

**COMO O PROCESSO DE ELICITAÇÃO DE PREFERÊNCIAS INFLUENCIA NA  
ACEITAÇÃO DE RECOMENDAÇÃO DE INTELIGÊNCIA ARTIFICIAL**

**SANDRO AUGUSTO HIRAI**

CENTRO UNIVERSITÁRIO DA FEI-SP

**JOSÉ MAURO DA COSTA HERNANDEZ**

CENTRO UNIVERSITÁRIO DA FUNDAÇÃO EDUCACIONAL INACIANA PE SABÓIA DE MEDEIROS (FEI)

## COMO O PROCESSO DE ELICITAÇÃO DE PREFERÊNCIAS INFLUENCIA A ACEITAÇÃO DE RECOMENDAÇÕES DE INTELIGÊNCIA ARTIFICIAL

### INTRODUÇÃO

Novas tecnologias têm permitido o desenvolvimento de sistemas avançados de recomendação que estão cada vez mais presentes na vida das pessoas, fornecendo dados e informações que auxiliam a tomada de decisões. Hoje há uma infinidade de aplicativos que oferecem recomendações para as atividades mais rotineiras dos indivíduos que vão desde aplicativos que auxiliam no deslocamento de um ponto a outro na cidade, apresentando as rotas com menor tempo de deslocamento (DOVE; HILL, 2020), passam por algoritmos de recomendação em sites de comércio eletrônico indicando livros, vinhos e outros produtos (RICCI; SHAPIRA; ROKACH, 2015), aplicativos de recomendação de filmes em serviços de streaming (RICCI; SHAPIRA; ROKACH, 2015), assistentes de voz que auxiliam a busca de conteúdos e compras de itens para o consumo diário (MCCAFFREY et al., 2018) e chegam até dispositivos interconectados como ar condicionado, termostato, câmera de segurança e fechaduras eletrônicas que tornam a casa mais “inteligente” (PRATA, 2019).

As aplicações acima são apenas alguns poucos exemplos de como os algoritmos de recomendação evoluíram rapidamente nos últimos anos, em grande parte devido aos avanços da tecnologia de processamento de dados, ao desenvolvimento da inteligência artificial e à gigantesca quantidade de dados disponíveis para uso em recomendações (HOSANAGAR, 2019). As denominações “sistemas de recomendação”, “agentes de recomendação” ou simplesmente “algoritmos” são terminologias comumente utilizados em pesquisas sobre adoção de recomendação provenientes de uma tecnologia e não de um ser humano. Mas como um sistema de recomendação ou agente de recomendação necessita de um algoritmo para tratar a informação e definir a recomendação (PORTUGAL; ALENCAR; COWAN, 2018), neste trabalho será utilizado somente o termo “algoritmo”. Este termo parece ser mais abrangente que os demais pois o algoritmo pode ser utilizado em qualquer plataforma tecnológica.

Uma vez que os algoritmos de recomendação estão direta ou indiretamente influenciando a vida cotidiana das pessoas, o seu estudo tem chamado a atenção dos pesquisadores da área de marketing, principalmente no que tange ao comportamento dos indivíduos em relação às recomendações apresentadas pelos algoritmos. Ao longo dos anos, as pesquisas se expandiram para o estudo de aplicativos com algoritmos de recomendação em aparelhos celulares e ultimamente surgiram pesquisas investigando a aceitação de algoritmos de recomendação para novas plataformas tecnológicas como veículos autônomos e campos de atuação como recomendações na área médica.

As pesquisas mais recentes sobre a aceitação de algoritmos de recomendação indicam caminhos conflitantes com respeito ao comportamento do consumidor: enquanto alguns estudos sugerem que os indivíduos estão dispostos a aceitarem as recomendações de agentes inteligentes, outros estudos apontam as limitações no processo de aceitação. Por exemplo, Logg, Minson e Moore (2019) identificaram que as pessoas confiam mais numa recomendação feita por um algoritmo do que numa recomendação feita por uma pessoa em situações envolvendo eventos geopolíticos, músicas e atratividade romântica de pares. Da mesma forma, Germann e Merkle (2019) constataram que os usuários aceitaram mais as recomendações de investimentos feitos por algoritmos do que por pessoas ao perceberem que os algoritmos eram mais eficientes.

Por outro lado, outras pesquisas concluíram que as pessoas podem desenvolver uma aversão a algoritmos de recomendação porque os indivíduos percebem que eles apresentam erros (DIETVORST; SIMMONS; MASSEY, 2015). Por exemplo, Yeomans, Shah,

Mullainathan e Kleinberg (2019) constataram que, apesar dos algoritmos serem mais precisos e eficazes, alguns indivíduos preferiram recomendações de pessoas conhecidas por não entenderem como um algoritmo podia produzir uma recomendação.

Os estudos citados acima são apenas alguns poucos exemplos de que a literatura ainda não explica suficientemente bem os motivos pelos quais os consumidores são mais ou menos inclinados a seguirem as recomendações de um algoritmo. As conclusões discrepantes entre os diversos estudos incentivaram o desenvolvimento deste trabalho cujo objetivo específico é verificar a probabilidade de aceitação de uma recomendação de acordo com a forma com que as informações iniciais são obtidas.

Para gerar uma recomendação, os algoritmos costumam se basear num conjunto de informações a respeito do usuário. A forma como o algoritmo coleta as preferências, necessidades e gostos dos usuários gera a expectativa de que elas serão usadas apropriadamente na definição das melhores recomendações e influencia a satisfação do usuário com a recomendação. (GRETZEL; FESENMAIER, 2005), aumentando a probabilidade de sua aceitação. As informações usadas pelos algoritmos podem ser obtidas de forma implícita, quando as informações não são solicitadas diretamente ao usuário (por exemplo, o histórico de transações de um cliente em uma loja ou o histórico de navegação em um website) ou explícita, quando o usuário é questionado diretamente pelo algoritmo (por exemplo, por meio do levantamento de preferências do usuário). Como será discutido na próxima seção, nossa hipótese é que o tipo de informação obtida neste estágio inicial pode influenciar a probabilidade de aceitação de uma recomendação.

Nosso estudo contribui tanto para a literatura sobre sistemas de recomendação quanto para os gerentes responsáveis pelo desenvolvimento e implantação de algoritmos de recomendação ao identificar formas de elicitación explícita que contribuem para a aceitação de recomendação.

## **1. O PROCESSO DE ELICITAÇÃO DE PREFERÊNCIAS**

Uma das aplicações de algoritmos mais facilmente encontradas no cotidiano das pessoas é a recomendação de produtos ou serviços, fornecendo sugestões relacionadas a vários processos de tomada de decisão como que livro comprar, que músicas escutar ou que filmes assistir. Os algoritmos de recomendação geralmente são classificados de acordo com a técnica utilizada para criar a recomendação (RICCI; SHAPIRA; ROKACH, 2015; PORTUGAL; ALENCAR; COWAN, 2018).

O algoritmo pode basear suas recomendações nas preferências do próprio usuário (quando se diz que o algoritmo está baseado em conteúdo, em dados demográficos ou em conhecimento) ou nas preferências de outros usuários com preferências semelhantes (quando se diz que o algoritmo está baseado em filtragem colaborativa). O algoritmo também pode se basear em dados obtidos de comunidades ou redes sociais como Facebook e Instagram ou ainda levar em conta o contexto da tomada de decisão (por exemplo, se é manhã ou noite ou se o usuário está trabalhando ou descansando). Também existem os algoritmos híbridos que usam informações de diferentes fontes.

Relevante para este estudo é reconhecer que a recomendação geralmente é criada a partir de informações sobre o usuário, informações estas que podem ser obtidas de forma implícita ou explícita. A informação obtida de forma implícita é aquela em que o usuário não é perguntado diretamente pelas suas preferências como, por exemplo, quando o algoritmo baseia a recomendação nos dados de navegação do usuário. A informação também pode ser diretamente obtida do usuário quando o algoritmo solicita ao usuário que registre perguntas sobre suas preferências.

A fase inicial de interação com o algoritmo pode gerar uma expectativa muito grande com respeito à qualidade da recomendação e é uma experiência importante para o usuário (GRETZEL; FESENMAIER, 2005). As quatro formas mais comuns de se obter as preferências dos usuários são as escalas de classificação de produtos ou atributos específicos por meio de avaliações como a quantidade de estrelas; em segundo, temos a atribuição de pesos relativos associados aos atributos do produto; depois, temos os comentários realizados pelos usuários; e, finalmente, temos algumas formas implícitas de elicitação, caracterizadas pelo mapeamento da navegação do usuário na página web ou qualquer outra forma indireta de obtenção das preferências (KNIJNENBURG; WILLEMSSEN, 2015).

De todo modo, um algoritmo de recomendação necessita de um certo número de avaliações dos produtos ou, pelo menos, uma base de dados inicial com essas informações para poder sugerir uma recomendação. Porém, em muitos casos, os indivíduos ainda não classificaram os produtos ou então são novos usuários que não possuem um histórico na base de dados. Esta situação é chamada de “*cold start problem*” do algoritmo de recomendação (KNIJNENBURG; WILLEMSSEN, 2015; NARA, 2019). Existem formas de minimizar essa dificuldade como, por exemplo, usando algoritmos híbridos que tendem a administrar melhor a situação de “*cold start problem*” ou encorajando os usuários a classificarem mais itens (KNIJNENBURG; WILLEMSSEN, 2015). Alguns estudos anteriores sugeriram que a forma de elicitação das preferências pode influenciar a probabilidade de aceitação de uma recomendação, como será visto na próxima seção.

## 2. ACEITAÇÃO DE RECOMENDAÇÕES

As pesquisas sobre algoritmos de recomendação iniciaram-se na metade da década de 1990 (PORTUGAL; ALENCAR; COWAN, 2018; RICCI; SHAPIRA; ROKACH, 2015) e desde então os trabalhos seguem evoluindo para a análise de novas aplicações (HEGNER; BELDAD; BRUNSWICK, 2019). Verruck e Nique (2017) identificaram que existem duas linhas de pesquisas mais utilizadas pelos estudiosos. A primeira linha de pesquisa está relacionada a aspectos técnicos e computacionais enquanto que a segunda linha de pesquisa busca entender como o comportamento do usuário é influenciado pela interação com o algoritmo de recomendação (VERRUCK; NIQUE, 2017).

Recente pesquisa observou que quando o algoritmo apresentava um pequeno erro, os respondentes perderam a confiança no algoritmo, deixando de utilizá-lo; no entanto, os participantes mantiveram a confiança em pessoas especialistas, mesmo quando elas apresentaram um erro superior ao do algoritmo. Os pesquisadores apontaram que os respondentes não aceitaram o algoritmo devido a outros fatores não identificados na pesquisa (DIETVORST; SIMMONS; MASSEY, 2015a). Em outro estudo, os mesmos pesquisadores descobriram que os respondentes teriam uma tendência maior de adoção quando havia a possibilidade de minimizar o erro, independentemente do nível de ajuste (pequeno ou grande), mesmo sabendo que quanto maior a intervenção, maior a imprecisão do algoritmo e, portanto, maior o nível de erros na recomendação (DIETVORST; SIMMONS; MASSEY, 2015b).

Logg (2018) indicou que as pessoas não aceitaram a recomendação do algoritmo ou porque preferem o próprio julgamento ou se consideram como especialistas ou apresentaram um excesso de confiança no processo de decisão. Foi apontado que para decisões em domínios subjetivos, aqueles que exigem mais a emoção ou a intuição no processo decisório, a preferência é pela recomendação de pares, como por exemplo a compra de livros. Por outro lado, é sugerido que domínios objetivos, definidos como sendo aqueles em que é possível uma mensuração, por exemplo decisões financeiras, há uma tendência de preferência por algoritmos. O artigo conclui que as pessoas adotam o algoritmo quando se sentem mais confortáveis com o raciocínio lógico e o processo de decisão é considerado mais racional. Este efeito, por sua vez, é moderado pelo

excesso de confiança, pela presença de uma especialista e pelo próprio conhecimento que a pessoa tem sobre a decisão (LOGG, 2018).

Outros pesquisadores manipularam recomendações de investimentos financeiros em que a mesma recomendação foi apresentada por algoritmos ou por gestores financeiros (GERMANN; MERKLE, 2019). Os participantes não perderam a confiança no algoritmo de investimento quando este apresentou erros, contrariamente ao que foi identificado por Dietvorst e seus colegas (2015a). Germann e Merkle (2019) constataram que os respondentes aceitaram mais o algoritmo quando eles perceberam que os resultados apresentados pelos algoritmos eram mais eficientes que os apresentados pelos gestores humanos, levando os autores a sugerir que o atendimento das expectativas após o uso da recomendação seria um fator influenciador na mudança de atitude do indivíduo em direção à adoção do algoritmo.

Yeomans, Shah, Mullainathan e Kleinberg (2019) realizaram uma pesquisa em que foram comparadas as recomendações de piadas dadas por algoritmos e por pessoas. As recomendações indicadas pelos algoritmos eram estatisticamente mais eficazes porque os pesquisadores utilizaram o método dos mínimos quadrados para encontrar uma equação de regressão estimada e desenvolveram um modelo que foi utilizado como algoritmo de recomendação. Apesar da maior precisão do algoritmo, os respondentes escolheram sugestões de pessoas ou optaram pelo próprio julgamento. Os pesquisadores descobriram que as pessoas não aceitaram o algoritmo porque não entenderam como o processo de recomendação das piadas foi criado no algoritmo (YEOMANS et al., 2019).

Castelo, Bos e Lehmann (2019) analisaram a aceitação do algoritmo sob a ótica da tarefa fim (“task”). Se a atividade era subjetiva e requeria emoção para a decisão, os indivíduos preferiram recomendações de humanos, ao passo que se a atividade fim era objetiva, a preferência foi por recomendação de um algoritmo. Os pesquisadores manipularam a subjetividade da tarefa para ser quantificável e, na medida em que foram apresentados exemplos reais de algoritmos com habilidades afetivas, os respondentes aumentaram a confiança nos algoritmos com tarefas subjetivas (CASTELO; BOS; LEHMANN, 2019).

Logg et. al. (2019) testaram a diferença de julgamento das pessoas quando as recomendações eram de um algoritmo ou de uma pessoa, constatando que os respondentes mudavam seu julgamento de acordo com a recomendação do algoritmo em previsões geopolíticas, popularidade de músicas e atratividade romântica de casais (LOGG; MINSON; MOORE, 2019). Porém, a preferência por um algoritmo diminuiu em situações em que a outra opção era um especialista externo, mesmo sabendo que a recomendação do especialista era menos precisa. Outro cenário com a mesma situação ocorreu quando o indivíduo já possuía um conhecimento prévio sobre o assunto.

Hegner, Beldad e Brunswick (2019) indicaram que, na medida em que se aumenta o controle percebido do respondente, aumenta a confiança na tecnologia sobre o veículo autônomo, o que por sua vez reduz a incerteza sobre a condução do veículo por meio de uma inteligência artificial (HEGNER; BELDAD; BRUNSWICK, 2019). Os pesquisadores constataram que ao se diminuir o controle do respondente, a intenção de uso de veículos autônomos foi influenciada negativamente, levando os autores a sugerir que percepções de controle específicos da situação em que se encontra o respondente é fator-chave na geração de confiança na recomendação do algoritmo.

Outra recente pesquisa constatou que os pesquisados escolheram mais as recomendações dadas pelo computador quando já tinham ouvido falar sobre o uso de computadores em situações semelhantes. Os pesquisadores sugerem que na medida em que os algoritmos continuem a serem utilizados em decisões cada vez mais importantes e sua implementação se torne cada vez mais visível para a sociedade, isso poderia gerar a aceitação dos algoritmos de recomendação (KRAMER et al., 2018).

Knijnenburg, Reijmer e com Willemsen (2011) compararam como diferentes processos de elicitación de preferências influenciaram a aceitação de recomendações de usuários que apresentavam características diferentes em termos de conhecimento sobre economia de energia, propensão à confiança e persistência na tomada de decisão (KNIJNENBURG; REIJMER; WILLEMSSEN, 2011). Os pesquisadores concluíram que as pessoas com pouco conhecimento sobre economia de energia (novatos) preferem métodos de interação que não demandem um conhecimento mais profundo dos atributos porque sentem mais controle sobre a situação. Já as pessoas com mais conhecimento (especialistas) preferiram os modelos Explícito e Híbrido, que permitiram controlar o algoritmo e aproveitaram o seu conhecimento com os atributos. Com respeito à persistência na tomada de decisão, os autores identificaram que indivíduos com traços de maximização estão mais satisfeitos com as suas escolhas porque o algoritmo oferece informações detalhadas de oitenta recomendações, aumentando as chances dos maximizadores de selecionarem as melhores recomendações.

Gretzel e Fesenmaier (2005) indicam que o processo de elicitación das preferências é importante porque se cria uma expectativa da qualidade na recomendação do algoritmo. Portanto, a forma como o usuário informa suas preferências pode ter um impacto significativo na avaliação das recomendações fornecidas pelo algoritmo (GRETZEL; FESENMAIER, 2005). Segundo os pesquisadores, o processo de elicitación pode gerar três interpretações sobre a recomendação: relevância, transparência (percepção de que as preferências serão usadas na recomendação e esforço (trabalho necessário para responder a elicitación). A pesquisa foi desenhada com uma manipulação dos três fatores (relevância, transparência e esforço). Os indivíduos foram apresentados a um de cinco destinos de “Spring Break” assinalados randomicamente e igualmente percebidos como atrativos pelos respondentes em pré-testes realizados anteriormente pelos pesquisadores (GRETZEL; FESENMAIER, 2005). Um ponto interessante foi a manipulação de perguntas relacionadas com o Spring Break (grupo 1) e outras perguntas sem nenhuma relação (grupo 2). A surpresa foi que os respondentes do grupo 2 interpretaram as perguntas como relacionadas a viagem. Gretzel e Fesenmaier (2005) concluem que o processo de coleta de preferências pode influenciar na aceitação da recomendação fornecida pelo algoritmo. (GRETZEL; FESENMAIER, 2005). Ao mesmo tempo, eles indicaram que os indivíduos precisam sentir que suas informações foram usadas nas recomendações dos algoritmos pois influencia na percepção de qualidade da recomendação (GRETZEL; FESENMAIER, 2005).

### **3. Método**

Os resultados de diversos estudos sugerem que um dos principais influenciadores da aceitação da recomendação é a forma como é feita a elicitación das preferências dos usuários do sistema de recomendações (GRETZEL; FESENMAIER, 2005). O objetivo deste estudo é ampliar esta área de investigação ao verificar se diferentes formatos de elicitación explícita de preferências influencia a probabilidade de aceitação de uma recomendação.

Para tanto, fizemos um experimento em que cada respondente foi exposto a um tipo diferente de elicitación de preferências explícito (KNIJNENBURG; WILLEMSSEN, 2015). O plano de fundo do experimento é a simulação de um algoritmo de recomendação de cervejas artesanais brasileiras baseado em inteligência artificial.

Os algoritmos de recomendação são frequentemente avaliados em termos de precisão das recomendações, mas a experiência do usuário com a recomendação também pode ser influenciada pelo método de elicitación de preferências (KNIJNENBURG; WILLEMSSEN, 2010). Em qualquer recomendação, há usuários com diversos níveis de conhecimento sobre o campo da recomendação. Por exemplo, algumas pessoas que não conhecem nada sobre o tema ou que sabem um pouco (iniciantes), ou outras que conhecem muito bem o assunto e têm

preferências e opiniões muito bem definidas (especialistas). Portanto, pode ser importante adaptar o método de obtenção das preferências de acordo com o usuário e assim melhorar sua experiência com o algoritmo de recomendação (KNIJNENBURG; WILLEMSSEN, 2010).

Gretzel e Fesenmaier (2005) indicam que o processo de elicitación de preferências é um processo que desenvolve uma experiência importante para a satisfação do usuário com a recomendação. No entanto, essa interação do algoritmo com a identificação das preferências da pessoa carece de novas pesquisas empíricas e são necessárias mais investigações.

### 3.1 Desenho da Pesquisa

O domínio de conhecimento escolhido para a realização deste experimento foi a cerveja pelo fato de ser uma bebida bastante popular no Brasil. Além do mais, surgiram recentemente as cervejas especiais que apresentam características distintas dos produtos de massa e, portanto, ainda existem poucos consumidores especialistas neste segmento. Assim o desenho de uma pesquisa abordando diferentes tipos de elicitación de preferências com um algoritmo de recomendação de cervejas especiais pode ser um cenário de investigação interessante e que, ao mesmo tempo, pode despertar um engajamento maior dos participantes com o estudo.

As preferências dos usuários serão elicitadas de quatro maneiras distintas, selecionadas para este estudo porque representam os métodos mais comuns de elicitación explícita de preferências. Um dos grupos foi exposto ao que denominamos grupo de controle já que nenhuma preferência foi elicitada e servirá de base de comparação com as demais formas de elicitación.

A primeira forma de elicitación foi denominada neste estudo “Histórico de Compras”. Neste formato de elicitación, o usuário indicou as últimas cervejas compradas ou consumidas de uma lista de cervejas de marcas conhecidas, formato de obtenção das preferências comumente utilizado em algoritmos de recomendação (RICCI; SHAPIRA; ROKACH, 2015). Dado que o indivíduo comprou as cervejas, é possível inferir que o produto possui uma classificação alta no ranking de suas preferências e portanto é um Processo de Elicitación de Preferências explícitas por classificação/ranking (KNIJNENBURG; WILLEMSSEN, 2015).

A segunda forma de elicitación é chamada “Características de Cerveja”. Neste método, os respondentes foram questionados sobre suas preferências em relação a diversas características de cervejas, incluindo, o tipo de sabor (leve ou maltada), o grau de amargor (moderado, acentuado), a coloração (claro, escura), o aroma (frutada, floral), o teor alcoólico (abaixo de três graus, acima de cinco graus), a origem (Belga, Americana, entre outros) e o estilo da cerveja artesanal (Indian Ale Pale, American Ale Pale, entre outros). Este pode ser considerado um Processo de Elicitación de Preferências baseado nos comentários dos indivíduos, conforme descrito por Knijnenburg e Willemsen (2015).

A terceira forma de elicitación foi denominada de “Características Pessoais”. Os indivíduos deste grupo foram questionados sobre preferências não relacionadas diretamente com os atributos de uma cerveja artesanal, incluindo tipos de restaurantes preferidos (churrascaria, comida japonesa, etc.), estilos preferidos de filmes (ação, romance, comédia, etc.), estilos de músicas preferidas (MPB, Sertanejo, Rock, etc.), esportes preferidos, viagem dos sonhos (Paris, Nova Iorque, Tailândia, etc.), cores preferidas e bebidas alcoólicas preferidas (Cerveja, Whisky, Vinho, etc).

A quarta forma de elicitación foi denominada de sugestões de preferências ao estilo “Tinder”. Neste modelo, os respondentes foram apresentados a dez marcas/tipos de cervejas artesanais brasileiras com informações sobre sua origem, fabricante, estilo, amargor, aparência, aroma, volume da embalagem, coloração, temperatura ideal para o consumo, copo sugerido, teor alcoólico e uma sugestão de harmonização com comidas. Nesta fase, o respondente deveria simplesmente indicar se gostou ou não da sugestão. Esta forma de interação pode ser

considerada como um Processo de Elicitação da Preferências por classificação explícita em que o indivíduo indica de forma binária (sim ou não) sua preferência.

A quinta e última forma de elicitação, o grupo de “Controle”, não exigiu nenhuma interação. Este será o grupo de controle do experimento e pode ser considerado uma espécie de “cold start problem” (KNIJNENBURG; WILLEMSSEN, 2015; NARA, 2019) em que o respondente é um novo usuário e não existe informações de preferências e o algoritmo informa as recomendações de cervejas especiais diretamente.

### 3.2 Amostra

A amostra foi composta por 485 pessoas (Idade Média = 42, Desvio-Padrão = 9.8; 66% homens) que participaram de um experimento com 5 grupos, entre sujeitos. Os participantes, membros de um painel de respondentes de pesquisa, foram convidados por mensagem eletrônica para participar de uma pesquisa em que deveriam avaliar um sistema de recomendação de cervejas especiais. Como incentivo, foi dito aos respondentes que eles entrariam em um sorteio de seis conjuntos de três cervejas especiais selecionadas entre aquelas que eles declararam preferir mais. O prêmio foi a forma encontrada para incentivar os respondentes a avaliarem cuidadosamente cada uma das recomendações do suposto algoritmo.

### 3.3 Procedimentos

Ao acessar o questionário eletrônico, os respondentes foram informados de que o objetivo da pesquisa era testar um sistema de recomendação de cervejas especiais. Em seguida, os respondentes declararam com que frequência costumam consumir cerveja, em que medida se consideram conhecedores de cervejas especiais usando uma escala de diferencial semântico de 7 pontos (1 = Não sei nada ou quase nada sobre cervejas especiais; 7 = Sei tudo ou quase tudo sobre cervejas especiais) e se tinham alguma restrição ao consumo de bebidas alcólicas. Todas as pessoas que declararam ter restrição ao consumo de bebidas alcólicas foram direcionadas para o fim da pesquisa e não puderam prosseguir. Em seguida, os respondentes leram as instruções relativas a cada um dos procedimentos cujo obtivo era convencer o respondente de que havia um sistema de inteligência artificial em funcionamento e que fazia as recomendações baseadas em seu perfil. Por exemplo, o grupo de “preferências baseadas no consumo passado” leu as seguintes instruções:

*O sistema de recomendações que estamos testando está baseado no histórico de compras de cervejas do consumidor. Como não conhecemos o seu histórico de compras e consumo, gostaríamos de saber as marcas de cerveja que você já comprou ou bebeu. Entre as cervejas abaixo, indique todas aquelas que você comprou ou bebeu no último ano”.*

As instruções foram ligeiramente adaptadas para cada tipo de elicitação de preferências. O grupo de controle foi apenas informado de que o sistema de recomendações fazia as recomendações em seguida.

Depois de responder às perguntas relativas ao seu sistema de preferências, foram apresentadas dez cervejas especiais selecionadas aleatoriamente dentre um grupo de vinte cervejas especiais. Cada cerveja era apresentada individualmente em uma página contendo uma fotografia da embalagem, o nome, uma breve descrição e outras informações como origem, fabricante, estilo, volume, coloração e temperatura de serviço. Todas as informações foram retiradas do website [www.clubedomalte.com.br](http://www.clubedomalte.com.br) (veja Figura 1 para um exemplo).





**Hocus Pocus Orange Sunshine**  
500ml

A Hocus Pocus Orange Sunshine é uma American Blonde Ale com adição de laranja. Esse rótulo traz toda a intensão da cervejaria quanto a produção dos seus rótulos, que é transmitir leveza, refrescância e paz. Apresenta corpo médio, sua coloração é alaranjada com aparência turva, espuma de média formação e notas frutadas, cítricas e final resinoso.

ORIGEM:	Rio de Janeiro	AMARGOR:	Baixo
CERVEJARIA	Hocus Pocus	APARÊNCIA:	Turva
ESTILO	Blonde Ale	AROMAS	Notas frutadas, cítricas e resinoso
VOLUME	500ml	COPO SUGERIDO	Tulipa
COLORAÇÃO	Alaranjada	TEOR ALCOÓLICO	5%
TEMPERATURA IDEAL	5 a 7 graus Celsius	SUGESTÃO DE HARMONIZAÇÃO	Veja abaixo



Salmon



Queijo Gouda



Comida Mexicana

Figura 1. Exemplo de estímulo do sistema de recomendação de cervejas especiais

Para cada cerveja apresentada, o respondente era solicitado a indicar em que medida aquela cerveja estava adequada à sua preferência usando uma escala de 9 pontos (1 = Não tem nada a ver comigo; 9 = Tem tudo a ver comigo) e qual a probabilidade de ele comprar aquela cerveja, também usando uma escala de 9 pontos (1 = Certamente não compraria; 9 = Certamente compraria). Depois de avaliar as 10 cervejas, os respondentes foram solicitados a indicar dados demográficos como idade, gênero e grau de escolaridade.

#### 4. Resultados

Uma vez que as mesmas cervejas foram apresentadas aleatoriamente a cada um dos respondentes, diferenças na preferência declarada e na intenção de compra só poderiam ser explicadas pelas diferenças nos procedimentos de elicitação de preferências iniciais. Uma MANOVA com 5 grupos sobre as variáveis dependentes preferência e intenção de compra não revelou diferenças significativas para a variável dependente preferência ( $F(4, 480) = 1.86, p = 0.12$ ) e uma diferença marginalmente significativa para a intenção de compra ( $F(4, 480) = 2.22, p = 0.07$ ). A figura 2 apresenta os resultados de preferência e intenção de compra para cada um dos modos de elicitação.




Figura 2. Preferência e Intenção de Compra por Tipo de Elicitação Inicial de Preferências

Estudos anteriores identificaram que a aceitação das recomendações dos algoritmos pode depender do conhecimento do usuário sobre o tema da recomendação (KNIJNENBURG; REIJMER; WILLEMSSEN, 2011; LOGG, 2018; YEOMANS et al., 2019). Para verificar se o conhecimento subjetivo teve efeito sobre a preferência e a intenção de compra identificadas neste estudo, recodificamos o conhecimento subjetivo dos respondentes em 3 grupos (alto, médio e baixo conhecimento subjetivo). Em seguida, fizemos uma MANOVA 5 (correspondentes aos 5 tipos de elicitação inicial de preferências) x 3 (correspondentes aos 3 níveis de conhecimento subjetivo) sobre as duas variáveis dependentes (preferência e intenção de compra). Os resultados revelaram um efeito principal do conhecimento subjetivo tanto para a variável dependente preferência ( $F(2,470) = 26,76$ ,  $p < 0,01$ ) quanto para a variável dependente intenção de compra ( $F(2,470) = 29,92$ ,  $p < 0,01$ ) e um efeito principal marginalmente significativo do tipo de elicitação inicial para a variável dependente preferência ( $F(4,470) = 2,15$ ,  $p = 0,07$ ) e significativo para a variável dependente intenção de compra ( $F(4,470) = 2,76$ ,  $p < 0,05$ ). Não verificamos efeitos significativos de interação entre o conhecimento subjetivo e o tipo de elicitação.

Testes post-hoc de Scheffé revelaram diferenças significativas ( $p < 0,05$ ) entre os grupos médio ( $M = 6.4$ ) e baixo conhecimento subjetivo ( $M = 5.1$ ) e alto e baixo conhecimento subjetivo ( $M = 5.1$ ) para a variável dependente preferência e diferenças significativas entre os grupos médio ( $M = 6.4$ ) e baixo conhecimento subjetivo ( $M = 5.0$ ) e alto ( $M = 6.4$ ) e baixo conhecimento subjetivo ( $M = 5.0$ ) para a variável dependente intenção de compra. Não foram verificadas diferenças significativas entre os grupos de médio e alto conhecimento subjetivo. Os testes post-hoc também sugerem diferenças significativas para as duas variáveis dependentes (preferência e intenção de compra) entre os grupos alto/médio e baixo para os tipos de elicitação inicial Características Pessoais e "Tinder". As Figuras 3 e 4 reportam os resultados obtidos para a preferência e intenção de compra de acordo com o tipo de elicitação inicial e grau de conhecimento subjetivo.

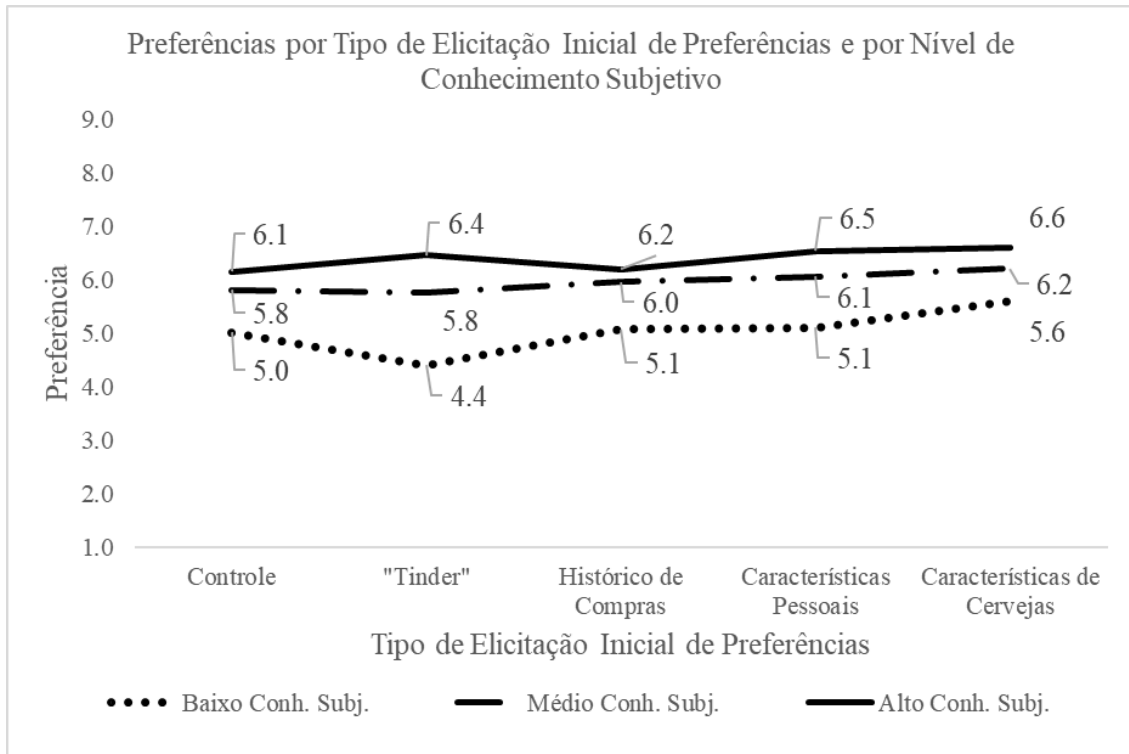


Figura 3. Preferência por Tipo de Elicitação Inicial de Preferências e Nível de Conhecimento Subjetivo




Figura 4. Intenção de Compra por Tipo de Elicitação Inicial de Preferências e Nível de Conhecimento Subjetivo

#### 4. Discussão e Conclusões

O campo de recomendação deste estudo foi a cerveja e pode ser considerada de domínio subjetivo uma vez que cada indivíduo tem a sua preferência pessoal e de acordo com estudos anteriores, passível de rejeição da recomendação do algoritmo não por não ser aceita pelos indivíduos (LOGG; MINSON; MOORE, 2019). De forma contrária, observou-se no estudo que os indivíduos aceitaram as recomendações de cervejas na medida que foi possível atribuir características comparativas como por exemplo, o grau de amargor, coloração e estilos, e dessa forma quantificar uma recomendação subjetiva, aumentando a sua adoção, conforme indicado por estudos anteriores (CASTELO; BOS; LEHMANN, 2019).

Os resultados comprovam o que estudos anteriores indicaram que o conhecimento que os indivíduos têm sobre o domínio, ou seja, a especialidade sobre o tema podem influenciar na aceitação da recomendação (LOGG, 2018).

Interessantemente foi a contatação que os indivíduos do grupo Características Pessoais ficaram satisfeitos com a recomendação, mesmo passando por um processo de elicitación de preferências não relacionado com o tema cerveja. Este fato também foi indicado em pesquisas anteriores (GRETZEL; FESENMAIER, 2005). Da mesma forma, é possível inferir que as pessoas não entendem o mecanismo pela qual um algoritmo processa as informações e definem a recomendação como sugerido em pesquisas anteriores (YEOMANS et al., 2019).

A pesquisa foi conduzido com um grupo de participantes que não representa a população do país e tão pouco pode concluir que seja indivíduos de outras regiões apresentem o mesmo comportamento, por essa razão é possível considerar como limitações deste trabalho.

Este estudo contribui para a literatura porque explorou a aceitação de recomendação em um domínio considerado subjetivo, o que contradiz com estudos anteriores que indicaram que os indivíduos preferiram as recomendações de pessoas em domínios não racionais (YEOMANS et al., 2019).

A pesquisa contribui também para os desenvolvedores de algoritmos de recomendação para a criação de novas formas de elicitación de preferência para minimizar o problema de “*cold start problem*”, bem como para empresas que possuem algum algoritmo de recomendação em suas plataformas tecnológicas no sentido de melhorar a experiência para o usuário e aumentar a satisfação com a recomendação dos produtos.

Por fim futuros trabalhos podem explorar como o conhecimento prévio sobre o tema da recomendação influencia a satisfação com o processo de elicitación de preferências, especialmente nos extremos do nível de conhecimento relativo, entre novatos que não conhecem nada sobre o assunto e os que se consideram “experts” que detêm muita informação.

#### Referências

- CASTELO, N.; BOS, M. W.; LEHMANN, D. R. Task-Dependent Algorithm Aversion. **Journal of Marketing Research**, v. 56, n. 5, p. 809–825, 2019.
- DIETVORST, B. J.; SIMMONS, J.; MASSEY, C. Understanding Algorithm Aversion: Forecasters Erroneously Avoid Algorithms After Seeing them Err. **Academy of Management Proceedings**, v. 2014, n. 1, p. 12227–12227, 2015a.
- DIETVORST, B.; SIMMONS, J. P.; MASSEY, C. Overcoming Algorithm Aversion: People Will Use Imperfect Algorithms If They Can (Even Slightly) Modify Them. **Management Science**, v. 64, n. 3, p. 1155–1170, 2015b.
- DOVE, J.; HILL, S. **How To Use Google Maps - Navigating Google Maps**. Disponível em: <<https://www.digitaltrends.com/mobile/how-to-use-google-maps/>>.

- GERMANN, M.; MERKLE, C. **Algorithm Aversion in Financial Investing**SSRN **Electronic Journal**. [s.l.: s.n.].
- GRETZEL, U.; FESENMAIER, D. R. Persuasiveness of Preference Elicitation Processes in Destination Recommendation Systems Department of Recreation , Park and Tourism Sciences National Laboratory for Tourism and e Commerce Persuasion through Preference Elicitation. **Information Technology & Tourism Information and Communication Technologies in Tourism 2005**, n. 2003, p. 194–204, 2005.
- HEGNER, S. M.; BELDAD, A. D.; BRUNSWICK, G. J. In Automatic We Trust: Investigating the Impact of Trust, Control, Personality Characteristics, and Extrinsic and Intrinsic Motivations on the Acceptance of Autonomous Vehicles. **International Journal of Human-Computer Interaction**, v. 35, n. 19, p. 1769–1780, 2019.
- HOSANAGAR, K. **A Human Guide's to Machine Intelligence: How Algorithms are shaping our lives and hoe we can stay in control**. 1st. ed. New York: Penguin, 2019.
- KNIJNENBURG, B. P.; REIJMER, N. J. M.; WILLEMSSEN, M. C. Each to his own: How different users call for different interaction methods in recommender systems. **RecSys'11 - Proceedings of the 5th ACM Conference on Recommender Systems**, p. 141–148, 2011.
- KNIJNENBURG, B. P.; WILLEMSSEN, M. C. **The effect of preference elicitation methods on the user experience of a recommender system**. Conference on Human Factors in Computing Systems - Proceedings. **Anais...**New York: ACM, 2010
- KNIJNENBURG, B. P.; WILLEMSSEN, M. C. Chapter 9 Evaluating Recommender Systems with User Experiments. In: RICCI, F.; ROKACH, L.; SHAPIRA, B. (Eds.). . **Recommender Systems Handbook, Second Edition**. 2nd. ed. New York: Springer, Berlin, Heidelberg, 2015. p. 315–316.
- KRAMER, M. F. et al. **When Do People Want AI to Make Decisions?** AIES 2018 - Proceedings of the 2018 AAAI/ACM Conference on AI, Ethics, and Society. **Anais...**2018
- LOGG, J. (HARVARD B. S. Theory of Machine: When Do People Rely on Algorithms? **SSRN Electronic Journal**, v. No. 17-086, n. March 2017, 2018.
- LOGG, J. M.; MINSON, J. A.; MOORE, D. A. Algorithm appreciation: People prefer algorithmic to human judgment. **Organizational Behavior and Human Decision Processes**, v. 151, n. April 2018, p. 90–103, 2019.
- MCCAFFREY, M. et al. **Consumer Intelligence Series: Prepare for the voice revolution**PricewaterhouseCoopers. [s.l.] PricewaterhouseCoopers, 2018.
- NARA, R. **Algoritmos de recomendação : o que são e como implementá-los ?** Disponível em: <<https://blog.geekhunter.com.br/algoritmos-de-recomendacao-o-que-sao-e-como-implementa-los/>>.
- PORTUGAL, I.; ALENCAR, P.; COWAN, D. The Use of Machine Learning Algorithms in Recommender Systems: A Systematic Review. **Expert Systems with Applications**, v. 97, n. 1, p. 205–277, 2018.
- PRATA, M. **Conheça o incrível mercado das casas conectadas**BrazilPrograma Mundo S/A, Globosat, , 2019. Disponível em: <<https://globosatplay.globo.com/globonews/v/7682804/>>
- RICCI, F.; SHAPIRA, B.; ROKACH, L. **Chapter 1 Recommender Systems: Introduction and Challenges**. Second ed. New York: Springer, 2015.
- VERRUCK, F.; NIQUE, M. W. THE BEHAVIORAL SIDE OF RECOMMENDATION AGENTS : A BIBLIOMETRIC REVIEW O LADO COMPORTAMENTAL DOS AGENTES DE RECOMENDAÇÃO : UMA REVISÃO BIBLIOMÉTRICA. **Brazilian Journal of Management & Innovation**, v. 5, n. 1, p. 101–124, 2017.
- YEOMANS, M. et al. Making sense of recommendations. **Journal of Behavioral Decision Making**, n. March 2018, p. 1–12, 2019.