

Evidências de melhorias do atendimento ao público sênior em uma instituição financeira pela Inteligência Artificial Generativa

Patrícia Cristina Campos dos Santos
UNIVERSIDADE DE SÃO PAULO – USP
Lucas Tronbjerg Villafuerte Bertolli Moreira
UNIVERSIDADE DE SÃO PAULO – USP

Resumo: O atendimento digital em instituições financeiras apresenta desafios de acessibilidade para clientes com 60 anos ou mais, resultando em baixa satisfação e altos custos operacionais. Este artigo tecnológico apresenta a implementação de uma solução baseada em Inteligência Artificial (IA) Generativa para aprimorar a comunicação via chat com este público em uma instituição de médio porte. O diagnóstico revelou que o sistema anterior, baseado em *chatbots* tradicionais, falhava devido à rigidez de seus roteiros e ao uso de linguagem técnica, gerando um índice de satisfação de apenas 48,6%. A solução consistiu na customização de um modelo de linguagem de larga escala (LLMs), treinado com um acervo de dados curado por uma equipe multidisciplinar e orientado por diretrizes de Linguagem Simples. Como resultado, o índice de satisfação (CSAT) aumentou para 64% e a necessidade de contato humano foi reduzida em 4 pontos percentuais. A proposta contribui com um roteiro prático para aliar inovação tecnológica à inclusão digital, gerando benefícios simultâneos de experiência do cliente e eficiência operacional.

Palavras-Chave: Inclusão digital; Público Sênior; Experiência do usuário; Inteligência Artificial Generativa; Transformação Digital

Evidências de melhorias do atendimento ao público sênior em uma instituição financeira pela Inteligência Artificial Generativa

1. Introdução

A transformação digital redefiniu as operações de negócios em escala global (Feyen et al., 2021). Uma das dimensões centrais dessa mudança é a maneira como as empresas interagem com seus clientes, com novos pontos de contato e expectativas perante um ritmo acelerado (Nwoke., 2024). Essa redefinição da interação com o cliente expõe uma tensão fortemente atrelada ao mundo da transformação digital, sendo ela a busca incessante por eficiência operacional frente a necessidade de garantir a inclusão de todos os públicos.

Neste novo cenário, um segmento populacional de crescente relevância estratégica emergiu, os clientes com 60 anos ou mais. Dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2023) confirmam o envelhecimento da população e a crescente adesão deste grupo ao ambiente digital. Este público, com perfil de alta fidelização e estabilidade financeira, busca nos canais digitais dimensões como a agilidade, a segurança, a clareza e atendimento satisfatório (Dal Moro & Vittorazzi, 2016; Chaouali & Souiden, 2019), demandando que as instituições superem uma abordagem tecnológica padronizada para oferecer uma experiência adaptada ao perfil deste público.

Muitas estratégias de autosserviço digital encontram um obstáculo de alto custo. O atendimento via *chatbots* tradicionais, operando com base em fluxos predefinidos e roteiros rígidos (Marcus & Davis, 2020), revelou-se, dentro do contexto empresarial específico estudado, particularmente inadequado para as necessidades do público sênior.

Na empresa estudada, esses sistemas falham em prover respostas claras e personalizadas, gerando uma comunicação ineficiente, com consequências para o negócio são diretas e mensuráveis, como baixos índices de satisfação do cliente (do inglês *customer satisfaction*, ou CSAT) e uma necessidade frequente de transferir o atendimento para equipes humanas. Esta falha sistêmica não apenas frustrou o cliente, mas também sobrecarregou a operação e infla os custos com a intervenção manual, comprometendo a própria eficiência prometida pela digitalização.

A origem dessa ineficiência pode ser identificada na rigidez da tecnologia de *chatbots* convencionais. Estes sistemas automatizados tradicionais são incapazes de interpretar perguntas formuladas fora de um roteiro, lidar com sinônimos ou compreender o contexto de uma conversa, gerando respostas repetitivas e desconectadas da real necessidade do usuário (Marcus & Davis, 2020). Em resposta direta a esta limitação, a Inteligência Artificial (IA) Generativa, por meio dos Modelos de Linguagem de Larga Escala (do inglês *Large Language Models*, ou LLMs) surgiu como uma solução tecnológica plausível, considerando sua capacidade de processar e gerar linguagem natural de forma fluida e contextual. As LLMs permitem a criação de diálogos dinâmicos, adaptados e personalizados, superando as barreiras de comunicação que marginalizam o público sênior no ambiente digital (Russell & Norvig, 2022; Barbosa et al., 2022).

Este artigo detalha a implementação de uma solução customizada de IA Generativa em uma instituição financeira de médio porte, que transformou o atendimento via chat para clientes com 60 anos ou mais. Enquadrado como um artigo com foco na melhoria (Motta, 2017, 2022), o trabalho se distingue por não focar apenas na tecnologia, mas no processo de sua aplicação,

envolvendo uma curadoria de conteúdo para ajustar o modelo de linguagem às particularidades deste público.

A intervenção gerou resultados mensuráveis e significativos. Identificou-se que CSAT aumentou de 48,6% para 64%, enquanto a taxa de contato humano foi reduzida em 4 pontos percentuais, de 23% para 19%. A contribuição deste relato é, portanto, dupla: (i) oferece um roteiro prático e replicável que demonstra o retorno sobre o investimento desta solução; e (ii) fornece evidências empíricas de que a aplicação supervisionada da IA Generativa de LLMs é uma ferramenta eficaz para promover a inclusão digital e, simultaneamente, otimizar a eficiência operacional no setor financeiro.

2. Contexto do problema

O problema em questão manifestou-se em uma instituição financeira brasileira de médio porte, cuja estratégia de negócio é fortemente ancorada em uma plataforma de serviços digitais. Dentro de sua base diversificada de clientes, a organização identificou uma participação crescente e estratégica do segmento com idade igual ou superior a 60 anos. Este público, embora progressivamente mais conectado, ainda enfrenta barreiras significativas no ambiente digital, que vão desde a complexidade de interfaces até a dificuldade de compreensão de jargões técnicos e financeiros (Msweli & Mawela, 2020; dos Santos, 2023).

O principal canal de autosserviço da organização é o atendimento via chat, projetado para resolver dúvidas de forma ágil e escalável. Contudo, a ferramenta, antes da intervenção, operava com base em um modelo de *chatbot* tradicional, com fluxos de diálogo predefinidos e respostas padronizadas. Esta abordagem mostrava-se inadequada para as necessidades do público sênior, que frequentemente apresenta um ritmo cognitivo distinto e demanda uma comunicação mais empática e contextualizada (Barbosa et al., 2022).

O ambiente externo reforça a relevância deste desafio. Primeiramente, o envelhecimento da população brasileira é uma realidade demográfica que pressiona as empresas a desenvolverem soluções mais inclusivas (Camarano & Pasinato, 2004). Ao mesmo tempo, o setor financeiro vivencia uma rápida adoção de novas tecnologias (Febraban & Deloitte, 2025; McKinsey & Company, 2023, 2024). Ademais, segundo o relatório da SAS (2024) indica que 53% das empresas brasileiras já implementaram políticas internas para o uso de IA Generativa, evidenciando um movimento setorial em direção à automação inteligente.

Adicionalmente, o contexto regulatório impõe uma camada de complexidade. A Lei Geral de Proteção de Dados (LGPD) (Brasil, 2018) e as diretrizes da Autoridade Nacional de Proteção de Dados (ANPD, 2022) estabelecem a necessidade de um uso ético e transparente de tecnologias que envolvam dados de clientes, com atenção especial a decisões automatizadas que afetam públicos vulneráveis. Sistemas de IA, portanto, precisam garantir não apenas a segurança, mas também a clareza e a rastreabilidade de suas interações.

Neste cruzamento de fatores, um público estratégico com necessidades específicas, uma tecnologia antiga inadequada, uma nova tecnologia emergindo em todo o setor e uma crescente pressão regulatória, a realidade da empresa era a de possuir um canal digital central para sua operação que atendia de forma precária um de seus segmentos de clientes mais importantes, criando tanto um risco de negócio quanto uma oportunidade de inovação.

3. Diagnóstico do problema

O diagnóstico para identificar as causas efetivas da ineficiência do atendimento ao público sênior foi realizado por meio de uma abordagem de métodos mistos. A estratégia combinou a análise de indicadores de desempenho (do inglês *Key Performance Indicators*, ou KPIs) do canal de chat com a análise de conteúdo dos relatos dos clientes, permitindo não apenas quantificar a dimensão do problema, mas também compreender suas origens à luz da literatura pertinente.

A análise quantitativa dos dados operacionais, referentes ao período anterior à intervenção, revelou um desempenho insatisfatório em métricas cruciais. De acordo com a base de dados da empresa, o CSAT era de apenas 48,6%, um patamar consideravelmente baixo que indicava uma falha sistêmica na experiência do usuário (Barbosa et al., 2022; Lee, 2023). Adicionalmente, a elevada taxa de contato humano de 23% evidenciava a incapacidade do *chatbot* tradicional em lidar com as demandas deste público, gerando um duplo efeito negativo. Tal cenário gerava frustração para o cliente, que não obtinha a solução esperada, e aumento dos custos operacionais para a instituição.

Para aprofundar a investigação, uma análise de conteúdo (Bardin, 2011) sobre os feedbacks espontâneos dos clientes permitiu identificar as causas qualitativas por trás desses números. A investigação revelou que a rigidez e a falta de contexto eram as falhas mais proeminentes. O *chatbot* tradicional operava com base em um roteiro fixo, sendo incapaz de interpretar perguntas formuladas fora do padrão ou de compreender o contexto da conversa.

Este achado é consistente com as limitações técnicas de sistemas de IA não-generativos, que carecem de uma compreensão robusta da linguagem e frequentemente falham em simular um raciocínio adaptativo (Marcus & Davis, 2020). Essa incapacidade de processar solicitações com múltiplas intenções ou que exigiam um raciocínio mais elaborado forçava o cliente a buscar o atendimento humano, gerando um ciclo de repetição e frustração com respostas como “*não entendi sua dúvida*”.

Além da falha técnica, o diagnóstico apontou uma falha de design comunicacional. A linguagem utilizada pelo sistema era percebida como impessoal e excessivamente técnica, com respostas padronizadas que não eram adaptadas às necessidades de clareza do público sênior. Esta barreira de comunicação é amplamente documentada como um dos principais obstáculos para a inclusão digital de idosos, que demandam uma linguagem mais acessível para se sentirem seguros em ambientes digitais (Barbosa et al., 2022). A utilização de uma linguagem que, embora tecnicamente correta, era percebida como distante, minava a confiança do cliente no canal de autosserviço e reforçava a percepção de que a tecnologia não era projetada para eles.

Portanto, o diagnóstico concluiu que a causa raiz do problema não residia na falta de adesão do público sênior ao canal digital, mas sim em uma dupla inadequação da solução empregada. Havia uma falha tecnológica, fundamentada na incapacidade do *chatbot* de processar a linguagem natural de forma flexível. Havia também uma falha de design, oriunda da não aplicação de princípios de comunicação inclusiva. Essa combinação resultou em uma experiência de usuário deficiente, que se manifestou nos indicadores de desempenho negativos e justificou a necessidade de uma intervenção profunda

4. Proposta da solução do problema

Com base no diagnóstico, a solução proposta consistiu na substituição do *chatbot* tradicional por um sistema de atendimento sociotécnico, fundamentado em um Grande Modelo

de Linguagem (LLM) de IA Generativa e um robusto processo de governança da informação. O projeto foi estruturado para atacar diretamente as causas identificadas na fase anterior, que eram a rigidez, a linguagem inadequada e a incapacidade de lidar com a complexidade das interações. Para tal, a solução integrou uma base tecnológica avançada com um processo de curadoria de conteúdo, embasado na literatura sobre comunicação, gestão da informação e ética em IA.

O componente tecnológico central da solução foi a implementação de um LLM proprietário baseado na arquitetura GPT-3.5 Turbo. Diferentemente do sistema anterior, essa tecnologia oferece a capacidade de gerar respostas dinâmicas e contextualizadas, adaptando-se em tempo real às perguntas dos usuários (Feuerriegel et al., 2024; Iusztin & Labonne, 2024; Kenthapadi et al., 2023; Manduchi et al., 2024). Contudo, a simples adoção de um LLM genérico apresentava riscos significativos. Sem um treinamento e ajuste adequados, o modelo poderia replicar vieses presentes em dados históricos ou gerar respostas tecnicamente corretas, mas inadequadas ao perfil comunicacional do público sênior, perpetuando o problema diagnosticado (Manduchi et al., 2024).

O diferencial da proposta, portanto, residiu no processo de customização e treinamento do modelo. Reconhecendo que a eficácia da IA depende diretamente da qualidade dos dados de treinamento (Feuerriegel et al., 2024; Iusztin & Labonne, 2024), a solução foi orientada por princípios de design de IA responsável. Uma equipe multidisciplinar, composta por especialistas em experiência do usuário (do inglês *User Experience*, ou UX), redatores técnicos, cientistas de dados e profissionais de atendimento, realizou um processo de curadoria sobre aproximadamente 10.000 interações históricas. Este processo foi essencial para mitigar o risco de preconceito algorítmico (Garcia et al., 2024; Kenthapadi et al., 2023), garantindo que o sistema aprendesse com dados coerentes, representativos e sem vieses excludentes. A aplicação prática da competência da informação, entendida como a habilidade de avaliar e adaptar dados com senso crítico, foi a base desta etapa.

Adicionalmente, todo o conteúdo utilizado para treinar e ajustar o modelo foi desenvolvido seguindo as diretrizes de Linguagem Simples da *Plain Language Association International* (traduzindo Associação Internacional de Linguagem Simples, ou PLAIN) (PLAIN, 2022). O objetivo explícito foi eliminar jargões e construir frases que facilitassem a compreensão, a confiança e a autonomia do público sênior. Para o monitoramento e a análise de desempenho da solução, foi utilizada a plataforma de *Business Intelligence* (BI) Microsoft Power BI, permitindo o acompanhamento em tempo real dos KPIs e a comparação objetiva entre o desempenho do sistema antigo e o da nova solução, conforme ilustrado no fluxo da Figura 1.




Figura 1. Fluxograma da Solução Proposta.
Fonte: Dados da Pesquisa. Elaborado pelos autores.

Dessa forma, a solução proposta não foi meramente uma atualização tecnológica. Tratou-se de uma intervenção organizacional que combinou o poder computacional dos LLMs com o conhecimento aplicado sobre comunicação inclusiva e governança de dados. Essa abordagem sociotécnica foi fundamental para resolver um problema de negócio concreto, garantindo que a inovação servisse efetivamente ao propósito de inclusão e melhoria da experiência do cliente.

5. Plano de ações da mudança

A transição do sistema de *chatbot* tradicional para a solução baseada em Inteligência Artificial Generativa foi concebida e executada como um projeto de intervenção organizacional, realizado ao longo de um trimestre, entre outubro e dezembro de 2024. O plano de ação foi estruturado em três fases lógicas e sequenciais: (i) Diagnóstico e Planejamento Estratégico; (ii) Desenvolvimento da Solução e Curadoria da Informação; e (iii) Implementação, Monitoramento e Validação. A execução foi liderada por uma equipe multidisciplinar dedicada, composta por especialistas das áreas de UX, Ciência de Dados, Atendimento ao Cliente e Redação Técnica, garantindo que as perspectivas de negócio, tecnologia e cliente fossem integradas em todas as etapas.

5.1. Diagnóstico e Planejamento Estratégico

A fase inaugural do projeto foi dedicada a construir um entendimento baseado em evidências do problema, utilizando princípios de metodologias de tomadas de decisão baseadas em evidências de (Pfeffer & Sutton, 2006). O objetivo era ir além das percepções superficiais para fundamentar todas as ações subsequentes em dados concretos. Para isso, a equipe de dados realizou uma extração e anonimização de um acervo de aproximadamente 60.000 interações históricas do canal de conversas.

Essa base de dados permitiu a mensuração dos KPIs do sistema legado, estabelecendo uma linha de base quantitativa para a tomada de decisão. Com este fundamento estabelecido, a fase de planejamento pôde avançar da simples identificação de um problema para a formulação de uma definição de sucesso baseada em dados (do inglês: *data-driven*) para o projeto. O objetivo estratégico passa a se tornar, portanto, na otimização de um conjunto específico de quatro KPIs, que, de acordo com os membros do projeto na empresa, juntos forneceriam uma visão holística do impacto da intervenção, que estão apresentados na Tabela 1.

Tabela 1. Indicadores de Desempenho Mensurados

Indicador Chave (KPI)	Dimensão Estratégica	Justificativa
Índice de Satisfação do Cliente (CSAT)	Experiência do Cliente	Mede a percepção de qualidade do serviço pelo cliente.
Taxa de Contato Humano	Eficiência Operacional	Mede o custo gerado pela falha do autosserviço.
Frequência de Reencaminhamento	Eficiência Operacional	Indica a ineficiência do fluxo e a repetição do problema.
Taxa de Não Transbordo Humano	Autonomia e Capacidade de Resolução	Mede a capacidade do sistema de resolver a demanda de forma autônoma.

Fonte: Dados da Pesquisa. Elaborado pelos Autores.

Em paralelo, a equipe de UX aplicou a técnica de análise de conteúdo baseada em (Belluzzo, 2020) sobre os feedbacks espontâneos dos clientes para mapear qualitativamente as falhas de comunicação, dificuldades percebidas e relatadas e as necessidades não atendidas do público sênior. O resultado desta fase foi um diagnóstico que foi capaz de criar um conjunto objetivo de requisitos para a nova solução, culminando na decisão estratégica de utilizar uma arquitetura de LLM customizável como a base tecnológica para o novo sistema.

5.2. *Desenvolvimento da Solução e Curadoria da Informação*

Esta fase representou o principal momento da intervenção, onde a tecnologia bruta foi transformada em uma ferramenta de comunicação com o objetivo de ser eficaz e responsável. O processo iniciou-se com a seleção de uma subamostra de 10.000 interações, que serviu como o conjunto de dados para o treinamento e ajuste fino do modelo de linguagem. O diferencial desta etapa, contudo, foi o intenso processo de curadoria. A equipe multidisciplinar teve como tarefa revisar cuidadosamente este acervo, identificando e reescrevendo exemplos que continham jargões, linguagem ambígua ou tom inadequado.

Este trabalho manual e especializado foi orientado pelas diretrizes e *framework* da PLAIN, garantindo que o modelo de IA fosse treinada com o objetivo de se comunicar de forma clara, empática e acessível. Essa ação, naturalmente, teve como objetivo garantir a eficácia da ferramenta, ao mesmo tempo que serviu como uma medida proativa para mitigar riscos de preconceito algorítmico e aplicar na prática os conceitos de competência da informação (Feuerriegel et al., 2024; Iusztin & Labonne, 2024; Kenthapadi et al., 2023; Manduchi et al., 2024), assegurando que a IA fosse treinada com dados de alta qualidade e eticamente alinhados às necessidades do público-alvo.

A escolha da arquitetura GPT-3.5 Turbo como base tecnológica foi uma decisão estratégica, visando equilibrar poder de processamento, velocidade e custo-benefício. Diferentemente de modelos maiores e mais lentos, a versão "*Turbo*" é otimizada para aplicações de diálogo em tempo real, oferecendo respostas com baixa latência (OpenAI, s.d.), um requisito essencial para a fluidez de uma conversa via chat. Essa arquitetura permitiu à instituição financeira implementar uma solução com a capacidade de compreensão contextual e geração de linguagem natural das LLMs, sem comprometer a agilidade da experiência do usuário ou incorrer em custos computacionais proibitivos para uma operação de larga escala.

Todo o manuseio dos dados durante esta fase foi estritamente guiado pelos princípios da LGPD. Antes de serem utilizados para o treinamento, todos os registros das 10.000 interações passaram por um rigoroso processo de anonimização para remover qualquer informação pessoalmente identificável. O tratamento dos dados seguiu os princípios de finalidade, sendo utilizados exclusivamente para o aprimoramento do modelo de atendimento, e de minimização, utilizando-se apenas as informações estritamente necessárias para o processo. Essa conformidade com a LGPD é uma dimensão fundamental da prática de trabalho com dados sensíveis de seres humanos, especialmente por lidar com um público sensível. Assim, a empresa teve como fundamento garantir que a inovação fosse implementada de forma ética e que a confiança do cliente fosse preservada.

5.3. *Implementação, Monitoramento, Resultados e Validação*

A etapa final do projeto focou na implementação técnica da solução e na mensuração rigorosa de seu impacto. A integração do novo modelo de IA ao canal de chat existente foi realizada, substituindo o sistema anterior. Imediatamente após a implementação, a equipe de dados ativou painéis de controle desenvolvidos na plataforma Microsoft Power BI para o acompanhamento em tempo real dos KPIs presentes na Tabela 1. Este monitoramento contínuo permitiu a rápida identificação de eventuais anomalias e a garantia da estabilidade do serviço.

Para validar o sucesso da intervenção, os dados de desempenho da nova solução foram coletados de forma contínua durante um período de 30 dias. Este recorte temporal foi estabelecido para permitir uma comparação direta e objetiva com a linha de base quantitativa definida na Fase 1, comprovando o retorno sobre o investimento da iniciativa e o cumprimento dos objetivos de melhoria da experiência do cliente e de eficiência operacional.

A validação do impacto da intervenção foi confirmada pela análise comparativa dos indicadores, cujos resultados estão consolidados na Figura 2. Os dados demonstram uma melhoria em todas as métricas de sucesso definidas na fase de planejamento, evidenciando o efeito positivo da nova solução de IA Generativa.

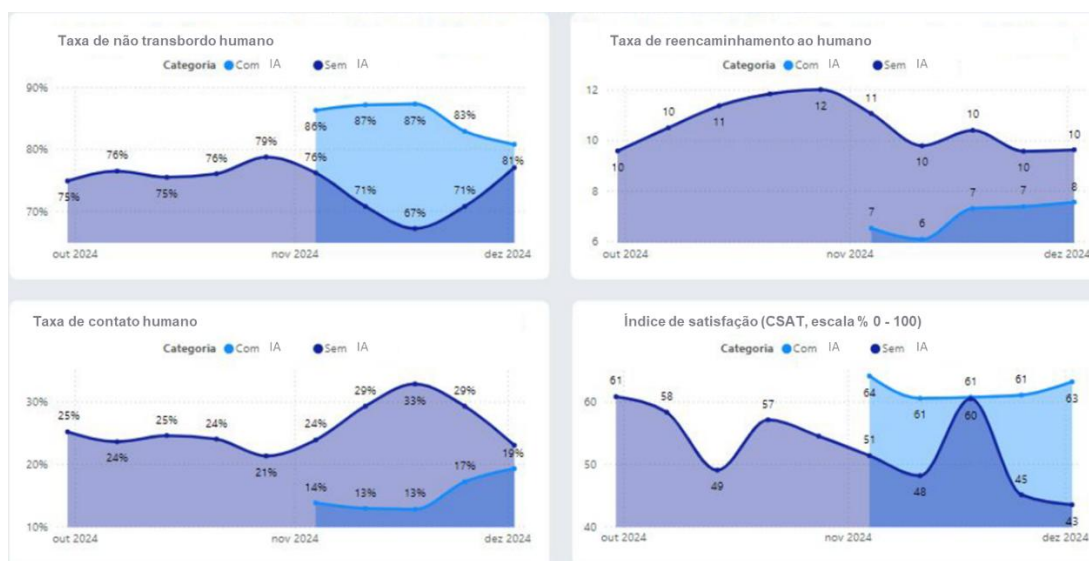


Figura 2. KPIs antes e depois da implementação da IA generativa por mês
Fonte: Dados de pesquisa. Elaborado pelos Autores.

Enquanto a Figura 2 ilustra a evolução mensal dos indicadores, a Tabela 2 oferece uma visão consolidada e direta do impacto geral da intervenção. Ela compara o desempenho médio do atendimento tradicional com o desempenho do novo sistema de IA Generativa ao longo do período de análise, permitindo uma avaliação clara do cumprimento dos objetivos estratégicos definidos para o projeto.

Tabela 2. Indicadores de Desempenho Mensurados Geral

Indicador	Atendimento tradicional	IA generativa
CSAT	48,6%	64,0%
Taxa de contato humano	23,0%	19,0%
Taxa de não transbordo humano	77,0%	81,0%

Taxa de reencaminhamento humano	9,0%	7,0%
---------------------------------	------	------

Fonte: Dados de pesquisa. Elaborado pelos Autores.

Para conferir maior robustez à análise, foi realizado um teste de significância estatística *t-Student* em uma subamostra de 1.000 interações disponibilizadas pela empresa. Os resultados indicaram que as melhorias no índice de satisfação ($p < 0,01$) e na taxa de não transbordo humano ($p < 0,05$) foram estatisticamente significativas, reforçando que a nova tecnologia contribuiu de forma relevante para o desempenho do canal.

Esses dados quantitativos demonstram o duplo benefício da solução implementada. O aumento expressivo no CSAT reflete uma melhora direta na percepção de qualidade e clareza por parte dos clientes sênior. Ao mesmo tempo, a queda de 4 pontos percentuais na taxa de contato humano representa um impacto financeiro relevante para a organização, otimizando a alocação da equipe de atendimento e reduzindo custos operacionais. A solução, se demonstrou ser eficaz tanto na perspectiva do cliente quanto na do negócio.

5.4. Monitoramento Qualitativo de Interações

Para além da validação quantitativa, foi realizada uma análise de conteúdo aprofundada sobre os relatos espontâneos dos clientes, buscando compreender as nuances da experiência com a nova tecnologia. Essa investigação qualitativa, fundamentada na metodologia de Bardin (2011), para contextualizar os indicadores de desempenho e revelar os fatores subjetivos que influenciaram a percepção do público sênior. Os achados foram categorizados em temas centrais que, juntos, pintam um quadro detalhado tanto dos sucessos quanto dos desafios remanescentes da solução implementada.

Um dos temas mais proeminentes foi a percepção de clareza e acolhimento, que validou diretamente a estratégia de curadoria. Clientes que relataram experiências positivas frequentemente destacavam a objetividade e a simplicidade da linguagem como um diferencial decisivo, com comentários como: “*gostei, porque respondeu fácil, sem enrolação*”. Este feedback positivo aponta que o investimento na adaptação do conteúdo, seguindo as diretrizes de Linguagem Simples do PLAIN, foi um fator chave para o aumento do CSAT, ao reduzir a carga cognitiva e aumentar a sensação de competência e autonomia do usuário durante a interação.

Contudo, a análise também expôs desafios significativos relacionados à confiança no sistema, um pilar fundamental para qualquer serviço financeiro. A natureza quase humana da IA Generativa, embora projetada para criar uma experiência mais fluida, paradoxalmente gerou insegurança em parte dos usuários. Essa ambiguidade foi manifestada em perguntas recorrentes como “*isso é uma pessoa ou uma máquina?*”, que não eram meras curiosidades, mas sim expressões de uma incerteza fundamental sobre com quem estavam compartilhando suas informações. Esse estranhamento é consistente com o efeito do Vale da Estranheza, conhecido em inglês como “*Uncanny Valley*” (Mori, 2012), que se trata de um fenômeno psicológico onde a semelhança imperfeita com a comunicação humana, em vez de gerar conforto, provoca uma sensação de desconforto e desconfiança. Para o público sênior, essa incerteza pode ser amplificada, minando a credibilidade do canal e a disposição do cliente em prosseguir com solicitações que envolvam dados sensíveis.

Adicionalmente, a preocupação com a privacidade foi explícita em relatos como “*tenho medo de passar meus dados pra robô*”. Este receio do cliente sênior reflete diretamente os

princípios da Lei Geral de Proteção de Dados (LGPD). A legislação (Lei nº 13.709/2018) estabelece diretrizes para o uso ético e transparente de tecnologias no Brasil, exigindo que sistemas automatizados não apenas protejam os dados, mas também ofereçam clareza sobre suas operações, o que é especialmente crítico no setor financeiro. Portanto, a importância de interfaces que comuniquem ativamente os protocolos de segurança não é apenas uma boa prática de design para construir confiança com um público mais vulnerável a fraudes digitais, mas também uma resposta direta às exigências legais de transparência e segurança.

Finalmente, observou-se que o desempenho da solução era dependente da complexidade da tarefa. Em interações de cunho transacional, que exigiam processar múltiplas solicitações ou compreender perguntas fora do escopo do treinamento, a eficácia do sistema diminuía, aumentando os relatos de frustração. Estes achados indicam que, para o estágio atual da tecnologia, modelos puramente automatizados ainda possuem barreiras.

6. Conclusões e contribuições

A implementação da solução de Inteligência Artificial Generativa, detalhada neste artigo, resultou em consequências diretas e substanciais para a instituição financeira, validando a abordagem sociotécnica como um caminho eficaz para a inovação no atendimento ao cliente (Nwoke, 2024). A consequência mais evidente foi a reversão de um cenário de baixo desempenho para um de sucesso mensurável.

O aumento do índice de satisfação (CSAT) de um patamar crítico de 48,6% para 64% representa uma mudança significativa na percepção de qualidade e valor pelo público sênior. Em paralelo, a redução da taxa de contato humano de 23% para 19% não apenas otimizou a alocação de recursos, mas também comprovou a maior autonomia e capacidade de resolução do novo sistema (veja também Lee, 2023). A análise qualitativa, contudo, oferece um quadro mais nuançado, revelando uma aceitação moderada, onde a clareza da comunicação foi celebrada, mas barreiras de confiança e dificuldades em interações complexas foram identificadas como pontos de atenção contínua.

O principal desdobramento desta iniciativa, e talvez sua contribuição mais relevante para a prática, é o entendimento de que a tecnologia por si só não é a solução. O sucesso do projeto esteve fundamentalmente ancorado no processo de curadoria humana e no design de uma comunicação inclusiva, um desafio prático central na intersecção entre IA Generativa e IA Responsável (Kenthapadi, Lakkaraju, & Rajani, 2023). A análise das interações demonstrou que a IA generativa, em seu estágio atual, ainda possui limitações para interpretar comandos transacionais complexos ou nuances emocionais (Manduchi et al., 2024), o que reforça a necessidade de modelos de serviço híbridos.

A recomendação estratégica que emerge deste estudo é que a automação para públicos sensíveis deve prever pontos de escalonamento fluidos para o atendimento humano em momentos críticos da jornada. Este aprendizado indica que a governança da IA, que envolveu a curadoria de dados, o monitoramento de vieses e a supervisão humana, é tão ou mais importante que a própria tecnologia (Marcus & Davis, 2020), um insight crucial para outras organizações que buscam trilhar um caminho similar.

A contribuição da proposta para a empresa pode ser sintetizada em um conjunto de benefícios estratégicos que se estendem por múltiplas áreas do negócio. Em relação a Melhora da Experiência e Inclusão do Cliente, a solução ofereceu um atendimento mais acessível, digno e eficaz para o público sênior (Msweli & Mawela, 2021). Isso não apenas resultou em maior

satisfação, mas fortaleceu a lealdade de um segmento de alto valor estratégico (Dalmoro & Vittorazzi, 2016), transformando um ponto de atrito em uma oportunidade de relacionamento e reforçando a imagem de uma marca que se preocupa com a inclusão.

Já para a Eficiência Operacional e Retorno sobre o Investimento, a comprovada redução da dependência do atendimento humano se traduz em uma otimização de custos diretos. Ao automatizar demandas de rotina de forma mais inteligente, a solução libera os agentes humanos para se concentrarem em casos de maior complexidade e valor agregado, alinhando-se às expectativas de crescimento e rentabilidade na era digital (McKinsey & Company, 2024), e demonstrando um claro retorno financeiro sobre o investimento em tecnologia e treinamento.

Por fim, considerando a Inovação Responsável e Vantagem Competitiva, ao implementar uma solução que alia tecnologia de ponta com princípios éticos e legais, como a LGPD, a empresa se posiciona como uma referência no setor (ANPD, 2022). Essa abordagem de inovação responsável não apenas mitiga riscos de discriminação algorítmica (Garcia, Garcia, & Rigobon, 2024), mas também cria uma vantagem competitiva ao atender de forma superior um nicho de mercado em crescimento (Camarano & Pasinato, 2004).

Embora os resultados sejam promissores, este estudo possui limitações inerentes a um relato de caso único, e seus achados devem ser contextualizados. Sugere-se que futuras pesquisas explorem os impactos de longo prazo do uso da IA Generativa com diferentes perfis de clientes e em outras geografias. Adicionalmente, investigar a implementação de modelos de "IA explicável", que possam justificar suas respostas de forma transparente, representa um caminho promissor para aprofundar a confiança digital. Em suma, este relato técnico oferece evidências concretas, nos moldes propostos por Motta (2017; 2022), de que a aplicação supervisionada e humanizada da IA Generativa é uma ferramenta viável e eficiente para resolver o dilema entre automação e inclusão no atendimento digital, gerando benefícios tangíveis tanto para o cliente quanto para o negócio.

Referências

- Autoridade Nacional de Proteção de Dados. (2022). *Relatório de Análise de Impacto Regulatório – Inteligência Artificial*. <https://www.gov.br/anpd/pt-br/assuntos/noticias/anpd-publica-relatorio-de-analise-de-impacto-regulatorio-sobre-inteligencia-artificial>
- Autoridade Nacional de Proteção de Dados. (2022). *Relatório do Ciclo de Diálogos com a Sociedade sobre Inteligência Artificial e Proteção de Dados Pessoais*. https://www.gov.br/anpd/pt-br/documentos-e-publicacoes/relatorio_ciclo_dialogos_ia.pdf
- Barbosa, M. C., Lima, J. S., & Andrade, R. M. (2022). Interação homem-máquina e a inclusão digital da população idosa: Desafios para o design de sistemas inteligentes. *Revista Tecnologia e Sociedade*, 18(47), 121–137. <https://doi.org/10.3895/rts.v18n47.14569>
- Bardin, L. (2016). *Análise de conteúdo*. Edições 70.
- Belluzzo, R. R. (2020). *Gestão da informação e do conhecimento nas organizações* (2. ed.). Saraiva Educação.

- Camarano, A. A., & Pasinato, M. T. (2004). O envelhecimento populacional na agenda das políticas públicas. In A. A. Camarano (Org.), *Os novos idosos brasileiros: Muito além dos 60?* (pp. 256-292). Ipea.
- Chaouali, W., & Souiden, N. (2019). The role of cognitive age in explaining mobile banking resistance among elderly people. *Journal of Retailing and Consumer Services*, 50, 342–350. <https://doi.org/10.1016/j.jretconser.2018.07.009>
- Dalmoro, M., & Vittorazzi, K. (2016). Trajetórias de consumo: O sujeito-consumidor de serviços bancários na terceira idade. *Revista de Administração Contemporânea*, 20(3), 328–346. <https://doi.org/10.1590/1982-7849rac2016140059>
- Deloitte & Febraban. (2025). *Pesquisa Febraban de Tecnologia Bancária 2025* (Vol. 2). https://cmsarquivos.febraban.org.br/Arquivos/documentos/PDF/Pesquisa%20Febraban%20de%20Tecnologia%20Banca%CC%81ria%202025%20-%20Vol_2%20-%20VF.pdf
- Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2024). Generative AI. *Business & Information Systems Engineering*, 66(1), 111-126. <https://doi.org/10.1007/s12599-024-00843-1>
- Feyen, E., Frost, J., Gambacorta, L., Natarajan, H., & Saal, M. (2021). *Fintech and the digital transformation of financial services: Implications for market structure and public policy* (BIS Papers No. 117). Bank for International Settlements.
- Garcia, A. C. B., Garcia, M. G. P., & Rigobon, R. (2024). Algorithmic discrimination in the credit domain: What do we know about it? *AI & SOCIETY*, 39(4), 2059-2098. <https://doi.org/10.1007/s00146-022-01450-x>
- Instituto Brasileiro de Geografia e Estatística. (2023). *Pesquisa Nacional por Amostra de Domicílios Contínua: Tecnologia da informação e comunicação 2022*. <https://www.ibge.gov.br>
- Iusztin, P., & Labonne, M. (2024). *LLM engineer's handbook: Master the art of engineering large language models from concept to production*. Packt Publishing Ltd.
- Kenthapadi, K., Lakkaraju, H., & Rajani, N. (2023, August). Generative AI meets responsible AI: Practical challenges and opportunities. In *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining* (pp. 5805-5806). ACM. <https://doi.org/10.1145/3580305.3599522>
- Lee, C. M. (2023). *Formulated Quality Assurance (QA) and Customer Satisfaction (CSAT) scorecards indexing and inference research information from the Business Process Outsource (BPO) workplace*. SSRN. <https://doi.org/10.2139/ssrn.4854813>

- Manduchi, L., Pandey, K., Meister, C., Bamler, R., Cotterell, R., Däubener, S., Groh, R., Hennig, P., Schölkopf, B., & Fortuin, V. (2024). *On the challenges and opportunities in generative AI*. arXiv preprint arXiv:2403.00025.
- Marcus, G., & Davis, E. (2020). *Rebooting AI: Building artificial intelligence we can trust*. Pantheon Books.
- McKinsey & Company. (2023, 11 de abril). *Why most digital banking transformations fail—and how to flip the odds*. <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/tech-forward/why-most-digital-banking-transformations-fail-and-how-to-flip-the-odds>
- McKinsey & Company. (2024, 10 de outubro). *The state of retail banking: Profitability and growth in the era of digital and AI*. <https://www.mckinsey.com/industries/financial-services/our-insights/the-state-of-retail-banking-profitability-and-growth-in-the-era-of-digital-and-ai>
- Mori, M. (2012). The uncanny valley. *IEEE Robotics & Automation Magazine*, 19(2), 98–100. <https://doi.org/10.1109/MRA.2012.2192811>
- Motta, G. S. (2017). Como escrever um bom artigo tecnológico? *Revista de Administração Contemporânea*, 21(5), 1-6. <https://doi.org/10.1590/1982-7849rac2017170258>
- Motta, G. S. (2022). O que é um artigo tecnológico? *Revista de Administração Contemporânea*, 26(1), e220208. <https://doi.org/10.1590/1982-7849rac2022220208.por>
- Msweli, N. T., & Mawela, T. (2021). Financial inclusion of the elderly: Exploring the role of mobile banking adoption. *Acta Informatica Pragensia*, 10(1), 1-21. <https://doi.org/10.18267/j.aip.152>
- Nwoke, J. (2024). Digital transformation in financial services and FinTech: Trends, innovations, and emerging technologies. *International Journal of Finance*, 9(6), 1–24. <https://doi.org/10.47941/ijf.2224>
- OpenAI. (n.d.). *Models*. Retrieved June 13, 2025, from <https://platform.openai.com/docs/models>
- Pfeffer, J., & Sutton, R. I. (2006). Evidence-based management. *Harvard Business Review*, 84(1), 62–74.
- Plain Language Association International. (2022). *Guidelines for plain language*. <https://plainlanguagenetwork.org>
- Russell, S. J., & Norvig, P. (2022). *Inteligência artificial* (4. ed.). Pearson.

- Santos, J. M. A. D. (2023). *Os afetos gerados a partir do autosserviço das organizações bancárias na vida da população idosa* [Trabalho de Conclusão de Curso - TCC]. Repositório Institucional da UFPE. <https://repositorio.ufpe.br/handle/123456789/53610>
- SAS. (2024). *Desafios e potenciais da IA generativa no Brasil*. <https://www.sas.com/content/dam/SAS/documents/marketing-whitepapers-ebooks/ebooks/pt/pt-ia-generativa-113981.pdf>