

AS VANTAGENS DE USAR O ML PARA ANALISAR DADOS DE NPS: UM OLHAR PARA A IMPORTÂNCIA DOS RESPONDENTES NEUTROS

Elaine Tolentino Alves - Universidade Estácio de Sá

Sandra Regina Freitas Da Silva Morgado De Gois - Universidade Estácio de Sá

Resumo

A pesquisa de satisfação é uma ferramenta amplamente utilizada pelas empresas como um importante indicador de desempenho a partir do ponto de vista do consumidor. Essas medidas apresentam-se através das reações dos clientes de três formas: satisfação, insatisfação e neutralidade. Conhecer quais os atributos que impactam a recomendação de neutralidade do nível de satisfação do cliente sobre determinado produto ou serviço fornecem informações relevantes para que essas empresas possam promovê-los a promotores de suas marcas, contribuindo para aumentar suas vantagens competitivas. Este artigo tem o objetivo de avaliar a possibilidade de predição do grau de satisfação do cliente de nível de serviço de uma empresa de transporte vertical que utiliza a metodologia do NPS como ferramenta de pesquisa, a partir de uma base de dados de avaliação da satisfação de clientes. Neste estudo são apresentados alguns resultados obtidos através de experimentos realizados com modelos quantitativos de Machine Learning (aprendizado de máquina) utilizando algoritmos como árvore de decisão, KNN, Floresta Aleatória e da regressão logística multinomial, para a análise dos indicadores que exercem uma maior influência na neutralidade do consumidor.

Palavras-chave:Satisfação de Cliente; NPS (Net Promoter Score); Machine learning

Abstract

The satisfaction survey is a tool widely used by companies as an important performance indicator from the consumer's point of view. These measures are presented through customer reactions in three ways: satisfaction, detractor, and passive. Knowing which attributes impact the recommendation of passivity of the level of customer satisfaction about a particular product or service provides relevant information so that these companies can promote them to promoters of their brands, contributing to increase their competitive advantages. This article aims to assess the possibility of predicting customer satisfaction through indicators of the level of logistical service of a company that uses the NPS methodology as a research tool from a database of customer satisfaction assessments. This study presents results from experiments carried out with quantitative Machine Learning models, using algorithms such Decision TreeClassifier, KNN, Random Forest and Multinomial Logistic Regression, for the analysis of the indicators that exert a greater influence on consumer neutrality.

Keywords: Customer Experience; NPS (Net Promoter Score); Machine learning

AS VANTAGENS DE USAR O ML PARA ANALISAR DADOS DE NPS:
A importância dos respondentes neutros

RESUMO:

A pesquisa de satisfação é uma ferramenta amplamente utilizada pelas empresas como um importante indicador de desempenho a partir do ponto de vista do consumidor. Essas medidas apresentam-se através das reações dos clientes de três formas: satisfação, insatisfação e neutralidade. Conhecer quais os atributos que impactam a recomendação de neutralidade do nível de satisfação do cliente sobre determinado produto ou serviço fornecem informações relevantes para que essas empresas possam promovê-los a promotores de suas marcas, contribuindo para aumentar suas vantagens competitivas. Este artigo tem o objetivo de avaliar a possibilidade de predição do grau de satisfação do cliente de nível de serviço de uma empresa de transporte vertical que utiliza a metodologia do NPS como ferramenta de pesquisa, a partir de uma base de dados de avaliação da satisfação de clientes. Neste estudo são apresentados alguns resultados obtidos através de experimentos realizados com modelos quantitativos de *Machine Learning* (aprendizado de máquina) utilizando algoritmos como árvore de decisão, KNN, Floresta Aleatória e da regressão logística multinomial, para a análise dos indicadores que exercem uma maior influência na neutralidade do consumidor.

Palavras-chave: Satisfação de Cliente; NPS (*Net Promoter Score*); *Machine learning*

ABSTRACT:

The satisfaction survey is a tool widely used by companies as an important performance indicator from the consumer's point of view. These measures are presented through customer reactions in three ways: satisfaction, detractor, and passive. Knowing which attributes impact the recommendation of passivity of the level of customer satisfaction about a particular product or service provides relevant information so that these companies can promote them to promoters of their brands, contributing to increase their competitive advantages. This article aims to assess the possibility of predicting customer satisfaction through indicators of the level of logistical service of a company that uses the NPS methodology as a research tool from a database of customer satisfaction assessments. This study presents results from experiments carried out with quantitative Machine Learning models, using algorithms such as Decision Tree Classifier, KNN, Random Forest and Multinomial Logistic Regression, for the analysis of the indicators that exert a greater influence on consumer neutrality.

Keywords: Customer Experience; NPS (*Net Promoter Score*); *Machine learning*

INTRODUÇÃO

O *Net promoter® Score* teve origem em um estudo realizado pelo pesquisador de negócios Frederick F. Reichheld, em seu artigo publicado na *Harvard Business Review* há 21 anos em dezembro de 2003, intitulado: “*The One Number You to Grow*” (Um número que você precisa para crescer), e posteriormente ao lado da *Bain & Company*, uma empresa americana de consultoria de gestão lançaram um livro em 2006 intitulado “*The Ultimate Question*” que explica a metodologia e aplicabilidade para a medição da lealdade dos clientes.

No NPS para a medição de lealdade a empresa pode usar um formulário simples para sua implementação, onde o cliente responde uma única pergunta que permite mensurar o sentimento deste consumidor em relação a empresa. É uma avaliação simples, que não gera nenhum desgaste para o cliente e é realizada em poucos minutos. Segundo as respostas dadas, são divididas em três grupos distintos: promotores, detratores e neutros. Para o cálculo do NPS, desconsidera as avaliações passivas (neutras). Se uma nota é baixa, significa que a empresa tem muitos clientes detratores ou passivos, indicando que há algo errado com o seu planejamento/ execução. (REICHHELD, 2003).

Desde a publicação do estudo, o NPS se espalhou rapidamente pelo mundo. Tornou-se a estrutura de sucesso do cliente predominante - usada hoje por dois terços das empresas mundiais conforme *Fortune 1000* (revista americana de negócios) onde as 1000 maiores empresas são classificadas por suas riquezas conforme publicação da *Harvard Business Review* (2023).

Importante destacar a importância de análise do NPS é um método aceito por grandes empresas pela sua capacidade de feedback rápido, tem uma aplicação simples e pode ser uma maneira de melhorar o gerenciamento de uma organização. Primordialmente é um indicador de fidelização e não de qualidade, onde tudo gira em torno do cliente indicar ou não a empresa.

O objetivo do artigo é explorar as vantagens de usar a IA (inteligência artificial) para analisar dados de NPS, focando nos respondentes neutros.

FUNDAMENTAÇÃO TEÓRICA

- Inteligência artificial

A revolução digital é uma inevitabilidade. Ela faz com que as empresas se preparem ainda mais para as mudanças, se capacitem e tragam inovação para a organização. Muitas vezes, há uma grande diferença entre a era da internet durante a década de 1990 e a era digital atual.

Como exemplo desta revolução digital temos a penetração mais ampla da internet e dos dispositivos móveis, principalmente dos smartphones, tornam as inovações mais intensas a partir dos anos 2000, o que pode ser o ponto de partida para a revolução digital. Dessa forma, o digital vem remodelando drasticamente os hábitos e preferências dos consumidores, cujas vidas estão cada vez mais envolvidas com a inovação digital, levando a um profundo impacto no setor de prestação de serviços (GANGULI et al., 2011).

Toda esta informação gera grande quantidade de dados e através da ML (*machine Learning*) é possível ganhar tempo de análise, diminuição do erro humano e precisão. (BORGES et al. (2021). Existe uma mina de ouro em bons dados onde os profissionais de marketing e gerentes de experiência do cliente souberem onde procurar e como analisá-los, usando as ferramentas de IA, que permite as empresas repensar seu programa de medição da satisfação dos clientes para diagnosticar os fatores subjacentes que causam problemas para os clientes e então priorizar as causas que necessitam de atenção. (ZAKY et al, 2019)

No ML a modelagem algorítmica preditiva é considerada uma evolução da adaptação estatística e como seu antecessor, tem como objetivo a extração de informação de um banco de

dados através de um modelo probabilístico. O aprendizado de máquina, um subcampo da inteligência artificial que utiliza algoritmos de computação que buscam reconhecer padrões para executar uma tarefa a partir de dados conhecidos ou dados de treinamento com um objetivo específico de evidenciar os fatores registrados. (BALDI e BRUNAK, 2001).

Há dois métodos de ML (*Machine Learning*): supervisionado e o não supervisionado que têm a sua principal diferença na rotulação prévia dos dados. Uma base supervisionada tem maior adaptabilidade e maior controle sobre o desenvolvimento do modelo e pode ser segmentada como regressão ou classificação, e neste estudo foi utilizada uma base supervisionada. Segundo Michalski et al (1984) a escolha do algoritmo mais apropriado vai depender do formato das variáveis de entrada chamadas independentes (discretas/ contínuas), formato das saídas do modelo (variáveis dependentes) e fatores ligados a falhas na base dados.

Este algoritmo mais apropriado utiliza um classificador que para Lorenzetti e Teloken (2016) definem como uma receita para executarmos uma tarefa e resolvermos algum problema, capaz de generalizar as informações aprendidas durante o treinamento, com a finalidade de posteriormente classificar nesta base de dados entre os 28 atributos estabelecidos pela variável independente melhorar – previamente conhecidas no conjunto de treinamento – objetos cujas classes sejam desconhecidas.

Algoritmos de classificação associam padrões de entrada a classes na saída, visando indicar o grupo de pertinência mais provável para uma entrada a partir de seus atributos. Esse método permite a identificação dos atributos que impactam para os respondentes neutros. Esse mapeamento entre entradas e saídas é aprendido durante o treinamento (KOTSIOANTIS et al., 2006).

- Pesquisa de NPS

A metodologia do estudo do NPS é determinar o nível da relação existente entre empresas e clientes. Consiste numa abordagem simples para a pesquisa do cliente, diretamente ligados aos resultados de uma empresa e se baseia em fazer uma única pergunta: “Qual a probabilidade de recomendar a nossa empresa/ produtos ou serviço a um colega?” Na escala de zero a dez. Posteriormente, os clientes são agrupados em 3(três) grupos: promotores, neutros e detratores, conforme ilustra a figura 2 abaixo. Cada grupo está ligado ao comportamento esperado do cliente.

Os clientes que classificaram 9 e 10 são considerados como promotores (positivamente satisfeitos) – repetem as compras, recomendam as marcas e mesmo assediados permanecem na carteira.

Os clientes que classificaram como 7-8 são denominados como neutros – nada representam para eles este modelo de medição.

Os clientes que classificaram como 6-0 são denominados detratores – têm opinião negativa da marca mudam para a concorrência.

É provável que os promotores permaneçam com a empresa em caso de assédio de concorrentes e são mais propensos a repetirem as compras. Podem, ainda, ter impactos positivos em outros clientes potenciais. Por outro lado, os detratores têm um impacto negativo sobre as expectativas de desempenho empresarial, podendo mudar para a concorrência e criar opiniões negativas.

Figura 1: Escala de pontos relativa à satisfação NPS



Fonte: Reichheld, 2003

Conforme ilustração acima (figura 1), o NPS é calculado subtraindo a porcentagem de clientes detratores da porcentagem de clientes promotores, em seguida, esse número é dividido pelo número total de respondedores. Os clientes neutros contam para o número total de entrevistados, embora não contribuam diretamente no resultado do NPS.

Por exemplo: se 75% de seus clientes são promotores, 15% são neutros e 10% são detratores, seu *Net Promoter Score* será de 65%. Os 15% neutros não são considerados no cálculo.

$$75\% \text{ promotor} - 10\% \text{ detratores} = \text{NPS } 65\%$$

METODOLOGIA

Este trabalho foi realizado com dados coletados de uma empresa fundada em 1961 pertencente a um grupo industrial diversificado que fornece produtos e serviços do ramo de transporte vertical. Estes dados correspondem ao período entre outubro do ano de 2019 a setembro de 2021, totalizando 5640 registros de clientes localizados na América Norte e América do Sul. Contudo, cabe destacar que não foi realizada uma análise temporal e sim acumulativa do total de registros.

Contudo, foram excluídos da base os registros que tinham informações faltantes em algum dos campos, onde a base ficou composta por 5484 registros. As variáveis de estudo estão descritas abaixo e foram transformadas para serem analisadas pelos algoritmos propostos.

Figura 2 – Campos da Base

\$ Operatingunit	<fct>	Latin America, Brazil, Latin America, Brazil, Brazil, Brazil, Latin America, Brazil, Brazil, Braz~
\$ Region	<fct>	LSouth, BSoutheast, LSouth, BSoutheast, BSoutheast, BMidwest, LSouth, BSouth, BSoutheast, BSouthe~
\$ Branch	<fct>	PERU, SAO PAULO, PERU, GUARULHOS, BELO HORIZONTE, GOIANIA, CHILE, CAXIAS DO SUL, BELO HORIZONTE, ~
\$ NPS1	<fct>	Promoter, Passive, Detractor, Detractor, Promoter, Promoter, Detractor, Promoter, Passive, Passiv~
\$ MELHORIA	<fct>	COM, COM, PQ, ADM, SERV, SERV, SERV, SERV, COM, PQ, COM, COM, NO, SERV, SERV, ADM, SERV, ADM, SER~
\$ MELHORAR	<fct>	COMCALL, CONGER, PQCONF, ADMTRANSP, SERVCORR, SERVPREV, SERVPRAZO, SERVTIME, CONSUP, PQCONF, COM~
\$ SEXO	<fct>	F, M, M, M, M, F, M, M, M, M, M, F, M, M, M, M, F, M, M, F, M, M, F, F, F, M, M, F, M, M, M~
\$ Fiscal	<int>	2019, 2020, 2019, 2020, 2019, 2020, 2019, 2019, 2021, 2019, 2021, 2019, 2019, 2021, 2020, 2020, 2~
\$ Istelephone	<fct>	No, N~

Fonte Próprio Autor

Destaque para as três variáveis: o campo NPS1 indica o grupo de respondentes da pesquisa de satisfação: detrator, promotor e o neutro; o campo melhoria indica o agrupamento das respostas sob o olhar da empresa: administração, qualidade do produto, comercial e serviço;

o campo melhorar indica a justificação da resposta para a nota dada (campo criado mediante a inclusão da segunda pergunta ao questionário. Abaixo destaca-se o quadro elucidando as variáveis melhoria e melhorar.

Figura 3 – Distribuição das Categorias e subcategorias (Melhoria e Melhorar)

DESCRIÇÃO DOS ATRIBUTOS	DIMENSÃO	ATRIBUTO
ADM	ADM	
Contas a receber	ADM	ADMBOL
Precisão e facilidade de compreensão do faturamento	ADM	ADMFAT
Clareza de cobranças extras quando aplicável	ADM	ADMTRANSP
Termo do contrato	ADM	ADMPRECO
Facilidade de processo de inspeção	ADM	ADMPROC
Nenhuma melhoria necessária	ADM	ADMNA
Viabilidade do trabalho real realizado	ADM	ADMPERF
COM	COM	
Facilidade de alcançar o contato certo	COM	COMCONT
Desempenho - Gerente de contas/vendas	COM	COMVEND
Desempenho - Gerente de filial	COM	COMGER
Desempenho - Call Center	COM	COMCALL
Desempenho - Supervisor de Operações	COM	COMSUP
Desempenho - Técnico	COM	COMTEC
ND	ND	
Nenhuma melhoria necessária	ND	NA
PQ	PQ	
Qualidade estética	PQ	PQBELO
Tempo de espera do elevador	PQ	PQPARA
Nenhuma melhoria necessária	PQ	PQNA
Confiabilidade do equipamento	PQ	PQCONF
Qualidade de deslocamento (vibração/ruído)	PQ	PQVIBE
SERV	SERV	
Consistência no atendimento das visitas agendadas	SERV	SERVAGEND
Nenhuma melhoria necessária	SERV	SERVNA
Prazo de entrega do material	SERV	SERVRAZO
Resolução imediata das paradas dos equipamentos	SERV	SERVRAP
Problemas técnicos resolvidos pela primeira vez	SERV	SERVASSERT
Técnico de check-in e check-out	SERV	SERVPREV
Tempos de resposta do técnico	SERV	SERV CORR
Tempo Total para concluir um reparo	SERV	SERV TIME
Agendamento de trabalho	SERV	SERV ORG

Fonte: Próprio autor

A modelagem do design da pesquisa quantitativa foi realizada a partir da análise de dados secundários obtidos da pesquisa de satisfação NPS, e tratado esta base (pré- processamento, limpeza, transformação, e bem como análise de potenciais outliers) e discutido o resultado do melhor classificador advindo do modelo de *machine learning* desenvolvido por meio da linguagem de programação *R Studio*.

A abordagem consistiu no pré-processamento dos dados teve a criação do banco de dados, limpeza dos dados e transformação dos dados (BATISTA, 2003). E avaliação do algoritmo de ML aplicado a um método supervisionado com boa capacidade preditiva e capacidade de indicar a importância das variáveis envolvidas na predição dos resultados para modelar a probabilidade de um cliente neutro tornar-se um promotor da marca com base nos atributos de satisfação.

São quatro modelos testados neste estudo de classificadores:

* *Árvore de decisão* é um método de fácil entendimento, mas bastante poderoso, que pode ser naturalmente estendido para classificação multiclases. O objetivo foi o de criar um modelo que previa o valor de uma variável de destino com base em diversas variáveis de entrada (GAMA, 2018).

* *Random Forest* é um método que tem maior vantagem na sua simplicidade de implementação e versatilidade, por funcionar bem com problemas de classificação e de regressão. (LORENZETT; TEOCKEN, 2016). Ele é uma forma média de múltiplas árvores de decisão, formados de diferentes partes de um mesmo conjunto treinamento, com o objetivo de reduzir a

variância obtendo um o modelo que explique bem o comportamento da variável resposta - um modelo parcimonioso (LORENZETT; TEOCKEN, 2016).

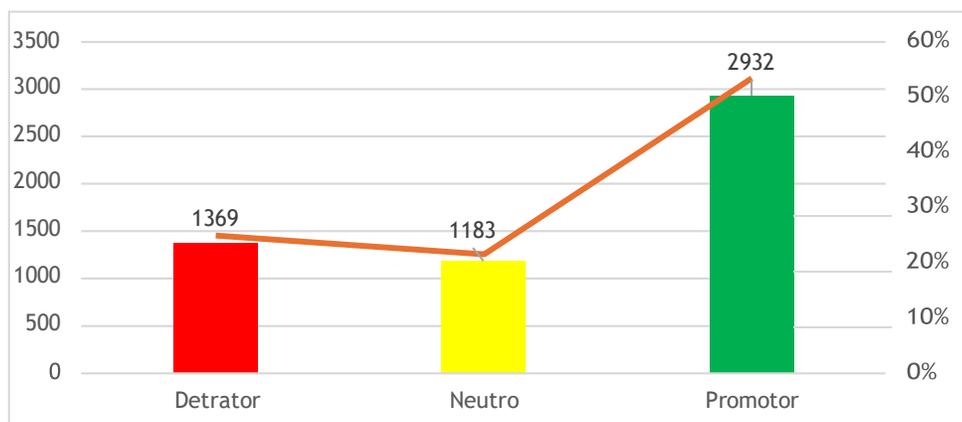
* O algoritmo *neighbors k-NN* é um método bastante simples e de fácil implementação, ele trabalha com um hiperparâmetro (tudo que nós informamos para um modelo/ algoritmo, antes dele começar o treino) que é o número de vizinhos. O algoritmo aprende a partir dos dados de treinamento por memorização deste conjunto e realiza a classificação/predição, somente se, esse novo dado tiver proximidades numéricas (K) com os dados antigos. (BHATIA, 2010).

* Regressão logística multinomial definida por Gouvêa et al. (2010) recomenda-se para a investigação se há uma relação da variável resposta (que é a variável dependente) entre as variáveis demais variáveis independentes (variável explicativa) que podem ser variáveis categóricas ou variáveis contínuas. Assume-se que as observações não afetam a outra, permite estimar a probabilidade associada à ocorrência de determinado evento em face de um conjunto de variáveis predictoras.

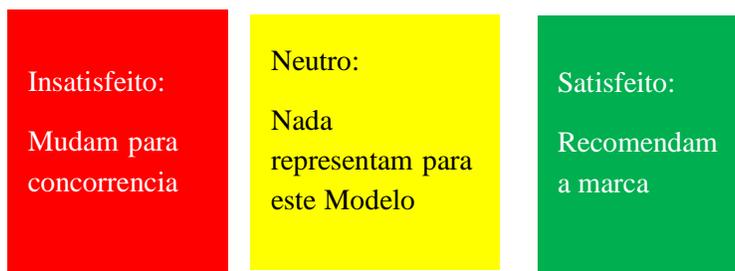
- Processo de análise a IA

No gráfico 1, é percebido um problema de viés que foi resolvido no pré-processamento para o uso *Machine learning* a técnica do undersampling - o qual foi reduzido o número de observações da classe majoritária (promotor) para diminuir a diferença entre as multiclasses (FAWCETT, 2001): neutros, detratores e promotores afim de obter um equilíbrio da variável para a formação de uma nova base. Em seu estudo Acabaya *et al*(2021) descreve a necessidade de balanceamento da base NPS.

Gráfico 1 – Distribuição do NPS



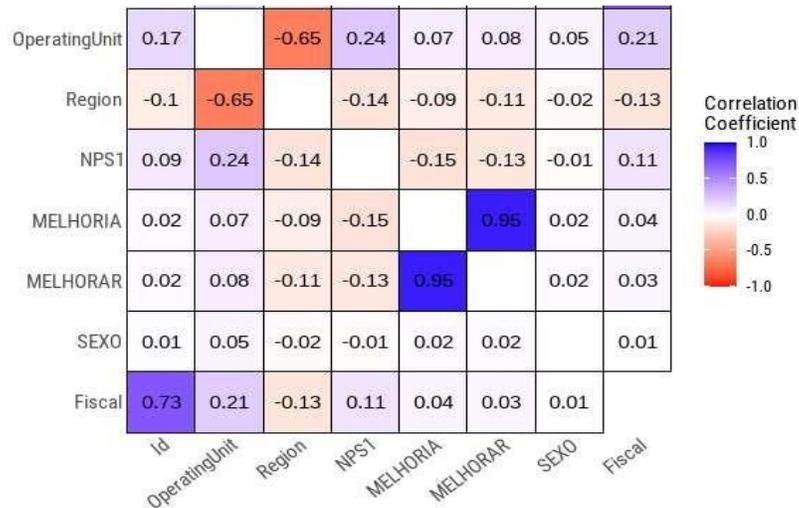
Fonte: Próprio autor (2023)



Análise do aprendizado de máquina exige os pré-processamentos, como:

1. A correlação de Spearman foi utilizada devido à variável ser qualitativa, e pedir interpretação e significado. Após o teste, foi confirmado a utilização destas variáveis.

Gráfico 2 – Correlação dos Atributos da Base



Fonte: Próprio Autor (2023)

O gráfico 2 acima, permite visualizar a correlação através da intensidade da cor, a relação dentro de uma ampla classe de relações estatísticas que envolva dependência entre duas variáveis pelas categorias de relevância entre a variável dependente NPS.

Uma correlação é preocupante quando o valor for maior 0,8 ou 0,9 pois indica a multicolinearidade como é no caso da melhoria com o melhorar. Ela foi estatisticamente respondida pelas variáveis independentes (variáveis explicativas): Melhorar ou Melhoria (definidas pelo cliente para a justificativa da nota emitida), Operação e a Região (estavam relacionadas a localização regional dos clientes que responderam à pesquisa).

2. Realização da checagem dos pressupostos da base:

a. Variável dependente nominal - a variável precisa ser mutuamente exclusiva, para que a resposta não possa ocorrer ao mesmo tempo para mesma observação: quem foi atributo neutro, não pode ser promotor; quem foi atributo promotor, não pode ser detrator; nem quem foi atributo neutro, não pode ser detrator;

b. Independências das observações - realização do teste de hipótese.

H0: há interdependência das alternativas irrelevantes

H1: Não há interdependência das alternativas irrelevantes

Não pode haver medidas repetidas, as amostras foram selecionadas aleatoriamente da população, em econometria utiliza o teste denominado Hausman-McFadden para testar essabase multinominal. O P_valor encontrado foi igual a 1, então, ele foi maior 0,05.

Desta forma, concluímos que, aceita-se H0: há interdependência das alternativas irrelevantes ($p \geq 0,05$), então há interdependência das alternativas para neutro, detrator e promotor;

c. Ausência de multicolinearidade - quando há uma forte relação linear, o que pode super-inflacionar os erros padrão (alta correlação entre as variáveis independentes do modelo, nesse estudo a variável é categórica). Foi testada a amostra pelo VIF (Variance Inflation Factor). Uma correlação torna-se preocupante quando o valor for maior 0,8 ou 0,9, o que ocorre no caso da varável Melhoria com o Melhorar, e com Região c Unidade de Operação. As demais variáveis isso não ocorre, (AGUIAR, 2016).

3. Os resultados de precisão para os quatro algoritmos foram comparados e para isso foi necessário dividir um conjunto treino para a criação do modelo, 70% da totalidade dos dados (3.838). Em seguida, testamos o modelo contra os novos dados na nova fase de construção que constituíam de 30% dos dados originais (1.645), simulando previsões reais que o modelo realizou, permitindo assim que o desempenho real fosse verificado para a obtenção do melhor classificador.

DISCUSSÃO

Em face aos desafios de interpretação dos dados brutos para a pesquisa sobre as recomendações neutras, a base de dados foi processada pela linguagem de programação *Rstudio.2021*, utilizando as técnicas de *Machine Learning* para medir os classificadores. O estudo trabalhou com o algoritmo supervisionado através da classificação por multiclases.

Após o processamento dos dados, foi necessária a definição dos métodos de aprendizado profundo conforme apresentado no estudo de Kotsiants, Idzabakis e Pintlos (2006) permitem encontrar padrões em dados, bem como gerar previsões que podem ser aplicadas a diversas soluções.

A variável dependente neste estudo foi NPS classificado como categórica multinomial: neutro, detrator e promotor somente assim, permitiria a realização da análise e independente (atributos dos clientes). Utilizando um método para inferir/prever resultados através de uma variável preditoras para os atributos do campo Melhorar. Para isso os atributos desta base foram transformados em fatores.

As variáveis independentes podem ser variáveis categóricas ou variáveis contínuas. Gouvêa et al. (2010) assume que as observações não afetam a outra, permite estimar a probabilidade associada à ocorrência de determinado evento em face de um conjunto de variáveis preditoras.

O experimento forneceu uma tabela com a taxa dos resultados positivos e negativos, e os falsos positivos e falsos negativos usualmente denominada matriz de confusão. Estes dados permitiu a geração da curva ROC (FAWCETT, 2006).

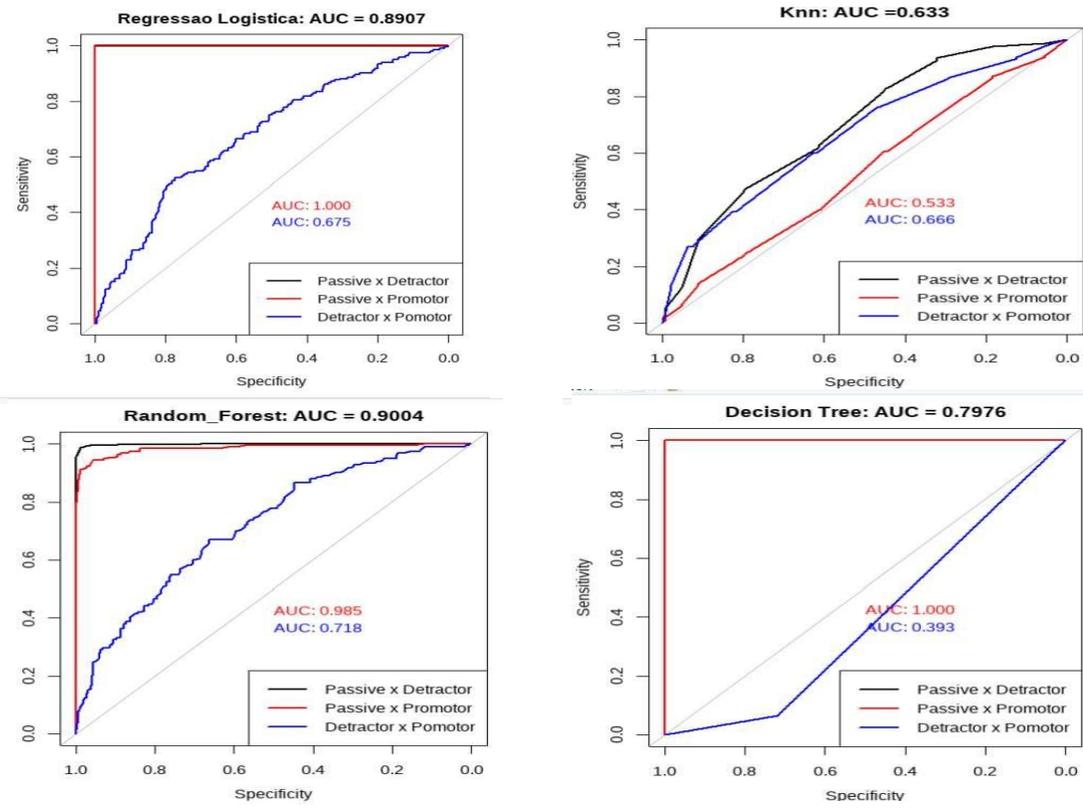
A curva ROC chamada de Característica de Operação do Receptor é uma ferramenta importante na análise preditiva que ilustra o desempenho de um sistema classificador à medida que o seu limiar de discriminação varia de definindo o modelo ótimo e descartando o modelo não tão ótimo.

No gráfico 3, abaixo, foram apresentados os resultados da curva ROC para os quatro classificadores propostos que plota os valores da relação da sensibilidade que é a capacidade de ocorrer quaisquer eventos positivos dentro de uma amostra observada (indicada no eixo Y = verdadeiros positivos = sensibilidade) e a especificidade que é a capacidade de ocorrer um evento negativo dentro de uma amostra observada (indicada no eixo X = falsos positivos).

A representação matemática da curva ROC é: $TP / (TP + FN)$, onde TP são os resultados verdadeiramente positivos e FN são os resultados dos falsos negativos.

O melhor teste é aquele com a curva mais alta e mais para esquerda (FAWCETT, 2006), o qual é analisado a área de dentro da curva (AUC) que corresponderá a valores entre 0 e 1 para estabelecer o melhor modelo classificador com base na performance preditiva de forma gráfica comparando a base neutra x promotor, base promotora x base detratora e a base neutra x detrator.

Gráfico 3: Receiver Operating Characteristic Curve



Fonte Próprio Autor (2023)

Hosmer e Lemeshow (2000) sugere a utilização de ROC acima de 70% como aceitável. Em média os modelos utilizados neste trabalho apresentaram altos índices de acurácia, evidenciando a alta capacidade de prever o problema proposto, exceto o método do KNN teve o valor o mais baixo de 63,3% e a Floresta aleatória obteve o mais alto índice de acurácia dentre os algoritmos testados com o valor obtido pela curva ROC de 90,04% para um intervalo de confiança ao nível de 95%.

A alta prevalência da classe “neutra” na base de dados reais utilizada foi outro ponto interessante acerca desta análise, enfatizando a importância de se estudar os fatores da neutralidade como um desafio gerencial para a melhoria da satisfação do cliente com a marca, dado que, tanto nas previsões, como na realidade, a proporção de neutros em 21,57% é consideravelmente próxima que a de detratores em 24,96%.

A técnica da análise multivariada encontrou o classificador com maior pertinência para as novas entradas desta base de NPS e precisão através da floresta aleatória e regressão logística, maximizando a eficiência do negócio.

No estudo de Rallis (2020) aplicou sobre uma base NPS as ferramentas de IA, a regressão logística seguido da Floresta aleatória tiveram o melhor desempenho. Neste estudo a Floresta aleatória foi o melhor classificador seguido da regressão logística. Desta forma, este estudo conseguiu resultado bem positivo para um modelo de aplicação de *Machine Learning*.

O classificador da floresta aleatória apesar de ter o melhor resultado, não respondia o objetivo proposto. Um dos objetivos específicos era avaliar quais os atributos preditivos que poderiam contribuir significativamente para a alteração do estado de neutralidade para o novo estado de promoção da marca.

O classificador da regressão logística teve um bom resultado neste estudo e sua técnica apropriadamente permitiu conforme Hair *et al.*, (1998) através da sua grande variedade de aplicações, estimar a probabilidade associada à ocorrência de determinado evento em face de um conjunto de variáveis explanatórias a análise dos atributos com maior chance (*odds ratio*) de reversão do status para a promoção da marca.

Desta forma, foram analisados quais os fatores que mais impactavam a resposta neutra aplicando a análise para o entendimento do tamanho da relação entre as demais variáveis categóricas: detrator e promotor através das razões de chance.

Tabela 1 – Índice de confiança do Neutro x Características

Característica	OR [ⓧ]	95% CI [ⓧ]	valor p	Característica	OR [ⓧ]	95% CI [ⓧ]	valor p
Detrator				Promotor			
MELHORAR	—	—		MELHORAR	—	—	
ADMBOL	—	—		ADMBOL	—	—	
ADMFAT	1,16	0,60, 2,22	0,7	ADMFAT	1,10	0,59, 2,07	0,8
ADMNA	0,06	0,02, 0,15	<0,001	ADMNA	3,09	6,29, 13,1	<0,001
ADPERF	1,34	0,65, 2,76	0,4	ADPERF	1,87	0,97, 3,60	0,06
ADMPRECO	0,87	0,54, 1,42	0,6	ADMPRECO	1,4	0,91, 2,14	0,13
ADMPROC	1,42	0,60, 3,32	0,4	ADMPROC	0,89	0,36, 2,19	0,8
ADMTRANSP	1,01	0,58, 1,74	>0,9	ADMTRANSP	0,81	0,49, 1,35	0,4
CHAMADA	0,49	0,24, 0,98	0,044	CHAMADA	2,09	1,21, 3,62	0,008
COMCONT	0,67	0,43, 1,03	0,07	COMCONT	1,42	0,96, 2,10	0,078
COMGER	1,02	0,54, 1,93	>0,9	COMGER	0,87	0,47, 1,61	0,7
COMSUP	1,39	0,83, 2,31	0,2	COMSUP	0,99	0,59, 1,66	>0,9
COMTEC	0,54	0,31, 0,93	0,026	COMTEC	1,28	0,81, 2,01	0,3
COMENDAR	1	0,63, 1,59	>0,9	COMENDAR	1,14	0,73, 1,76	0,6
PQBELO	0,44	0,13, 1,53	0,2	PQBELO	0,88	0,35, 2,20	0,8
PQCONF	2,43	1,51, 3,91	<0,001	PQCONF	0,94	0,57, 1,54	0,8
PQPARA	0,64	0,23, 1,76	0,4	PQPARA	0,56	0,22, 1,43	0,2
PQVIBE	0,96	0,52, 1,76	>0,9	PQVIBE	0,95	0,55, 1,64	0,9
SERVIÇO	1,86	1,07, 3,24	0,029	SERVIÇO	1,34	0,78, 2,31	0,3
SERVASSER	1,97	1,36, 2,88	<0,001	SERVASSER	0,8	0,55, 1,17	0,3
SERVCORR	0,94	0,54, 1,66	0,8	SERVCORR	1,15	0,67, 1,98	0,6
SERVORG	1,63	0,99, 2,68	0,056	SERVORG	1,56	0,97, 2,50	0,067
SERVPRAZO	1,3	0,84, 2,01	0,2	SERVPRAZO	0,76	0,49, 1,18	0,2
SERVPREV	0,5	0,27, 0,92	0,027	SERVPREV	0,79	0,47, 1,33	0,4
SERVAP	2,27	1,16, 4,43	0,017	SERVAP	1,09	0,54, 2,20	0,8
SERVTIME	1,5	0,97, 2,32	0,07	SERVTIME	0,46	0,28, 0,74	0,001
SEXO	0,82	0,68, 0,98	0,029	SEXO	0,83	0,70, 0,98	0,027
Região				Região			
BMidwest	—	—		BMidwest	—	—	
BNorte	1,15	0,60, 2,22	0,7	BNorte	1,67	0,89, 3,11	0,11
B Nordeste	0,98	0,64, 1,49	>0,9	B Nordeste	1,05	0,70, 1,58	0,8
BSul	0,66	0,44, 0,99	0,045	BSul	1,89	1,31, 2,74	<0,001
B Sudeste	1,05	0,72, 1,52	0,8	B Sudeste	1,52	1,06, 2,17	0,022
LNorte	1,9	1,20, 3,00	0,006	LNorte	0,95	0,60, 1,51	0,8
LSul	2,03	1,33, 3,10	0,001	LSul	0,75	0,49, 1,15	0,2

[ⓧ] OR = Odds Ratio, CI = Intervalo de Confiança

[ⓧ] OR = Odds Ratio, CI = Intervalo de Confiança

Fonte Próprio Autor (2023)

Legenda
 Não Impacta
 Impacta

A Tabela 1 acima indica a lista as variáveis independentes (atributos) usadas na modelagem e suas respectivas *odds ratios*.

Os atributos acima na cor branca representam as características que os clientes entendem que impactam na neutralidade de suas respostas e na cor rosa não impactam no comportamento destes clientes.

Odds ratios é a razão entre a chance de um evento ocorrer em um grupo e a chance de ocorrer em outro grupo. Uma odds ratio entre 0 e 1 indica que aquele atributo está associado a uma menor chance de ocorrência da classe de interesse da variável-alvo (codificada como 1).

Já valores de *odds ratio* maiores do que 1 indicam que o atributo aumenta as chances de ocorrência da classe de interesse e, quanto maior o valor, maior a chance (PEREIRA, 2017).

Os intervalos de confiança utilizados foram de 95% e as razões de chances (OR) foram estatisticamente significativas e diferentes de 1 (um). Se fosse igual a 1(um), não teria efeito (o número não podia estar contido no intervalo para ter a oportunidade de ocorrer).

Os resultados indicaram que o tempo de execução do serviço (SERVTIME) e o atendimento da mesa de chamados (COMCALL) são os atributos mais influentes na transição de clientes neutros para promotores com coeficientes de 0,46 e 2,49, respectivamente. A precisão do modelo foi de 89,07% indicando uma boa capacidade preditiva.

Esse resultado sugere que melhorias no tempo do serviço e no atendimento ao cliente pelo call center podem significativamente aumentar o número de promotores. A Empresa deve focar nesse aspecto para otimizar a satisfação e lealdade dos clientes.

A regressão logística multinomial é um classificador que permite identificar os atributos que podem influenciar a transição de clientes de um status “neutro” para “promotor” tanto quanto não sendo trabalhado, este atributo poderá ter o status de insatisfação total como “detrator”. A aplicação permite que as empresas tomem decisões baseadas em dados, otimizando recurso e aumentando a fidelidade e satisfação dos clientes.

O código de programação elaborador pode ser aplicado para qualquer base de dados de pesquisa de satisfação NPS para qualquer negócio e a construção do mesmo permite a geração de um programa a ser apresentado para as organizações do mercado com o objetivo de identificar os atributos que causam a neutralidade dos respondentes e possuem grandes chances de serem trabalhados para sua modificação de satisfação para promotores da marca.

CONCLUSÃO

Com a realização deste trabalho deve-se ressaltar as contribuições e a importância dos respondentes neutros para a pesquisa de satisfação de clientes e a vantagem da utilização da IA na análise de dados NPS pois:

O foco na administração visa a melhoria do processo aumento da rentabilidade para as empresas e sua correlação ao aumento da retenção de clientes através do uso dos respondentes neutros que são ignorados nos modelos atuais de análise. E o foco da informática agrega a aplicabilidade dos códigos de programação do *machine learning* aumentando a capacidade de análise de uma quantidade maior de dados em um tempo menor. Desta forma, aderência deste estudo contribuiu para agregar a Ciência de dados e a Administração, esperando fomentar pesquisas conjuntas para o avançar do conhecimento acadêmico e empresarial.

A experiência do cliente é agora a principal diferenciação entre os concorrentes. Como muitos clientes hoje usam serviços inteligentes e em tempo real e aplicativos amigáveis, as empresas podem coletar cada vez mais dados sobre as jornadas dos clientes, em vez de depender de formas simplificadas e de métrica única de medir a experiência do cliente.

Ao implementar um modelo orientado por IA como o descrito acima, as organizações podem monitorar a jornada do cliente em tempo real e gerar insights que permitiriam aos provedores de serviços fornecerem uma experiência perfeita ao cliente e intervir em tempo hábil para uma recuperação eficaz do serviço.

O grau de complexidade é alto, a modelagem e interpretação dos dados de *machine learning* requer técnica e domínio do contexto do negócio envolvido no problema de classificação ou regressão. Necessita de conhecimento de programação em R e estudado o código específico para encontrar o melhor classificador para aplicabilidade a esta base de dados.

Este programa de código pode ser replicado para em qualquer empresa ou negócio para a identificação dos fatores de neutralidade a serem trabalhados para aumentar a probabilidade de satisfação e fidelização.

Em resumo, este estudo demonstrou o potencial do aprendizado de máquina (ML) e da análise de dados na compreensão e aprimoramento da satisfação do cliente. Os dados utilizados são transparentes e imutáveis, garantindo sua integridade e forneceu insights valiosos para os profissionais e empresas, destacando a necessidade de estratégias sólidas e equipes qualificadas para aproveitar ao máximo essa tecnologia em benefício dos clientes e do crescimento dos negócios.

REFERÊNCIA BIBLIOGRAFICA

ACAYABA, Edvaldo; DOS SANTOS, Rafaela Ramos; BISPO, Thais. “**Predição de Satisfação de Clientes Utilizando Modelos de Machine Learning em Pesquisa Net Promoter Score**”. Revista de Engenharia e Pesquisa Aplicada. v. 6, n. 5, p. 65-72, 2021. Disponível em: <http://revistas.poli.br/index.php/rep/article/view/1763/785>. Acesso em: 28 ago. 2022.

AGUIAR, Jéssica Simon.” **Software R: capacitação em análise estatística de dados utilizando um software livre** “. Anais do SEPE-Seminário de Ensino, Pesquisa e Extensão da UFFS.v. 6, n. 1, 2016.

BADI, P., BRUNAK, S, “**Bioinformatics: The Machine learning Approach second Edition**”, 2001
https://www.researchgate.net/publication/237044460_Bioinformatics_The_Machine_Learning_Approach

BATISTA, G. E. A. P. A.” **Pré-processamento de dados em aprendizado supervisionado. Tese (Doutorado em Ciências de Computação e Matemática Computacional)**”. Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo. S. Carlos, 2003.

BHATIA, N.; Vandana. “**Survey of Nearest Neighbor Techniques**”. International Journal of Computer Science and Information Security, Vol 8, No. 2, P.302-305, 2010.

FAWCETT, T Reitor. “**Usando conjuntos de regras para maximizar o desempenho do ROC**”. Em: Proc. IEEE Interna. Conf. sobre Mineração de Dados (ICDM), p. 131–138.), 2001

GANGULI, S., & SK, Roy. “**Dimensões genéricas de qualidade de serviço baseadas em tecnologia no setor bancário impactam na satisfação e fidelidade do cliente**”. International Journal of Bank Marketing, 29 (2), p.168–189. 2011

GOUVÊA, Maria Aparecida; PREARO, Leandro Campi; ROMEIRO, Maria do Carmo. “**Abordagem exploratória do emprego das técnicas de análise de regressão e análise conjunta em estudos do comportamento do consumidor**”. Revista Brasileira de Gestão de Negócios.v. 12, p. 253-270, 2010. Disponível em: <https://doi.org/10.7819/rbgn.v12i36.661> . Acesso em: jun.2022

HAIR, Joseph F. “**Análise Multivariada de dados**”. V.6, 2009

HOSMER Jr., D.W and LEMESHOW, S. (2000) “**Applied logistic regression**”. 2nd Edition, John Wiley & Sons, Inc., New York. <http://dx.doi.org/10.1002/0471722146>

KOTSIANTS, SB; ZABAKIS, ID; PINTLOS, PE. “**Aprendizado de máquina: uma revisão de classificação e técnicas de combinação**”. Artificial intelligence Review. Vol.26, n.3, p.159- 190. 2006

LORENZETT, C. D. C., & TELÖCKEN, A. V. “**Estudo Comparativo entre os algoritmos de Mineração de Dados Random Forests e J48 na tomada de Decisão**”. Simpósio de Pesquisa e Desenvolvimento em Computação (SPDC), 2(1). 2016

MICHALSKI, R. S., CARBONELL, J. G., MITCHELL, T. M. ”**Machine Learning: An artificial Intelligence approach**”. Artificial Intelligence Vol.25. nr. 2, Pages 236-238. 1984.

PEREIRA, Francisco Coimbra Carneiro. **“Modelos Preditivos para Evasão de Alunos no Ensino Superior Privado – Uma aplicação de Machine Learning para Gestão de Marketing de Relacionamento”**. 2017. 69 f. Dissertação (Mestrado em Administração de Empresas) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro.

RALLIS, Ioannis et al. **“Um novo método de classificação para análise de pesquisa de experiência do cliente”**. In: Proceedings of the 13th ACM International Conference on Pervasive Technologies Related to Assistive Environments. pp. 1-9. 2020

REICHHELD, FF. **“O único número que você precisa para crescer”**. Harvard Business Review, 81(12) p.46-55. 2003

ROSSI, C A V & SLONGO L.A. **“Pesquisa de satisfação de clientes o estado da arte e proposição de um método brasileiro”**. Revista de administração contemporânea. V.2, n.1, p 101-125, 2011. Disponível em: <https://doi.org/10.1590/S1415-65551998000100007>. Acesso em abr. 2022

ZAKI, M; KANDEIL, D; NEELY, A; MCCOLL-KENNEDY, R. J. **“A falácia do Net Promoter Score: modelo preditivo de fidelização do cliente”**. Cambridge Service Alliance, v. 1-25, 2019.