

Escala de avaliação da codestruição de valor em interações com chatbots de atendimento habilitados por inteligência artificial: perspectiva do cliente

ELAINY CRISTINA DA SILVA COELHO
INSTITUTO FEDERAL DO TOCANTINS

JOSIVANIA SILVA FARIAS
UNIVERSIDADE DE BRASÍLIA (UNB)

Escala de avaliação da codestruição de valor em interações com chatbots de atendimento habilitados por inteligência artificial: perspectiva do cliente

Introdução

Chatbots habilitados por inteligência artificial (IA) estão sendo utilizados cada vez mais nos ecossistemas de serviço para atendimento e comunicação com clientes (Lee et al., 2023). Esses agentes virtuais de conversação, também conhecidos como robôs de serviço, atuam na linha de frente da prestação de serviço (Larivière et al., 2017), substituindo ou complementando o trabalho humano em transações recorrentes (Wirtz et al., 2018). A IA, definida como máquinas que simulam capacidades de inteligência humana, tem se desenvolvido a ponto de realizar tarefas mecânicas, de pensamento e de sentimento (Huang & Rust, 2022a). Nesse contexto, os chatbots com IA conseguem simular conversas humanas, processando e respondendo em linguagem natural.

A IA possibilita a automatização do atendimento ao extrapolar as funcionalidades de outras tecnologias da informação, dadas as capacidades de aprendizado, conexão e adaptação (Huang & Rust, 2021). Ao substituir funcionários, a IA modifica os processos de formação de valor e a forma como o valor é experienciado (Corsaro et al., 2022), apresentando tanto potencial para a cocriação quanto para a codestruição de valor (Caic et al., 2018; Neuhofer et al., 2021). Do lado positivo, na cocriação, o valor é criado colaborativamente pelos atores por meio da integração de recursos diferenciados (Vargo & Lusch, 2016). Em contraste, a codestruição ocorre quando há má integração de recursos durante o encontro de serviço, resultando em experiências negativas (Echeverri & Skålén, 2021).

A utilização da IA é promissora ao permitir atendimento ininterrupto, alta personalização, agilidade, redução de custos e atendimento em escala (Castelo et al., 2023; Lalicic & Weismayer, 2021; Payne et al., 2021). Contudo, falhas no atendimento realizado pela IA são comuns, e comprometem a experiência do cliente, levando a sentimentos negativos (Caic et al., 2018; Castelo et al., 2023; Neuhofer et al., 2021). Por exemplo, problemas como interpretações equivocadas e respostas inadequadas geram frustração com o chatbot (Følstad & Brandtzaeg, 2020; Xing et al., 2022). Assim, as interações malsucedidas com chatbots de IA podem resultar em codestruição de valor ao causarem raiva, confusão e descontentamento no cliente, comprometendo a integração de recursos e a interação necessária para a formação positiva de valor (Castillo et al., 2021).

A avaliação da codestruição de valor contribui para evitar o mal-estar nas relações de serviço e para identificar pontos críticos que comprometem a experiência dos clientes. Contudo, as pesquisas sobre esse construto têm recebido menos atenção em comparação à cocriação de valor, resultando em um campo ainda em desenvolvimento (Coelho & Farias, 2024).

As escalas existentes oferecem uma base relevante para a compreensão da codestruição de valor (Guan et al., 2020, 2022; Kong et al., 2024; Ogunbodede et al., 2022; Yi & Gong, 2013). Contudo, observa-se uma lacuna de instrumentos capazes de captar as particularidades do construto de forma bidirecional em interações entre clientes e chatbots de atendimento habilitados por IA. Assim, este trabalho busca responder às seguintes questões de pesquisa: quais são as dimensões do comportamento de codestruição de valor em interações de clientes com chatbots de atendimento habilitados por IA? Como medir o comportamento de codestruição de valor em tais interações?

Diante do exposto, o presente trabalho tem o objetivo de obter evidências de validade e confiabilidade científica de uma escala de medição do comportamento de codestruição de valor em interações com chatbots de atendimento habilitados por IA, com base na perspectiva do cliente. A proposição de uma nova escala justifica-se pela complexidade do fenômeno no contexto da IA e pelo fato de as escalas existentes serem voltadas principalmente para

relacionamentos interpessoais (Guan et al., 2022, 2022; Ogunbodede et al., 2022), ou para a avaliação de uma perspectiva unilateral do conceito (Kong et al., 2024).

Ao propor uma escala de medição em interações com chatbots habilitados por IA, este artigo visa preencher uma lacuna de pesquisa, avançando na compreensão de aspectos negativos da formação de valor, e contribuindo para o avanço teórico e prático na área. Como ferramenta prática, a escala pode auxiliar gestores na avaliação do uso de chatbots de atendimento ao cliente, fornecendo informações para a melhoria do serviço. Além disso, o estudo atende ao chamado de pesquisadores que solicitaram mais pesquisas para ampliar a compreensão sobre as interações entre humanos e a IA (De Keyser & Kunz, 2022; Robinson et al., 2020).

Fundamentação teórica

Cocriação de valor e codestruição de valor

Para a Lógica Dominante do Serviço (LDS), proposta por Vargo e Lusch (2004), o valor é colaborativamente criado, ou seja, cocriado na troca de serviço pelos interagentes. A cocriação de valor é um axioma da respectiva perspectiva teórica, sendo conceituada como a ampliação do bem-estar mútuo dos atores na interação de serviço, e ocorre por meio da integração de recursos (Vargo & Lusch, 2016). O valor é sempre cocriado pelos atores (Vargo & Lusch, 2017), e definido de forma única pelo beneficiário, a partir da sua experiência (Vargo & Lusch, 2016). A cocriação de valor depende das atividades de troca de serviço e da integração de recursos dos atores (Vargo & Lusch, 2017), sendo, portanto, responsabilidade não apenas de parte, mas de todos os interagentes. Para isso, são integrados recursos *operant*, como conhecimento e habilidades, e recursos *operand*, como bens e recursos naturais (Vargo & Lusch, 2016).

Vargo, Peters, et al. (2023, p. 7) citam, num contexto de emergência do marketing, que o valor pode ser conceituado como “uma mudança, positiva ou negativa, na viabilidade ou bem-estar de um sistema”. Apesar deste entendimento de variação de valor num sentido negativo, a LDS segue uma visão excessivamente otimista, não considerando controvérsias que desequilibram os encontros de serviço e que levam a uma redução do valor (X. Wang et al., 2019), isto é, podem resultar na codestruição de valor (Echeverri & Skålén, 2021; Plé & Cáceres, 2010). A codestruição de valor é conceituada “como um processo de interação entre sistemas de serviços que resulta em um declínio no bem-estar de pelo menos um dos sistemas (que, dada a natureza do sistema de serviços, pode ser individual ou organizacional)” e ocorre pelo mau uso de recursos próprios ou alheios, ou de ambos (Plé & Cáceres, 2010, p. 431).

A codestruição implica que os atores de um relacionamento de serviço podem ter resultados negativos que afetam o seu bem-estar (Järvi et al., 2018) e a percepção de benefícios é reduzida. Echeverri e Skålén (2011, p. 367) passaram a considerar a codestruição de valor como elemento constitutivo da formação interativa de valor (FIV), na qual a ocorrência se dá a partir de incongruência em elementos das práticas, isto é, “quando provedores e clientes não concordam em quais procedimentos, entendimentos e engajamentos devem informar uma interação específica”. O fenômeno da codestruição abarca perda, bem como uma gradação da minimização do valor (Echeverri & Skålén, 2011), podendo haver uma redução/diminuição do valor sem configurar perda irreparável. Ressalta-se que a codestruição de valor é resultante de uma relação de serviço interativa (Prior & Marcos-Cuevas, 2016).

Em experiências de serviço, os clientes podem experimentar eventos de codestruição de valor devido aos problemas na integração de recursos (Laud et al., 2019; Plé, 2016; Smith, 2013). O uso indevido ou a deficiência de recursos nas interações de serviços poderá ocorrer tanto do lado do cliente, como do lado do provedor (Smith, 2013; Vafeas et al., 2016), consequentemente, resultando em codestruição de valor para um dos atores ou para ambos (Plé & Cáceres, 2010). Além disso, o uso indevido de recursos pode ser intencional ou não intencional (Plé & Cáceres, 2010).

Escalas e comportamentos de codestruição de valor

As escalas de medição da codestruição de valor são ainda limitadas na literatura, tendo sido identificados os trabalhos de Guan et al. (2020), Ogunbodede et al. (2022), Guan, Gong, Liu, et al. (2022) e, mais recentemente, (Kong et al., 2024), conforme resumido na Figura 1. Essas escalas apresentam abordagens distintas para a avaliação do comportamento de codestruição de valor, cobrindo diferentes contextos e dimensões.

Figura 1 - Escalas de codestruição de valor

Escala	Dimensões da escala	Referências
Comportamento de codestruição do consumidor no turismo na perspectiva funcionário-cliente	Comportamento de comunicação interpessoal ruim, comportamento de interação ruim com informações, comportamento irresponsável do cliente, comportamento de violação de contrato do funcionário, e comportamento irresponsável do funcionário.	Guan et al. (2020)
Comportamento de codestruição do consumidor	Ignorando informações, informações retidas, interação impessoal, comportamento irresponsável, avaliação negativa, oposição, negligência e intolerância	Ogunbodede et al. (2022)
Comportamento de codestruição de valor no contexto de atendimento business-to-customer.	Mau comportamento de integração de recursos dos funcionários, mau comportamento de integração de recursos do cliente, mau comportamento de interação interpessoal dos funcionários, e mau comportamento de interação interpessoal do cliente.	Guan, Gong, Liu, et al. (2022)
Comportamentos de codestruição de valor do cliente em encontros de serviços inteligentes	Comportamentos de negligência e não participação, e mau uso e comportamentos perturbadores	Kong et al. (2024)

Fonte: elaborada pelas autoras.

Guan et al. (2020) desenvolveram uma escala voltada ao turismo, focada na perspectiva funcionário-cliente. Ogunbodede et al. (2022), por sua vez, adaptaram uma escala de Yi e Gong (2013), originalmente voltada ao comportamento de cocriação de valor, invertendo os itens para avaliar a codestruição de valor. Já Guan, Gong, Liu, et al. (2022) propuseram uma escala para o contexto de atendimento *business-to-customer*, identificando dimensões relacionadas a comportamentos ruins de integração de recursos e de interação interpessoal entre funcionários e clientes. E Kong et al. (2024) elaboraram uma escala direcionada ao comportamento de codestruição de valor em serviços inteligentes, destacando negligência, mau uso e comportamentos perturbadores.

Comportamento de codestruição de valor em interações com IA no atendimento

Ao substituir humanos em encontros de serviço, a IA se configura como um ator não humano autônomo (Grundner & Neuhofer, 2021; Neuhofer et al., 2021). Todavia, assim como as interações entre atores humanos, as interações com a IA também estão sujeitas à codestruição de valor (Castillo et al., 2021; Coelho & Farias, 2024; Neuhofer et al., 2021).

A codestruição de valor é observada no mau funcionamento das plataformas habilitadas por IA (Neuhofer et al., 2021), e o comportamento e as capacidades de conversação dos robôs de serviço impactam as atitudes e as percepções dos consumidores (De Keyser & Kunz, 2022). No relacionamento com a IA, devido às falhas ou às inseguranças dos sistemas, os clientes podem ter sentimentos de medo, ansiedade e suspeita (Neuhofer et al., 2021). Os chatbots podem apresentar problemas de cognição nos diálogos, não compreendendo adequadamente o que é mencionado ou perguntado pelo ator humano (Castillo et al., 2021). Nesse sentido, há relatos sobre o chatbot ser repetitivo em perguntas e respostas (Følstad & Brandtzaeg, 2020). Problemas na interação também dependem da participação dos beneficiários. Assim, usuários

podem se opor a cooperar com robôs de serviço (Caic et al., 2018), bem como utilizar uma linguagem rude ao interagirem com a IA (Hill et al., 2015).

A codestruição de valor é manifestada nos processos de interação social e integração de recursos (Cabiddu et al., 2019; Guan, Gong, Liu, et al., 2022; M. Li & Tuunanen, 2022). Assim, o comportamento de codestruição de valor em interações com chatbots de atendimento habilitados por inteligência artificial pode ser definido como atos negativos de atores humanos e atores de IA na interação de serviço, que reduzem o valor e se manifestam pela má integração de recursos e pelas dificuldades de interação social.

Diante do exposto, e com base no trabalho de Guan, Gong, Liu, et al. (2022), as dimensões mais apropriadas que abarcam o fenômeno são: mau comportamento de integração de recursos do chatbot (MCIR-BOT); mau comportamento de integração de recursos do cliente (MCIR-CLI), mau comportamento de interação social do chatbot (MCIS-BOT) e mau comportamento de interação social do cliente (MCIS-CLI). Considerando que a codestruição de valor resulta de uma relação interativa entre os atores, as dimensões devem estar associadas às responsabilidades tanto do cliente quanto dos chatbots de atendimento. Ressalta-se que a escala será respondida pelos clientes, uma vez que o valor é determinado pelo beneficiário (Vargo & Lusch, 2016).

No contexto da pesquisa sobre cocriação e codestruição de valor, verificou-se que os elementos da interação social são compostos pela comunicação e pelo diálogo (Li & Tuunanen, 2022), mais especificamente diálogo conflituoso e comunicação inadequada (Vafeas et al., 2016). E com base em Laud et al. (2019), o mau comportamento de integração de recursos se deve à carência ou ao mau uso de recursos, e possui as seguintes subdimensões: ausência de acesso aos recursos, dificuldades de adaptação dos recursos para integração, e problemas na combinação e na aplicação de recursos.

Desenvolvimento da escala

Escala são desenvolvidas para mensurar construtos, que são conceitos definidos teoricamente e representados por itens — expressões que indicam o comportamento do construto (Pasquali, 2010). O protocolo adotado para o desenvolvimento da escala seguiu as seguintes etapas: (i) elaboração da tabela de referência, (ii) validade de conteúdo, e (iii) validade baseada na estrutura interna (American Educational Research Association et al., 2014; Churchill, 1979; Netemeyer et al., 2003; Pasquali, 2010).

Elaboração da tabela de referência - construção dos itens

Para a elaboração da tabela de referência, foi realizada uma revisão da literatura para identificar as definições constitutivas e operacionais do construto “comportamento de codestruição de valor” (Hair et al., 2019; Pasquali, 2010). Foram utilizadas como referência as escalas de comportamento de codestruição de valor já validadas em outros contextos, conforme as orientações de Pasquali (2010). Na sequência, a revisão abordou a codestruição de valor e suas evidências em interações de serviços habilitados por inteligência artificial, com foco específico nas interações com chatbots de atendimento. Dessa forma, foram elaborados 40 itens, distribuídos nas quatro dimensões: MCIR-BOT, MCIS-BOT, MCIR-CLI e MCIS-CLI.

Validade de conteúdo

Análise de juízes/experts

A validade de conteúdo busca garantir que os itens representem o domínio teórico do construto (Netemeyer et al., 2003). Para isso, pesquisadores da área, com titulação de doutor(a),

e profissionais com notório saber e experiência sobre a temática foram convidados a avaliar os itens levantados e sua adequação/pertinência ao construto (Pasquali, 2010). Dessa forma, cinco juízes, especialistas no tema e no uso de tecnologias de inteligência artificial, avaliaram os itens.

Os juízes avaliaram a clareza da linguagem, considerando quão compreensível é o item, a relevância teórica, verificando se o item representa o construto ou comportamento, e a pertinência prática, avaliando se o item é relevante para o instrumento (Hernández-Nieto, 2002). Para isso, os juízes responderam a uma planilha utilizando uma escala do tipo Likert de 1 a 5, variando de 'nada claro' a 'totalmente claro', 'nada relevante' a 'totalmente relevante', e 'nada pertinente' a 'totalmente pertinente'. Além disso, foi permitido aos juízes sugerir reformulações, exclusões ou inclusões de itens (Pasquali, 2010).

Para a análise dos dados da avaliação do conteúdo do instrumento pelos juízes, foi utilizado o Coeficiente de Validade de Conteúdo (CVC) desenvolvido por Hernández-Nieto (2002), considerando-se adequados os valores de CVC, por item e global, iguais ou superiores a 0,80. Como resultado, nove itens foram excluídos e sete foram reformulados em algum grau. O CVC geral do instrumento foi de 0,92. Dessa forma, 31 itens foram selecionados para a fase seguinte.

Análise semântica e pré-teste

Nesta etapa, foram realizadas avaliações semânticas com 24 potenciais respondentes da escala, com o objetivo de obter a validade facial do instrumento, ou seja, uma adequação em termos de aparência e compreensão (Netemeyer et al., 2003). A amostra desta fase foi definida por saturação teórica (Falqueto et al., 2018). Os respondentes foram convidados a avaliar se os itens eram compreensíveis em termos semânticos e se não geravam dúvidas. Como resultado, oito itens tiveram a redação adaptada e um foi excluído, devido à indicação de sobreposição de conteúdo relatada em mais de um formulário.

Na sequência, foi aplicado um pré-teste para aprovar a versão piloto da escala (Malhotra, 2019). Esse pré-teste foi realizado com 10 clientes que já haviam utilizado chatbots de atendimento e relataram experiências negativas. Não houve qualquer problema no pré-teste, e 30 itens seguiram para a avaliação pela população-alvo.

Validade baseada na estrutura interna

Para verificar se os dados empíricos representam a estrutura teórica, foram coletadas duas amostras distintas: uma para a realização da Análise Fatorial Exploratória (AFE) e outra para a confirmação da estrutura da medida por meio da Análise Fatorial Confirmatória (AFC). Em ambas as análises, a adequação da estrutura fatorial foi avaliada com base no agrupamento dos itens, nos índices de ajuste e nas medidas de confiabilidade.

Descrição das amostras

Os dados foram coletados por meio de pesquisa de campo com recorte transversal, utilizando questionários com as versões da escala, antes do refinamento (amostra 1) e após o refinamento (amostra 2). A amostragem foi do tipo não probabilística por conveniência, por ser adequada quando as populações são amplas ou tendem ao infinito (Cochran, 1991), como ocorre neste estudo, considerando a crescente utilização de chatbots para atendimento ao cliente (Mobile Time, 2023).

Para a aplicação do instrumento de pesquisa, foi utilizada uma escala tipo Likert de sete pontos (Likert, 1932), reconhecida por proporcionar maior sensibilidade às respostas e captar nuances nas percepções dos participantes. Assim, as afirmações puderam ser avaliadas em uma gradação de 1 (discordo totalmente) a 7 (concordo totalmente). Além da versão piloto da escala,

o instrumento incluiu uma carta-convite, o Termo de Consentimento Livre e Esclarecido, e questões sociodemográficas para caracterização da amostra.

O critério de inclusão dos respondentes na pesquisa consistia em responder à pergunta: “Você já teve alguma experiência negativa com chatbots habilitados por inteligência artificial, ou seja, que aceitam o uso de linguagem natural, como se estivesse escrevendo ou falando para uma pessoa?”. Assim, a coleta de dados foi direcionada a clientes que afirmaram ter tido experiências negativas em interações com chatbots de atendimento habilitados por IA.

Para a amostra 1, os questionários foram aplicados online por meio da plataforma *Microsoft Forms*, utilizando a técnica de bola de neve. Essa técnica envolveu a distribuição do instrumento com um convite à participação e o pedido para que os respondentes o repassassem a outras pessoas elegíveis, repetindo-se o processo até alcançar o tamanho amostral desejado (Johnson, 2014). Para ampliar o alcance, utilizaram-se estratégias de recrutamento online, como divulgação em redes sociais e envio de convites por e-mail. A amostra 1 foi composta por 226 observações, atendendo ao critério mínimo de cinco respondentes por item da escala (Hair et al., 2019; Pasquali, 2010).

Para a composição da amostra 2, a coleta de dados foi realizada presencialmente nas cidades de Brasília/DF, Goiânia/GO e Palmas/TO. A escolha dessas cidades se deu pela facilidade de acesso, conveniência e também como forma de diversificar a amostra. Utilizou-se um questionário autoaplicável, aplicado junto a potenciais participantes em locais de grande circulação, como aeroportos, rodoviárias e *shopping centers*. Após confirmarem experiências negativas com chatbots de atendimento, os participantes foram convidados a responder ao questionário, podendo optar pela versão impressa ou digital, acessada via *QR Code* ou *link*. No total, 462 respostas foram obtidas, sendo que, após o tratamento dos dados e verificações para a AFC (Tabachnick & Fidel, 2019), 394 observações compuseram a amostra 2. Essa quantidade atendeu ao critério de 10 a 20 respondentes por item da escala (Hair et al., 2018; Kline, 2015). As características demográficas das amostras estão apresentadas na Tabela 1.

Ressalta-se que esta pesquisa não foi submetida à apreciação pelos Comitês de Ética em Pesquisa (CEP) e pela Comissão Nacional de Ética em Pesquisa (CONEP). Conforme a Resolução nº 510/2016 do Conselho Nacional de Saúde, pesquisas de opinião pública que assegurem o anonimato e a confidencialidade dos sujeitos estão dispensadas de tais trâmites (Conselho Nacional de Saúde, 2016).

Tabela 1 - Características demográficas das amostras

Variáveis	Categorias	Amostra 1 (AFE)		Amostra 2 (AFC)	
		n = 226	%	n = 394	%
Gênero	Feminino	124	54,87%	194	49,24%
	Masculino	100	44,25%	195	49,49%
	Outro	1	0,44%	4	1,02%
	Preferiu não dizer	1	0,44%	1	0,25%
Idade	18-24 anos	25	11,06%	82	20,81%
	25-34 anos	48	21,24%	118	29,95%
	35-44 anos	83	36,73%	110	27,92%
	45-54 anos	48	21,24%	49	12,44%
	55-64 anos	16	7,08%	28	7,11%
	65 anos ou mais	6	2,65%	7	1,78%
Nível de escolaridade	Ensino fundamental	2	0,88%	3	0,76%
	Ensino médio	31	13,72%	93	23,60%
	Graduação (ensino superior)	37	16,37%	175	44,42%
	Pós-graduação	156	69,03%	123	31,22%

Fonte: dados da pesquisa de campo.

Análise Fatorial Exploratória (AFE)

Inicialmente, a AFE foi empregada para a purificação da escala do comportamento de codestruição de valor na interação com chatbots de IA, permitindo identificar fatores consistentes do construto (Churchill, 1979; Rossiter, 2002). Trata-se de uma técnica multivariada utilizada para verificar quais itens explicam cada fator (Field et al., 2012). Nessa abordagem, não se utilizam informações prévias sobre a associação dos itens aos construtos, uma vez que a análise é guiada pelos dados, que revelam os fatores (variáveis latentes) com base no compartilhamento de variância (Tabachnick & Fidel, 2019).

Para a realização da AFE, foi utilizado o *software Factor*, que possui ampla gama de recursos, como métodos de retenção de fatores, técnicas de rotação e índices de ajuste (Damásio et al., 2021). A fatorabilidade da matriz de dados foi avaliada por meio de dois testes para a aplicação e validade da AFE: o índice *Kaiser-Meyer-Olkin* (KMO) e o teste de esfericidade de Bartlett. Valores superiores a 0,60 no índice KMO indicam que o tamanho da amostra é suficiente para a aplicação da AFE (Kerlinger & Lee, 2008). Por sua vez, o teste de esfericidade de Bartlett avalia se os dados apresentam correlações suficientes entre os itens para justificar o uso da AFE, sendo necessário que o teste seja significativo ($p < 0,05$) (Hair, Gabriel, et al., 2019). Os resultados obtidos no teste de esfericidade de Bartlett ($\chi^2 = 2461,8$, $gl = 465$, $p < 0,001$) e no índice KMO (0,64) indicaram que a matriz de correlação dos itens é adequada para a aplicação e interpretação da AFE.

A AFE foi conduzida utilizando uma matriz policórica e o método de extração *Robust Diagonally Weighted Least Squares* (RDWLS) (Asparouhov & Muthen, 2010). A definição do número de fatores a serem retidos foi baseada na técnica de análise paralela com permutação aleatória dos dados observados (Timmerman & Lorenzo-Seva, 2011), pois é considerada adequada e confiável em 92% dos casos (Laros e Puente-Palacios, 2004). Para a rotação, foi aplicado o método Robust Promin (Lorenzo-Seva & Ferrando, 2019). A análise paralela indicou a retenção de quatro fatores como adequados para representar os itens, conforme demonstrado na Tabela 2. Destaca-se que o critério dos autovalores (Field et al., 2012) corroborou essa decisão, pois quatro fatores apresentaram autovalores superiores a 1.

Tabela 2 - Resultados da análise paralela

Fatores	Variância explicada dos dados reais	Variância explicada dos dados aleatórios (95% IC)
1	25.5444*	7.8054
2	17.0617*	7.0998
3	7.4026*	6.5702
4	6.5659*	6.1844
5	4.7012	5.8693

Nota: O número de fatores a ser retido é quatro, pois quatro fatores dos dados reais apresentam % de variância explicada maior do que os dados aleatórios. Foram apresentadas apenas as linhas iniciais que são suficientes para identificar o número de fatores.

Fonte: elaborada pela autora com base nos dados da pesquisa.

A avaliação da adequação do modelo foi realizada utilizando os índices de ajuste *Root Mean Square Error of Approximation* (RMSEA), *Comparative Fit Index* (CFI) e *Tucker-Lewis Index* (TLI). De acordo com a literatura, os valores de RMSEA devem ser inferiores a 0,08, com o intervalo de confiança não ultrapassando 0,10. Já os valores de CFI e TLI devem ser superiores a 0,90, sendo preferível que alcancem 0,95 (Brown, 2015). Com base nesses critérios, os índices de ajuste da escala foram considerados apropriados, todos contabilizados em um intervalo de confiança de 95%. O índice RMSEA foi de 0,000, classificado como excelente. Os demais índices também demonstraram um ajuste adequado ($\chi^2 = 328,17$, $gl = 430$; $p = 0,999$; CFI = 0,999; TLI = 1,030).

Tabela 3 - AFE do comportamento de codestruição de valor em interações com chatbots de atendimento habilitados por IA

ITENS	F1	F2	F3	F4
MCIR-BOT: Mau comportamento de integração de recursos do chatbot				
IRB1 - O chatbot não entendeu o que eu escrevi/falei	0.581	0.026	-0.100	0.050
IRB2 - O chatbot me forneceu informações desnecessárias ou que não possuíam relação com a minha solicitação	0.691	0.056	0.016	0.041
IRB3 - O chatbot respondeu meus questionamentos de forma incompleta	0.738	0.001	0.054	-0.041
IRB4 - O chatbot forneceu informações incorretas**	0.489	-0.087	0.321	-0.022
IRB5 - A minha solicitação não foi atendida pelo chatbot	0.627	-0.019	-0.203	0.173
IRB6 - O tempo de atendimento realizado pelo chatbot foi demorado**	0.419	0.035	0.368	-0.257
IRB7 - O chatbot transferiu a conversa para um atendente humano, devido à sua incapacidade de atender à minha solicitação*	0.274	0.165	0.049	-0.025
IRB8 - O chatbot ficou repetindo respostas excessivamente	0.686	-0.061	0.165	0.077
IRB9 - O chatbot não me direcionou para atendimento humano quando solicitado**	0.545	-0.077	0.278	0.003
IRB10 - O chatbot solicitou grande quantidade de dados pessoais para seguir com o atendimento*	0.441	-0.031	0.529	-0.133
IRB11 - O chatbot falhou em reconhecer que eu estava ficando frustrado(a) ou irritado(a), e continuou com a mesma forma de interação	0.514	-0.012	-0.000	0.167
MCIR-CLI: Mau comportamento de integração de recursos do cliente				
IRC1 - Tenho pouco conhecimento para lidar com o chatbot	0.115	0.733	-0.096	-0.067
IRC2 - Eu não forneci informações suficientes ao chatbot	0.032	0.837	-0.230	-0.120
IRC3 - Eu não compreendi adequadamente como lidar com o chatbot	0.174	0.951	-0.142	-0.057
IRC4 - Eu não segui as orientações fornecidas pelo chatbot	0.024	0.881	-0.039	0.000
IRC5 - Eu não expressei claramente as minhas necessidades ao chatbot**	-0.017	0.830	-0.021	0.076
IRC6 - Eu forneci intencionalmente informações incorretas ou enganosas ao chatbot**	-0.126	0.514	0.427	-0.020
IRC7 - Eu não forneci informações no tempo adequado	-0.073	0.662	0.113	0.113
IRC8 - Eu não me esforcei para interagir com o chatbot**	-0.094	0.681	0.080	0.137
IRC9 - Eu tratei sobre diferentes assuntos ao mesmo tempo com o chatbot	-0.171	0.487	0.256	0.097
MCIS-BOT: Mau comportamento de interação social do chatbot				
ISB1 - O chatbot me interrompeu repetidamente, não permitindo que eu terminasse perguntas ou explicações	0.336	0.170	0.527	-0.145
ISB2 - O chatbot utilizou linguagem desrespeitosa ou rude**	-0.239	0.052	0.737	0.093
ISB3 - A linguagem do chatbot pareceu insensível às minhas emoções	0.242	-0.077	0.419	0.180
ISB4 - O chatbot utilizou linguagem que pode ser vista como agressiva ou ofensiva**	-0.212	0.040	0.711	0.013
ISB5 - O atendimento foi encerrado pelo chatbot de forma repentina ou inesperada	0.247	-0.162	0.474	0.101
MCIS-CLI: Mau comportamento de interação social do cliente				
ISC1 - Eu usei linguagem desrespeitosa ou rude durante a conversa com o chatbot**	-0.126	0.038	0.570	0.363
ISC2 - Eu culpei o chatbot pela dificuldade de comunicação	-0.069	-0.030	0.036	0.667
ISC3 - Fiz comentários ao chatbot que poderiam ser interpretados como agressivos ou ofensivos**	-0.098	-0.023	0.541	0.463
ISC4 - Eu abandonei a conversa ao ficar frustrado(a) com o chatbot	0.184	-0.003	-0.114	0.643
ISC5 - Eu perdi a paciência com o chatbot	0.258	0.050	-0.056	0.676
Confiabilidade Composta	0,828	0,915	0,715	0,703
H-latent	0,888	0,938	0,890	0,801
H-observed	0,915	0,878	0,744	0,720

Nota: * itens excluídos na AFE. **itens excluídos na AFC.

Fonte: elaborada pela autora com base nos dados da pesquisa.

As cargas fatoriais dos itens estão apresentadas na Tabela 3, que também informa os índices de fidedignidade composta e as estimativas de replicabilidade dos escores fatoriais, representadas pelos índices *H-latent* e *H-observed* (Ferrando & Lorenzo-Seva, 2018). No geral, os itens apresentaram cargas fatoriais adequadas em seus fatores previamente definidos teoricamente. No entanto, alguns itens exibiram cargas cruzadas, isto é, cargas fatoriais superiores a 0,30 em mais de um fator. Para esses casos, foram utilizadas as medidas de importância de Pratt (Wu & Zumbo, 2017) como critério para decidir sobre a manutenção ou exclusão dos itens, complementadas por fundamentos teóricos que embasaram as decisões. Assim, após cuidadosa análise, 28 itens seguiram para AFC. Mesmo com carga cruzada, optou-se por reavaliar a manutenção de certos itens na AFC, considerando que uma amostra maior e distinta tende a oferecer maior suporte à decisão.

A fidedignidade composta dos fatores apresentou valores aceitáveis, com índices superiores a 0,70 (Fornell & Larcker, 1981), embora os fatores MCIS-BOT e MCIS-CLI tenham apresentado valores mais próximos desse limite. A estabilidade dos fatores foi verificada por meio do índice H (Ferrando & Lorenzo-Seva, 2018), que mede a capacidade de um conjunto de itens em representar adequadamente um fator comum. Esse índice tem variação de 0 a 1, com valores elevados (> 0,80) indicando uma variável latente bem definida e com maior probabilidade de estabilidade em diferentes estudos (Ferrando & Lorenzo-Seva, 2018). Conforme demonstrado na Tabela 4.3, os fatores MCIS-BOT e MCIS-CLI apresentaram *H-observed* inferior a 0,80, o que sugere que esses fatores podem não se replicar em estudos futuros. No entanto, os mesmos fatores apresentaram *H-latent* superior a 0,80, indicando que, na teoria, ainda possuem uma estrutura latente robusta e bem definida.

Análise Fatorial Confirmatória (AFC)

Após a primeira purificação da escala com a AFE, foi realizada uma nova purificação utilizando a AFC (Churchill, 1979; Rossiter, 2002), para “testar o quão bem as variáveis medidas representam os construtos” (Hair et al. 2009, p. 587), e avaliar a plausibilidade da estrutura multidimensional da escala CCV-ChatbotIA-Cliente. Para isso, foram utilizados os dados da amostra 2, conforme descrito anteriormente.

A análise foi realizada no *Mplus 8.11* (Muthén & Muthén, 2019), um *software* de reconhecida reputação para conduzir análises de modelos com variáveis latentes (J. Wang & Wang, 2019). O método de estimação utilizado foi o RDWLS, considerado apropriado para dados categóricos (DiStefano & Morgan, 2014). Foram utilizados os seguintes índices de ajuste: χ^2 ; χ^2/gl ; CFI; TLI; *Standardized Root Mean Residual* (SRMR) e RMSEA. Além do que já foi mencionado anteriormente sobre os índices de ajuste, espera-se que os valores de χ^2 não sejam significativos; a razão χ^2/gl seja \leq que 5 ou, preferencialmente \leq que 3 (Brown, 2015). Um valor SRMR esperado como bom ajuste é menor que 0,08 (Hu & Bentler, 1998; Kline, 2023).

O modelo original, isto é, a estrutura multifatorial identificada na AFE, foi testado na AFC. Porém, o modelo apresentou resultados de ajuste contraditórios. De acordo com a Tabela 4, os índices de ajuste não suportaram adequadamente o modelo inicial. Diante do exposto, foram realizados vários testes para reespecificar o modelo, sempre observando os índices de modificação sugeridos e o embasamento teórico.

Tabela 4 - Índices de ajuste do modelo multifatorial CCV-ChatbotIA-Cliente

	χ^2 (gl)	χ^2/gl	CFI	TLI	SRMR	RMSEA (90% IC)
Original	1758.644** (344)	5,11	0,810	0,791	0,108	0,102 (0,097 – 0,107)
Reespecificado	303.947** (129)	2,35	0,953	0,945	0,049	0,059 (0,050-0,067)

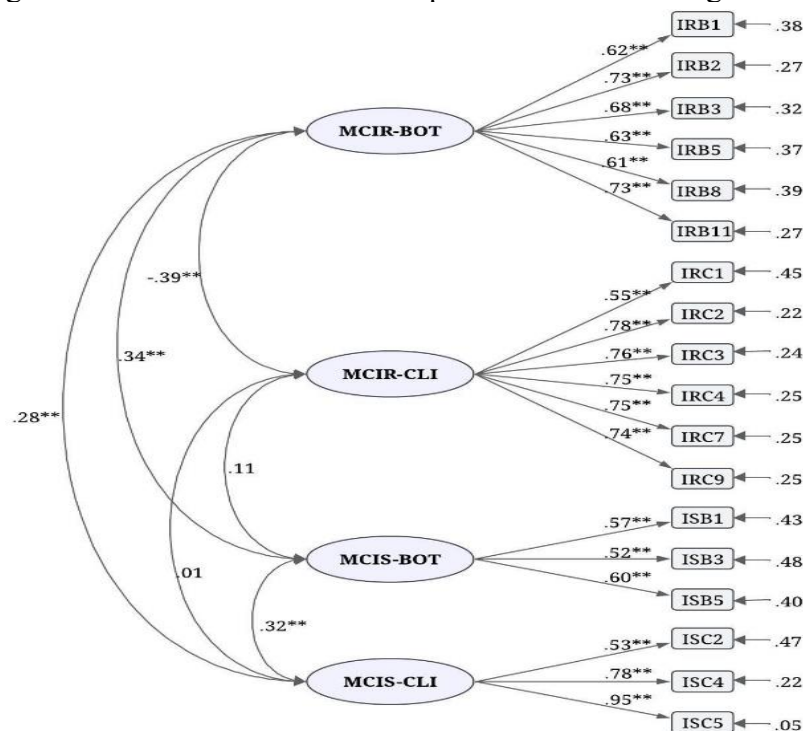
Nota: χ^2 = qui-quadrado; *gl* = graus de liberdade; CFI = *Comparative Fit Index*; TLI = *Tucker-Lewis Index*; SRMR = *Standardized Root Mean Square Residual*; RMSEA = *Root Mean Square Error of Approximation*; ** $p < 0,001$. Fonte: elaborada pela autora com base nos dados da pesquisa.

Os índices de modificação indicaram problemas com itens dos fatores MCIS-BOT (ISB2, ISB4) e MCIS-CLI (ISC1, ISC3), cujas respostas foram predominantemente baixas, sugerindo baixa aplicabilidade ao contexto e impacto negativo no ajuste do modelo. Por isso, esses itens foram excluídos, apesar de sua relevância teórica. No fator MCIR-BOT, os itens IRB4, IRB6 e IRB9 também foram eliminados devido aos índices de modificação, e também uma análise mais precisa demonstrou redundância de conteúdo. Já no fator MCIR-CLI, os itens IRC5, IRC6 e IRC8 apresentaram respostas concentradas no polo inferior da escala e forte correlação entre si, justificando sua exclusão. Essas remoções contribuíram para um modelo mais parcimonioso e uma escala mais adequada à autoaplicação (Netemeyer et al., 2003).

Após as alterações mencionadas, o modelo re-especificado apresentou resultados plausíveis, com índices indicando um bom ajuste: RMSEA = 0,059 (IC 90%: [0,050, 0,067]), CFI = 0,953, TLI = 0,945, SRMR = 0,049 e $\chi^2/gf = 2,35$. Esses valores atendem aos critérios de ajustamento recomendados na literatura. Embora os valores de χ^2 tenham sido significativos, isso é esperado em amostras maiores. Além disso, o valor de χ^2/gf (qui-quadrado normalizado) ficou entre 2 e 5, indicando um ajuste aceitável (Kline, 2023).

O modelo confirmou os quatro fatores latentes: MCIR-BOT, MCIR-CLI, MCIS-BOT e MCIS-CLI, todos com cargas fatoriais padronizadas significativas e adequadas (mínimo de 0,52), valor considerado aceitável em AFC quando o modelo apresenta bom ajuste (Hair et al., 2019; Tabachnick & Fidell, 2019). O item ISC5 apresentou forte relação com seu fator, o que merece atenção em pesquisas futuras. As correlações entre os fatores foram estatisticamente significativas, variando de baixas a moderadas, o que sugere distinção e relação entre eles (Kline, 2023). A Figura 2 ilustra a estrutura multifatorial, as cargas e as correlações.

Figura 2 - Diagrama do modelo estrutural re-especificado com as cargas fatoriais dos itens



Nota: As informações foram arredondadas para duas casas decimais. Nível de significância: ** $p < 0,001$.

Fonte: elaborada pela autora com base nos dados da pesquisa.

A confiabilidade composta (*Composite Reliability* – CR) foi utilizada para verificar a consistência interna dos fatores avaliados. No presente estudo, os fatores MCIR-BOT (CR = 0,83), MCIR-CLI (CR = 0,87) e MCIS-CLI (CR = 0,81) apresentaram índices adequados, com valores acima de 0,70 (Fornell & Larcker, 1981), o que indica consistência interna satisfatória.

No entanto, o fator MCIS-BOT (CR = 0,58) apresentou um valor abaixo do recomendado, porém valores próximos a 0,60 são considerados aceitáveis (Ursachi et al., 2015). Ainda assim, o resultado indica a necessidade de revisar e ampliar os itens associados a esse fator em pesquisas futuras. Vale destacar que esse fator teve seu número de itens reduzido na AFC, e que a CR tende a ser mais baixa em fatores com poucos itens.

Discussão dos resultados

As análises realizadas confirmaram a validade dos escores e a estrutura teórica da escala CCV-ChatbotIA-Cliente, que avalia a codestruição de valor em interações com chatbots sob a perspectiva do cliente. O fenômeno foi validado como multidimensional, à semelhança do que ocorre em relações interpessoais (Guan et al., 2020, 2022). A escala é composta por quatro fatores: dois relacionados ao comportamento de codestruição de valor do chatbot — MCIR-BOT e MCIS-BOT — e dois ao comportamento de codestruição de valor do cliente — MCIR-CLI e MCIS-CLI. Os resultados indicaram evidências de validade de conteúdo e validade baseada na estrutura interna. Os índices de ajuste mostraram que o modelo representa adequadamente os dados, com os itens aderindo bem aos seus respectivos fatores. A escala apresentou confiabilidade satisfatória, embora o fator MCIS-BOT tenha revelado valor próximo ao limite inferior, o que sugere a necessidade de aprimoramentos futuros, ainda que valores em torno de 0,60 sejam aceitáveis quando há bons índices de ajuste (Ursachi et al., 2015).

O modelo confirmou que os maus comportamentos de integração de recursos e de interação social, tanto por parte do chatbot quanto do cliente, estão inter-relacionados. Esses achados reforçam o entendimento de que a codestruição de valor é um fenômeno dinâmico e bidirecional (Echeverri & Skálén, 2021; Plé & Cáceres, 2010), explicando como se manifesta a codestruição de valor no contexto de interações com chatbots de IA.

Em suma, os resultados confirmam que o mau comportamento de codestruição de valor se manifesta não apenas pela integração inadequada de recursos (Kong et al., 2024; Laud et al., 2019), mas também pelo mau comportamento de interação social dos atores. A estrutura de medição que abrange ambas as partes envolvidas na interação mostra-se mais completa, refletindo a natureza colaborativa expressa no prefixo “co” do conceito de codestruição de valor. Isto é, trata-se de um fenômeno que envolve a responsabilidade mútua dos participantes. Essa abordagem mais ampla contribui para o avanço do entendimento empírico e teórico da codestruição de valor, ao apresentar evidências estatísticas significativas sobre o fenômeno.

Em termos de interações entre os fatores, verificou-se correlação negativa entre MCIR-BOT e MCIR-CLI, sugerindo que os clientes tendem a responsabilizar o chatbot ou o provedor do serviço pelo mau comportamento de integração de recursos. Esse resultado está alinhado com os achados qualitativos de Castillo et al. (2021), agora confirmados estatisticamente. Vale ressaltar que MCIR-CLI apresentou correlação apenas com MCIR-BOT, reforçando a percepção de que os clientes consideram o chatbot como o principal responsável pelos problemas de integração de recursos.

Cabe aqui uma discussão sobre a atribuição externa de culpa, em que clientes responsabilizam o chatbot (ou o provedor) pelos problemas, sem reconhecer suas próprias falhas na integração de recursos. Não se trata de isentar o provedor, mas de refletir sobre o equilíbrio de responsabilidades em uma interação bidirecional. O viés do autoengano pode explicar esse resultado, ao levar os indivíduos a ignorarem falhas pessoais e focarem apenas no que lhes é conveniente (Hippel & Trivers, 2011).

Os resultados revelaram também correlações positivas entre MCIR-BOT e MCIS-BOT, bem como entre MCIR-BOT e MCIS-CLI, evidenciando que comportamentos problemáticos de integração de recursos por parte do chatbot contribuem para interações sociais problemáticas. Assim, quando um chatbot apresenta problemas de integração de recursos,

também tende a exibir comportamentos inadequados em termos de interação social. Esses achados corroboram a ideia de que deficiências na integração de recursos impactam negativamente as habilidades de interação social (Bidar et al., 2024; Liljeroos-Cork & Luhtala, 2024). Inversamente, interações sociais inadequadas podem comprometer a integração de recursos.

Outro achado relevante foi a correlação positiva entre MCIS-BOT e MCIS-CLI, indicando influência mútua no mau comportamento de interação social. Essa associação confirma, de forma empírica e estatística, que a codestruição de valor é colaborativa, com os clientes reconhecendo a responsabilidade compartilhada. As correlações entre os fatores sociais reforçam o papel crítico da interação social nesse processo (Chen et al., 2024), sugerindo que falhas do chatbot podem provocar reações adversas nos clientes.

Conclusão / Contribuições

A escala de Codestruição de Valor em Interações com Chatbots de IA apresentou evidências de validade de conteúdo e validade baseada na estrutura interna. O instrumento é composto por quatro fatores relacionados ao mau comportamento de integração de recursos e de interação social, tanto do cliente quanto do chatbot: MCIR-BOT, MCIS-BOT, MCIR-CLI e MCIS-CLI. Os resultados comprovam estatisticamente a natureza colaborativa da codestruição de valor, com base na avaliação mútua dos envolvidos e nas relações entre as dimensões do construto.

Nos estudos sobre cocriação de valor, é amplamente reconhecido que a responsabilidade pela formação de valor é colaborativa (Vargo & Lusch, 2017). Por outro lado, na codestruição de valor, conforme evidenciado neste trabalho, o cliente — enquanto beneficiário — reconhece parcialmente sua responsabilidade ao assumir o mau comportamento de interação social, mas atribui, em maior medida, os problemas de integração de recursos ao chatbot de atendimento. Ainda assim, os achados estão alinhados aos princípios da Lógica Dominante do Serviço (LDS), que postula o valor como um fenômeno colaborativo (Vargo & Lusch, 2016). Com base nisso, os resultados sugerem a ampliação de um dos axiomas da LDS, de modo a incluir a possibilidade de codestruição de valor, conforme a seguinte proposição: “O valor é sempre colaborativamente cocriado, codestruído ou sujeito a ambos os processos, de forma simultânea ou alternada”.

Em suma, este trabalho contribui com um instrumento que, além de avaliar experiências, enriquece o entendimento sobre a codestruição de valor. A escala pode ser utilizada como ferramenta de medida em estudos futuros, ampliando a compreensão de um conceito teórico que ainda está em fase inicial de investigação (Coelho & Farias, 2024). Vale destacar que as dimensões do instrumento proposto possibilitam a divisão em subescalas (Netemeyer et al., 2003), o que pode ser útil para estudos que explorem aspectos específicos do fenômeno.

Tais achados destacam a importância de monitorar as interações cliente-chatbot, especialmente diante do papel crítico do mau comportamento de interação social nesse processo. O acompanhamento contínuo e os ajustes nas práticas de atendimento tornam-se essenciais, pois falhas como interpretações equivocadas ou respostas inadequadas podem gerar experiências negativas e ampliar custos (Castillo et al., 2021). Esses resultados oferecem evidências práticas da necessidade de aprimoramento constante dos chatbots, bem como de que as empresas adotem formatos integrados de atendimento híbrido (humano-IA).

A escala CCV-ChatbotIA-Cliente se apresenta como uma ferramenta valiosa para compreender a propensão à codestruição de valor. Além disso, auxilia no diagnóstico e monitoramento de problemas na experiência do cliente, fornecendo orientações para o aperfeiçoamento do design dos chatbots, o que pode incluir melhorias nas formas de resposta e na linguagem adotada. Compreender os aspectos associados às experiências negativas também

favorece a aplicação de estratégias que promovam uma boa reputação organizacional, ao minimizar os impactos negativos, fortalecendo as relações com os clientes.

Uma das principais limitações deste estudo é que a escala foi testada exclusivamente no contexto brasileiro. Entretanto, a adaptação e validação transcultural da escala representam um caminho necessário em futuras investigações. Além disso, a utilização de amostras por conveniência restringe a generalização dos resultados. Outra limitação está no fato de que a escala captura apenas a perspectiva do cliente. Embora o valor deva ser avaliado pelo beneficiário do serviço (Vargo & Lusch, 2016), a análise da percepção dos provedores de serviços de chatbots pode oferecer uma visão mais abrangente do fenômeno. Além disso, os fatores MCIS-BOT e MCIS-CLI apresentaram um número reduzido de itens na AFC, o que sugere a necessidade de incluir novos itens para ampliar e fortalecer esses fatores.

Outro ponto a considerar é que a escala foi validada em um contexto geral de usuários de chatbots. Portanto, a validação setorial – em áreas como bancária, saúde, turismo e serviços públicos digitais – representa uma oportunidade de pesquisa relevante para o aprimoramento e a aplicação contextual da escala. Conforme apontado por Netemeyer et al. (2003), testes ao longo do tempo são fundamentais para o refinamento das estruturas teóricas, especialmente em contextos tecnológicos dinâmicos e em constante evolução, como o da IA. Nesse sentido, estudos longitudinais podem avaliar como o comportamento de codestruição de valor se desenvolve com o avanço das tecnologias e o uso crescente de chatbots em serviços. Por fim, a construção e validação de escalas para avaliar sistemas híbridos – ou seja, a combinação de chatbots e atendentes humanos – surge como uma oportunidade de pesquisa alinhada às tendências do setor de atendimento ao cliente.

REFERÊNCIAS

- American Educational Research Association, American Psychological Association, & National Council on Measurement in Education. (2014). *Standards for educational and psychological testing*. American Educational Research Association.
- Asparouhov, T., & Muthen, B. (2010). Simple Second Order Chi-Square Correction. *Mplus Technical Appendix*, 1–8.
- Bidar, D. R., Jabbari, D. M., & Luck, D. E. (2024). Value co-destruction in online collaborative networks. *European Management Journal*, 42(1), 98–107. <https://doi.org/10.1016/j.emj.2022.08.001>
- Brown, T. A. (2015). *Confirmatory factor analysis for applied research*. Guilford publications.
- Caic, M., Odekerken-Schroder, G., & Mahr, D. (2018). Service robots: Value co-creation and co-destruction in elderly care networks. Em *Journal of Service Management* (Vol. 29, Número 2, p. 178–205). <https://doi.org/10.1108/JOSM-07-2017-0179>
- Camilleri, J., & Neuhofer, B. (2017). Value co-creation and co-destruction in the Airbnb sharing economy. *International Journal of Contemporary Hospitality Management*, 29(9), 2322–2340. <https://doi.org/10.1108/IJCHM-09-2016-0492>
- Castelo, N., Boegershausen, J., Hildebrand, C., & Henkel, A. P. (2023). Understanding and Improving Consumer Reactions to Service Bots. *Journal of Consumer Research*, 50(4), 848–863. <https://doi.org/10.1093/jcr/ucad023>
- Castillo, D., Canhoto, A. I., & Said, E. (2021). The dark side of AI-powered service interactions: Exploring the process of co-destruction from the customer perspective. *Service Industries Journal*, 41(13–14), 900–925. <https://doi.org/10.1080/02642069.2020.1787993>
- Chen, W., Yu, M., Wang, Y., Lu, X., & Hou, J. (2024). Evolutionary analysis of value co-destruction in urban village renovation using SEM-FCM model. *Engineering, Construction and Architectural Management, ahead-of-print*(ahead-of-print). <https://doi.org/10.1108/ECAM-04-2024-0411>
- Churchill, G. A. (1979). A Paradigm for Developing Better Measures of Marketing Constructs. *Journal of Marketing Research*, 16(1), 64. <https://doi.org/10.2307/3150876>

- Cochran, W. G. (1991). *Sampling Techniques* (3^o ed). Wiley.
- Coelho, E. C. da S., & Farias, J. S. (2024). Value cocreation and codestruction in artificial intelligence-enabled service interactions: Literature review and research agenda. *Spanish Journal of Marketing - ESIC, ahead-of-print*(ahead-of-print). <https://doi.org/10.1108/SJME-09-2023-0248>
- Corsaro, D., Vargo, S. L., Hofacker, C., & Massara, F. (2022). Artificial intelligence and the shaping of the business context. *Journal of Business Research, 145*, 210–214. <https://doi.org/10.1016/j.jbusres.2022.02.072>
- Damásio, B. F., Dutra, D. de F., & Baptista, M. N. (2021). Análise fatorial exploratória (AFE) e teoria de resposta ao item via software Factor. Em *Tutoriais em análise de dados aplicados à psicometria* (p. 292–319). Vozes.
- De Keyser, A., & Kunz, W. H. (2022). Living and working with service robots: A TCCM analysis and considerations for future research. *Journal of Service Management, 33*(2), 165–196. <https://doi.org/10.1108/JOSM-12-2021-0488>
- Echeverri, P., & Skålén, P. (2011). Co-creation and co-destruction: A practice-theory based study of interactive value formation. *Marketing Theory, 11*(3), 351–373. <https://doi.org/10.1177/1470593111408181>
- Echeverri, P., & Skålén, P. (2021). Value co-destruction: Review and conceptualization of interactive value formation. *Marketing Theory, 21*(2), 227–249. <https://doi.org/10.1177/1470593120983390>
- Falqueto, J. maria zandonade, Hoffmann, V. E., & Farias, J. S. (2018). Saturação Teórica em Pesquisas Qualitativas: Relato de uma Experiência de Aplicação em Estudo na Área de Administração. *Revista de Ciências da Administração, 40–53*. <https://doi.org/10.5007/2175-8077.2018V20N52P40>
- Ferrando, P. J., & Lorenzo-Seva, U. (2018). Assessing the Quality and Appropriateness of Factor Solutions and Factor Score Estimates in Exploratory Item Factor Analysis. *Educational and Psychological Measurement, 78*(5), 762–780. <https://doi.org/10.1177/0013164417719308>
- Følstad, A., & Brandtzaeg, P. B. (2020). Users' experiences with chatbots: Findings from a questionnaire study. *Quality and User Experience, 5*(1), 3. <https://doi.org/10.1007/s41233-020-00033-2>
- Fornell, C., & Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research, 18*(1), 39–50. <https://doi.org/10.2307/3151312>
- Grönroos, C. (2011). Value co-creation in service logic: A critical analysis. *Marketing Theory, 11*(3), 279–301. <https://doi.org/10.1177/1470593111408177>
- Grundner, L., & Neuhofer, B. (2021). The bright and dark sides of artificial intelligence: A futures perspective on tourist destination experiences. *Journal of Destination Marketing and Management, 19*, 100511. <https://doi.org/10.1016/j.jdmm.2020.100511>
- Guan, X., Gong, J., Liu, Q., & Huan, T.-C. (2022). Constructing a value co-destruction behavior scale in business-to-customer service context. *Service Industries Journal*. <https://doi.org/10.1080/02642069.2022.2128779>
- Guan, X., Gong, J., Xie, L., & Huan, T. (2020). Scale development of value co-destruction behavior in tourism. *Tourism Management Perspectives, 36*. <https://doi.org/10.1016/j.tmp.2020.100757>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate Data Analysis*. Cengage Learning EMEA.
- Hernández-Nieto, R. (2002). *Contributions to statistical analysis*. Universidad de Los Andes.
- Hippel, W. von, & Trivers, R. (2011). The evolution and psychology of self-deception. *Behavioral and Brain Sciences, 34*(1), 1–16. <https://doi.org/10.1017/S0140525X10001354>
- Hu, L., & Bentler, P. M. (1998). Fit indices in covariance structure modeling: Sensitivity to underparameterized model misspecification. *Psychological Methods, 3*(4), 424–453. <https://doi.org/10.1037/1082-989X.3.4.424>
- Huang, M. H., & Rust, R. T. (2021). Engaged to a Robot? The Role of AI in Service. *Journal of Service Research, 24*(1), 30–41. <https://doi.org/10.1177/1094670520902266>
- Huang, M. H., & Rust, R. T. (2022a). A Framework for Collaborative Artificial Intelligence in Marketing. *Journal of Retailing, 98*(2), 209–223. <https://doi.org/10.1016/j.jretai.2021.03.001>

- Huang, M. H., & Rust, R. T. (2022b). AI as customer. *Journal of Service Management*, 33(2), 210–220. <https://doi.org/10.1108/JOSM-11-2021-0425>
- Järvi, H., Kähkönen, A. K., & Torvinen, H. (2018). When value co-creation fails: Reasons that lead to value co-destruction. *Scandinavian Journal of Management*, 34(1), 63–77. <https://doi.org/10.1016/J.SCAMAN.2018.01.002>
- Kline, R. B. (2023). *Principles and Practice of Structural Equation Modeling*. Guilford Publications.
- Kong, Y., Kim, W. G., Zhou, X., & Yang, Y. (2024). Customer value co-destruction behaviors in smart service encounters: Scale development and cross-cultural validation. *International Journal of Hospitality Management*, 122, 103854. <https://doi.org/10.1016/j.ijhm.2024.103854>
- Lalicic, L., & Weismayer, C. (2021). Consumers' reasons and perceived value co-creation of using artificial intelligence-enabled travel service agents. *Journal of Business Research*, 129, 891–901. <https://doi.org/10.1016/j.jbusres.2020.11.005>
- Larivière, B., Bowen, D., Andreassen, T. W., Kunz, W., Sirianni, N. J., Voss, C., Wunderlich, N. V., & Keyser, A. D. (2017). “Service Encounter 2.0”: An investigation into the roles of technology, employees and customers. *Journal of Business Research*, 79, 238–246. <https://doi.org/10.1016/J.JBUSRES.2017.03.008>
- Laud, G., Bove, L., Ranaweera, C., Leo, W. W. C., Sweeney, J., & Smith, S. (2019). Value co-destruction: A typology of resource misintegration manifestations. *Journal of Services Marketing*, 31(7), 866–889. <https://doi.org/10.1108/JSM-01-2019-0022>
- Lee, S. E., Ju, N., & Lee, K.-H. (2023). Service chatbot: Co-citation and big data analysis toward a review and research agenda. *Technological Forecasting and Social Change*, 194, 122722. <https://doi.org/10.1016/j.techfore.2023.122722>
- Liljeroos-Cork, J., & Luhtala, M. (2024). Value co-destruction through misintegration of resources within a public service ecosystem. *Public Management Review*, 0(0), 1–24. <https://doi.org/10.1080/14719037.2024.2366986>
- Lorenzo-Seva, U., & Ferrando, P. J. (2019). Robust Promin: A method for diagonally weighted factor rotation. *Liberabit*, 25(1), 99–106.
- Malhotra, N. K. (2019). *Pesquisa de Marketing: Uma orientação aplicada* (7. ed.). Bookman.
- Mobile Time. (2023). *Mapa do ecossistema brasileiro de bots 2023* (No. 08/2023). Mobile Time. <https://www.mobiletime.com.br/pesquisas/>
- Muthén, B., & Muthén, L. (2019). Mplus: A General Latent Variable Modeling Program. *Muthén & Muthén*.
- Netemeyer, R. G., Bearden, W. O., & Sharma, S. (2003). *Scaling procedures: Issues and applications*. 203.
- Neuhofer, B., Magnus, B., & Celuch, K. (2021). The impact of artificial intelligence on event experiences: A scenario technique approach. *Electronic Markets*, 31(3), 601–617. <https://doi.org/10.1007/s12525-020-00433-4>
- Ogunbodede, O., Papagiannidis, S., & Alamanos, E. (2022). Value co-creation and co-destruction behaviour: Relationship with basic human values and personality traits. *International Journal of Consumer Studies*, 46(4), 1278–1298. <https://doi.org/10.1111/ijcs.12757>
- Pasquali, L. (2010). testes referentes a construto: Teoria e modelo de construção. Em L. Pasquali & Colaboradores (Orgs.), *Instrumentação psicológica* (Número spe, p. 165–198). Artmed.
- Pavone, G., Meyer-Waarden, L., & Munzel, A. (2023). Rage Against the Machine: Experimental Insights into Customers' Negative Emotional Responses, Attributions of Responsibility, and Coping Strategies in Artificial Intelligence-Based Service Failures. *Journal of Interactive Marketing*, 58(1), 52–71. <https://doi.org/10.1177/10949968221134492>
- Payne, E. H. M., Peltier, J., & Barger, V. A. (2021). Enhancing the value co-creation process: Artificial intelligence and mobile banking service platforms. *Journal of Research in Interactive Marketing*, 15(1), 68–85. <https://doi.org/10.1108/JRIM-10-2020-0214>
- Plé, L. (2016). Studying customers' resource integration by service employees in interactional value co-creation. *Journal of Services Marketing*, 30(2), 152–164. <https://doi.org/10.1108/JSM-02-2015-0065>
- Plé, L., & Cáceres, R. C. (2010). Not always co-creation: Introducing interactional co-destruction of value in service-dominant logic. *Journal of Services Marketing*, 24(6), 430–437. <https://doi.org/10.1108/08876041011072546>

- Prior, D., & Marcos-Cuevas, J. (2016). Value co-destruction in interfirm relationships: The impact of actor engagement styles. *Marketing Theory*, 16(4), 533–552. <https://doi.org/10.1177/1470593116649792>
- Robinson, S., Orsingher, C., Alkire, L., Keyser, A. D., Giebelhausen, M., Papamichail, K. N., Shams, P., & Temerak, M. S. (2020). Frontline encounters of the AI kind: An evolved service encounter framework. *Journal of Business Research*, 116, 366–376. <https://doi.org/10.1016/j.jbusres.2019.08.038>
- Smith, A. M. (2013). The value co-destruction process: A customer resource perspective. *European Journal of Marketing*, 47(11), 1889–1909. <https://doi.org/10.1108/EJM-08-2011-0420>
- Tabachnick, B. G., & Fidell, L. S. (2019). *Using Multivariate Statistics* (7. ed.). Pearson.
- Timmerman, M. E., & Lorenzo-Seva, U. (2011). Dimensionality assessment of ordered polytomous items with parallel analysis. *Psychological Methods*, 16(2), 209–220. <https://doi.org/10.1037/a0023353>
- Ursachi, G., Horodnic, I. A., & Zait, A. (2015). How Reliable are Measurement Scales? External Factors with Indirect Influence on Reliability Estimators. *Procedia Economics and Finance*, 20, 679–686. [https://doi.org/10.1016/S2212-5671\(15\)00123-9](https://doi.org/10.1016/S2212-5671(15)00123-9)
- Vafeas, M., Hughes, T., & Hilton, T. (2016). Antecedents to value diminution: A dyadic perspective. *Marketing Theory*, 16(4), 469–491. <https://doi.org/10.1177/1470593116652005>
- Vargo, S. L., & Lusch, R. F. (2004). Evolving to a New Dominant Logic for Marketing. *Journal of Marketing*, 68(1), 1–17. <https://doi.org/10.1509/JMKG.68.1.1.24036>
- Vargo, S. L., & Lusch, R. F. (2016). Institutions and axioms: An extension and update of service-dominant logic. *Journal of the Academy of Marketing Science* 2015 44:1, 44(1), 5–23. <https://doi.org/10.1007/S11747-015-0456-3>
- Vargo, S. L., & Lusch, R. F. (2017). Service-dominant logic 2025. *International Journal of Research in Marketing*, 34(1), 46–67. <https://doi.org/10.1016/J.IJRESMAR.2016.11.001>
- Vargo, S. L., Peters, L., Kjellberg, H., Koskela-Huotari, K., Nenonen, S., Polese, F., Sarno, D., & Vaughan, C. (2023). Emergence in marketing: An institutional and ecosystem framework. *Journal of the Academy of Marketing Science*, 51(1), 2–22. <https://doi.org/10.1007/s11747-022-00849-8>
- Wang, J., & Wang, X. (2019). *Structural Equation Modeling: Applications Using Mplus*. John Wiley & Sons.
- Wang, X., Wong, Y., Teo, C., & Yuen, K. (2019). A critical review on value co-creation: Towards a contingency framework and research agenda. *Journal of Service Theory and Practice*, 29(2), 165–188. <https://doi.org/10.1108/JSTP-11-2017-0209>
- Wirtz, J., Patterson, P. G., Kunz, W. H., Gruber, T., Lu, V. N., Paluch, S., & Martins, A. (2018). Brave new world: Service robots in the frontline. *Journal of Service Management*, 29(5), 907–931. <https://doi.org/10.1108/JOSM-04-2018-0119>
- Wu, A. D., & Zumbo, B. D. (2017). Using Pratt's Importance Measures in Confirmatory Factor Analyses. *Journal of Modern Applied Statistical Methods*, 16, 81–98. <https://doi.org/10.56801/10.56801/v16.i.928>
- Xing, X., Song, M., Duan, Y., & Mou, J. (2022). Effects of different service failure types and recovery strategies on the consumer response mechanism of chatbots. *Technology in Society*, 70, 102049. <https://doi.org/10.1016/j.techsoc.2022.102049>
- Yi, Y., & Gong, T. (2013). Customer value co-creation behavior: Scale development and validation. *Journal of Business Research*, 66(9), 1279–1284. <https://doi.org/10.1016/J.JBUSRES.2012.02.026>