amostra, ou seja, um modelo adequado deve possuir p-valor maior ou igual ao nível de significância estabelecido (Hosmer e Lemeshow, 2000).

1.7 Avaliação do desempenho do modelo

Para avaliar a qualidade do(s) modelo(s) utilizamos como referência a área abaixo da curva ROC (AUC) e o coeficiente de Gini. A AUC e o coeficiente de Gini são duas medidas de desempenho para

modelos de classificação binária. A AUC é uma medida de quanto um modelo é capaz de distinguir entre as classes positivas e negativas, enquanto o coeficiente de Gini é uma medida de quanto um modelo é capaz de classificar corretamente todas as observações.

A AUC é calculada traçando uma curva ROC, que plota a taxa de verdadeiros positivos (TPR) contra a taxa de falsos positivos (FPR) para diferentes valores de limiar de classificação. A TPR é a proporção de observações positivas que são corretamente classificadas como positivas, enquanto a FPR é a proporção de observações negativas que são incorretamente classificadas como positivas. Um bom modelo de classificação terá uma TPR alta e uma FPR baixa.

O coeficiente de Gini é calculado como o dobro da área entre a curva ROC e a diagonal principal. A diagonal principal representa um modelo aleatório, que classificaria as observações com a mesma probabilidade, independentemente da classe a que pertencem. Um modelo perfeito teria um coeficiente de Gini de 1, enquanto um modelo aleatório teria um coeficiente de Gini de 0.5.

RESULTADOS E DISCUSSÃO

Considerando que a ocorrência de reclamações é relativamente baixa em comparação ao volume de atendimentos realizados (evento raro), optamos por avaliar o número de reclamações como uma taxa por cada 1.000 atendimentos realizados. Durante o período analisado, observou-se uma taxa de reclamações de 1,17 a cada 1.000 atendimentos.

Nos atendimentos em que não houve registro de reclamação, observamos uma média de tempo porta-médico aparentemente menor, com uma média de 44,9 minutos, em comparação com os 72,9 minutos observados nos atendimentos com reclamação. Isso sugere que os pacientes que expressaram insatisfação com o atendimento tendem a ser aqueles que tiveram que esperar mais tempo para serem atendidos pelo médico. Analisando a Figura 1, podemos observar que, embora a mediana dos pacientes que registraram reclamações seja maior, há uma certa sobreposição entre as caixas que representam as duas categorias. Para uma parcela dos dados esta variável pode não ser suficiente para diferenciar atendimentos com registro de reclamação, embora o p-valor para o modelo de regressão logística univariado tenha significativo a 5%.




Figura 1: Representação Box Plot para o tempo porta-médico com atendimento que geraram reclamação (Não / Sim). Fonte: Dados originais da pesquisa

Na tabela 4 são apresentadas as estatísticas descritivas da variável preditora *Tempo porta-médico* por categoria de Reclamação (Não / Sim) em atendimentos de urgência em unidades de uma operação de plano de saúde, de janeiro de 2022 a julho de 2023.

Tabela 4: Estatísticas descritivas da variável preditora Tempo porta-médico

	Reclamação		p-valor*
	Não	Sim	
Média	44,9	72,9	<0,001
(desvio-padrão)	(41,5)	(57,2)	
Mediana	30,9	55,8	
(Interquartilico)	(49,1)	(94,4)	

Fonte: Dados originais da pesquisa

Em relação ao tipo de contratação, O número total de reclamações é de 701, sendo 454 reclamações do tipo coletivo empresa, 127 reclamações do tipo coletivo adesão e 120 reclamações do tipo individual. Os planos individuais e coletivos por adesão apresentaram taxas de reclamações significativamente maiores do que os planos coletivos empresa ($p\text{-valor} < 0,001$). A taxa de reclamações por 1.000 atendimentos foi de 1,04 para os planos coletivos empresa, 1,45 para os planos coletivos por adesão e 1,56 para os planos individuais.

Na tabela 5 são apresentadas as frequências absolutas de atendimentos, reclamações e taxa de reclamação por categoria da variável preditora *Tipo de Contratação* em atendimentos de urgência em unidades de uma operação de plano de saúde, de janeiro de 2022 a julho de 2023.

Tabela 5: Frequências absolutas de atendimentos, reclamações e taxa de reclamação

Categoria	numero de atendimentos	numero de reclamacoes	taxa de reclamacoes por 1.000	p-valor*
Coletivo empresa	436.594	454	1,04	-
Coletivo adesao	87.304	127	1,45	<0,001
Individual	77.073	120	1,56	<0,001

Fonte: Dados originais da pesquisa

Os capítulos Cid VIII, XIV, XVIII e XX apresentaram taxas de reclamações significativamente maiores do que os capítulos XXI, VI e outros capítulos a 5% de significância. A taxa de reclamações por 1.000 atendimentos foi de 1,03 para os outros capítulos, 1,42 para o capítulo VI, 1,68 para o capítulo VIII, 1,74 para o capítulo XIV, 1,57 para o capítulo XVIII, 2,61 para capítulo XX e 1,57 para o capítulo XXI.

As frequências absolutas de atendimentos, reclamações e taxa de reclamação por categoria da variável preditora *Capítulo Cid* em atendimentos de urgência em unidades de uma operação de plano de saúde, de janeiro de 2022 a junho de 2023, são apresentados na tabela 6.

Tabela 6: Frequências absolutas de atendimentos, reclamações e taxa de reclamação por categoria da variável preditora Capítulo Cid

Categoria	numero de atendimentos	numero de reclamacoes	taxa de reclamacoes por 1.000	p-valor
Outros capitulos	465.727	482	1,03	-
Capítulo XVIII - Sintomas, sinais e achados anormais de exames clinicos e de laboratorio, nao classificados em outra parte	70.210	110	1,57	<0,001
Capítulo XIV - Doencas do aparelho geniturinario	23.621	41	1,74	0,001
Capítulo XXI - Fatores que influenciam o estado de saude e o contato com os servicos de saude	14.003	22	1,57	0,055
Capítulo VIII - Doencas do ouvido e da apofise mastoide	13.100	22	1,68	0,026
Capítulo VI - Doencas do sistema nervoso	11.244	16	1,42	0,210
Capítulo XX - Causas externas de morbidade e de mortalidade	3.066	8	2,61	0,009

Fonte: Dados originais da pesquisa

Essas três variáveis juntas (Tempo porta-médico, tipo de contratação e Capítulo Cid) são teorizadas pela instituição como sendo as principais preditoras para a reclamação de clientes em

atendimento de urgência e este foi o ponto de partida para o modelo de classificação por meio de regressão logística binária.

O modelo apresentado na Tabela 7 abaixo foi obtido seguindo o seguinte processo: no modelo multivariado foram incluídas todas as categorias que na análise univariada obtiveram p-valor de no máximo de 10%. Por este critério a categoria *Capítulo VI - Doenças do sistema nervoso* da variável Capítulo Cid não foi considerada no modelo multivariado; foram excluídas do modelo multivariado as categorias que apresentaram p-valor maior que 5%. Nesta etapa foi excluída do modelo a categoria *Capítulo VIII - Doenças do ouvido e da apófise mastoide* da variável Capítulo Cid.

Tabela 7: Resultado do modelo binomial⁽¹⁾, após procedimento de seleção de variáveis⁽²⁾

ind reclamação				
Preditores	Coefficientes	Erro padrão	azão das chances	IC ⁽³⁾
(Intercepto)	-7,689	0,074	0,00	0,00 – 0,00
tempo_porta_medico_min	0,012	0,001	1,01	1,01 – 1,01
ds_tipo_contratacao_individual	0,458	0,103	1,58	1,29 – 1,93
ds_tipo_contratacao_adesao	0,430	0,101	1,54	1,26 – 1,87
cod_capitulo_cid_agr_capxviii	0,373	0,105	1,45	1,18 – 1,78
cod_capitulo_cid_agr_capxiv	0,532	0,162	1,70	1,24 – 2,34
cod_capitulo_cid_agr_capxxi	0,481	0,218	1,62	1,06 – 2,48
cod_capitulo_cid_agr_capxx	1,014	0,357	2,76	1,37 – 5,55

Fonte: Dados originais da pesquisa

Nota: ⁽¹⁾ Modelo glmmTMB

⁽²⁾ Método de seleção simples, mantendo no modelo somente as variáveis cujo valor-p < 0,05

⁽³⁾ IC – intervalo de confiança de 95%

De acordo com os resultados apresentados na Tabela 7, todas as variáveis/categorias do modelo contribuem para aumentar a probabilidade de reclamação. Isso ocorre porque todos os coeficientes são positivos (exceto o intercepto). No entanto, o modelo ainda pode ser melhorado, pois a área abaixo da curva ROC (AUC) é de 0,6709 e o coeficiente de Gini é de 0,3418.




Figura 2: Gráfico curva ROC, Receiver Operating Characteristic Curve, para o modelo de regressão logística apresentado na Tabela 7
Fonte: Dados originais da pesquisa

Os resultados obtidos indicam que o modelo não é capaz de distinguir com precisão entre atendimentos que geraram ou não reclamação. Isso é evidenciado pelo valor de AUC próximo de 0,5, o que indica que o modelo é tão bom quanto um modelo aleatório. Além disso, o valor de Gini é inferior a 0,5, o que indica que o modelo não está classificando corretamente todas as observações.

Para melhorar o desempenho do modelo, foram feitas duas abordagens:

- A primeira abordagem foi incluir outras variáveis explicativas no modelo, com o intuito de ajudar o modelo a distinguir melhor entre atendimentos que geraram ou não reclamação.
- A segunda abordagem foi incluir o fator com inflação de zeros no modelo de regressão logística, visando melhorar a acurácia do modelo para atendimentos que geraram reclamação.

Inclusão de outras variáveis explicativas no modelo

O banco de dados utilizado neste trabalho contém outras variáveis de atendimento e de cliente, que estão apresentadas nas tabelas a seguir.

Em relação às variáveis de atendimento, a análise dos resultados de classificação de risco mostrou

que os atendimentos classificados como Verde não têm taxas de reclamações estatisticamente diferentes de outros atendimentos considerados de menor gravidade (Azul e Branco), com um nível de significância de 5%. Por outro lado, eles diferem significativamente dos atendimentos de maior gravidade (Amarelo e Vermelho). No entanto, como o evento de interesse é raro, é possível que as estimativas apresentadas estejam sendo afetadas pelo baixo número de reclamações em algumas categorias. Para tentar minimizar esse efeito, pareceu razoável agrupar as classificações em: Atendimentos menos urgentes: Não classificado, Branco, Azul e Verde; Atendimentos mais urgentes: Amarelo, Laranja e Vermelho. É importante destacar que, em essência, a classificação de risco é uma variável ordinal, em que os atendimentos azuis representam situações não urgentes, enquanto os vermelhos representam situações emergentes que requerem atendimento imediato. Os atendimentos Brancos e Não classificados, por uma característica no negócio, podem ser

considerados também atendimentos menos urgentes.

Em relação as demais variáveis de atendimento, de maneira individual, as categorias que apresentam maiores taxas de reclamação os atendimentos realizados: aos finais de semana; tipo de produto I e II; atendimentos realizados em Abr e Nov; atendimentos realizados nas unidades de pronto atendimento; no turno de 19:00 a 06:59; retorno em 48 horas; com utilização de Unidade de Decisão Clínica (UDC); com prescrição de medicação, exames de imagem ou laboratório; atendimentos com evasão do cliente; atendimentos em especialidades pediátricas.

Analisando os resultados para as variáveis de cliente, também de maneira individual, as categorias que apresentaram maiores taxas foram: Tipo de plano I e II; Sexo feminino; Faixa etária de 00 a 09 anos de idade; cujo histórico de utilização mais prevalente foi de serviços de urgência ou consulta eletiva; tipo de contratação coletivo por adesão ou individual; com asma como condição de saúde e com experiência de utilização de serviço de urgência on-line.

Os atendimentos que geraram reclamação, possuem ainda: menor média de atendimentos realizados nas 24 horas anteriores pelo médico; maior média de atendimentos classificados pelo enfermeiro nas 24 horas anteriores; clientes com maior score de reclamação; maior tempo de duração da consulta (tempo início fim médico).

Na tabela 8 são apresentadas as Frequências absolutas de atendimentos, reclamações e taxa de reclamação por variável preditora categórica de atendimento de urgência em unidades de uma operação de plano de saúde, de janeiro de 2022 a julho de 2023

Tabela 8: Frequências absolutas de atendimentos, reclamações e taxa de reclamação por variável preditora categórica

(continua)

Variável / categoria	numero de atendimentos	numero de reclamacoes	taxa de reclamacoes por 1.000	p-valor (1)
Cor classificação risco				
Verde	383.989	512	1,33	-
Não classificado	150.033	74	0,49	<0,001
Amarelo	54.596	93	1,70	0,030
Branco	6.849	14	2,04	0,115
Azul	3.591	6	1,67	0,582
Laranja	1.803	1	0,55	0,381
Vermelho	110	1	9,09	0,055
Dia da semana atendimento				
Seg	109.373	117	1,07	-
Ter	95.168	106	1,11	0,763
Qua	91.870	80	0,87	0,156
Qui	91.033	96	1,05	0,917
Sex	82.843	87	1,05	0,896
Sáb	68.833	106	1,54	0,007
Dom	61.851	109	1,76	<0,001
Ano atendimento				
2022	363.192	446	1,23	-
2023	237.779	255	1,07	0,084
Mês atendimento				
Jun	72.759	78	1,07	-
Mai	72.705	68	0,94	0,411
Jul	66.355	77	1,16	0,622
Jan	65.135	62	0,95	0,485
Abr	61.191	90	1,47	0,041
Mar	60.597	79	1,30	0,220
Fev	49.250	47	0,95	0,529
Nov	34.852	58	1,66	0,011
Dez	31.335	33	1,05	0,932
Out	30.757	40	1,30	0,320
Set	28.173	35	1,24	0,468
Ago	27.862	34	1,22	0,528
Tipo de unidade				
Unidade pronto atendimento i	286.102	410	1,43	-
Unidade pronto atendimento ii	171.208	221	1,29	0,21
Unidade ambulatorial	143.661	70	0,49	<0,001

Tabela 8: Frequências absolutas de atendimentos, reclamações e taxa de reclamação por variável preditora categórica

(conclusão)

Variável / categoria	numero de atendimentos	numero de reclamações	taxa de reclamações por 1.000	p-valor (1)
Turno atendimento				
07:00 a 18:59	478.169	491	1,03	-
19:00 a 06:59	122.802	210	1,71	<0,001
Atendimento de retorno em até 48 horas				
Não	585.275	634	1,08	-
Sim	15.696	67	4,27	<0,001
Atendimento com utilização de unidade de decisão clínica				
Não	597.665	694	1,16	-
Sim	3.306	7	2,12	0,114
Atendimento com prescrição de medicação				
Não	404.657	412	1,02	-
Sim	196.314	289	1,47	<0,001
Atendimento com prescrição de exame laboratorial				
Não	516.583	546	1,06	-
Sim	84.388	155	1,84	<0,001
Atendimento com prescrição de exame de imagem				
Não	437.170	485	1,11	-
Sim	163.801	216	1,32	0,035
Atendimento com alta por evasão				
Não	599.546	689	1,15	-
Sim	1.425	12	8,42	<0,001
Atendimento pediátrico				
Não	516.202	547	1,06	-
Sim	84.769	154	1,82	<0,001

Fonte: Dados originais da pesquisa

Nota: (1) p-valor para o teste qui-quadrado que avalia na hipótese nula se o respectivo coeficiente do modelo regressão logística univariado é igual a zero

Na tabela 9 a seguir são apresentadas as estatísticas descritivas das variáveis contínuas relacionadas dos atendimentos em uma unidade de atendimento de urgência privada, de janeiro 2022 a julho de 2023.

Tabela 9: Estatísticas descritivas das variáveis contínuas.

Variável	Reclamação		p-valor ⁽²⁾
	Não	Sim	
	Média (desvio padrão)		
atend_med_24h	17,9 (15,0)	16,5 (14,2)	0,010
atend_enf_24h	34,2 (31,9)	42,2 (32,5)	<0,001
atendimentos_vistos	2,9 (8,40)	3,1 (8,47)	0,637
score_reclamacao (x1000)	0,06 (2,39)	8,97 (43,0)	<0,001
tempo_inicio_fim_medico_min (1)	50,1 (65,3)	74,2 (84,3)	<0,001

Fonte: Dados originais da pesquisa Nota:

⁽¹⁾Tempo expresso em minutos

⁽²⁾ p-valor para o teste qui-quadrado que avalia na hipótese nula se o respectivo coeficiente do modelo regressão logística univariado é igual a zero

As frequências absolutas de atendimentos, reclamações e taxa de reclamação por variável preditora categórica de cliente em atendimentos de urgência em unidades de uma operação de plano de saúde, de janeiro de 2022 a julho de 2023.

Tabela 10: Frequências absolutas de atendimentos, reclamações e taxa de reclamação por variável preditora categórica de cliente.

(continua)

	numero de atendimentos	numero de reclamacoes	taxa de reclamacoes por 1.000	p-valor (1)
Total				
	600.971	701	1,17	-
Tipo de produto				
Tipo plano iii	280.909	267	0,95	-
Tipo plano ii	235.625	343	1,46	<0,001
Tipo plano i	39.395	54	1,37	0,014
Saude familia	27.577	24	0,87	0,679
Outros	17.465	13	0,74	0,389
Sexo				
Feminino	340.377	446	1,31	-
Masculino	260.594	255	0,98	<0,001

Tabela 10: Frequências absolutas de atendimentos, reclamações e taxa de reclamação por variável preditora categórica de cliente.

(conclusão)

	numero de atendimentos	numero de reclamacoes	taxa de reclamacoes por 1.000	p-valor (1)
Faixa etária				
20 a 29 anos	114.919	113	0,98	-
30 a 39 anos	113.617	137	1,21	0,108
40 a 49 anos	108.042	124	1,15	0,234
00 a 09 anos	82.166	143	1,74	<0,001
50 a 59 anos	64.426	62	0,96	0,892
10 a 19 anos	52.540	67	1,28	0,092
60 a 69 anos	34.142	29	0,85	0,482
70 a 79 anos	19.584	11	0,56	0,076
80 a 89 anos	9.531	12	1,26	0,415
90 a 99 anos	1.943	3	1,54	0,440
100 anos ou mais	61	0	0,00	0,999
Tipo de utilização prevalente				
Sem historico	594.179	11	0,02	-
Urgencia	4.166	376	90,25	<0,001
Eletiva	2.626	314	119,57	<0,001
Tipo de contratação				
Coletivo empresa	436.594	454	1,04	-
Coletivo adesao	87.304	127	1,45	<0,001
Individual	77.073	120	1,56	<0,001
Condição de saúde: asma				
Não	579.996	663	1,14	-
Sim	20.975	38	1,81	0,006
Cliente com experiência em atendimento on-line				
Não	600.500	665	1,11	-
Sim	471	36	76,43	<0,001

Fonte: Dados originais da pesquisa

Nota: ⁽¹⁾ p-valor para o teste qui-quadrado que avalia na hipótese nula se o respectivo coeficiente do modelo regressão logística univariado é igual a zero

Para tentar melhorar a predição do modelo, utilizamos uma abordagem hierárquica.

- No step 0, modelo inicial apresentado na Tabela 7
- No step 1, adicionamos a variável que apresentou o maior incremento na proporção de verdadeiros positivos do modelo do step anterior, desde que essa variável apresente um p-valor menor ou igual a 0,10 em ambas as análises (univariada e multivariada)
- Os steps subsequentes (2, 3, 4, 5 e 6) seguiu o mesmo procedimento, adicionando a variável que apresenta o maior incremento na proporção de verdadeiros positivos do modelo do step anterior.

De acordo com esses critérios, a categoria ds_util_prev_urgencia foi incluída primeiro no modelo, a variável ind_alta_evasao foi a última. Os resultados são apresentados na Tabela 11 abaixo. Houve um incremento de aproximadamente 0,14 na proporção de verdadeiros positivos ao final do processo.

Tabela 11: Procedimento para seleção de variáveis

Step	Modelo: ind_reclamacao ~	Proporção de verdadeiros positivos ⁽¹⁾
0	tempo_porta_medico_min + ds_tipo_contratacao_individual + ds_tipo_contratacao_adesao + cod_capitulo_cid_agr_capxviii + cod_capitulo_cid_agr_capxiv + cod_capitulo_cid_agr_capxxi + cod_capitulo_cid_agr_capxx	0,002
1	+ds_util_prev_urgencia	0,003
2	+ds_util_prev_eletiva	0,124
	+tempo_inicio_fim_medico_min	0,130
3	+ind_asma	0,134
4	+ind_retorno_48hs	0,136
5	+ds_mes_mai	0,140
6	+ind_alta_evasao	0,142

Fonte: Dados originais da pesquisa

Nota: ⁽¹⁾ Proporção de verdadeiros positivos calculados com sensibilidade mínima de 0,8.

Após procedimento para inclusão de variáveis que potencializam a assertividade do modelo, fizemos novo procedimento de seleção de variáveis, desta vez para mantermos no modelo somente aquelas que apresentaram p-valor significativo a 5% de significância. Foram excluídas, respectivamente as variáveis/categorias cod_capitulo_cid_agr_capxviii, ds_tipo_contratacao_adesao, cod_capitulo_cid_agr_capxiv, cod_capitulo_cid_agr_capxxi.

Após selecionar as variáveis que melhor classificam os atendimentos que geraram reclamação (tabela 12), adicionamos um componente para tratar a inflação de zeros. Esse componente é um novo modelo binomial que modela a probabilidade de um atendimento não gerar reclamação.

Tabela 12: Resultado do modelo binomial⁽¹⁾, após procedimento de seleção de variáveis⁽²⁾

Preditores	ind reclamação			
	Coefficientes	Erro padrão	Razão das chances	IC(3)
(Intercepto)	-11,730	0,310	0,00	0,00 – 0,00
tempo_porta_medico_min	0,012	0,001	1,01	1,01 – 1,01
ds_tipo_contratacao_individual	-0,302	0,109	0,74	0,60 – 0,92
cod_capitulo_cid_agr_capxx	1,017	0,415	2,76	1,22 – 6,24

ds_util_prev_urgencia	8,571	0,307	5274,46	2890,03 – 9626,17
ds_util_prev_eletiva	8,918	0,308	7468,74	4082,92 – 13662,31
tempo_inicio_fim_medico_min	0,003	0,001	1,00	1,00 – 1,00
ind_asma	-0,738	0,177	0,48	0,34 – 0,68
ind_retorno_48hs	0,943	0,149	2,57	1,92 – 3,43
ds_mes_mai	-0,335	0,138	0,72	0,55 – 0,94
ind_alta_evasao	1,291	0,363	3,64	1,78 – 7,41

Fonte: Dados originais da pesquisa Nota: ⁽¹⁾

Modelo glmmTMB

⁽²⁾ Método de seleção simples, mantendo no modelo somente as variáveis cujo valor-p < 0,05

⁽³⁾ IC – intervalo de confiança de 95%

Para selecionar as variáveis para esse componente, usamos um critério experimental: testamos a inclusão de cada variável, uma a uma, mesmo aquelas que não foram selecionadas no modelo condicional (apresentado na Tabela 7). No final, selecionamos a variável para o modelo de inflação de zeros: *score_reclamação*. Essa alteração afetou a estrutura do modelo condicional, as variáveis *ds_util_prev_urgencia* e *ds_util_prev_eletiva* passaram a não mais serem significativas a 5%. O modelo resultante é apresentado na tabela 13.

Tabela 13: Resultado do modelo binomial⁽¹⁾, após procedimento de seleção de variáveis⁽²⁾

ind reclamação				
Preditores	Coefficientes	Erro padrão	Razão das chances	IC ⁽³⁾
Modelo condicional				
(Intercepto)	-2,762	0,099	0,06	0,05 – 0,08
tempo_porta_medico_min	0,013	0,001	1,01	1,01 – 1,01
ds_tipo_contratacao_individual	-0,249	0,115	0,78	0,62 – 0,98
cod_capitulo_cid_agr_capxx	0,968	0,449	2,63	1,09 – 6,34
tempo_inicio_fim_medico_min	0,003	0,001	1,00	1,00 – 1,00
ind_asma	-0,775	0,182	0,46	0,32 – 0,66
ind_retorno_48hs	0,935	0,159	2,55	1,86 – 3,48
ds_mes_mai	-0,329	0,144	0,72	0,54 – 0,95
ind_alta_evasao	1,367	0,413	3,92	1,75 – 8,81
Modelo para inflação de zeros				

(Intercept)	8,898	0,321	7318,60	3904,70 – 13717,29
score_reclamacao	-3548,753	137,436	0,00	0,00 – 0,00

Hosmer and Lemeshow goodness of fit: X-squared = 1.9899, df = 8, p-value = 0.9813 Fonte: Dados originais da pesquisa

Nota: ⁽¹⁾ Modelo glmmTMB

⁽²⁾ Método de seleção simples, mantendo no modelo somente as variáveis cujo valor-p < 0,05

⁽³⁾ IC – intervalo de confiança de 95%

Desta maneira, aplicando a equação para modelo de regressão logística binária com informação de zeros apresentado no item 1.5 da seção Material e Métodos, temos que:

Modelo para inflação de zeros

$$Z_i = 8,898 + 3548,753 \cdot score_reclamacao_i$$

Modelo condicional

$$C_i = -2,762 + 0,013 \cdot tempo_porta_medico_min_i - 0,249 \cdot ds_tipo_contratacao_individual_i + 0,986 \cdot cod_capitulo_cid_agr_capxx_i + 0,003 \cdot tempo_inicio_fim_medico_min_i - 0,775 \cdot ind_asma_i + 0,935 \cdot ind_retorno_48hs_i - 0,329 \cdot ds_mes_mai_i + 1,367 \cdot ind_alta_evasao_i$$

Supondo o seguinte cenário:

- tempo_porta_medico = 60 minutos
- tipo_contratacao = coletivo adesão
- cod_capitulo_cid_agr = XX
- tempo_inicio_fim_medico = 20 minutos
- ind_asma = Não
- ind_retorno_48hs = Sim
- ds_mes = Janeiro
- ind_alta_evasao = Sim
- score_reclamacao = 0,0

Tempos que:

$$p(Y_i = 1) = \left(\frac{1}{1 + e^{-[-2,762 + 0,013(60) - 0,249(0) + 0,986(1) + 0,003(20) - 0,775(0) + 0,935(1) - 0,329(0) + 1,367(1)]}} \right) \cdot \left(1 - \frac{1}{1 + e^{-[8,898 + 3548,753(0)]}} \right)$$

$$p(Y_i = 1) = \left(\frac{1}{1 + e^{-(1,366)}} \right) \cdot \left(1 - \frac{1}{1 + e^{-(8,898)}} \right)$$

$$p(Y_i = 1) = (0,20327) \cdot (0,99986) = 0,20324$$

$$p(Y_i = 1) = 0,20324$$

Desta maneira a probabilidade de um atendimento com as características acima gerar reclamação é de 0,20324.

Em relação a aderência do modelo, o método proposto por *Hosmer and Lemeshow* foi utilizado para avaliar o modelo de regressão logística. Um valor de p-valor próximo de 1 indica que o modelo se ajusta bem aos dados. No caso do modelo da tabela 13, o p-valor do teste foi de 0,9813, o que é um indicativo de bom ajuste.

Em relação ao desempenho do modelo, podemos observar através da área abaixo da curva ROC (0,9919) e coeficiente de Gini (0,9837) que o modelo possui desempenho bastante aceitável.

Além da medida de ajuste, o modelo também foi avaliado por outras medidas de desempenho. A Tabela 14 mostra que, para um cut-off de 0,25, o modelo apresentou acurácia de 0,9939 e uma sensibilidade de 0,1940. Isso significa que o modelo classificou corretamente 99,39% dos atendimentos, mas apenas 19,40% dos atendimentos que geraram reclamação foram identificados pelo modelo. Outra informação relevante é que 34,43% dos atendimentos que o modelo indicou que gerariam reclamação realmente geram reclamação (verdadeiros positivos). Mesmo que os testes de significância dos coeficientes e a área abaixo da curva ROC indiquem um bom ajuste, o modelo não apresenta um bom desempenho.

Como alternativa ao modelo de regressão logística binária, testamos outros modelos de *machine learning*, mas os indicadores de desempenho desses modelos não foram melhores. A área abaixo da curva ROC e o coeficiente de Gini indicaram um bom ajuste, mas outros resultados de desempenho, como a sensibilidade e os verdadeiros positivos, mostraram que todos os modelos são deficientes para alcançar de maneira satisfatória o objetivo proposto.

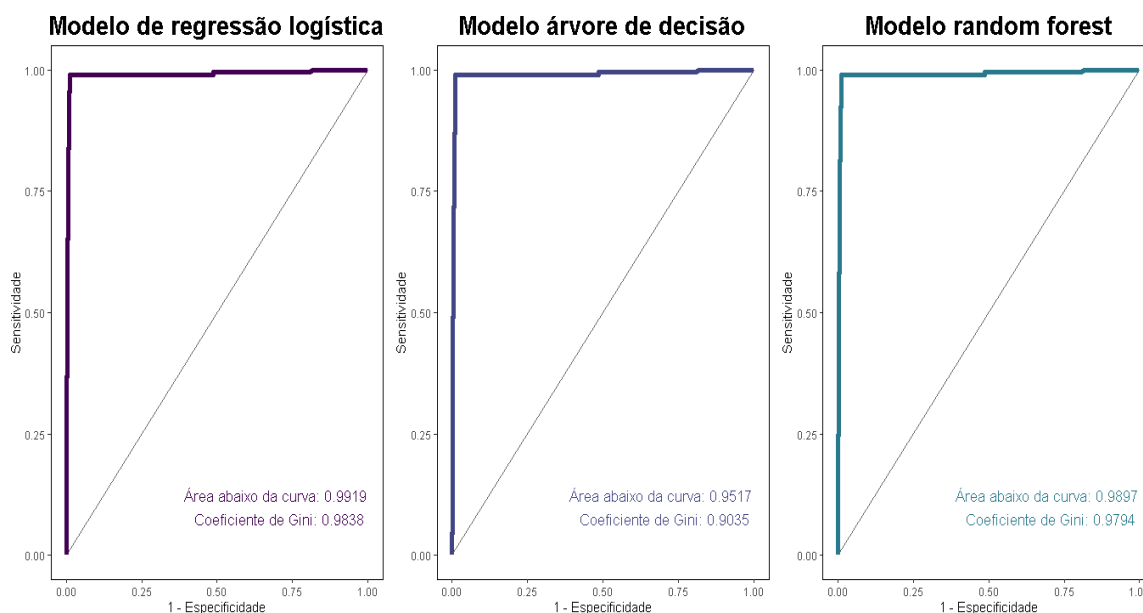


Figura 3: Comparativo das medidas de desempenho dos modelos de classificação regressão logística binária, árvore de decisão e random forest
Fonte: Dados originais da pesquisa

Na tabela a seguir são apresentadas o comparativo das medidas de desempenho dos modelos.

Tabela 14: Comparativo das medidas de desempenho dos modelos de classificação para *cutoff* de 0,25

Estatística	Modelo de regressão logística⁽¹⁾	Modelo árvore de decisão⁽²⁾	Modelo random forest⁽³⁾
Acurácia	0,9939	0,9986	0,9985
Acurácia balanceada	0,5968	0,5579	0,5982
Sensitividade	0,1940	0,1162	0,1970
Especificidade	0,9996	0,9996	0,9994
Verdadeiros positivos	0,3443	0,2300	0,2583
Verdadeiros negativos	0,9990	0,9990	0,9991

Fonte: Dados originais da pesquisa

Nota: ⁽¹⁾ Modelo binomial utilizando função *glmTMB*

⁽²⁾ Desempenho do modelo árvore de decisão com profundidade máxima igual a 30, utilizando as mesmas preditoras do modelo binomial e 30% da base para teste

⁽³⁾ Desempenho do modelo random forest com número de árvores igual a 30, utilizando as mesmas preditoras do modelo binomial e 30% da base para teste

CONSIDERAÇÕES FINAIS

Os serviços de urgência enfrentam a difícil tarefa de conciliar a alta demanda por atendimento, a complexidade dos casos, o tempo de espera prolongado e a necessidade de resolver os problemas de saúde de forma rápida e eficiente. Clientes que precisam utilizar serviços de urgência geralmente apresentam níveis de satisfação mais baixos do que aqueles que utilizam consultas eletivas, exames ou até mesmo internação. O fator mais comumente encontrado na literatura para explicar o baixo nível de satisfação desses clientes está relacionado ao tempo de espera para ser atendido.

A proposta deste trabalho foi, em serviços de urgência de uma operadora de plano de saúde da região sudeste, avaliar se um maior tempo de espera para atendimento aumenta as chances de registro de reclamação e, além disso, verificar se outras características do atendimento ou do indivíduo também têm contribuição.

O modelo de regressão logística binária com inflação de zeros foi utilizado para estimar as probabilidades de reclamação, pois a proporção de atendimentos que geraram reclamações é baixa. Esse modelo é adequado para modelar eventos raros pois leva em consideração a possibilidade de que um evento não ocorra.

No presente estudo observamos que de fato o tempo de espera é um fator importante, porém, não é o único. Outros fatores que aumentam a chance de reclamação são: o diagnóstico de doença ou condição de saúde que se enquadra no capítulo CID XX; o tempo de duração elevado da consulta médica; o retorno ao serviço em até 48 horas após atendimento de urgência anterior; e a desistência do

atendimento. Por outro lado, os seguintes fatores diminuem a chance de reclamação: contratação individual do plano de saúde; asma no histórico de condições de saúde do cliente; atendimento no mês de maio. Além disso, foi observado que o histórico de reclamação do cliente foi a principal causa de inflação de zeros no modelo. Quanto menor o *score de reclamação* do cliente, maiores as chances de reclamações ocorrerem zero vezes.

Embora o modelo tenha apresentado bons resultados para os testes de significância dos coeficientes de maneira individual e multivariada, o desempenho dele de maneira geral não foi bom, com resultados de sensibilidade e proporção de verdadeiros positivos abaixo de 20% e 35% respectivamente. A avaliação de desempenho do modelo por meio de análise da curva ROC não se mostrou eficaz, provavelmente por se tratar de modelagem de evento raro. O desbalanceamento dos dados aliado as baixas probabilidades estimadas para o evento de interesse fazem os valores de sensibilidade e especificidade não serem bons parâmetros para avaliar o desempenho do modelo.

Uma discussão válida e pouco explorada na literatura é a seguinte: as probabilidades estimadas através de modelos *machine learning* são intrinsecamente menores quando o evento em estudo é um evento raro? Se esta hipótese for verdadeira, poder-se-ia revisar também o limiar de probabilidade para distinguir evento e não evento (que tradicionalmente parte de 0,7).

Com este conjunto de variáveis, mesmo buscando alternativas como modelos baseados em árvores, não foi possível encontrar um com desempenho satisfatório. Possíveis soluções são: reduzir a dimensionalidade das variáveis de atendimento; utilizar outras abordagens, como modelos baseados em boosting, bagging ou redes neurais; ou ainda enriquecer o banco de dados com variáveis que possam captar os hábitos do cliente ou variáveis de contexto/multinível.

Referências

- Agência Nacional de Saúde Suplementar. (2023). Caderno de Informação da Saúde Suplementar. http://www.ans.gov.br/anstabnet/cgi-bin/tabnet?dados/tabnet_rec.def
- Brasil. (2000). Lei nº 9.961, de 28 de janeiro de 2000. Cria a Agência Nacional de Saúde Suplementar – ANS e dá outras providências. Diário Oficial da União, 29 jan. 2000, p. 5.
- Carvalho, R. M. N., Porto, A. J. M., & Ramalho, B. A. (2018). Papel institucional dos canais de reclamação para a resolução extrajudicial de conflitos sobre planos de saúde: Uma análise comparada. *Revista Brasileira de Políticas Públicas*, 8(3), 369–393.
- Fávero, L. P. L., & Belfiore, P. P. (2017). Manual de análise de dados: Estatística e modelagem multivariada com Excel, SPSS e Stata (p. 611–632). Elsevier.
- Fernandes, R. V. C., Rule, C., Ono, T. T., & Cardoso, G. E. B. (2018). The expansion of online dispute resolution in Brazil. *International Journal for Court Administration*, 9(2), 20–34. <https://doi.org/10.18352/ijca.255>

Hosmer, D. W., & Lemeshow, S. (2000). *Applied logistic regression* (2nd ed.). Wiley.

Instituto Brasileiro de Geografia e Estatística. (2021). Pesquisa Nacional por Amostra de Domicílios Contínua. <https://www.ibge.gov.br/estatisticas/sociais/populacao/17270-pnad-continua.html?edicao=34949&t=resultados>

Medicina S/A. (2022). Hospitais melhoram a avaliação por parte dos consumidores. <https://medicinasa.com.br/hospitais-avaliacao>

Peixoto, L. H. R. (s.d.). *Aprendizado de máquina aplicado no atendimento de reclamações de clientes* [Dissertação de mestrado, Universidade de São Paulo]. Instituto de Ciências Matemáticas e de Computação – ICMC.

Pinheiro, E. G., & Castells, M. (1999). *A sociedade em rede* (Vol. 1). Paz e Terra.

Rodrigues Filho, L. C. (2017). *Experiência e relacionamento organização/consumidor em mídias sociais: O que o modelo estratégico de social CRM pretende entregar e o que o usuário afirma receber no atendimento das marcas* [Trabalho não publicado].

Sabry, A. A. F., Abdel Salam, W. N., Abdel Salam, M. M., Moustafa, K. S., Gaber, E. M., & Beshey, B. N. (2023). Impact of implementing five-level triage system on patients outcomes and resource utilization in the emergency department of Alexandria main university hospital. *Egyptian Journal of Anaesthesia*, 39(1), 546–556. <https://doi.org/10.1080/11101849.2023.2234712>

Sharma, M., & Chaubey, D. S. (n.d.). An empirical study of customer experience and its relationship with customer satisfaction towards the services of banking sector. *Journal of Marketing & Communication*, 9, 18–27.

Silva, A. D. C., Chianca, T. C. M., Pádua, D. R., Guimarães, G. L., Manzo, B. F., & Correa, A. R. (2019). Caracterização dos atendimentos de um pronto-socorro público segundo o Sistema de Triage de Manchester. *REME – Revista Mineira de Enfermagem*, 23, e-1178.

Silva, A. D. C., Chianca, T. C. M., Pádua, D. R., de Lima Guimarães, G., Manzo, B. F., & dos Reis Correa, A. (2019). Caracterização dos atendimentos de um pronto-socorro público segundo o Sistema de Triage de Manchester. *REME – Revista Mineira de Enfermagem*, 23(1). <https://doi.org/10.5935/1415-2762.20190026>