

DISSERTAÇÃO

**O PARADOXO DA ATENÇÃO: A PERSONALIZAÇÃO
ALGORÍTMICA BASEADA EM INTELIGÊNCIA ARTIFICIAL
MELHORA OU PREJUDICA A ATENÇÃO DOS UTILIZADORES?**

AUTOR(A): Beatriz Marques Ribeiro

ORIENTADOR(A): João Paixão

INSTITUTO PORTUGÊS DE MARKETING DE LISBOA, JUNHO, 2025

O PARADOXO DA ATENÇÃO

A PERSONALIZAÇÃO ALGORÍTMICA BASEADA EM INTELIGÊNCIA ARTIFICIAL MELHORA OU PREJUDICA A ATENÇÃO DOS UTILIZADORES?

AUTOR(A): Beatriz Marques Ribeiro

Dissertação apresentado(a) ao IPAM, para cumprimento dos requisitos necessários à obtenção do grau de Mestre em *Gestão de Marketing* realizado(a) sob a orientação científica do Professor Doutor *João Paixão*.

INSTITUTO PORTUGÊS DE MARKETING DE LISBOA, JUNHO, 2025

AGRADECIMENTOS

A concretização desta dissertação representa um marco importante na minha vida pessoal e académica. Chegar até aqui foi um caminho exigente, e não teria sido possível sem o apoio incondicional de várias pessoas que me acompanharam em cada etapa. A todas elas, deixo a minha mais sincera gratidão.

Ao Ricardo, meu noivo, companheiro de vida e de projetos, agradeço por ter estado sempre ao meu lado com uma paciência infinita, por me amparar nos momentos de maior exigência, por acreditar em mim mesmo quando eu duvidava, e por nunca me deixar desistir. A tua força silenciosa e presença constante foram âncoras ao longo de todo este percurso.

Ao meu pai, o meu pilar, o meu herói, agradeço por cada palavra de encorajamento, por cada gesto de apoio e por ser, em todas as circunstâncias, um exemplo de dedicação, sabedoria e amor incondicional. À minha mãe, o meu agradecimento mais profundo. Obrigada por seres a minha maior inspiração, pela força diária que me transmites e pelo orgulho que sentes em mim. O vosso amor, dedicação e coragem são a base de tudo o que sou.

Ao meu irmão, pela preocupação genuína, pelas conversas, pela curiosidade com que acompanhou cada etapa desta investigação, e por ser sempre um ouvinte atento e presente. A tua preocupação e apoio deram-me segurança ao longo do processo.

À minha cunhada, amiga e também parceira no trabalho, agradeço por teres partilhado o peso dos dias difíceis e por me dares força nas alturas mais críticas.

Ao meu orientador, deixo um agradecimento especial pela disponibilidade, pela orientação rigorosa, mas sempre encorajadora, e pelo acompanhamento atento ao longo de todo o processo. A sua dedicação e apoio foram cruciais para que esta dissertação se concretizasse com a qualidade e profundidade que eu ambicionava.

A todos vós, o meu mais sincero obrigada.

RESUMO

Num contexto digital cada vez mais mediado por sistemas de recomendação, esta dissertação analisa o impacto da personalização algorítmica nos processos atencionais dos utilizadores, com especial foco na atenção dirigida a conteúdos patrocinados. Partindo do contexto das plataformas de redes sociais, mais especificamente utilizando a plataforma TikTok como caso de estudo, procurou-se compreender de que forma a intensidade da personalização influencia a atenção percebida, bem como o papel mediador da percepção das *filter bubbles* e da fadiga algorítmica nesta relação.

A metodologia adotada consistiu num estudo experimental com 34 participantes divididos em dois grupos: um exposto ao feed “Para Ti” (n = 19), altamente personalizado, e outro ao feed “A Seguir” (n = 15), composto predominantemente por publicações de contas seguidas pelo utilizador e com menor intervenção algorítmica (ainda que sujeito a conteúdos patrocinados e alguma curadoria). Foi aplicado um questionário online após a exposição aos conteúdos, analisando-se variáveis como percepção de personalização, *filter bubbles*, fadiga algorítmica e atenção percebida.

Os resultados revelaram que a personalização algorítmica afeta negativamente a atenção dos utilizadores, sendo esse efeito mediado pela fadiga algorítmica, mas não significativamente pela percepção de *filter bubbles*. Estes dados sugerem que a sobrecarga cognitiva provocada por algoritmos excessivamente personalizados pode comprometer a eficácia da publicidade digital, quer orgânica, quer paga. As conclusões apontam para a necessidade de estratégias de personalização mais equilibradas, que tenham em conta os limites da atenção humana e o bem-estar digital dos utilizadores. A principal limitação do estudo prende-se com o reduzido tamanho da amostra, o que condiciona a generalização dos resultados. Ainda assim, esta investigação contribui para o debate emergente sobre o futuro da atenção em ambientes digitais altamente personalizados, sendo especialmente relevante para profissionais de marketing e investigadores na área de comportamento do consumidor.

Palavras-chave: personalização algorítmica, inteligência artificial, *filter bubbles*, fadiga algorítmica, atenção do utilizador, redes sociais, publicidade digital

ABSTRACT

In a digital environment increasingly mediated by recommendation systems, this dissertation investigates the impact of algorithmic personalization on users' attentional processes, with a particular focus on attention directed towards sponsored content. Drawing on the context of social media platforms - specifically using TikTok as a case study - this study aimed to understand how the intensity of personalization influences perceived attention, as well as the mediating role of filter bubbles and algorithmic fatigue in this relationship.

The methodology consisted of an experimental study involving 34 participants divided into two groups: one exposed to the "For You" feed ($n = 19$), characterized by a high level of personalization, and another exposed to the "Following" feed ($n = 15$), composed predominantly of posts from followed accounts and with less algorithmic intervention (though still subject to sponsored content and some degree of curation). After the exposure, participants completed an online questionnaire assessing perceived personalization, filter bubbles, algorithmic fatigue, and perceived attention.

The results showed that algorithmic personalization negatively affects users' attention, with this effect being mediated by algorithmic fatigue, but not significantly by the perception of filter bubbles. These findings suggest that the cognitive overload caused by highly personalized algorithms may undermine the effectiveness of both organic and paid digital advertising. The conclusions highlight the need for more balanced personalization strategies that consider the limits of human attention and users' digital well-being. The main limitation of the study lies in the small sample size, which constrains the generalizability of the results. Nevertheless, this research contributes to the ongoing debate on the future of attention in highly personalized digital environments, being especially relevant for marketing professionals and scholars in the field of consumer behaviour.

Keywords: algorithmic personalization, artificial intelligence, filter bubbles, algorithmic fatigue, user attention, social media, digital advertising

Índice

| | |
|--|-----------|
| AGRADECIMENTOS | 2 |
| RESUMO | 3 |
| ABSTRACT..... | 4 |
| ÍNDICE DE FIGURAS..... | 6 |
| ÍNDICE DE TABELAS | 7 |
| 1. INTRODUÇÃO | 9 |
| 2. REVISÃO DA LITERATURA | 14 |
| Inteligência Artificial no Marketing Digital | 14 |
| Personalização Algorítmica e os Efeitos na Atenção do Consumidor | 16 |
| Filter Bubbles, Isolamento Cognitivo e Sobrecarga Cognitiva nas Redes Sociais | 25 |
| Fundamentação Teórica do Modelo Conceptual..... | 31 |
| Descrição das Variáveis e Modelo Conceptual Gráfico | 34 |
| Formulação das Hipóteses..... | 40 |
| 3. METODOLOGIA | 44 |
| Justificação do Contexto Experimental | 45 |
| Operacionalização das Variáveis | 47 |
| Descrição do Método Experimental..... | 49 |
| 4. ANÁLISE DE DADOS | 52 |
| Estatística Descritiva | 53 |
| Análise de Regressão | 67 |
| Teste de Mediação (com a macro PROCESS – Modelo 6)..... | 71 |
| 5. DISCUSSÃO | 75 |
| 6. CONCLUSÃO | 79 |
| Limitação do Estudo e Sugestões para Investigações Futuras..... | 80 |
| REFERÊNCIAS BIBLIOGRÁFICAS..... | 82 |
| APÊNDICES..... | 92 |
| ANEXOS..... | 95 |

Índice de Figuras

| | |
|---|----|
| Figura 1 - Modelo Conceptual: Representação das relações entre a intensidade da personalização algorítmica e a atenção do utilizador, considerando a mediação sequencial por filter bubbles e fadiga algorítmica. A variável dependente é subdividida em “Atenção Geral do Utilizador” e “Atenção do Utilizador a Conteúdos Patrocinados” | 38 |
| Figura 2 – Gráfico de Barras relativo às Médias das variáveis principais por grupo experimental..... | 56 |
| Figura 3 - Boxplots comparativos entre os grupos experimentais para as variáveis filter_bubbles, fadiga_algorítmica, atenção e atenção_patrocinados..... | 57 |

Índice de Tabelas

| | |
|--|----|
| Tabela 1 - Validação da Escala para Medição de <i>Filter Bubbles</i> através do Alpha de Cronbach..... | 47 |
| Tabela 2 - Validação da Escala para Medição de Fadiga Algorítmica através do Alpha de Cronbach..... | 48 |
| Tabela 3 - Validação da Escala para Medição da Atenção Geral do Utilizador através do Alpha de Cronbach..... | 48 |
| Tabela 4 - Validação da Escala para Medição da Atenção do Utilizador a Conteúdos Patrocinados através do Alpha de Cronbach..... | 49 |
| Tabela 5 - Estatística Descritiva por Grupo | 55 |
| Tabela 6 - Teste de Normalidade | 58 |
| Tabela 7 - Teste T de Amostras Independentes | 58 |
| Tabela 8 - Correlações de Pearson | 59 |
| Tabela 9 - Verificação da H1a recorrendo a Teste-t para comparação entre grupos | 60 |
| Tabela 10 - Verificação da H1b com atenção a conteúdos patrocinados recorrendo a Teste-t para comparação entre grupos..... | 61 |
| Tabela 11 - Verificação da H2 recorrendo a Teste-t para comparação entre grupos | 62 |
| Tabela 12 - Verificação da H3 recorrendo a Teste-t para comparação entre grupos | 62 |
| Tabela 13 - Verificação da H4 recorrendo a Teste-t para comparação entre grupos com alta e baixa perceção de <i>Filter Bubbles</i> | 63 |
| Tabela 14 - Verificação da H5a recorrendo a Teste-t para comparação da atenção geral do utilizador entre grupos com alta e baixa perceção de <i>Filter Bubbles</i> | 64 |
| Tabela 15 - Verificação da H5b recorrendo a Teste-t para comparação da atenção do utilizador a conteúdos entre grupos com alta e baixa perceção de <i>Filter Bubbles</i> | 65 |
| Tabela 16 - resultados do teste t realizado para avaliar o impacto da fadiga algorítmica na atenção geral do utilizador (H6a). | 65 |

| | |
|--|----|
| Tabela 17 – Test-t para comparação dos níveis de atenção a conteúdos patrocinados entre utilizadores com alta e baixa perceção de fadiga algorítmica (H6b). | 66 |
| Tabela 18 - Resultados das análises de regressão linear simples realizadas para os grupos A (alta personalização algorítmica) e B (baixa personalização), com o objetivo de testar as hipóteses H4, H5a, H5b, H6a e H6b | 68 |
| Tabela 19 - Regressão Linear Múltipla para teste do Modelo Estrutural Completo..... | 71 |
| Tabela 20 - Efeitos diretos, indiretos e totais da intensidade da personalização algorítmica sobre a atenção geral do utilizador, com mediação sequencial pela perceção de filter bubbles e pela fadiga algorítmica..... | 72 |
| Tabela 21 - Efeitos direto, indireto e total da intensidade da personalização algorítmica sobre a atenção geral do utilizador, com mediação simples pela fadiga algorítmica (Modelo 4 – PROCESS)..... | 72 |
| Tabela 22 - Efeitos direto, indireto e total da intensidade da personalização algorítmica sobre a atenção do utilizador a conteúdos patrocinados, com mediação em série pela perceção de filter bubbles e pela fadiga algorítmica (Modelo 6 – PROCESS) | 73 |
| Tabela 23 - Efeitos total, direto e indireto da intensidade da personalização algorítmica sobre a atenção do utilizador a conteúdos patrocinados, com mediação pela fadiga algorítmica (Modelo 4 – PROCESS) | 74 |

1. Introdução

A área do Marketing Digital é uma disciplina em constante evolução e de crescente importância na era digital, sendo essencial para que marcas e negócios consigam propagar a sua mensagem e alcançar mais pessoas interessadas nos seus produtos e serviços. Para tal, é fundamental que as empresas se mantenham atualizadas sobre o mercado e as novas ferramentas que possam suportar a produção de conteúdo com foco nos interesses do potencial cliente. Como Kaplan e Haenlein (2019) destacam, a integração da tecnologia no marketing transformou fundamentalmente a forma como as empresas se comunicam com os consumidores. Paralelamente, a forma como os consumidores interagem e se relacionam com os negócios também tem vindo a mudar, verificando-se uma tendência crescente para uma menor interação espontânea com conteúdos digitais, em grande parte motivada por fenómenos de fadiga digital e saturação resultantes da sobre-exposição a algoritmos de personalização (Golbeck, 2020).

Atualmente, há uma preferência por conteúdos personalizados, que agreguem valor específico ao utilizador e sejam suficientemente relevantes para serem guardados e consultados posteriormente, especialmente entre utilizadores frequentes de plataformas digitais (Stevenson & Pasek, 2015).

Neste contexto, importa compreender quais os efeitos reais da personalização algorítmica, definida como o processo de seleção automática de conteúdos digitais com base em dados comportamentais, históricos e nas preferências dos utilizadores, com o objetivo de maximizar o envolvimento e a relevância percebida (Gillespie, 2014), sobre a forma como os utilizadores consomem e processam a informação, particularmente em ambientes digitais fortemente mediados por Inteligência Artificial (IA). Torna-se, assim, essencial delimitar com clareza o foco da presente investigação, apresentando a sua questão central e os respetivos objetivos, que orientarão o desenvolvimento empírico do estudo.

Seguindo este enquadramento, a presente investigação procura responder à seguinte questão central:

Qual o impacto direto da personalização algorítmica baseada em IA na atenção dos utilizadores a conteúdos patrocinados?

Objetivo geral: Analisar de forma empírica o impacto da personalização algorítmica baseada em IA na atenção dos consumidores a conteúdos patrocinados em redes sociais, considerando efeitos diretos e indiretos.

Objetivos específicos:

- Analisar a relação entre a intensidade da personalização algorítmica e os níveis de atenção do utilizador;
- Investigar se níveis elevados de personalização contribuem para o surgimento de fadiga algorítmica;
- Explorar a influência das *filter bubbles* na flexibilidade cognitiva e no processamento de novos estímulos;
- Avaliar os impactos da fadiga algorítmica na capacidade de concentração e retenção de informação;
- Compreender em que medida a atenção dos utilizadores a conteúdos patrocinados é afetada por diferentes níveis de personalização algorítmica;
- Propor estratégias práticas para otimizar a atenção dos utilizadores enquanto consumidores de conteúdos digitais patrocinados em ambientes digitais personalizados.

O problema central desta investigação passa precisamente por compreender o impacto da personalização algorítmica baseada em IA na atenção dos utilizadores a conteúdos patrocinados, analisando de que forma este tipo de recomendação pode influenciar os padrões de consumo de informação e o processamento cognitivo. O crescente desenvolvimento de sistemas algorítmicos tem permitido uma segmentação cada vez mais precisa do público-alvo, adaptando o conteúdo exibido de acordo com os interesses individuais dos utilizadores (Davenport et al., 2020). No entanto, a literatura levanta questões sobre se esta personalização melhora a capacidade de atenção do utilizador ou, pelo contrário, contribui para a dispersão cognitiva e a redução da retenção de informação (Haefner et al., 2021).

A personalização algorítmica assenta na recolha e análise de dados comportamentais para prever preferências e sugerir conteúdos, produtos ou serviços de forma automatizada (Kumar et al., 2019). Diversos estudos indicam que esta estratégia pode ser vantajosa na medida em que reduz a sobrecarga informativa e apresenta opções altamente relevantes para cada utilizador, aumentando, teoricamente, a sua capacidade de manter a atenção (Kaplan e Haenlein, 2019). No entanto, a excessiva exposição a conteúdos personalizados pode gerar *algorithmic fatigue*, um fenómeno em que o utilizador perde interesse devido à previsibilidade excessiva das

recomendações, resultando na diminuição da atenção e numa menor predisposição para interagir com os conteúdos apresentados (Li et al., 2024).

Outro fator crítico associado à personalização algorítmica é a criação de *filter bubbles*, que limitam a diversidade informativa ao restringir a exposição do utilizador a conteúdos que reforçam as suas crenças e interesses preexistentes (Flaxman, Goel & Rao, 2016). Embora este mecanismo tenha como objetivo otimizar a experiência do utilizador, pode reduzir a sua capacidade de manter a atenção em conteúdos novos ou menos alinhados com os seus padrões habituais de consumo, tornando-o cognitivamente menos flexível e mais sujeito a comportamentos de consumo previsíveis (Kumar et al., 2019).

A literatura sublinha também a sobrecarga cognitiva como uma das principais consequências da personalização excessiva. Quando confrontados com um volume excessivo de recomendações altamente direcionadas, os utilizadores podem experienciar a chamada *decision fatigue*, um estado no qual a tomada de decisão se torna mentalmente exaustiva, afetando negativamente a capacidade de atenção e a satisfação com o conteúdo consumido (Haefner et al., 2021). Esta fragmentação da atenção pode resultar na redução da retenção de informação, na diminuição do envolvimento cognitivo e, em última instância, na perda de interesse pelos conteúdos personalizados (Davenport et al., 2020).

A relevância do presente estudo reside na necessidade de aprofundar a compreensão sobre o impacto da personalização algorítmica na atenção dos utilizadores a estímulos de marcas, com foco especial em conteúdos patrocinados, num contexto em que os sistemas de inteligência artificial reconfiguram progressivamente os modos de consumo de informação digital. Embora a relação entre sobrecarga informativa e atenção se encontre amplamente documentada na literatura (Haefner, Wincent, Parida, & Gassmann, 2021), cumpre esclarecer que a problemática abordada neste trabalho não se refere à quantidade absoluta de informação, mas antes à sua redundância estruturada. Isto é, à exposição continuada a conteúdos altamente semelhantes, resultante da personalização algorítmica. Este tipo de curadoria automatizada, ao restringir a diversidade informativa, pode desencadear efeitos contraditórios: aumentar a atenção inicial ao apresentar conteúdos considerados relevantes, mas simultaneamente induzir fenómenos como a fadiga algorítmica (Li, Chen, & Zhao, 2024) e a formação de *filter bubbles* (Flaxman, Goel, & Rao, 2016), com potenciais impactos negativos na atenção sustentada e na flexibilidade cognitiva do utilizador.

Este tipo de “fadiga pela repetição” distingue-se da sobrecarga clássica, visto que, não decorre do volume de informação, mas da homogeneidade e previsibilidade dos conteúdos apresentados, como destacado por autores como Kaluža (2021) e Zhang et al. (2025).

Ao longo desta investigação, será analisado se a personalização algorítmica baseada em IA pode ser considerada uma ferramenta eficaz para melhorar a atenção dos utilizadores a conteúdos em geral e especificamente a patrocinados, ou se, pelo contrário, representa um risco de desatenção cognitiva. Para além disso, pretende-se examinar os limites da *hiperpersonalização*, entendida como o grau de personalização que excede o limiar de tolerância do consumidor, resultando em previsibilidade excessiva e potencial saturação cognitiva (Wang, Yu, Feng, & Song, 2022). Será igualmente analisado de que forma a exposição continuada a conteúdos semelhantes influencia a retenção de informação e a capacidade de concentração. A investigação procura também explorar o impacto das *filter bubbles* (já previamente definidas como ambientes informacionais fechados causados por algoritmos) na atenção do consumidor, procurando compreender até que ponto estas limitam a flexibilidade cognitiva e o processamento de novos estímulos. Finalmente, serão discutidas estratégias para mitigar os efeitos da personalização algorítmica, de forma a permitir uma utilização mais equilibrada e ética da IA em plataformas digitais por profissionais de marketing digital, bem como, permitir a criação de estratégias que promovam maior atenção dos utilizadores a conteúdos patrocinados.

Com o crescimento acelerado do uso de IA e a influência crescente das recomendações algorítmicas na experiência do utilizador, torna-se essencial compreender os limites e desafios desta tecnologia, garantindo que a sua aplicação promova um consumo de informação saudável e sustentável (Davenport et al., 2020). Esta investigação tem como objetivo oferecer insights práticos para profissionais de marketing digital, permitindo uma melhor compreensão do equilíbrio necessário entre personalização e atenção do utilizador a estímulos de marca patrocinados. A originalidade deste estudo reside na sua abordagem focada exclusivamente na atenção e personalização, diferenciando-se de investigações que abordam apenas a sobrecarga de informação ou o *engagement* do consumidor, um conceito ainda sem métricas consensuais na literatura (Coombs, 2020).

A presente investigação oferece contribuições significativas no campo do marketing digital, particularmente no que tange à intersecção entre a personalização via inteligência artificial (IA)

e a atenção do utilizador a conteúdos patrocinados. Primeiramente, será proporcionada uma análise detalhada do impacto da personalização através de IA na criação de *filter bubbles* e consequentemente na capacidade de atenção a estímulos de marketing digital pagos.

Esta análise é fundamentada em estudos como os de Davenport et al. (2020), que examinam como a IA está a remodelar as interações entre marcas e consumidores, enfatizando a importância da personalização e da relevância do conteúdo.

2. Revisão da Literatura

Inteligência Artificial no Marketing Digital

Na obra "Marketing 4.0", Kotler et al. (2016) examinam a transformação do marketing na era digital, sublinhando o papel cada vez mais preponderante da Inteligência Artificial (IA). Os autores defendem que a IA, ao personalizar a experiência do consumidor, está a reconfigurar fundamentalmente o modo como as marcas comunicam e interagem com os seus públicos. Esta perspetiva é também reforçada por outras investigações na área com as de Shaw e Ivans (2020), no seu trabalho "Marketing in the Age of Alexa", onde discutem como a IA está a mudar a interação dos consumidores com a tecnologia, particularmente através de assistentes de voz e personalização algorítmica para a criação de experiências personalizadas. Argumentam que a IA está a criar oportunidades para as marcas se envolverem com os consumidores de maneira mais intuitiva e imersiva. A crescente adoção deste tipo de tecnologias permite que as marcas ofereçam comunicações mais vocacionadas e contextuais, otimizando consequentemente o alcance e a conversão de leads e vendas.

Para além disto, também Meeker (2018), no seu relatório anual sobre tendências da internet, destaca que a IA está a impulsionar uma mudança nos padrões de consumo de media, com implicações significativas para o marketing digital. Segundo Meeker, esta mudança está centrada na capacidade da IA de analisar grandes volumes de dados para fornecer estatísticas e dados mais precisos sobre preferências e comportamentos dos consumidores.

Meeker (2018) destaca que a IA tem um impacto direto nos padrões de consumo de media, pois consegue processar grandes volumes de dados e fornecer estatísticas detalhadas sobre preferências dos utilizadores. Esta análise preditiva permite às empresas ajustar o conteúdo apresentado, aumentando a retenção do utilizador e a sua experiência geral.

Portanto, à medida que a IA continua a evoluir, é imperativo que os profissionais de marketing compreendam e adaptem as suas estratégias para aproveitar ao máximo as oportunidades oferecidas por esta tecnologia disruptiva.

Obiegbu e Larsen (2024) aprofundam a relação entre personalização algorítmica e lealdade à marca, evidenciando que quando o consumidor sente que o algoritmo compreende os seus gostos e comportamentos, a perceção de valor aumenta e o vínculo emocional fortalece-se. Este loop de personalização cria uma experiência de marca mais rica, mas pode ser facilmente

invertido se as recomendações se tornarem irrelevantes ou intrusivas, levando à ruptura da relação consumidor-marca.

Por sua vez, Puntoni et al. (2021) destacam os riscos psicossociais da IA no marketing, alertando para efeitos de perda de autonomia, percepções de vigilância e redução da espontaneidade nas interações consumidor-marca. A eficácia da IA depende, portanto, não só da sua capacidade técnica, mas também da sensibilidade ao impacto humano que gera.

A aplicação da IA no marketing digital tem sido objeto de diversos estudos recentes que evidenciam a sua eficácia na personalização de experiências e na melhoria do desempenho das campanhas. Por exemplo, a empresa europeia Zalando integrou IA generativa para acelerar a produção de conteúdos para campanhas de marketing, reduzindo significativamente o tempo e os custos associados. Esta abordagem permitiu à Zalando responder mais rapidamente às tendências emergentes nas redes sociais, demonstrando a capacidade da IA em adaptar-se a contextos dinâmicos e em constante mudança (Reuters, 2025).

Ao mesmo tempo, diversos estudos académicos têm explorado o impacto da personalização impulsionada por IA no comportamento do consumidor e no envolvimento com as marcas. Ahmed et al. (2025) investigaram como a integração da IA em estratégias de marketing online influencia o envolvimento do cliente e o comportamento de compra, destacando a importância de recomendações personalizadas e chatbots na satisfação e lealdade do cliente.

Mustak et al. (2021), numa análise bibliométrica extensa, identificam a personalização de conteúdo e a geração automática de mensagens como duas das áreas mais ativamente exploradas em marketing digital com IA. Os autores sublinham que, para além dos ganhos operacionais, estas técnicas exigem elevada atenção ética, principalmente no que toca à transparência algorítmica, coerência da voz da marca e à percepção de manipulação pelo consumidor.

A IA também tem sido fundamental na transformação da experiência do cliente, permitindo que as empresas ofereçam interações mais relevantes e personalizadas em grande escala. Segundo Medallia (2024), a personalização baseada em IA ajuda as empresas a cortar o ruído do mercado saturado, entregando experiências personalizadas que aumentam a satisfação e a fidelização dos clientes.

No contexto das redes sociais, a Inteligência Artificial (IA) tem desempenhado um papel fundamental na análise de grandes volumes de dados para identificar padrões de comportamento e preferências dos utilizadores (Perakakis et al., 2019). Esta capacidade permite às marcas adaptar as suas mensagens e conteúdos de forma mais eficaz, melhorando o envolvimento e conseqüentemente a conversão, como demonstrado por diversas investigações que analisam o impacto da IA na personalização de conteúdos e na eficácia das estratégias de marketing digital (Gupta & Khan, 2024); (Nazir et al., 2022).

Contudo, a literatura também alerta para potenciais efeitos negativos da personalização excessiva, como a previsibilidade dos conteúdos e a fadiga informativa. Quando os algoritmos filtram excessivamente a informação com base no comportamento passado do utilizador, há um risco de redução do envolvimento e da atenção, dado que os consumidores podem sentir-se saturados com sugestões repetitivas e pouco diversificadas (Li et al., 2024).

Personalização Algorítmica e os Efeitos na Atenção do Consumidor

A personalização algorítmica refere-se ao uso de machine learning para analisar padrões de comportamento e prever interesses dos consumidores, ajustando as recomendações de conteúdos apresentados nas plataformas digitais (Kumar et al., 2019). Esta tecnologia tem sido amplamente utilizada em setores como e-commerce, redes sociais e serviços de streaming, proporcionando experiências altamente personalizadas aos utilizadores. A personalização permite que os consumidores sejam expostos a conteúdos mais relevantes, reduzindo a necessidade de filtragem manual da informação e, conseqüentemente, minimizando a sobrecarga informativa (Haefner et al., 2021). No entanto, a crescente sofisticação dos algoritmos de recomendação levanta questões sobre os seus efeitos na capacidade de atenção do consumidor e no seu envolvimento com os conteúdos apresentados.

A literatura sugere que, quando implementada de forma equilibrada, a personalização pode aumentar significativamente a atenção dos consumidores, proporcionando uma navegação mais intuitiva e reduzindo a distração provocada pelo excesso de opções disponíveis. Haefner et al. (2021) argumentam que sistemas de personalização bem calibrados são capazes de aumentar o tempo de interação com os conteúdos sugeridos, favorecendo o envolvimento do utilizador. Da mesma forma, Kumar et al. (2019) defendem que a personalização pode fortalecer a lealdade

do consumidor à marca, pois gera uma experiência de consumo mais fluida e ajustada às suas preferências individuais.

A personalização algorítmica tornou-se onipresente nas redes sociais, e-commerce e plataformas de conteúdo, moldando de forma decisiva a disputa pela atenção do consumidor. Estudos mais recentes destacam efeitos ambíguos dessa personalização sobre a atenção: aumenta a relevância do conteúdo exibido para cada utilizador, potencializando o envolvimento, mas ao mesmo tempo, acarreta riscos como perda de autonomia, redução da diversidade informativa e preocupações com privacidade. Segundo Tønnesen e Tennfjord (2023), embora a personalização melhore a relevância percebida do serviço para o utilizador, também introduz riscos associados à limitação do controlo pessoal, à previsibilidade excessiva e à restrição de acesso a perspetivas diversas, o que pode afetar negativamente a experiência digital.

Do ponto de vista teórico, Cloarec (2020) propõe que a personalização deve ser analisada à luz da economia da atenção, pois representa um equilíbrio delicado entre conveniência e risco. O autor argumenta que, ao utilizar dados pessoais para personalizar a experiência do utilizador, os profissionais de marketing levantam preocupações legítimas relacionadas com a privacidade e o controlo individual. Nesse contexto, introduz o conceito de “paradoxo personalização–privacidade”, segundo o qual os consumidores valorizam a relevância dos conteúdos oferecidos, mas simultaneamente receiam os custos associados à partilha de dados pessoais e à perceção de manipulação algorítmica. Fatores que podem comprometer a atenção e o envolvimento com o conteúdo apresentado.

Apesar de se encontrarem alguns benefícios, há um ponto de saturação no qual o efeito positivo da personalização pode ser revertido. O conceito de *Algorithmic Fatigue* tem sido estudado como um fenómeno que ocorre quando os consumidores são constantemente expostos a recomendações previsíveis e repetitivas, levando à perda de interesse e à redução da atenção (Li et al., 2024). Este fenómeno está associado à previsibilidade dos conteúdos recomendados, que, em vez de estimular a descoberta e o envolvimento do utilizador, cria um ambiente de consumo monótono e limitado. Estudos como o de Flaxman, Goel & Rao (2016) indicam que a diversidade do conteúdo apresentado desempenha um papel essencial na manutenção da

atenção do utilizador, pois ao expô-lo a diferentes perspetivas e opções estimula o processamento cognitivo e reduz a probabilidade de desinteresse precoce.

Zhang et al. (2025) reforçam esta preocupação ao demonstrarem que a fadiga algorítmica atua como uma variável mediadora na relação entre perceções negativas da personalização e a intenção de abandono das plataformas digitais. Os autores explicam que, quando os utilizadores percecionam os conteúdos personalizados como excessivamente repetitivos ou previsíveis, a eficácia das recomendações diminui. Este efeito leva a uma redução do tempo de permanência nas plataformas e a uma menor atenção dedicada ao conteúdo apresentado.

Outro fator a considerar é o impacto da personalização algorítmica na criação de *filter bubbles*, onde os consumidores são sistematicamente expostos a conteúdos alinhados às suas preferências prévias, limitando a diversidade de informação recebida e, potencialmente, reduzindo a sua capacidade de atenção para conteúdos não familiares (Flaxman, Goel & Rao, 2016). Este isolamento informativo pode restringir a capacidade do utilizador de processar novas informações e explorar diferentes perspetivas, o que pode ser particularmente prejudicial em contextos como a informação noticiosa e a tomada de decisão de consumo (Coombs, 2020). Para além disto, a exposição contínua a conteúdos muito semelhantes pode levar a um efeito de habituação, onde os utilizadores desenvolvem uma menor resposta emocional e cognitiva ao conteúdo apresentado, reduzindo a sua eficácia em captar e reter a atenção (Li et al., 2024).

Kaluža (2022) propõe que as *filter bubbles* devem ser compreendidas como resultado de uma adaptação bidirecional entre os utilizadores e os algoritmos de personalização. À medida que os utilizadores interagem repetidamente com determinados tipos de conteúdo, os algoritmos ajustam as suas recomendações para se alinharem com essas preferências, o que pode levar a uma exposição informativa cada vez mais restrita. Este processo de personalização contínua pode limitar o repertório cognitivo dos utilizadores, direcionando a sua atenção para temas previsíveis e confortáveis, potencialmente reduzindo a diversidade de informações a que estão expostos.

Esta problemática torna-se ainda mais relevante no caso dos conteúdos patrocinados em redes sociais. Estudos demonstram que a personalização de anúncios pode aumentar significativamente a atenção visual e a taxa de cliques, desde que os conteúdos sejam percebidos como relevantes e não intrusivos. Por exemplo, Bang e Wojdyski (2016)

observaram que anúncios personalizados provocam maior tempo de fixação visual e níveis mais altos de atenção em comparação com anúncios genéricos. Contudo, Aguirre et al. (2015) alertam para o chamado “paradoxo da personalização”: quando o utilizador percebe os anúncios como excessivamente personalizados ou invasivos, há uma reação negativa que leva à rejeição ou evitamento desses conteúdos.

Ao mesmo tempo, Jung (2017) demonstrou que a percepção de relevância do anúncio é um forte preditor da atenção do utilizador e da sua aceitação do conteúdo patrocinado. No entanto, esta percepção depende do contexto e da transparência percebida na personalização. Em ambientes saturados, como o feed algorítmico do TikTok, Jung e Heo (2021) identificaram que, mesmo formatos nativos de anúncios personalizados, quando excessivos ou mal integrados, podem perder eficácia.

Plume e Slade (2018) também contribuíram para a compreensão deste fenómeno ao demonstrar que a motivação para interagir com conteúdos patrocinados em redes sociais depende da combinação de valor informativo, entretenimento e congruência com os interesses pessoais. Todos elementos que podem ser amplificados ou prejudicados por sistemas de personalização algorítmica.

A literatura também sugere que a personalização algorítmica pode contribuir para a sobrecarga cognitiva na tomada de decisão (*decision fatigue*), um fenómeno no qual a sobrecarga de opções altamente personalizadas leva ao cansaço mental, dificultando a tomada de decisões e diminuindo a atenção do consumidor (Davenport et al., 2020). Quando confrontados com um número elevado de sugestões semelhantes, os utilizadores podem passar pela experiência de viver um efeito paradoxal onde, em vez de facilitar a escolha, a personalização excessiva torna o processo de decisão mais desgastante e menos eficiente (Haefner et al., 2021). Este efeito tem sido identificado principalmente em plataformas de streaming e e-commerce, onde a vasta gama de recomendações personalizadas pode levar à paralisia da escolha e a um menor envolvimento com o conteúdo final selecionado (Li et al., 2024).

Neglur e Rajeswari (2024) analisaram o caso da Netflix e verificaram que, apesar da eficácia do algoritmo em manter os utilizadores envolvidos, as estratégias de persuasão digital podem ultrapassar a linha entre persuasão e manipulação. A atenção dos utilizadores começa a dissipar-se quando sentem que não têm, na realidade, liberdade de escolha.

Conseguimos desta forma compreender que a literatura mais atual enfatiza que a personalização algorítmica só cumpre o seu potencial relativamente à retenção de atenção quando equilibrada com diversidade, transparência e controlo por parte do utilizador. Algoritmos centrados no utilizador, que permitam ajustar manualmente os seus interesses e introduzam elementos de novidade nos feeds, são atualmente apontados como boas práticas para preservar a atenção sem esgotar o utilizador.

Embora a literatura sugira que a personalização algorítmica pode influenciar tanto positiva como negativamente a atenção do consumidor, ainda não existe consenso sobre os seus impactos específicos. Alguns estudos indicam que a previsibilidade excessiva das recomendações pode reduzir o envolvimento e a interação do consumidor com os conteúdos apresentados (Flaxman, Goel & Rao, 2016). Outros sugerem que a diversidade informativa e a transparência na operação dos algoritmos podem desempenhar um papel importante na experiência digital do consumidor, mas não há evidências conclusivas sobre até que ponto estas variáveis mitigam os efeitos negativos da personalização algorítmica (Li et al., 2024). Dada esta falta de consenso na literatura, é necessário continuar a aprofundar o estudo empírico para explorar de que forma a personalização algorítmica contribui para melhorar ou prejudicar a atenção dos consumidores.

A personalização algorítmica tem-se consolidado como uma ferramenta central no marketing digital, permitindo às empresas adaptar conteúdos e ofertas às preferências individuais dos consumidores. Esta prática, embora potencialmente benéfica, levanta questões sobre os seus efeitos na atenção e no comportamento dos utilizadores como podemos verificar anteriormente.

Enquanto a personalização algorítmica visa tornar a experiência digital mais relevante para cada utilizador, existe um risco inerente de que essa filtragem excessiva leve a um consumo de informação limitado a determinados pontos de vista. Neste contexto, surge o conceito de *filter bubbles*, que descreve o fenómeno em que algoritmos personalizados filtram a informação apresentada aos utilizadores, expondo-os predominantemente a conteúdos que reforçam as suas crenças e interesses pré-existentes (Harner, Ray & Wakoko-Studstill, 2022). Este processo pode levar ao isolamento cognitivo, onde os indivíduos são menos expostos a perspetivas divergentes, potencialmente limitando a sua compreensão e abertura a novas ideias (Pariser, 2011). Há estudos que indicam que as "*filter bubbles*" resultam da personalização algorítmica

em plataformas digitais, criando um ambiente informativo homogêneo (Resende, 2023). Este isolamento pode reforçar preconceitos e contribuir para a polarização, uma vez que os utilizadores são continuamente expostos a informações que confirmam as suas opiniões. Esta falta de exposição a conteúdos diversos pode restringir também a capacidade crítica e a compreensão abrangente de temas complexos (Vohs et al., 2008).

No entanto, há debates académicos sobre a extensão e o impacto real das "*filter bubbles*". Alguns investigadores argumentam que os utilizadores ainda têm acesso a uma variedade de informações e que o efeito das "*filter bubbles*" pode ser menos pronunciado do que inicialmente sugerido (Pariser, 2011). Apesar destes estudos, a preocupação com o isolamento cognitivo permanece relevante, especialmente considerando o papel crescente dos algoritmos na mediação da informação consumida diariamente.

A sobrecarga cognitiva ocorre quando a quantidade de informação disponível excede a capacidade de processamento do indivíduo, levando a dificuldades na tomada de decisões e na retenção de informações. Na era digital, a exposição constante a vastos volumes de dados pode resultar em fadiga mental, afetando negativamente o desempenho cognitivo (Bentes, 2019). A fadiga da decisão, por sua vez, refere-se ao declínio na qualidade das decisões após um período prolongado de tomada de decisões. Quando confrontados com escolhas excessivas ou complexas, os indivíduos podem vir a experimentar um elevado cansaço mental, levando a decisões impulsivas ou à procrastinação (Vohs et al., 2008).

A própria pressão temporal pode exacerbar a sobrecarga cognitiva. Diferentes pesquisas indicam que, sob restrições de tempo, os consumidores tendem a simplificar o processo de decisão, podendo optar por escolhas menos ótimas devido à necessidade de rapidez na execução (Zuboff, 2019). Este cenário destaca a importância de procurar implementar estratégias que auxiliem na gestão da informação e no apoio à tomada de decisões, minimizando os efeitos adversos da sobrecarga cognitiva e da fadiga da decisão.

A personalização algorítmica, ao adaptar conteúdos às preferências individuais, visa captar e manter a atenção do consumidor. No entanto, a exposição contínua a conteúdos semelhantes pode levar à monotonia e à redução do interesse, resultando em menor envolvimento com a

plataforma (Pariser, 2011). Este fenómeno, conhecido como "fadiga algorítmica", sugere que a previsibilidade excessiva nas recomendações pode ser contraproducente, diminuindo a eficácia das estratégias de retenção de atenção (Yang, Li & Hu, 2024).

Isto pode sugerir que as plataformas digitais devem procurar implementar estratégias que promovam a diversidade de conteúdos e a transparência nos processos algorítmicos. Ao permitir que os utilizadores compreendam e controlem o nível de personalização, as empresas podem fomentar um ambiente mais equilibrado, onde a personalização não comprometa a exposição a novas informações e perspectivas (Bentes, 2019).

A literatura atual discute a dualidade da personalização algorítmica: enquanto alguns estudos indicam benefícios significativos na adaptação de conteúdos às preferências dos consumidores, outros apontam desafios relacionados ao isolamento cognitivo e à sobrecarga informativa.

No entanto, ainda não existe um consenso sobre até que ponto a personalização melhora ou prejudica a atenção do consumidor. Embora algumas abordagens sugiram que a diversidade de conteúdos e a transparência algorítmica podem mitigar os seus efeitos negativos, há uma carência de estudos empíricos que comprovem a sua eficácia. Desta forma, torna-se essencial uma investigação aprofundada sobre os impactos da personalização algorítmica na atenção dos consumidores, bem como sobre os possíveis fatores que influenciam essa relação.

Embora grande parte da literatura trate a personalização algorítmica como uma variável binária (ou seja, presente ou ausente), estudos mais recentes sugerem que os seus efeitos sobre o comportamento e a atenção do consumidor variam de acordo com o seu volume ou intensidade. Nesse sentido, torna-se relevante conceptualizar esta variável de forma contínua, distinguindo entre níveis de personalização algorítmica baixa, moderada e elevada. Bang et al. (2019) demonstraram que indivíduos com níveis mais elevados de narcisismo tendem a prestar mais atenção visual e a envolver-se mais intensamente com anúncios altamente personalizados a nível individual, em comparação com anúncios direcionados a um grupo, o que reforça a influência da intensidade da personalização na captação da atenção do utilizador.

Complementarmente, Fan e Liu (2022) identificam uma relação curvilínea entre o nível de personalização e a avaliação do consumidor, ao constatar que a utilidade percebida tende a aumentar até certo ponto, mas decresce quando a personalização é excessiva, devido à saturação

cognitiva e à repetição de estímulos semelhantes. Os autores concluem que existe uma relação em U invertida entre o nível de autonomia algorítmica (como forma de personalização) e a avaliação do consumidor, alertando para os riscos de sobrecarga quando o volume de personalização ultrapassa um limiar psicológico tolerável. Este efeito é intensificado pela fadiga algorítmica, resultante da exposição repetida a conteúdos semelhantes, que esgota a atenção do utilizador e reduz a eficácia das recomendações personalizadas (Fan & Liu, 2022); (Yang et al., 2024).

Desta forma, a presente investigação adota o conceito de intensidade da personalização algorítmica, classificando-a em três níveis (baixa, moderada e elevada), por forma a analisar mais especificamente a sua influência nos fenómenos psicológicos associados à atenção, fadiga algorítmica e criação de *filter bubbles*. Esta abordagem permite observar os efeitos diretos, mas também as dinâmicas mediadas entre os diferentes níveis de personalização e os seus impactos cognitivos e emocionais nos utilizadores.

A atenção dos utilizadores a conteúdos patrocinados constitui, atualmente, uma dimensão central na análise da eficácia comunicacional em ambientes digitais. A complexidade do ecossistema mediático, amplificada pela personalização algorítmica e pela presença contínua de estímulos de natureza comercial, exige uma abordagem teórica que articule aspetos perceptivos, atitudinais e contextuais.

No contexto da comunicação de influência, Giuffredi-Kähr, Petrova e Malär (2022) demonstram que a sinalização explícita do patrocínio pode contribuir para atenuar os efeitos negativos da ativação do conhecimento persuasivo, conduzindo a uma perceção mais favorável do conteúdo e, conseqüentemente, a níveis superiores de atenção. A transparência da intencionalidade comercial, quando comunicada de forma clara, parece constituir um facilitador da aceitação e do envolvimento do utilizador, contrariando algumas premissas tradicionais da teoria da persuasão encoberta.

Paralelamente, a investigação de Lin e Kim (2016) evidencia que perceções de intrusão associadas à publicidade personalizada tendem a comprometer a utilidade atribuída ao conteúdo e a provocar uma atitude negativa face à marca. Neste sentido, a atenção publicitária emerge como um constructo vulnerável à tensão entre relevância percebida e invasão sentida.

Do ponto de vista visual, Brüns e Meißner (2023) sublinham que elementos gráficos salientados (como cor, contraste ou posicionamento) podem neutralizar parcialmente os efeitos adversos da ativação do ceticismo persuasivo, promovendo uma maior captação visual e facilitando o processamento da mensagem publicitária.

Por sua vez, Plume e Slade (2018), com base na teoria das utilizações e gratificações, identificam que a atenção a conteúdos patrocinados se encontra correlacionada com motivações utilitárias e hedônicas. A obtenção de informação, o entretenimento e o desejo de partilha social são fatores determinantes para a retenção atencional, sobretudo em contextos de elevada saturação mediática.

Em síntese, a atenção a conteúdos patrocinados revela-se dependente de um conjunto de variáveis que ultrapassam a mera exposição ao estímulo publicitário. Fatores como a clareza da origem comercial, a qualidade visual, a relevância percebida e a motivação do utilizador interagem na determinação do grau de envolvimento atencional, justificando a necessidade de uma maior profundidade de investigação neste sentido.

Adicionalmente, importa considerar que o contexto algorítmico em que os conteúdos patrocinados são disseminados pode interferir significativamente nos níveis de atenção dispensados pelos utilizadores. A personalização algorítmica, embora concebida para maximizar a relevância percebida, tende a restringir a diversidade informacional a que os indivíduos são expostos, promovendo a formação de *filter bubbles* que reduzem o potencial disruptivo dos estímulos publicitários (Han et al., 2022; Zanathy, 2021). Esta limitação da heterogeneidade do conteúdo pode afetar a saliência cognitiva das mensagens patrocinadas, especialmente em ambientes marcados por elevada previsibilidade. Acresce que, quando submetidos a uma exposição contínua a conteúdos muito semelhantes, os utilizadores podem experienciar fenómenos de fadiga algorítmica, traduzidos numa diminuição da responsividade atencional e no reforço de atitudes de evasão seletiva (Kaluža, 2021). Neste enquadramento, a atenção a conteúdos patrocinados não pode ser dissociada das dinâmicas estruturais das plataformas digitais, sendo influenciada por fatores sistémicos que moldam, filtram e, por vezes, esgotam a experiência mediática do utilizador.

Filter Bubbles, Isolamento Cognitivo e Sobrecarga Cognitiva nas Redes Sociais

A personalização algorítmica tem sido amplamente utilizada nas plataformas digitais para adaptar conteúdos aos perfis individuais de cada utilizador, no entanto, o impacto causado por esta personalização através de mecanismos de IA é muito mais do que só uma questão de maior conveniência para o utilizador, pois, quando aplicada de forma intensa e repetitiva, pode gerar efeitos colaterais relevantes, como o isolamento informacional, a sobrecarga cognitiva e uma alteração significativa na forma como os utilizadores direcionam e sustentam a sua atenção. Este tipo de personalização oferece vantagens inegáveis na adaptação de conteúdos às preferências individuais do utilizador. No entanto, o seu uso intensivo tem vindo a gerar preocupações quanto ao impacto na atenção, na literacia crítica e na saúde mental digital dos utilizadores.

As bolhas de filtro surgem como consequência direta da personalização algorítmica intensiva. Ao analisar o comportamento passado do utilizador, os algoritmos selecionam e priorizam conteúdos que confirmam interesses, gostos e crenças já existentes. Este processo, embora aparentemente benéfico, limita a exposição a ideias divergentes e conduz a um ecossistema informativo fechado.

Pariser (2011) descreve este fenómeno como uma “bolha de filtros”, no qual os utilizadores são progressivamente expostos a conteúdos alinhados com as suas preferências e comportamentos anteriores, criando um ambiente informativo altamente personalizado, mas potencialmente limitador. Este isolamento cognitivo resulta de algoritmos que priorizam conteúdos com base em interações passadas, reforçando ciclos de retroalimentação que reduzem a diversidade de perspetivas e de informações recebidas.

A personalização algorítmica nas redes sociais levanta também um paradoxo da atenção: os mesmos algoritmos de recomendação que captam intensamente a atenção do utilizador, fornecendo conteúdo altamente relevante e envolvente, podem prejudicar a qualidade e sustentabilidade dessa atenção a longo prazo, através de efeitos colaterais como “*filter bubbles*” (bolhas de filtro), isolamento cognitivo, sobrecarga cognitiva e fadiga algorítmica. Neste capítulo, analisam-se estes conceitos interligados no contexto das redes sociais contemporâneas, com ênfase no TikTok, articulando-os com o fenómeno da personalização algorítmica e com a atenção do utilizador. Serão analisados trabalhos académicos de referência

para fundamentar teoricamente cada conceito e explicitar como cada um se relaciona com a experiência do utilizador em plataformas algorítmicas, comparando, quando pertinente, o TikTok com outras plataformas semelhantes.

A expressão *filter bubble* (bolha de filtro) foi popularizada por Eli Pariser (2011) para descrever o fenómeno em que os algoritmos personalizados das plataformas online criam um ambiente de informação isolado, mostrando ao utilizador apenas conteúdos alinhados com as suas preferências e filtrando conteúdos dissonantes. Trata-se de um tipo de “câmara de eco” algorítmica, na qual o utilizador encontra apenas opiniões ou informações concordantes com as suas crenças, sem ter de considerar alternativas (Avin, Daltrophe, & Lotker, 2024, p. 2). Em termos técnicos, as *filter bubbles* representam um processo de isolamento intelectual provocado por algoritmos que selecionam e exibem ao utilizador conteúdos com os quais este provavelmente concorda, reforçando as suas crenças existentes e limitando a exposição a perspectivas divergentes (Avin, Daltrophe, & Lotker, 2024).

Ou seja, a plataforma personaliza o *feed* de forma tão afinada aos dados de interação do utilizador que acaba por reduzir drasticamente a diversidade de conteúdo apresentada.

Este processo pode levar ao isolamento cognitivo do utilizador, reforçando crenças preexistentes e limitando a exposição a perspectivas divergentes. Esse fenómeno amplifica o viés de confirmação, levando os indivíduos a consumir informação que confirma as suas crenças, ao invés de os confrontar com visões alternativas. Estudos mais recentes, como o de Shcherbakova & Nikiforchuk (2022), reforçam que a personalização algorítmica acentua este viés, limitando a diversidade informativa e enfraquecendo o pensamento crítico ao promover bolhas de informação confortáveis e previsíveis.

No contexto do TikTok, estas dinâmicas assumem contornos específicos. O TikTok distingue-se de redes sociais de primeira geração (como Facebook ou Instagram) por basear o seu feed "Para Ti" primariamente em clusters de interesse algorítmicos, mais do que nas conexões sociais diretas. O algoritmo do TikTok analisa cada micro-interação (tempo de visualização de cada vídeo, gostos, partilhas, revisualizações) para afinar continuamente as recomendações e apresentar ao utilizador mais do mesmo tipo de conteúdo que o reteve antes (Avin, Daltrophe, & Lotker, 2024).

Esta eficácia algorítmica, embora maximize o envolvimento a curto prazo, pode encerrar o utilizador numa bolha de conteúdo altamente personalizada, por exemplo, focada apenas em determinado género de vídeos humorísticos, num nicho musical ou em opiniões políticas específicas. Estudos sugerem que as plataformas de vídeos curtos como o TikTok e Instagram Reels exibem efetivamente um efeito de bolha de filtro, ainda que com graus diferentes (com Instagram a apresentar até um efeito mais forte em certos contextos do que o TikTok) (Zuiderveen Borgesius et al., 2016).

O resultado para o utilizador é uma experiência cada vez mais previsível e monotemática, que pode levar ao enfraquecimento do contacto com notícias ou visões do mundo, exteriores à bolha pessoal. Em comparação, plataformas como o YouTube também personalizam recomendações, mas o TikTok fá-lo de forma mais acelerada e menos dependente de escolhas explícitas do utilizador (seguir amigos ou canais), o que acelera o ciclo de realimentação algorítmica. Neste sentido, o "isolamento cognitivo" algorítmico tende a ser ainda mais pronunciado no TikTok, sendo que, o utilizador pode mergulhar num "loop" de conteúdo praticamente sem se aperceber, pois o feed infinito adapta-se instantaneamente ao seu comportamento, criando uma esfera informativa à sua medida.

Do ponto de vista da atenção do utilizador, as bolhas de filtros e o conseqüente isolamento cognitivo apresentam impactos ambíguos. Por um lado, ao receber sobretudo conteúdo compatível com os seus interesses, o utilizador tende a manter-se mais tempo atento e envolvido com a plataforma, pois a realidade é que o feed foi otimizado para capturar a sua atenção. Por outro lado, essa atenção fica restrita em foco e escopo, diminuindo potencialmente a capacidade de atenção a estímulos novos ou discrepantes. Em último caso, a personalização extrema pode converter-se numa desvantagem cognitiva, ou seja, o utilizador habituado a um fluxo curado de conteúdos familiares pode demonstrar menor paciência ou capacidade de processar informação não filtrada, perdendo oportunidades de aprendizagem e tornando-se intelectualmente menos estimulado (Pariser, 2011, p. 88).

Podemos então começar a perceber que a bolha algorítmica tende a funcionar como um paradoxo no que toca à retenção de informação, pois mantém o utilizador cativado no curto prazo, mas potencialmente atrofia a elasticidade da sua atenção e curiosidade a longo prazo.

Para além do isolamento num nicho de conteúdo, a arquitetura do TikTok e plataformas semelhantes coloca outro desafio à cognição: a sobrecarga de informação ou sobrecarga cognitiva. Mesmo que o conteúdo exibido esteja dentro dos interesses do utilizador, a quantidade e rapidez com que é apresentado pode exceder a capacidade cognitiva de processar informação de forma profunda. A literatura sobre *information overload* já destacava que a mente humana tem limites rígidos de memória de trabalho e atenção simultânea (Sweller, 2011). Quando confrontado com um fluxo incessante de estímulos (como a sucessão indeterminável de vídeos curtos no *feed* algorítmico) o utilizador pode entrar num estado de sobrecarga cognitiva, caracterizado por cansaço mental, diminuição da concentração e processamento superficial dos conteúdos.

Plataformas de vídeos curtos (SVA – short video applications) como o TikTok intensificam esta dinâmica, pois combinam scrolling vertical contínuo e conteúdo altamente personalizado algorítmicamente. Segundo Jiang e Ma (2024), o uso destas plataformas pode comprometer a capacidade de pensamento analítico, ao promover padrões cognitivos mais rápidos e intuitivos. Embora sejam consumidos em contexto de lazer, os SVA exigem uma constante alternância da atenção, criando uma sucessão rápida de estímulos visuais e auditivos que, segundo os autores, pode conduzir à sobrecarga de informação e dificultar o processamento analítico. Este ciclo contínuo de exposição e mudança de conteúdo contribui, a curto prazo, para um estado de flow superficial, mas a longo prazo pode gerar saturação mental e diminuição do bem-estar cognitivo (Jiang & Ma, 2024).

No caso do TikTok, a personalização algorítmica agrava a intensidade do estímulo, pois o algoritmo seleciona vídeos do interesse do utilizador, mas também seleciona aqueles com maior probabilidade de provocar respostas emocionais fortes ou captar atenção imediata (vídeos extremamente engraçados, chocantes, *trending*, etc.). Desta forma, o utilizador é bombardeado com conteúdos altamente estimulantes em sequência rápida, o que sobrecarrega os seus recursos cognitivos de atenção e processamento. Um utilizador médio pode passar no *feed* do TikTok por dezenas ou centenas de vídeos numa única sessão, numa experiência de consumo fragmentada que contrasta com, por exemplo, ver um único vídeo longo no YouTube ou ler um artigo completo. Wang e Scherr (2022) demonstraram que o uso automático e repetido do TikTok antes de dormir está associado a uma maior excitação cognitiva no período pré-sono, o que compromete a qualidade do descanso e resulta em níveis mais elevados de fadiga diurna.

Estes resultados ilustram como o excesso de estímulos algorítmicos e altamente envolventes pode perturbar os ritmos naturais de recuperação mental, afetando negativamente a atenção e o bem-estar no dia seguinte.

A sobrecarga cognitiva resultante manifesta-se também na atenção instável ou superficial. Com tanta informação a competir pela mente do utilizador, torna-se difícil no TikTok haver um foco, ou uma recordação do que foi visualizado, e desenvolve-se como consequência uma tendência de passar rapidamente pelo conteúdo sem o assimilar profundamente. Isto pode estar relacionado com o conceito de atenção fragmentada, em que a pessoa procura prestar atenção a todos os estímulos, não dedicando concentração prolongada a nenhum em específico. A personalização algorítmica, ao garantir um fluxo interminável de novidades relevantes, paradoxalmente pode diminuir significativamente a capacidade de atenção. Cada novo vídeo de interesse faz o cérebro saltar aleatoriamente de foco em foco, impedindo o exercício de atenção contínua numa mesma tarefa ou tópico. O utilizador pode sentir-se entretido, mas ao mesmo tempo cognitivamente esgotado e disperso após longos períodos de uso.

A fadiga algorítmica tem emergido como um fenómeno relevante na literatura recente sobre os impactos das redes sociais, especialmente aquelas sustentadas por sistemas de recomendação baseados em inteligência artificial. Este conceito refere-se ao esgotamento mental e emocional induzido pela exposição prolongada e intensiva a conteúdos personalizados por algoritmos, que, ao otimizarem o envolvimento do utilizador, acabam por gerar sobrecarga informativa, previsibilidade excessiva e sensação de perda de controlo (Zhang et al., 2019). Em plataformas como o TikTok, onde os conteúdos são curados de forma automática e incessante, os efeitos da fadiga algorítmica manifestam-se de forma particularmente aguda, impactando a atenção e o bem-estar digital do utilizador.

Wang e Scherr (2022) demonstram que o uso automático e intensivo do TikTok antes de dormir está associado a um aumento significativo da excitação cognitiva, provocada pela exposição contínua a estímulos audiovisuais altamente envolventes e algorítmicamente seleccionados. Este padrão de consumo perturba os processos naturais de autorregulação mental, reduz a qualidade do sono e resulta em maiores níveis de fadiga durante o dia seguinte, com impactos negativos na capacidade de foco e atenção.

A literatura aponta ainda para uma ligação direta entre a personalização algorítmica e a diminuição da diversidade informativa, um fator que contribui para a experiência de fadiga. Yang, Li e Hu (2024) demonstram que os utilizadores expostos repetidamente ao mesmo tipo de conteúdo (um fenómeno que os autores designam como “cocoons de informação”) experienciam exaustão mental e emocional, bem como uma redução da sua atenção e envolvimento. Esta homogeneidade algorítmica, que visa maximizar o tempo de permanência nas plataformas, gera uma sobre-estimulação previsível que, paradoxalmente, reduz o interesse e a atenção sustentada do utilizador ao longo do tempo.

A fadiga algorítmica não se limita ao TikTok, sendo observada noutras plataformas com modelos semelhantes, como o Instagram Reels ou o YouTube Shorts. No entanto, o design específico do TikTok, com ênfase no feed “Para Ti” altamente personalizado, acentua o ciclo de exposição-reação, minimizando a autonomia do utilizador e amplificando a sensação de saturação. Bright, Kleiser e Grau (2015) identificam que a diminuição da perceção de controlo, aliada à sobrecarga informativa e às preocupações com privacidade, é um fator determinante no surgimento da fadiga nas redes sociais, fenómeno que compromete a atenção e o envolvimento contínuo dos utilizadores.

Resumidamente, a fadiga algorítmica representa um ponto de fricção no modelo da personalização algorítmica. Ao mesmo tempo que sustenta o envolvimento contínuo, compromete a atenção do utilizador quando ultrapassa os limites de estimulação cognitiva. Compreender esta dinâmica é essencial para avaliar criticamente os impactos da inteligência artificial na experiência digital contemporânea, especialmente nos dias de hoje, em que pela nossa própria utilização, podemos verificar que as redes sociais têm tido uma tendência cada vez mais elevada para mostrar apenas conteúdos altamente personalizados por IA, sendo que, sobrepõem-se até a conteúdos das pessoas que o próprio utilizador escolheu seguir.

A literatura revista evidencia de forma robusta que a personalização algorítmica, embora inicialmente concebida como facilitadora da experiência do utilizador, pode desencadear efeitos adversos quando levada ao extremo. A criação de bolhas de filtro reduz a diversidade informativa, promovendo o isolamento cognitivo e reforçando vieses preexistentes (Pariser, 2011; Zuiderveen Borgesius et al., 2016). Esta fragmentação informacional, agravada pela natureza acelerada e intensamente estimulante das plataformas de vídeo curto, contribui para

fenómenos de sobrecarga cognitiva e, posteriormente, para a fadiga algorítmica, uma exaustão atencional e emocional que mina o envolvimento do utilizador (Jiang & Ma, 2024; Wang & Scherr, 2023). Os estudos analisados convergem na ideia de que, apesar da eficácia algorítmica em captar atenção, o seu impacto a longo prazo pode ser contraproducente, enfraquecendo a atenção sustentada e a autonomia do utilizador (Bright et al., 2015; Zhang et al., 2019). Desta forma, torna-se essencial, tanto para investigadores como para profissionais de marketing e tecnologia, compreender estas dinâmicas para encontrar um equilíbrio entre personalização, diversidade informativa e bem-estar cognitivo, especialmente num contexto em que a atenção se tornou o principal ativo da economia digital.

Fundamentação Teórica do Modelo Conceptual

Com o avanço da Inteligência Artificial no Marketing Digital, os sistemas algorítmicos têm sido amplamente utilizados para personalizar conteúdos de acordo com o comportamento dos utilizadores. No entanto, a literatura levanta preocupações sobre os seus possíveis efeitos adversos na retenção de informação e na flexibilidade cognitiva dos consumidores (Haefner et al., 2021); (Li et al., 2024). Estudos sugerem que a personalização algorítmica pode, por um lado, aumentar a atenção e retenção da informação ao apresentar conteúdos mais relevantes para o utilizador (Davenport et al., 2020), mas, por outro, também contribui para a fadiga algorítmica e para uma menor diversidade informativa, promovendo um consumo repetitivo e previsível (Flaxman, Goel & Rao, 2016).

A estrutura teórica deste estudo assenta na análise das relações entre a intensidade da personalização algorítmica e a atenção do utilizador, sendo mediadas por dois mecanismos psicológicos identificados na literatura: as *filter bubbles* e a fadiga algorítmica.

Para compreender as relações entre a personalização algorítmica e a atenção do consumidor, propõe-se um modelo conceptual que estrutura as variáveis da investigação e as inter-relações causais.

O modelo conceptual adotado nesta investigação estrutura-se numa cadeia relacional que posiciona a intensidade de personalização algorítmica como variável independente, influenciando a atenção do consumidor de forma direta e indireta, através de duas variáveis mediadoras em série: as *filter bubbles* e a *fadiga algorítmica*. Esta configuração é teoricamente sustentada por estudos recentes que analisam os efeitos da curadoria algorítmica de conteúdos

sobre o comportamento digital dos utilizadores, conforme comprovado na Revisão de Literatura.

A personalização algorítmica tem sido apontada como um dos pilares centrais das plataformas digitais modernas, ao adaptar conteúdos às preferências individuais de cada utilizador com base em dados comportamentais e históricos de interação. Esta prática tem como objetivo aumentar a relevância percebida da informação e melhorar a experiência do utilizador.

No entanto, vários autores alertam para o facto de que esta personalização pode reduzir a diversidade informativa e reforçar tendências cognitivas preexistentes, dando origem ao fenómeno das *filter bubbles* (Bozdag, 2013). Estas bolhas informativas consistem na limitação da exposição a conteúdos divergentes, criando um ambiente informacional fechado onde o utilizador é confrontado sobretudo com perspetivas alinhadas com as suas opiniões e preferências passadas. Ao contrário de uma visão simplista que considera as *filter bubbles* como um efeito colateral inevitável da personalização, estudos recentes evidenciam que estas resultam de um processo de reforço bidirecional, no qual o comportamento do utilizador e a resposta algorítmica se coadaptam progressivamente, reduzindo a variedade de estímulos informativos e promovendo padrões de consumo previsíveis (Pasca, 2023).

Assim, justifica-se a inclusão das *filter bubbles* como variável mediadora distinta no modelo, uma vez que representam uma condição ambiental que influencia subsequentemente a disposição cognitiva do utilizador. Este ambiente fechado, ao tornar-se repetitivo e previsível, contribui para o surgimento de fadiga algorítmica, entendida como um estado psicológico de exaustão mental e desinteresse perante conteúdos personalizados. A literatura sugere que, quando o utilizador é continuamente exposto a um fluxo informacional homogéneo, pode sentir uma sobrecarga cognitiva que reduz a sua capacidade de foco e motivação para interagir com o conteúdo (Chandrakumar, 2024; Broklyn, Olukemi & Bell, 2024).

A fadiga algorítmica é, neste sentido, compreendida como uma resposta emocional e cognitiva ao ambiente monótono gerado pela personalização excessiva, constituindo uma etapa crítica na mediação entre os estímulos informacionais e os comportamentos de atenção. Este fenómeno, para além de afetar a atenção geral do utilizador, pode também comprometer significativamente a sua capacidade de reagir a conteúdos patrocinados. A literatura indica que a eficácia de anúncios em redes sociais depende significativamente do estado cognitivo do

utilizador no momento da exposição, sendo que, ambientes repetitivos e saturados reduzem a atenção visual e emocional a esses estímulos (Teixeira, Wedel & Pieters, 2012). Boerman, van Reijmersdal e Neijens (2015) demonstram que a presença de personalização algorítmica e o tipo de disclosure (sinalização de conteúdo patrocinado) influenciam significativamente o processamento cognitivo da publicidade nativa. Os autores argumentam que, em contextos de elevada personalização, os utilizadores tendem a adotar uma postura mais crítica e defensiva, especialmente quando experienciam estados de fadiga cognitiva ou percepção de manipulação, o que resulta numa redução do envolvimento com a mensagem publicitária e numa menor eficácia do estímulo promocional.

Importa, portanto, clarificar que, embora a atenção do utilizador surja como constructo geral no modelo, o foco desta investigação recai especificamente sobre a atenção dirigida a conteúdos patrocinados. Esta distinção justifica-se pelo facto de a atenção publicitária depender não apenas da capacidade cognitiva do utilizador, mas também da natureza persuasiva da mensagem e do contexto em que é processada. A literatura indica que estados de fadiga e saturação, derivados de ambientes informativos repetitivos, reduzem significativamente a eficácia dos estímulos patrocinados em plataformas sociais (Teixeira, Wedel & Pieters, 2012). Adicionalmente, estudos como o de Boerman, van Reijmersdal e Neijens (2015) demonstram que o envolvimento atencional com publicidade nativa é particularmente sensível à personalização algorítmica, reforçando a pertinência de analisar esta variável como desfecho específico.

Deste modo, a atenção dirigida a conteúdos patrocinados constitui a variável dependente final do modelo, representando a capacidade do utilizador em focar-se e processar estímulos promocionais em ambientes digitais mediados por personalização algorítmica. A literatura aponta que tanto a homogeneidade informativa como o cansaço derivado da previsibilidade afetam negativamente a capacidade de concentração, a retenção de informação e o envolvimento cognitivo (Bozdag, 2013; Broklyn et al., 2024). Desta forma, compreender os fatores que prejudicam ou fortalecem a atenção dos consumidores torna-se fundamental num cenário digital onde a disputa pela atenção é constante.

Em suma, este modelo conceptual propõe que:

1. A personalização algorítmica, ao segmentar conteúdos com base em preferências passadas, aumenta a probabilidade de formação de filter bubbles (Bozdag, 2013; Pasca, 2023);
2. As filter bubbles, ao restringirem a diversidade informativa, contribuem para o desenvolvimento de fadiga algorítmica (Chandrakumar, 2024);
3. A fadiga algorítmica, como estado psicológico resultante da repetição e saturação, reduz a atenção do utilizador, ao comprometer o seu envolvimento com mensagens comerciais em ambientes digitais personalizados (Boerman et al., 2015; Teixeira et al., 2012).

Este encadeamento teórico fornece uma base sólida para a estruturação do protocolo experimental da presente investigação, bem como para a análise empírica dos dados recolhidos.

Descrição das Variáveis e Modelo Conceptual Gráfico

O presente estudo estrutura-se em torno de quatro variáveis principais, organizadas conforme o modelo conceptual proposto: uma variável independente (personalização algorítmica), duas variáveis mediadoras (*filter bubbles* e fadiga algorítmica) e uma variável dependente (atenção do utilizador). Esta variável dependente é operacionalizada em duas dimensões: atenção geral do utilizador e atenção a conteúdos patrocinados, permitindo captar com maior precisão o impacto diferenciado da experiência algorítmica sobre diversos estímulos. A seleção e organização destas variáveis são sustentadas por uma extensa revisão de literatura, que evidencia as suas inter-relações e pertinência no contexto das redes sociais digitais, em particular na plataforma TikTok.

1. Intensidade da Personalização Algorítmica (Variável Independente)

A personalização algorítmica é entendida como o processo automatizado pelo qual os sistemas digitais, através de técnicas de inteligência artificial, analisam o comportamento do utilizador e ajustam o conteúdo exibido em função dos seus padrões de interação, interesses e preferências anteriores. Este fenómeno é particularmente acentuado em plataformas como o TikTok, cujo feed principal (“Para Ti”) é inteiramente gerado com base em dados comportamentais dos utilizadores, como tempo de visualização, gostos e revisualizações (Boeker & Urman, 2022).

A literatura destaca que este tipo de personalização, apesar de eficaz na retenção da atenção a curto prazo, pode induzir consequências não intencionais, nomeadamente redução da diversidade de conteúdo e exposição repetitiva a estímulos semelhantes (Lv, Kang & Liu, 2024).

Neste estudo, a variável independente é operacionalizada como a intensidade da personalização algorítmica, medida com base no grau de adaptação do conteúdo aos dados comportamentais do utilizador. Esta personalização é realizada através de algoritmos que analisam padrões de uso, tempo de visualização, gostos, partilhas e interações anteriores. No contexto de plataformas como o TikTok, esta personalização é particularmente intensa, uma vez que o feed principal (“Para Ti”) é gerado inteiramente com base em comportamentos algorítmicos individualizados (Boeker & Urman, 2022).

Ao invés de tratar a personalização como uma variável binária (existente ou não), esta investigação adota uma perspetiva contínua, classificando a personalização algorítmica em três níveis: baixa, moderada e elevada. Esta abordagem é justificada por estudos empíricos que demonstram variações significativas nos efeitos da personalização consoante a sua intensidade. Bang et al. (2019), por exemplo, concluem que “indivíduos com níveis elevados de narcisismo prestaram mais atenção e com maior frequência aos anúncios personalizados a nível individual do que aos anúncios personalizados a nível de grupo” (p. 1127), evidenciando que níveis mais intensos de personalização influenciam mais significativamente a atenção visual (Bang et al., 2019).

Wang et al. (2022) identificam também uma relação em U invertida entre o nível de personalização e a avaliação do consumidor, alertando para os efeitos potencialmente negativos da hiperpersonalização. Segundo os autores, “o aumento progressivo da personalização melhora a perceção de utilidade apenas até um certo ponto; ultrapassado esse limite, os consumidores começam a experienciar saturação e desconforto” (Wang et al., 2022).

Desta forma, a intensidade da personalização algorítmica será operacionalizada através da exposição do utilizador a diferentes tipos de feed no TikTok: o feed “Para Ti” (representando um nível elevado de personalização) e o feed “A Seguir” (representando um nível mais baixo ou neutro de personalização, baseado em escolhas explícitas). Esta distinção experimental permitirá aferir de que forma diferentes intensidades de personalização influenciam variáveis

mediadoras (filter bubbles e fadiga algorítmica) e, em última instância, a atenção do consumidor.

2. Filter Bubbles (Variável Mediadora 1)

O conceito de filter bubble, originalmente proposto por Pariser (2011), refere-se à condição em que o utilizador é sistematicamente exposto a conteúdos que reforçam as suas crenças e interesses já existentes, resultando numa bolha informativa personalizada que restringe o acesso a perspetivas divergentes. Kaluža (2021) defende que as filter bubbles não são apenas resultado da ação algorítmica, mas sim uma forma de adaptação habitual entre utilizadores e tecnologia, criando um ciclo de reforço que limita a diversidade informativa (Kaluža, 2021).

Este processo é amplificado no TikTok, onde a curadoria algorítmica se baseia predominantemente em métricas comportamentais como o tempo de visualização e as interações com os vídeos. Segundo os autores, “os principais preditores do feed personalizado no TikTok são o tempo que o utilizador passa a ver um vídeo, as interações como gostos e partilhas, e a localização do utilizador. Estes fatores influenciam significativamente o conteúdo apresentado, conduzindo à formação de silos de conteúdo” (Boeker & Urman, 2022, p. 6). Tais silos funcionam como filter bubbles, que promovem o consumo repetitivo e previsível de conteúdos, reduzindo o estímulo cognitivo e a exposição a ideias novas. (Beam, 2014; Flaxman, Goel & Rao, 2016).

3. Fadiga Algorítmica (Variável Mediadora 2)

A fadiga algorítmica é definida como um estado de saturação mental e emocional causado pela exposição contínua a conteúdos previsíveis e excessivamente personalizados. Esta condição tem sido observada em estudos focados na experiência de utilizadores do TikTok, especialmente em públicos mais jovens, que relatam uma sensação de cansaço e perda de interesse associada à previsibilidade dos conteúdos sugeridos (Chandrakumar, 2024).

A fadiga algorítmica emerge como uma resposta psicológica à interação prolongada com sistemas de recomendação opacos e repetitivos. Segundo Yang, Li e Hu (2024), este fenómeno “descreve o esgotamento mental e emocional resultante da exposição prolongada a interações com algoritmos” (p. 4). Os autores identificam como causas principais a “exposição a conteúdos repetitivos (information cocoons) e a opacidade algorítmica”, realçando que esta fadiga conduz

a um comportamento de resistência e menor atenção aos conteúdos apresentados (Yang, Li & Hu, 2024).

Em contextos de elevada previsibilidade algorítmica, a fadiga tende a comprometer o envolvimento cognitivo e a capacidade do utilizador em responder a estímulos informacionais diversos, como demonstrado por investigações que apontam a relação entre exposição repetitiva e desinteresse atencional (Dhir et al., 2019; Zhang et al., 2021; Sheng et al., 2022).

4. Atenção do Utilizador (Variável Dependente)

A atenção do consumidor é aqui entendida como a capacidade percebida de manter o foco, recordar conteúdos e evitar distrações durante a navegação numa plataforma digital. No contexto de redes sociais com fluxos de informação rápidos e fragmentados, esta variável assume especial relevância. Pradana & Efendi (2024) mostram que o uso repetido do TikTok, com conteúdos filtrados de forma algorítmica, leva a uma menor exposição a ideias novas e, conseqüentemente, a uma redução na flexibilidade cognitiva e atenção crítica (Pradana & Efendi, 2024).

Por outro lado, Bunza (2024) destaca que a persistência dentro de uma bolha de conteúdo personalizada reduz o tempo necessário para o utilizador explorar novas categorias de conteúdo, implicando um estreitamento progressivo do foco atencional.

Neste contexto, a atenção a conteúdos patrocinados é compreendida como uma extensão específica da atenção geral do utilizador, refletindo de forma mais direta o seu estado cognitivo diante de estímulos comerciais em plataformas digitais. Esta forma de atenção envolve a capacidade de distinguir, avaliar e responder a conteúdos identificados como publicidade (tais como anúncios e publicações promovidas em redes sociais) e está fortemente relacionada com o reconhecimento da intenção persuasiva do conteúdo (Boerman et al., 2017). A literatura indica que fatores como a clareza das etiquetas (#ad, #sponsored) ou o design da publicação podem aumentar a atenção visual e cognitiva, especialmente quando os utilizadores compreendem a natureza publicitária da mensagem (Cao & Belo, 2024).

A distinção entre atenção geral e atenção a conteúdos patrocinados justifica-se pela natureza diferente dos estímulos e pelos mecanismos cognitivos envolvidos. Enquanto a atenção geral se refere à capacidade ampla de concentração e retenção durante o uso de redes sociais, a atenção a conteúdos patrocinados exige um nível adicional de processamento crítico, relacionado com a identificação de intencionalidades comerciais e a ativação do conhecimento

persuasivo do utilizador (Boerman, Willemsen, & Van Der Aa, 2017). Esta distinção é relevante, pois foram analisadas investigações que apontam que a atenção à publicidade em ambientes digitais está mais sujeita à influência de fatores como fadiga, saturação algorítmica e relevância percebida (Evans, Phua, Lim, & Jun, 2017). Desta forma, ao operacionalizar estas variáveis separadamente, o modelo analítico assegura maior sensibilidade na deteção de impactos diferenciados da personalização algorítmica sobre os diversos tipos de atenção.

Contudo, a fadiga algorítmica e a previsibilidade excessiva dos conteúdos reduzem esse envolvimento, diminuindo a atenção dedicada a publicações comerciais, mesmo quando estas estão claramente sinalizadas como patrocinadas (Boerman et al., 2017).

Esta estrutura de variáveis permite analisar, de forma empírica e teoricamente fundamentada, a complexa relação entre a personalização algorítmica e os mecanismos de atenção no ambiente digital, especificamente neste caso orientada para conteúdos patrocinados. O modelo conceptual proposto considera, assim os efeitos diretos da personalização algorítmica via IA e também os efeitos mediadores que contribuem para a compreensão aprofundada do fenómeno.

A estrutura sequencial e causal deste modelo pode ser representada graficamente da seguinte forma:

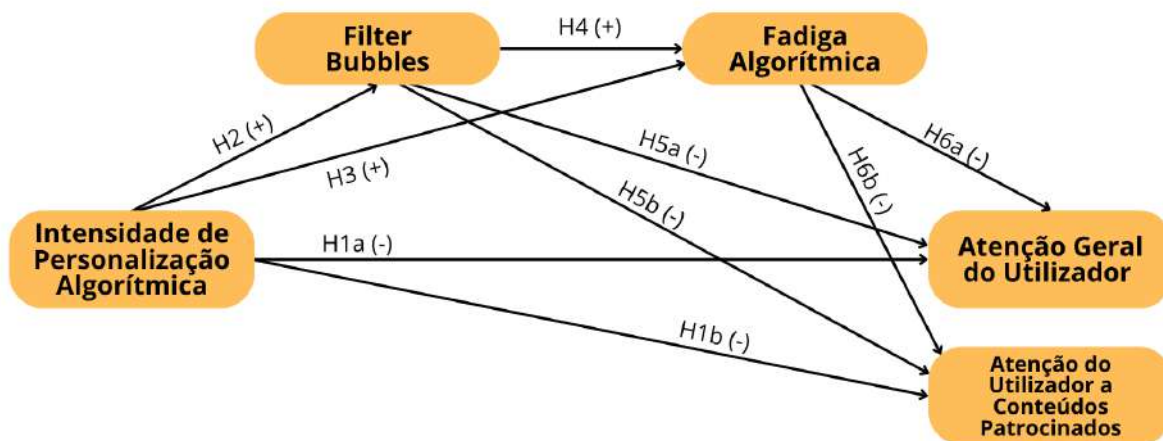


Figura 1 - Modelo Conceptual: Representação das relações entre a intensidade da personalização algorítmica e a atenção do utilizador, considerando a mediação sequencial por filter bubbles e fadiga algorítmica. A variável dependente é subdividida em “Atenção Geral do Utilizador” e “Atenção do Utilizador a Conteúdos Patrocinados”

Com base no modelo proposto, serão analisados os seguintes vetores que operacionalizam as relações entre as variáveis:

- Avaliar a perceção de personalização algorítmica por parte dos utilizadores expostos ao feed “Para Ti” do TikTok;

- Analisar o efeito da personalização algorítmica na percepção de *filter bubbles* e diversidade informativa;
- Investigar a relação entre a percepção de *filter bubbles* e a fadiga algorítmica reportada pelos utilizadores;
- Medir o impacto da fadiga algorítmica na atenção dos utilizadores, considerando duas dimensões distintas: (a) atenção geral e (b) atenção específica dirigida a conteúdos patrocinados, incidindo mais especificamente sobre esta última.
- Comparar os níveis de atenção entre utilizadores expostos a conteúdos personalizados (“Para Ti”) e conteúdos estáveis (“A Seguir”).

Estes vetores permitem operacionalizar o modelo conceptual definido, articulando variáveis independentes, mediadoras e dependentes de forma clara, e asseguram uma estrutura coerente para a recolha, análise e interpretação dos dados.

O modelo conceptual adotado nesta investigação estrutura-se de forma sequencial e encadeada, partindo da variável independente intensidade da personalização algorítmica e culminando no impacto final sobre a atenção do consumidor. A seleção e organização das variáveis resulta de uma revisão de literatura extensa e atualizada, que permite compreender os efeitos diretos da personalização algorítmica e os seus efeitos mediadores através de mecanismos psicológicos e cognitivos.

A variável intensidade da personalização algorítmica é entendida como o grau com que os sistemas de recomendação adaptam os conteúdos com base nos dados comportamentais do utilizador. Tal intensidade pode variar entre níveis baixos, moderados e elevados, e influencia diretamente a construção de *filter bubbles*, espaços informacionais altamente homogéneos e previsíveis, nos quais os utilizadores são expostos repetidamente a conteúdos semelhantes às suas preferências anteriores. (Bang et al., 2019); (Wang et al., 2022).

As *filter bubbles* funcionam como mediadoras relevantes ao promoverem um fenómeno identificado na literatura como fadiga algorítmica, um estado de saturação mental e emocional causado pela exposição prolongada a conteúdos altamente previsíveis e pela percepção de perda de controlo sobre a experiência digital (Yang, Li & Hu, 2024). Esta fadiga afeta negativamente a capacidade do utilizador de se envolver de forma profunda com os conteúdos, conduzindo a uma diminuição da atenção sustentada e da retenção da informação.

Posto isto, o modelo proposto pressupõe que a intensidade da personalização algorítmica afeta a atenção do consumidor de forma indireta e conseqüentemente a atenção especificamente a conteúdos patrocinados, através de duas variáveis mediadoras encadeadas: *filter bubbles* e

fadiga algorítmica. Esta estrutura sequencial permite analisar os impactos cumulativos e progressivos da personalização algorítmica no comportamento atencional do utilizador em plataformas digitais, com especial enfoque no TikTok (cuja arquitetura algorítmica é central na experiência do utilizador e amplamente referida como promotora destes fenómenos) e nos conteúdos patrocinados.

Formulação das Hipóteses

Tendo em conta este enquadramento teórico, e com base nas relações propostas no modelo conceptual apresentado, são formuladas as seguintes hipóteses. Dado que o modelo distingue entre atenção geral e atenção específica a conteúdos patrocinados, as hipóteses relativas à variável “atenção do utilizador” são subdivididas de forma a refletir esta diferenciação.

H1a. A intensidade da personalização algorítmica tem uma relação negativa com a atenção geral do utilizador.

Esta hipótese baseia-se na evidência de que níveis elevados de personalização algorítmica, ao promoverem um fluxo contínuo de conteúdos moldados às preferências prévias do utilizador, podem gerar saturação cognitiva e dispersão atencional. Este tipo de exposição reduz frequentemente a diversidade de informação e induz padrões repetitivos que contribuem para a fragmentação do foco e a sobrecarga cognitiva (Perra & Rocha, 2018); (Bozdog, 2013); (Anderson et al., 2018). A fragmentação e repetição dos estímulos diminuem a capacidade de foco sustentado e reduzem a eficácia da retenção de informação, mesmo em conteúdos não comerciais. Adicionalmente, a literatura tem mostrado que a sobrepersonalização compromete a coerência informativa e estimula padrões de consumo passivo, dificultando o envolvimento cognitivo profundo (Rydenfelt et al., 2022); (Eg et al., 2023).

H1b. A intensidade da personalização algorítmica tem uma relação negativa com a atenção do utilizador a conteúdos patrocinados.

Esta hipótese baseia-se na literatura que sugere que elevados níveis de personalização algorítmica podem reduzir a atenção dedicada a conteúdos patrocinados, ao torná-los menos distinguíveis de conteúdos orgânicos. A sobreintegração da publicidade no feed pode enfraquecer o alerta cognitivo associado a mensagens comerciais, comprometendo a sua visibilidade e eficácia (Hobbs, 2020). Estudos de rastreamento ocular indicam que os

utilizadores tendem a dedicar menos atenção visual a anúncios personalizados, um fenómeno associado à habituação e menor novidade percebida (Köster et al., 2015). Este efeito tem implicações diretas para as estratégias de tráfego pago em redes sociais, já que campanhas publicitárias altamente personalizadas podem ser cognitivamente filtradas pelo utilizador, resultando em menor eficácia atencional e persuasiva (Eg et al., 2023).

H2. A intensidade da personalização algorítmica está positivamente associada à formação de filter bubbles.

Diversos estudos demonstram que sistemas de recomendação personalizados tendem a reforçar as preferências existentes dos utilizadores, restringindo a diversidade de conteúdos aos quais estes são expostos. Esta dinâmica conduz à formação de bolhas informativas que limitam o contacto com perspectivas divergentes (Pariser, 2011); (Zuiderveen Borgesius et al., 2016).

H3. Uma maior intensidade de personalização algorítmica contribuirá para níveis mais elevados de fadiga algorítmica.

A exposição prolongada a conteúdos semelhantes e previsíveis pode gerar esgotamento cognitivo e desinteresse (Yang et al., 2024), (Chandrakumar, 2024). À medida que a personalização algorítmica se intensifica, a experiência do utilizador tende a tornar-se repetitiva, previsível e cognitivamente exaustiva, levando ao surgimento de sintomas de fadiga algorítmica, como exaustão emocional e perda de motivação, conforme demonstrado em estudos com utilizadores expostos a elevados níveis de anúncios personalizados (Alwafi & Fakieh, 2024).

H4. A presença de *filter bubbles* está positivamente associada à fadiga algorítmica.

Embora a literatura empírica sobre esta relação ainda seja limitada, autores como Kaluža (2021) defendem que a formação de *filter bubbles* resulta de um processo de adaptação contínua entre os utilizadores e os sistemas de personalização algorítmica. Este ciclo de reforço conduz à exposição repetitiva a conteúdos previsíveis, reduzindo a diversidade informativa e, conseqüentemente, a estimulação cognitiva. A monotonia resultante desse ambiente informativo homogéneo pode contribuir para estados de saturação mental e esgotamento, favorecendo o desenvolvimento de fadiga algorítmica.

H5a. A presença de filter bubbles afetará negativamente a atenção geral do utilizador.

O consumo sistemático de conteúdos previsíveis reduz a capacidade do utilizador para manter a atenção de forma sustentada, o que compromete o envolvimento cognitivo e emocional com a informação recebida (Bright et al., 2015). Este fenómeno, associado às filter bubbles, reduz a estimulação cognitiva e favorece a formação de padrões atencionais automatizados, que comprometem a capacidade do utilizador para manter o foco e processar conteúdos diversos durante a navegação em redes sociais, conforme evidenciado por estudos que demonstram a limitação da diversidade informativa e o reforço de hábitos de consumo repetitivos em ambientes algorítmicos (Cinelli et al., 2021); (Pariser, 2011); (Bakshy et al., 2015).

H5b. A presença de filter bubbles afetará negativamente a atenção do utilizador a conteúdos patrocinados.

Em ambientes informacionais excessivamente personalizados, as *filter bubbles* tendem a diminuir a perceção de novidade e relevância (fatores críticos para a captação de atenção a mensagens publicitárias) (Bunza, 2024); (Pradana & Efendi, 2024). Nestes contextos, o foco do utilizador tende a restringir-se ao conteúdo familiar, em detrimento de comunicações com cariz promocional, mesmo quando estas são contextualmente integradas na interface da rede social (Boerman et al., 2017).

H6a. A fadiga algorítmica tem um impacto negativo na atenção geral do utilizador.

A exposição contínua a conteúdos repetitivos em plataformas digitais altamente personalizadas tem sido associada ao surgimento de fadiga mental, interferindo com a autorregulação cognitiva e dificultando a concentração. Esta condição compromete a capacidade de manter a atenção ao longo do tempo e prejudica o processamento e retenção de conteúdos, especialmente quando estes não apresentam apelo promocional evidente (Dhir et al., 2019), (Zhang et al., 2021), (Sheng et al., 2022).

H6b. A fadiga algorítmica tem um impacto negativo na atenção do utilizador a conteúdos patrocinados.

Num estado de fadiga algorítmica, o utilizador tende a apresentar menor capacidade de filtrar estímulos publicitários dentro do fluxo de conteúdos. Esta exaustão cognitiva dificulta o

reconhecimento e processamento eficaz de comunicações patrocinadas, diminuindo a sua saliência e a probabilidade de gerar envolvimento significativo (Kaur et al., 2021), (Sheng et al., 2022).

H7a. A relação entre a intensidade da personalização algorítmica e a atenção geral do utilizador é mediada, em série, pela perceção de *filter bubbles* e pela fadiga algorítmica.

Sistemas de personalização intensiva tendem a reforçar bolhas informativas ao expor o utilizador, de forma reiterada, a conteúdos homogéneos e alinhados com as suas preferências prévias (Cinelli et al., 2021). Esta exposição limitada à diversidade informativa reduz o estímulo cognitivo, conduzindo à sensação de saturação e, conseqüentemente, à fadiga algorítmica (Yang & Hu, 2025). Esta, por sua vez, prejudica a capacidade de concentração e reduz a atenção geral durante a navegação digital (Zhou & Tian, 2022). O teste dos efeitos de mediação resulta implicitamente da presença de variáveis intermédias no modelo.

H7b. A relação entre a intensidade da personalização algorítmica e a atenção do utilizador a conteúdos patrocinados é mediada, em série, pela perceção de *filter bubbles* e pela fadiga algorítmica.

A fadiga gerada pela exposição repetitiva a conteúdos previsíveis compromete o envolvimento cognitivo do utilizador com estímulos informacionais distintos, como anúncios e publicações comerciais. A menor perceção de novidade e a redução do foco tornam mais difícil o reconhecimento e processamento dos conteúdos patrocinados (Hattingh et al., 2022), (Boerman et al., 2017). O teste dos efeitos de mediação resulta implicitamente da presença de variáveis intermédias no modelo.

3. METODOLOGIA

A presente investigação pretende compreender de que forma a personalização algorítmica baseada em IA influencia a atenção dos utilizadores no digital, mais especificamente em plataformas de redes sociais. Neste estudo, a plataforma TikTok será utilizada como ambiente de investigação (research setting), tendo em conta a sua forte orientação para a personalização algorítmica. Esta escolha justifica-se pela predominância do TikTok entre utilizadores mais jovens, um público particularmente exposto aos efeitos da hiperpersonalização. Esta característica torna a plataforma especialmente relevante para os objetivos da presente investigação, permitindo analisar com maior profundidade os potenciais impactos cognitivos associados à personalização excessiva.

Ao recorrer a um desenho experimental, torna-se possível observar e quantificar a influência da personalização sobre constructos psicossociais específicos, como a perceção de diversidade informacional, estados de fadiga e níveis de atenção, utilizando escalas psicométricas validadas previamente na literatura científica.

Desta forma, a mesma investigação adota uma abordagem quantitativa com base num desenho experimental, procurando testar empiricamente as relações causais entre variáveis identificadas na literatura, a partir do modelo conceptual desenvolvido. O objetivo principal consiste em compreender de que forma a personalização algorítmica baseada em Inteligência Artificial (IA), enquanto mecanismo central das plataformas digitais, afeta a atenção dos consumidores, tendo em conta os efeitos mediadores das *filter bubbles* e da fadiga algorítmica. Para tal, as variáveis do modelo conceptual foram operacionalizadas com base em instrumentos validados cientificamente, permitindo a medição fiável de cada dimensão.

A escolha por uma metodologia de natureza quantitativa justifica-se pela necessidade de mensurar constructos psicológicos e comportamentais (como a fadiga cognitiva, a perceção de diversidade informativa e a atenção) com base em dados recolhidos de forma padronizada e analisáveis estatisticamente. Tal abordagem permite, assim, aferir correlações, diferenças entre grupos e potenciais relações causais entre variáveis. A investigação quantitativa, é particularmente indicada quando se pretende explorar relações entre variáveis mensuráveis num determinado contexto populacional, permitindo inferências generalizáveis com base em dados estatísticos (Creswell & Creswell, 2018).

A metodologia proposta visa, portanto, testar empiricamente este modelo relacional, construído com base na revisão da literatura e representado no modelo conceptual apresentado.

Através de uma comparação entre dois grupos experimentais expostos a diferentes níveis de personalização algorítmica na plataforma TikTok, será possível observar a influência da personalização na percepção de *filter bubbles*, na fadiga algorítmica e, em última instância, na atenção dos consumidores.

Este modelo procura mapear de forma sequencial o percurso cognitivo do utilizador exposto à personalização algorítmica, desde a relevância percebida dos conteúdos até aos possíveis efeitos de exaustão ou desinteresse. As investigações mais recentes sublinham que a personalização algorítmica, embora tenda a aumentar o envolvimento inicial, pode também conduzir a fenómenos de saturação informativa e diminuição da atenção quando não é equilibrada com diversidade e controlo (Lv, Kang & Liu, 2024); (Babadoğan, 2024).

Permite-nos assim, desdobrar a problemática principal em dimensões analíticas específicas, garantindo uma abordagem sistemática e coerente com o modelo conceptual proposto. Conforme demonstrado por Rehani (2020), a interação entre personalização, confinamento informativo e fadiga digital constitui um ciclo interdependente que impacta diretamente o comportamento do utilizador em ambientes digitais.

Justificação do Contexto Experimental

A seleção da plataforma TikTok como objeto empírico desta investigação justifica-se pela sua singularidade no ecossistema digital contemporâneo, quer em termos de estrutura algorítmica, quer pela intensidade de personalização baseada em Inteligência Artificial (IA). O TikTok tornou-se, em poucos anos, uma das redes sociais com maior taxa de crescimento mundial, ultrapassando a marca de mil milhões de utilizadores ativos mensais, com um forte predomínio da Geração Z (Boeker & Urman, 2022). Este crescimento exponencial decorre, em larga medida, do poder do seu algoritmo de recomendação, sendo considerado o principal motor de retenção de atenção na plataforma.

Ao contrário de plataformas como Instagram ou Facebook, cujo conteúdo ainda é parcialmente mediado por conexões sociais, o TikTok apresenta uma lógica predominantemente algorítmica. O seu feed “Para Ti” baseia-se quase exclusivamente em sinais comportamentais (como o tempo de visualização, gostos, partilhas e interações) para entregar conteúdos hiperpersonalizados (Boeker & Urman, 2022). Esta arquitetura cria

condições particularmente relevantes para o estudo dos efeitos da personalização algorítmica sobre a atenção do utilizador e a conteúdos patrocinados, dado que cada utilizador é exposto a um fluxo de conteúdo continuamente ajustado às suas micropreferências.

Estudos mais recentes confirmam que o TikTok acentua de forma significativa a formação de *filter bubbles*, ambientes informacionais homogêneos resultantes da repetição de padrões algorítmicos. A investigação de Pradana & Efendi (2024) mostra que, entre estudantes universitários, o uso intensivo do TikTok molda os hábitos de consumo de informação, mas também os padrões de linguagem, criatividade e exposição cultural. Enquanto alguns utilizadores relatam ganhos em fluência expressiva, outros sentem-se limitados a conteúdos repetitivos que restringem a visão crítica e o contacto com perspetivas divergentes.

Para além disso, a investigação de Bunza (2024) revela que, entre TikTok, Instagram Reels e YouTube Shorts, é no TikTok que os utilizadores demoram mais tempo a sair de uma bolha de conteúdo, evidenciando uma resistência algorítmica mais elevada à diversidade informativa. Esta característica torna a plataforma especialmente adequada ao estudo dos efeitos de longo prazo da personalização sobre a atenção do consumidor e flexibilidade cognitiva.

Adicionalmente, Tan & Yoon (2024) demonstram empiricamente que, apesar de os utilizadores reconhecerem benefícios em termos de entretenimento e conveniência, tanto o serviço de recomendação personalizado como a presença de *filter bubbles*, aumentam o envolvimento com a plataforma, mas também provocam preocupações relativas à autonomia e fadiga digital. Tal resultado reforça a pertinência do TikTok como ambiente natural de teste para hipóteses relacionadas com fadiga algorítmica e dispersão cognitiva.

Por último, o TikTok permite uma diferenciação experimental clara entre dois contextos de exposição: o feed “Para Ti”, altamente personalizado, e o feed “A Seguir”, baseado nas escolhas explícitas do utilizador. Esta distinção é metodologicamente estratégica, pois possibilita a criação de dois grupos experimentais expostos a diferentes níveis de personalização, em total alinhamento com o modelo conceptual proposto.

A escolha do TikTok como cenário experimental responde a três critérios fundamentais:

- (1) Intensidade algorítmica: a personalização está no centro da experiência da plataforma;
- (2) Relevância comportamental; é uma das redes mais utilizadas por públicos jovens, mais suscetíveis à fadiga algorítmica;
- (3) Pertinência metodológica: permite a manipulação clara dos níveis de personalização.

Operacionalização das Variáveis

Variável Independente

Intensidade da Personalização Algorítmica: Representa o grau de personalização dos conteúdos exibidos ao utilizador, podendo variar entre personalização baixa, moderada e alta. Esta definição baseia-se na tipologia de personalização progressiva discutida por Wang et al. (2022) e Bang et al. (2019), que identificam diferentes efeitos cognitivos consoante o nível de personalização.

Esta variável foi operacionalizada através da exposição dos participantes a dois tipos de feed no TikTok: o feed “Para Ti” (personalização elevada) e o feed “A Seguir” (personalização reduzida ou neutra).

Variáveis Mediadoras

Filter Bubbles: Analisa a limitação da diversidade de conteúdos apresentados ao utilizador, refletindo o grau de exposição a conteúdos homogéneos e alinhados com preferências prévias, característica típica de ambientes mediados por algoritmos de recomendação personalizados (Pariser, 2011); (Boeker & Urman, 2022). A medição foi realizada com base na escala “Identity Bubble Reinforcement Scale” de Kaakinen et al. (2018), com itens adaptados para avaliar perceções de homogeneidade e confirmação ideológica (medido pelos itens Q2 a Q10 do questionário). A consistência interna da escala foi verificada através do alfa de Cronbach, tendo apresentado um valor de 0.955, o que indica uma excelente fiabilidade na medição da perceção de bolhas informativas.

| Reliability Statistics | Filter Bubbles |
|------------------------|----------------|
| Cronbach's Alpha | N of Items |
| .955 | 9 |

Tabela 1 - Validação da Escala para Medição de *Filter Bubbles* através do Alpha de Cronbach

Fadiga algorítmica: Reflete a diminuição do envolvimento com os conteúdos devido à previsibilidade excessiva das recomendações e à repetição de estímulos semelhantes, o que gera cansaço mental e resistência cognitiva (Yang, Li & Hu, 2024); (Zhang et al., 2016). Foi medida com base na Social Media Fatigue Scale (Zhang et al., 2016), e sua versão abreviada BSMFS (Zarei et al., 2021), operacionalizada e adaptada para o questionário com os itens Q11–Q20. A fiabilidade da escala foi avaliada através do alfa de Cronbach, tendo obtido um valor de 0.783,

o que reflete uma boa consistência interna na medição da fadiga provocada por conteúdos previsíveis e repetitivos.

| Reliability Statistics | Fadiga Algorítmica |
|------------------------|--------------------|
| Cronbach's Alpha | N of Items |
| .783 | 10 |

Tabela 2 - Validação da Escala para Medição de Fadiga Algorítmica através do Alpha de Cronbach

Variável Dependente

Atenção Geral do Utilizador (a): Refere-se à capacidade do utilizador de manter o foco, absorver e processar informação durante a navegação em plataformas digitais. Está associada à percepção de concentração, distração e absorção no uso. Esta forma de atenção é influenciada pela fragmentação dos estímulos digitais e pela carga cognitiva associada à navegação em ambientes personalizados (Zhao et al., 2016). A medição desta variável foi aplicada com base nos itens da escala de Zhao et al. (2016), adaptados para o questionário (Q21–Q25). A consistência interna da escala foi avaliada com o alfa de Cronbach, tendo obtido um valor de 0.925, o que indica excelente fiabilidade na medição da atenção geral durante a navegação em redes sociais.

| Reliability Statistics | Atenção Geral do Utilizador |
|------------------------|-----------------------------|
| Cronbach's Alpha | N of Items |
| .925 | 5 |

Tabela 3 - Validação da Escala para Medição da Atenção Geral do Utilizador através do Alpha de Cronbach

Atenção do utilizador a conteúdos patrocinados (b): Refere-se à atenção direcionada especificamente a conteúdos com natureza promocional, tais como anúncios ou publicações promovidas em redes sociais. Esta forma de atenção envolve o reconhecimento da intenção persuasiva do conteúdo e a capacidade de o distinguir de mensagens orgânicas, ativando o chamado “conhecimento persuasivo” do utilizador (Boerman, Willemsen, & Van Der Aa, 2017). Esta competência cognitiva é essencial para que os utilizadores consigam interpretar corretamente os estímulos publicitários e tomar decisões conscientes em ambientes digitais saturados de conteúdo (Friestad & Wright, 1994). A sua medição foi realizada com base na escala Persuasion Knowledge Scale for Sponsored Content (Boerman et al., 2018), adaptada ao contexto de redes sociais, operacionalizada no questionário através dos itens Q26–Q36. A escala utilizada para medir a atenção dirigida a conteúdos patrocinados demonstrou uma

excelente consistência interna, com um valor de $\alpha = 0.939$, validando a sua fiabilidade na avaliação da percepção atencional relativamente a estímulos com intenção comercial.

| Reliability Statistics | |
|------------------------|------------|
| Cronbach's Alpha | N of Items |
| .939 | 11 |

Tabela 4 - Validação da Escala para Medição da Atenção do Utilizador a Conteúdos Patrocinados através do Alpha de Cronbach

Descrição do Método Experimental

Esta investigação adota um desenho experimental de grupo único com divisão interna (desenho intersujeitos), em que participantes são atribuídos aleatoriamente a dois subgrupos distintos (Grupo A e Grupo B), para analisar os efeitos da personalização algorítmica sobre a atenção. O contexto experimental é a plataforma TikTok, escolhida por ser uma das mais avançadas em termos de personalização algorítmica baseada em dados comportamentais (Boeker & Urman, 2022).

A duração da experiência experimental foi definida em 25 minutos com base em evidência empírica que demonstra que períodos relativamente curtos de uso de redes sociais em smartphone são suficientes para induzir sinais de fadiga mental significativa. Por exemplo, Gantois et al. (2021) verificaram que uma sessão de 30 minutos de uso de apps de redes sociais (como TikTok e Instagram) causou aumento mensurável da fadiga subjetiva e diminuição do desempenho em atividades subsequentes. Estudos em tarefas cognitivas gerais (Tanaka et al., 2014; Lim et al., 2010) também suportam que mesmo exposições de 10–20 minutos podem desencadear efeitos neurológicos e de percepção de cansaço mental.

Complementarmente, o estudo experimental de Rauch e Schmitt (2009) sobre tarefas de controlo cognitivo demonstrou que a fadiga mental pode instalar-se já ao fim de 15 minutos de atividade cognitiva contínua, com impacto mensurável no foco e na estabilidade da atenção.

Desta forma, justifica-se a adoção de um período de 25 minutos como suficiente e adequado para observar potenciais efeitos de fadiga algorítmica e de alterações na atenção do consumidor no contexto do TikTok.

Estrutura dos Grupos

Grupo A: navega durante 25 minutos no feed “Para Ti”, caracterizado por elevada personalização algorítmica com base em machine learning e histórico comportamental.

Grupo B: navega durante 25 minutos no feed “A Seguir”, composto exclusivamente por conteúdos de contas que o utilizador decidiu seguir, representando menor personalização algorítmica.

Protocolo Experimental

Primeiramente, os participantes foram submetidos a um breve formulário (via Google Forms) para inscrição no Grupo Experimental, onde tiveram de indicar informações básicas necessárias para realização dos convites para a sessão online e validação da inscrição. Os dados do formulário foram utilizados única e exclusivamente para efeitos de inscrição, verificação de condições de participação, consentimento e partilha de contacto.

Os participantes foram previamente instruídos a utilizar o TikTok num ambiente silencioso, com a câmara do computador apontada para o ecrã do telemóvel (ou para si mesmo de forma que o investigador consiga observar a utilização contínua da plataforma), para possibilitar o registo de comportamentos visuais e validação do tempo de exposição.

A plataforma de gravação (Google Meet) foi utilizada apenas para observação em tempo real do comportamento de navegação, respeitando o RGPD e mediante consentimento informado.

Após os 25 minutos de navegação, os participantes serão redirecionados para um questionário online (via Google Forms), onde responderão a escalas que medem:

- Presença de filter bubbles
- Perceção de Fadiga algorítmica
- Atenção percebida e retenção de informação

Fundamentação Científica do Método

A utilização de navegação simulada no TikTok (com distinção clara entre o feed algorítmico (“Para Ti”) e um feed limitado a contas seguidas pelo utilizador (feed “A Seguir”)) já foi empregue com sucesso por Tan & Yoon (2024). Nesse mesmo estudo, observou-se que a exposição repetitiva ao feed personalizado do TikTok provoca perceções de cansaço digital, perda de controlo e declínio na atenção

Por sua vez, Yang, Xu et al. (2023) desenvolveram um protocolo experimental semelhante com inquérito pós-exposição para aferir perceção de bolhas informativas e cansaço cognitivo. Estes métodos são consistentes com a abordagem adotada na presente dissertação, permitindo uma avaliação empírica precisa da relação entre personalização algorítmica e atenção digital.

4. Análise de Dados

Este capítulo apresenta a análise estatística dos dados recolhidos no âmbito do presente estudo, cujo objetivo central consiste em compreender os efeitos da personalização algorítmica sobre os processos atencionais dos utilizadores em ambientes digitais, com ênfase na atenção dirigida a conteúdos patrocinados. Com base no modelo conceptual previamente delineado, a análise procura ainda investigar o papel mediador da percepção de *filter bubbles* e da fadiga algorítmica na relação entre a intensidade da personalização e a atenção percebida.

A amostra é composta por 34 participantes, divididos em dois grupos experimentais: um exposto a um feed altamente personalizado (“Para Ti”) ($n = 19$) e outro a um feed (“A Seguir”) ($n = 15$), que apresenta apenas conteúdos publicados por contas que o utilizador segue, com uma menor personalização algorítmica em comparação com o feed “Para Ti” (Boeker & Urman, 2022), ambos no contexto da plataforma TikTok. Esta divisão visa operacionalizar a variável independente (intensidade da personalização algorítmica) e permitir a comparação entre níveis distintos de exposição a algoritmos de recomendação.

A literatura científica tem vindo a alertar para os potenciais impactos cognitivos da personalização intensiva nas redes sociais. Estudos mais recentes demonstram que tais sistemas favorecem a formação de ambientes informacionais homogéneos (denominados *filter bubbles*) que reduzem a diversidade de perspetivas a que os utilizadores são expostos (Cinelli et al., 2021). Simultaneamente, essa homogeneidade pode desencadear sintomas de fadiga algorítmica, resultantes da exposição contínua a estímulos repetitivos e da percepção de perda de controlo sobre o conteúdo visualizado (Qiao, Liu, & Xu, 2024). Estas condições têm sido associadas a um comprometimento da atenção sustentada, particularmente em contextos de elevada carga cognitiva ou saturação informativa (Bright, Kleiser, & Grau, 2015; Kümpel, 2021).

A análise estatística foi conduzida em três fases sucessivas e complementares:

Estatística descritiva - Inclui a análise de medidas de tendência central (média) e dispersão (desvio padrão), avaliação da normalidade das distribuições (testes de Kolmogorov-Smirnov e Shapiro-Wilk), visualização gráfica dos dados (histogramas), bem como a realização de testes t de amostras independentes para comparação entre os dois grupos e verificação da existência de diferenças significativas nas respostas. Adicionalmente, serão também exploradas as matrizes de correlação de Pearson para cada grupo, permitindo observar associações preliminares entre variáveis.

Regressão - Foram conduzidas análises de regressão linear simples para avaliar empiricamente as relações bivariadas entre as variáveis do modelo, nomeadamente entre a condição experimental (intensidade da personalização), perceção de *filter bubbles*, fadiga algorítmica e níveis de atenção (tanto geral como direcionada a conteúdos patrocinados).

Para além disso, foi aplicada regressão linear múltipla com o objetivo de testar o modelo estrutural completo e aferir os efeitos diretos e mediadores das variáveis. Esta abordagem permitiu identificar a contribuição relativa de cada preditor na variância explicada das variáveis dependentes, garantindo uma avaliação estatística mais robusta e alinhada com a complexidade do modelo conceptual proposto.

Teste de Mediação - Foi utilizada a macro PROCESS (modelo 6), proposta por Hayes (2018), para testar um modelo de mediação sequencial. Esta abordagem visa avaliar em que medida a relação entre a personalização algorítmica e a atenção é mediada, em cadeia, pelas *filter bubbles* e pela fadiga algorítmica, em consonância com os pressupostos teóricos subjacentes ao modelo conceptual proposto.

Ao longo deste capítulo, os resultados obtidos são interpretados criticamente à luz do corpo teórico existente, procurando testar as hipóteses formuladas e compreender o seu enquadramento nos fenómenos psicológicos e comunicacionais que caracterizam o consumo de conteúdo mediado por algoritmos. Esta análise visa, assim, contribuir para o aprofundamento do conhecimento sobre os impactos cumulativos da personalização algorítmica sobre os utilizadores, especialmente no que respeita à sua capacidade de manter atenção sustentada e avaliar criticamente os estímulos publicitários em ambientes digitais.

Estatística Descritiva

A presente secção apresenta a análise descritiva inicial dos dados recolhidos, com o objetivo de caracterizar a amostra e explorar a distribuição das variáveis principais incluídas no modelo conceptual. Esta etapa constitui uma fase fundamental para verificar a qualidade dos dados, identificar padrões gerais e validar os pressupostos necessários para análises estatísticas subsequentes.

Foram calculadas medidas de tendência central (média) e dispersão (desvio padrão) para cada uma das dimensões consideradas: perceção de *filter bubbles*, fadiga algorítmica, atenção percebida e atenção a conteúdos patrocinados. Estas variáveis foram operacionalizadas com

base nas médias das questões associadas a cada construto, conforme previamente definido no questionário e fundamentado na literatura.

Adicionalmente, foram aplicados testes de normalidade (Kolmogorov-Smirnov e Shapiro-Wilk), com vista a determinar se as distribuições das variáveis seguem uma curva normal (condição importante para a validade dos testes paramétricos utilizados posteriormente). Os dados foram ainda representados graficamente através de histogramas, facilitando a visualização da assimetria, curtose e eventuais valores atípicos.

No sentido de avaliar diferenças preliminares entre os dois grupos experimentais (feed “Para Ti” vs. feed “A Seguir”), foi realizado um teste t de amostras independentes (independent samples t-test) para cada uma das variáveis principais. Esta análise permitiu comparar as médias entre os grupos, identificando variações iniciais que possam estar associadas ao tipo de personalização algorítmica a que os participantes foram expostos.

Por fim, foram construídas matrizes de correlação de Pearson separadas para os dois grupos experimentais, com o objetivo de identificar padrões de associação entre variáveis dentro de cada condição. Esta análise permite verificar se a direção e a intensidade das correlações entre os construtos se mantêm ou se diferenciam em função da presença ou ausência de personalização algorítmica.

A Tabela 1 apresenta as médias e os desvios padrão das variáveis principais do estudo (Perceção de *Filter Bubbles*, Fadiga Algorítmica, Atenção Geral e Atenção a Conteúdos Patrocinados) para os dois grupos experimentais: o Grupo A (n = 19), exposto ao feed personalizado “Para Ti”, e o Grupo B (n = 15), exposto ao feed cronológico “A Seguir”.

Perceção de *Filter Bubbles*

O Grupo A registou uma média de $M = 4.47$ ($DP = 0.17$), enquanto o Grupo B obteve $M = 1.96$ ($DP = 0.23$). A magnitude da diferença entre grupos evidencia que a personalização algorítmica intensiva contribui para uma perceção mais forte de homogeneidade informativa. A baixa dispersão ($DP < 0.25$) em ambos os grupos, indica elevada consistência nas respostas, sugerindo que os participantes partilham perceções semelhantes dentro de cada condição experimental (Bright, Kleiser, & Grau, 2015). Esta convergência traz robustez à distinção entre os ambientes experimentais.

Descriptives Statistics

| | GRUPO | Statistic | |
|----------------------|-------|----------------|--------|
| filter_bubbles | 1 | Mean | 4.4737 |
| | | Std. Deviation | .17309 |
| | | Minimum | 4.22 |
| | | Maximum | 4.78 |
| | 2 | Mean | 1.9630 |
| | | Std. Deviation | .23256 |
| | | Minimum | 1.56 |
| | | Maximum | 2.33 |
| fadiga_algoritmica | 1 | Mean | 4.0468 |
| | | Std. Deviation | .26272 |
| | | Minimum | 3.33 |
| | | Maximum | 4.44 |
| | 2 | Mean | 2.2519 |
| | | Std. Deviation | .54021 |
| | | Minimum | 1.33 |
| | | Maximum | 3.00 |
| atenção | 1 | Mean | 1.9561 |
| | | Std. Deviation | .51772 |
| | | Minimum | 1.00 |
| | | Maximum | 2.83 |
| | 2 | Mean | 4.0778 |
| | | Std. Deviation | .55943 |
| | | Minimum | 3.33 |
| | | Maximum | 5.00 |
| atenção_patrocinados | 1 | Mean | 1.9569 |
| | | Std. Deviation | .57205 |
| | | Minimum | 1.09 |
| | | Maximum | 2.91 |
| | 2 | Mean | 3.8606 |
| | | Std. Deviation | .52994 |
| | | Minimum | 3.00 |
| | | Maximum | 4.73 |

Tabela 5 - Estatística Descritiva por Grupo

Fadiga Algorítmica

A média da fadiga algorítmica foi de $M = 4.05$ ($DP = 0.26$) no Grupo A e $M = 2.25$ ($DP = 0.54$) no Grupo B. Os valores indicam maior saturação mental no feed personalizado, alinhando-se com estudos que associam repetição de estímulos e falta de diversidade informativa à fadiga cognitiva (Qiao, Liu, & Xu, 2024). Importa destacar que o desvio padrão no Grupo B é mais que o dobro do verificado no Grupo A, refletindo maior variabilidade individual, sugerindo que nem todos os utilizadores experienciam da mesma forma o ambiente menos personalizado, a personalização tende a uniformizar os efeitos, embora adversos.

Atenção Geral do Utilizador

Na variável atenção, os participantes do Grupo B apresentaram maior foco ($M = 4.08$, $DP = 0.56$), ao passo que o Grupo A revelou um envolvimento reduzido ($M = 1.96$, $DP = 0.52$). A semelhança nos desvios padrão entre grupos revela níveis comparáveis de variabilidade interna, o que fortalece a fiabilidade da diferença observada nas médias. Estudos previamente analisados demonstram que algoritmos personalizados podem fragmentar o envolvimento atencional através de estímulos curtos e repetitivos, conduzindo a um tipo de atenção superficial e descontínua (Montag et al., 2019; Epstein et al., 2022).

Atenção a Conteúdos Patrocinados

A atenção dedicada aos conteúdos patrocinados segue um padrão similar. O Grupo A apresenta uma média de $M = 1.96$ ($DP = 0.57$), em contraste com o Grupo B, que atinge $M = 3.86$ ($DP = 0.53$). A consistência dos desvios padrão próximos sugere que, embora a atenção publicitária seja globalmente mais elevada no feed cronológico, a dispersão das respostas é comparável. Tal reforça a hipótese de que a personalização algorítmica pode atenuar a saliência dos estímulos publicitários, possivelmente devido à saturação ou à homogeneidade perceptiva, dificultando a diferenciação entre conteúdos pagos e orgânicos (Alwafi & Fakieh, 2024).

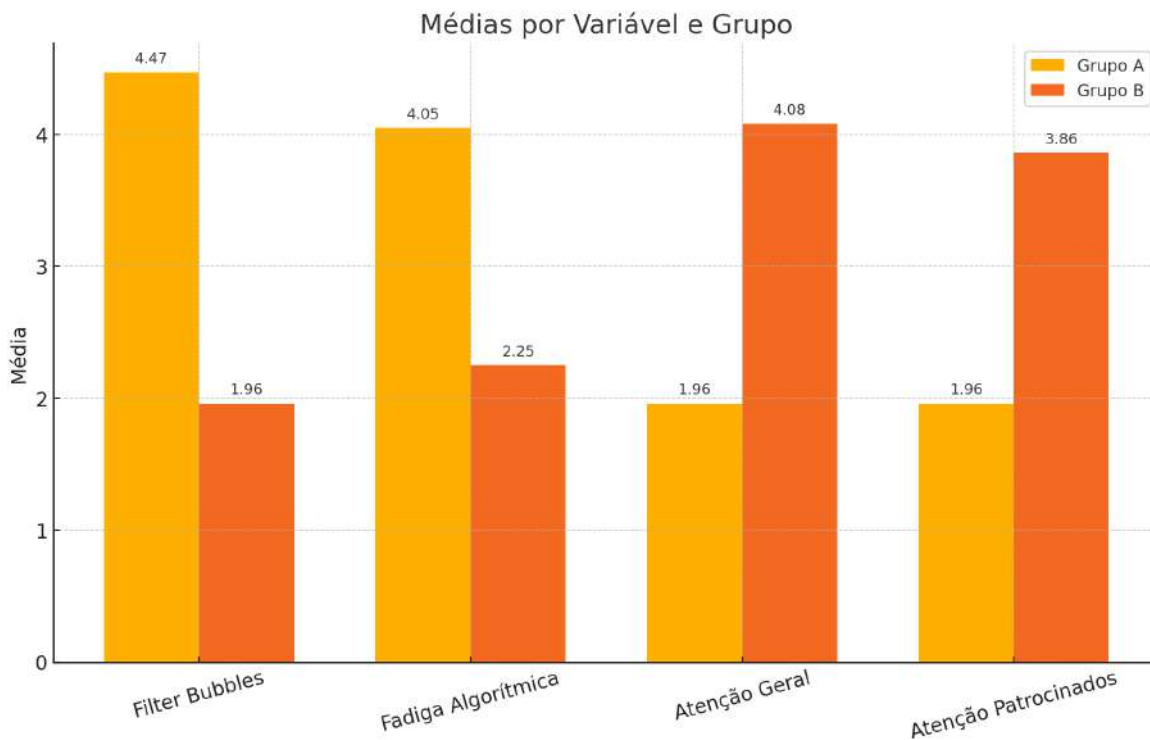


Figura 2 – Gráfico de Barras relativo às Médias das variáveis principais por grupo experimental

Representação gráfica das médias obtidas para as quatro variáveis principais do estudo (percepção de filter bubbles, fadiga algorítmica, atenção geral e atenção a conteúdos patrocinados) nos dois grupos experimentais: Grupo A (exposto ao feed personalizado “Para Ti”) e Grupo B (exposto ao feed cronológico “A Seguir”).

A figura evidencia diferenças claras entre os grupos nas quatro variáveis analisadas. O Grupo A (personalização algorítmica elevada) apresenta valores médios substancialmente mais altos nas variáveis *filter bubbles* ($M \approx 4.47$) e fadiga algorítmica ($M \approx 4.05$), sugerindo uma percepção mais forte de homogeneidade e saturação informativa. Inversamente, o Grupo B (feed cronológico) obteve médias mais elevadas na atenção geral ($M \approx 4.08$) e na atenção a conteúdos patrocinados ($M \approx 3.86$), refletindo maior envolvimento e foco na navegação.

Estas diferenças são coerentes com o modelo conceptual proposto, que prevê que a personalização algorítmica intensiva, ao reforçar bolhas informativas e provocar fadiga cognitiva, compromete a atenção dos utilizadores (especialmente perante estímulos publicitários). Esta representação gráfica, reforça visualmente os padrões observados nas análises descritivas e fundamenta as análises inferenciais subsequentes.

As diferenças de médias entre os grupos são marcantes e consistentes, mas o desvio padrão revela nuances importantes de analisar. No ambiente personalizado, os efeitos tendem a ser mais uniformes (menor DP), o que pode indicar efeitos estruturais dos algoritmos sobre a perceção e cognição. Já no ambiente menos personalizado, há maior diversidade de respostas em variáveis como, neste caso, a fadiga, o que poderá dever-se a estilos de navegação mais livres e não mediados por algoritmos de recomendação.




Figura 3 - Boxplots comparativos entre os grupos experimentais para as variáveis filter_bubbles, fadiga_algorítmica, atenção e atenção_patrocinados.

Os padrões identificados anteriormente ao nível das médias e desvios-padrão são agora visualizados de forma gráfica nos diagramas de caixa (boxplots), refletindo as tendências gerais e a dispersão das respostas por grupo experimental.

Estes resultados reforçam as tendências observadas nas médias descritivas, fornecendo uma base sólida para avançar com testes inferenciais mais robustos.

| Tests of Normality | | | | | | | |
|----------------------|-------|---------------------------------|----|-------|--------------|----|------|
| | GRUPO | Kolmogorov-Smirnov ^a | | | Shapiro-Wilk | | |
| | | Statistic | df | Sig. | Statistic | df | Sig. |
| filter_bubbles | 1 | .170 | 19 | .152 | .914 | 19 | .086 |
| | 2 | .120 | 15 | .200* | .964 | 15 | .756 |
| fadiga_algorítmica | 1 | .166 | 19 | .177 | .929 | 19 | .167 |
| | 2 | .213 | 15 | .066 | .913 | 15 | .152 |
| atenção | 1 | .133 | 19 | .200* | .963 | 19 | .634 |
| | 2 | .143 | 15 | .200* | .934 | 15 | .317 |
| atenção_patrocinados | 1 | .133 | 19 | .200* | .949 | 19 | .386 |
| | 2 | .132 | 15 | .200* | .960 | 15 | .687 |

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Tabela 6 - Teste de Normalidade

Antes de avançar com os testes inferenciais, foi avaliada a distribuição das variáveis principais do estudo através do teste de Shapiro-Wilk, considerado o mais adequado para amostras pequenas ($n < 50$), pela sua elevada sensibilidade na deteção de desvios à normalidade (Razali & Wah, 2011). Os resultados demonstraram que, para ambas as condições experimentais (Grupo A (1) - feed “Para Ti”; Grupo B (2) - feed “A Seguir”), todas as variáveis compostas (perceção de *filter bubbles*, fadiga algorítmica, atenção geral e atenção a conteúdos patrocinados) apresentaram valores de significância superiores a .05.

Este padrão confirma a normalidade das distribuições em todos os casos, validando a utilização de testes paramétricos nas análises seguintes, como o teste t para amostras independentes e as regressões lineares. A conformidade com este pressuposto é essencial para garantir a fiabilidade e validade estatística dos resultados (Mishra et al., 2019).

| Variável | Levene's Test (p) | t (df) | p (bilateral) | Diferença de Médias | IC 95% da Diferença | Linha Utilizada |
|----------------------|-------------------|---------------|---------------|---------------------|---------------------|-----------------------------|
| Filter Bubbles | .218 | 36.11 (32) | < .001 | 2.51 | [2.37, 2.65] | Equal variances assumed |
| Fadiga Algorítmica | < .001 | 11.81 (19.20) | < .001 | 1.79 | [1.48, 2.11] | Equal variances not assumed |
| Atenção Geral | .636 | -11.45 (32) | < .001 | -2.12 | [-2.50, -1.74] | Equal variances assumed |
| Atenção Patrocinados | .555 | -9.95 (32) | < .001 | -1.90 | [-2.29, -1.51] | Equal variances assumed |

Tabela 7 - Teste T de Amostras Independentes

Os resultados do teste t revelam diferenças estatisticamente significativas entre o Grupo A (exposto ao feed “Para Ti”) e o Grupo B (exposto ao feed cronológico “A Seguir”) em todas as variáveis principais do estudo. Os participantes do Grupo A apresentaram percepções significativamente mais elevadas de *filter bubbles* ($p < .001$) e fadiga algorítmica ($p < .001$), bem como níveis significativamente inferiores de atenção geral ($p < .001$) e atenção a conteúdos patrocinados ($p < .001$). Estes resultados sustentam a literatura que identifica a personalização algorítmica como promotora de homogeneização informativa e sobrecarga cognitiva (Cinelli et al., 2021; Qiao, Liu & Xu, 2024), com impacto negativo na atenção sustentada, especialmente em contextos comerciais (Montag et al., 2021; Alwafi & Fakieh, 2024). A violação da heterogeneidade das variâncias apenas na variável “fadiga algorítmica” (Levene $p < .001$) justifica o uso da linha corrigida no teste t, assegurando a robustez estatística das inferências realizadas.

Correlações

| Grupo | Variável 1 | Variável 2 | Correlação (r) | Sig. (p) |
|---------|--------------------|----------------------|----------------|----------|
| Grupo A | filter_bubbles | fadiga_algorítmica | 0,15 | 0,542 |
| Grupo A | fadiga_algorítmica | atenção | -0,48 | 0,04 |
| Grupo A | atenção | atenção_patrocinados | -0,32 | 0,18 |
| Grupo A | filter_bubbles | atenção_patrocinados | -0,02 | 0,937 |
| Grupo A | fadiga_algorítmica | atenção | 0,18 | 0,452 |
| Grupo A | atenção | filter_bubbles | 0,37 | 0,175 |
| Grupo B | filter_bubbles | fadiga_algorítmica | 0,03 | 0,914 |
| Grupo B | fadiga_algorítmica | atenção | -0,56 | 0,032 |
| Grupo B | atenção | atenção_patrocinados | -0,31 | 0,254 |
| Grupo B | filter_bubbles | atenção_patrocinados | -0,04 | 0,873 |
| Grupo B | fadiga_algorítmica | atenção | 0,31 | 0,262 |
| Grupo B | atenção | filter_bubbles | 0,31 | 0,262 |

Tabela 8 - Correlações de Pearson

A Tabela 8 apresenta as correlações de Pearson entre as variáveis principais do estudo (percepção de *filter bubbles*, fadiga algorítmica, atenção geral do utilizador e atenção a conteúdos patrocinados), analisadas separadamente para o Grupo A (feed personalizado) e o Grupo B (feed com menor personalização). Esta segmentação permite avaliar se os padrões relacionais diferem consoante o tipo de exposição algorítmica, indo ao encontro da lógica experimental do modelo conceptual.

No Grupo A, destaca-se uma correlação negativa moderada e estatisticamente significativa entre fadiga algorítmica e atenção geral ($r = -0.476$, $p = 0.040$), sugerindo que maiores níveis de fadiga estão associados a menor capacidade de manter a atenção. Este resultado está alinhado com investigações que relacionam sobrecarga cognitiva induzida por feeds altamente personalizados à deterioração da atenção (Qiao, Liu, & Xu, 2024; Alwafi & Fakieh, 2024). As restantes correlações, incluindo a relação entre filter bubbles e as variáveis atencionais, não se revelam estatisticamente significativas neste grupo.

No Grupo B, verifica-se um padrão semelhante: a fadiga algorítmica correlaciona-se negativamente com a atenção ($r = -0.555$, $p = 0.032$), confirmando que, mesmo em ambientes menos personalizados, o cansaço digital pode comprometer o envolvimento atencional. No entanto, nenhuma das correlações com atenção a conteúdos patrocinados se revelou estatisticamente significativa em qualquer dos grupos, o que poderá sugerir que este tipo específico de estímulo requer uma abordagem analítica mais robusta, nomeadamente através de modelos de regressão ou mediação.

Importa ainda observar que a perceção de *filter bubbles* não apresenta correlações significativas com as demais variáveis em nenhum dos grupos, contrariando parcialmente a literatura que sugere um papel relevante destas bolhas informativas na formação da fadiga cognitiva (Cinelli et al., 2021; Pariser, 2011). Tal poderá dever-se ao tamanho reduzido da amostra ou a características específicas da manipulação experimental.

Em conjunto, os resultados desta matriz de correlação sugerem que a fadiga algorítmica atua como um preditor negativo da atenção, reforçando a sua importância como mediador no modelo proposto.

| Grupo | Média Atenção | Desvio Padrão | t | gl | p (2-tailed) | Diferença entre grupos | Resultado da H1a |
|--------------------------|---------------|---------------|---------|----|--------------|-------------------------------------|-----------------------------|
| A (Alta personalização) | 1,96 | 0,52 | -11,452 | 32 | < .001 | Atenção significativamente inferior | Confirmada para Grupo A |
| B (Baixa personalização) | 4,08 | 0,56 | | | | Atenção significativamente superior | Não confirmada para Grupo B |

Tabela 9 - Verificação da H1a recorrendo a Teste-t para comparação entre grupos

Para testar a hipótese H1a - “A intensidade da personalização algorítmica tem uma relação negativa com a atenção do utilizador”, recorreu-se ao teste t de amostras independentes, dado que a variável independente, intensidade algorítmica, é operacionalizada como uma variável

dicotómica entre grupos (Grupo A = elevada personalização; Grupo B = baixa personalização). Esta escolha metodológica é estatisticamente equivalente à aplicação de uma regressão linear simples com uma variável dummy (Field, 2018), mas apresenta maior clareza na comparação direta entre médias dos dois grupos.

A utilização do teste t é amplamente recomendada pela literatura em delineamentos experimentais com duas condições independentes (Pallant, 2020) e permite verificar se existem diferenças estatisticamente significativas no nível de atenção dos participantes. Os resultados ($p < .001$) sustentam a hipótese no Grupo A, evidenciando menor atenção sob elevada personalização, o que corrobora a literatura que associa ambientes hipersonalizados à fragmentação da atenção (Campos & Campos, 2024). Em contraste, os participantes do Grupo B revelaram níveis superiores de atenção, contrariando o efeito esperado no caso de baixa personalização.

Esta análise está alinhada com o objetivo central da investigação: examinar se os efeitos do modelo conceptual se expressam de forma diferenciada entre condições de personalização algorítmica.

| Grupo | Média Atenção Patrocinados | Desvio Padrão | t | gl | p (2-tailed) | Diferença entre grupos | Resultado da H1b |
|--------------------------|----------------------------|---------------|--------|----|--------------|--|-----------------------------|
| A (Alta personalização) | 1,96 | 0,57 | -9,948 | 32 | < .001 | Atenção a patrocinados significativamente inferior | Confirmada para Grupo A |
| B (Baixa personalização) | 3,86 | 0,53 | | | | Atenção a patrocinados significativamente superior | Não confirmada para Grupo B |

Tabela 10 - Verificação da H1b com atenção a conteúdos patrocinados recorrendo a Teste-t para comparação entre grupos

Para testar a hipótese H1b - “A intensidade da personalização algorítmica tem uma relação negativa com a atenção a conteúdos patrocinados”, recorreu-se ao teste t de amostras independentes, adequado à comparação entre dois grupos com manipulação experimental (Field, 2018; Pallant, 2020).

Os resultados demonstraram diferenças estatisticamente significativas ($t(32) = -9.948, p < .001$), com o Grupo A ($M = 1.96; DP = 0.57$) a apresentar menor atenção a conteúdos patrocinados do que o Grupo B ($M = 3.86; DP = 0.53$). Assim, a hipótese confirma-se para o Grupo A, mas não para o Grupo B.

Estes dados sugerem que a elevada personalização compromete a atenção publicitária, possivelmente devido à saturação cognitiva e à perceção reduzida de novidade nos conteúdos apresentados (Campos & Campos, 2024; Boerman et al., 2017).

| Grupo | Média Filter Bubbles | Desvio Padrão | t | gl | p (2-tailed) | Diferença entre grupos | Resultado da H2 |
|--------------------------|----------------------|---------------|--------|----|--------------|--|-----------------------------|
| A (Alta personalização) | 4,47 | 0,17 | 36,113 | 32 | < .001 | Filter bubbles significativamente superiores | Confirmada para Grupo A |
| B (Baixa personalização) | 1,96 | 0,23 | | | | Filter bubbles significativamente inferiores | Não confirmada para Grupo B |

Tabela 11 - Verificação da H2 recorrendo a Teste-t para comparação entre grupos

Para testar a hipótese H2 - “A intensidade da personalização algorítmica está positivamente associada à formação de *filter bubbles*”, utilizou-se o teste t de amostras independentes, uma vez que a variável intensidade algorítmica é dicotómica e foi manipulada entre dois grupos experimentais. Esta abordagem permite comparar diretamente os níveis médios de *filter bubbles* entre os grupos A (alta personalização) e B (baixa personalização), seguindo a recomendação metodológica para análises entre dois grupos independentes (Pallant, 2020).

Os resultados do teste t ($p < .001$) revelaram que o Grupo A apresenta significativamente maiores níveis de filter bubbles do que o Grupo B, confirmando a hipótese e alinhando-se com a literatura que relaciona personalização elevada com o reforço de conteúdos similares e a limitação da diversidade informativa (Zuiderveen Borgesius et al., 2016).

| Grupo | Média Fadiga Algorítmica | Desvio Padrão | t | gl | p (2-tailed) | Diferença entre grupos | Resultado da H3 |
|--------------------------|--------------------------|---------------|--------|------|--------------|--|-----------------------------|
| A (Alta personalização) | 4,05 | 0,26 | 11,813 | 19,2 | < .001 | Fadiga algorítmica significativamente superior | Confirmada para Grupo A |
| B (Baixa personalização) | 2,25 | 0,54 | | | | Fadiga algorítmica significativamente inferior | Não confirmada para Grupo B |

Tabela 12 - Verificação da H3 recorrendo a Teste-t para comparação entre grupos

A hipótese H3 - “Uma maior intensidade de personalização algorítmica contribuirá para níveis mais elevados de fadiga algorítmica”, foi igualmente testada através do teste t de amostras independentes, adequado para comparar médias entre dois grupos independentes definidos pela variável intensidade algorítmica.

O teste revelou uma diferença estatisticamente significativa ($p < .001$), com o Grupo A (alta personalização) a apresentar níveis superiores de fadiga algorítmica. Este resultado confirma a hipótese e reforça a evidência teórica de que ambientes sobrepersonalizados geram saturação cognitiva e fadiga do utilizador (Yang et al., 2024; Alwafi & Fakieh, 2024).

A hipótese H4 propõe que “a presença de *filter bubbles* está positivamente associada à fadiga algorítmica”. Para testar esta relação, procedeu-se à divisão dos participantes em dois grupos com base nos seus níveis de perceção de *filter bubbles*, obtidos através das respostas às questões Q2 a Q10, avaliadas numa escala de Likert de 1 a 5. Com base na média das respostas, os participantes foram categorizados em:

- Grupo 1 – Baixa perceção de filter bubbles (valores inferiores a 3.5);
- Grupo 2 – Alta perceção de filter bubbles (valores iguais ou superiores a 3.5).

Posteriormente, aplicou-se um teste t para amostras independentes com o objetivo de comparar os níveis médios de fadiga algorítmica entre os dois grupos (medida com base nas respostas às questões Q11 a Q20). Os resultados encontram-se sistematizados na Tabela 13.

| Grupo (Perceção de Filter Bubbles) | Média Fadiga Algorítmica | Desvio Padrão | t | gl | p (2-tailed) | Diferença entre grupos | Resultado da H4 |
|------------------------------------|--------------------------|---------------|----------|------|--------------|--|-----------------|
| Alta perceção | 4,05 | 0,26 | - 11,813 | 19,2 | < .001 | Fadiga algorítmica significativamente superior | Confirmada |
| Baixa perceção | 2,25 | | | | | Fadiga algorítmica significativamente inferior | Não confirmada |

Tabela 13 - Verificação da H4 recorrendo a Teste-t para comparação entre grupos com alta e baixa perceção de Filter Bubbles

A análise estatística revelou diferenças significativas entre os grupos ($t = -11,813$; $gl = 19,2$; $p < .001$), indicando que os participantes com maior perceção de *filter bubbles* experienciaram níveis significativamente superiores de fadiga algorítmica. Estes resultados sustentam a H4, confirmando que ambientes digitais com elevada homogeneidade informacional contribuem para a saturação cognitiva do utilizador.

Esta verificação é coerente com a literatura existente. Segundo Yang, Li e Hu (2024), a exposição contínua a conteúdos previsíveis e redundantes, típica de sistemas de recomendação personalizados, está associada ao aumento da fadiga algorítmica, resultado da baixa diversidade de estímulos. De forma semelhante, Kaluža (2021) argumenta que as *filter bubbles* limitam a estimulação cognitiva, o que pode induzir um estado de cansaço mental e reduzir o envolvimento com os conteúdos consumidos. Estes efeitos foram também observados no TikTok, onde a curadoria algorítmica baseada em comportamento tende a reforçar silos informacionais (Boeker & Urman, 2022).

Conclui-se assim, que os dados empíricos obtidos confirmam que a percepção de *filter bubbles* desempenha um papel importante na intensificação da fadiga algorítmica, especialmente em ambientes digitais altamente personalizados.

| Grupo | Média Atenção Geral | Desvio Padrão | t | gl | p (2-tailed) | Diferença entre grupos | Resultado da H5a |
|-----------------------------------|---------------------|---------------|--------|--------|--------------|-------------------------------------|-------------------------------------|
| Alta percepção de filter bubbles | 4,08 | 0,56 | 11,345 | 29,015 | < .001 | Atenção significativamente superior | Confirmada para Alta percepção |
| Baixa percepção de filter bubbles | 1,96 | 0,52 | | | | Atenção significativamente inferior | Não confirmada para Baixa percepção |

Tabela 14 - Verificação da H5a recorrendo a Teste-t para comparação da atenção geral do utilizador entre grupos com alta e baixa percepção de Filter Bubbles

A hipótese H5a propõe que a presença de *filter bubbles* afeta negativamente a atenção geral do utilizador. Para testar esta relação, foi realizado um teste t para amostras independentes, comparando os níveis médios de atenção geral entre os participantes com baixa percepção e alta percepção de *filter bubbles*, com base nas respostas aos itens Q2 a Q10.

A análise revelou uma diferença estatisticamente significativa entre os dois grupos ($t(32) = 11.45; p < .001$), com os utilizadores com baixa percepção de *filter bubbles* a apresentarem uma média de atenção geral de 4.08 (DP = 0.56), significativamente superior à média de 1.96 (DP = 0.52) verificada nos utilizadores com alta percepção. Estes resultados confirmam a hipótese de que a presença percebida de *filter bubbles* está associada a uma redução da atenção geral do utilizador. Esta constatação alinha-se com a literatura, que sugere que ambientes informacionais altamente personalizados, ao promoverem conteúdos previsíveis e homogêneos, reduzem o estímulo cognitivo e a flexibilidade atencional (Bright et al., 2015); (Boerman et al., 2017).

O fenómeno das *filter bubbles* contribui, assim, para uma experiência digital menos variada e menos desafiante, o que tende a comprometer o envolvimento ativo com os conteúdos e a capacidade de manter o foco em tarefas cognitivas diversificadas (Pradana & Efendi, 2024); (Bunza, 2024).

| Grupo | Média Atenção a Conteúdos Patrocinados | Desvio Padrão | t | gl | p (2-tailed) | Diferença entre grupos | Resultado da H5b |
|--|--|---------------|--------|--------|--------------|-------------------------------------|--|
| Alta percepção de <i>filter bubbles</i> | 3,01 | 0,44 | 10,041 | 31,121 | < .001 | Atenção significativamente inferior | Confirmada para grupo com alta percepção de <i>filter bubbles</i> |
| Baixa percepção de <i>filter bubbles</i> | 4,91 | 0,68 | | | | Atenção significativamente superior | Não confirmada para grupo com baixa percepção de <i>filter bubbles</i> |

Tabela 15 - Verificação da H5b recorrendo a Teste-t para comparação da atenção do utilizador a conteúdos entre grupos com alta e baixa percepção de *Filter Bubbles*

No âmbito da presente investigação, a hipótese H5b postulava que a percepção de *filter bubbles* teria um impacto negativo na atenção do utilizador a conteúdos patrocinados. Os resultados do teste t demonstraram uma diferença estatisticamente significativa entre os dois grupos analisados. Os utilizadores com baixa percepção de *filter bubbles* apresentaram uma média de atenção mais elevada ($M = 4,15$), em contraste com os utilizadores com alta percepção, cuja média foi consideravelmente inferior ($M = 2,25$), $t(31,121) = 10,041$, $p < .001$.

Estes resultados sustentam a hipótese H5b, indicando que a permanência em ambientes digitais caracterizados por baixa diversidade de conteúdos, como é o caso das *filter bubbles*, compromete significativamente a atenção dedicada a mensagens comerciais. Esta evidência está em consonância com estudos anteriores que sugerem que ambientes informacionais altamente previsíveis reduzem a estimulação cognitiva e conduzem a um processamento superficial da informação, incluindo publicidade (Boerman et al., 2017); (Pradana & Efendi, 2024).

| Grupo | Média Atenção Geral | Desvio Padrão | t | gl | p (2-tailed) | Diferença entre grupos | Resultado da H6a |
|--------------------------|---------------------|---------------|--------|----|--------------|-------------------------------------|---------------------------------|
| Baixa Fadiga Algorítmica | 4,08 | 0,56 | 11,452 | 32 | < .001 | Atenção significativamente superior | Confirmada para Baixa Fadiga |
| Alta Fadiga Algorítmica | 1,96 | 0,52 | | | | Atenção significativamente inferior | Não confirmada para Alta Fadiga |

Tabela 16 - resultados do teste t realizado para avaliar o impacto da fadiga algorítmica na atenção geral do utilizador (H6a).

De forma semelhante, a hipótese H6a propunha que a fadiga algorítmica teria um impacto negativo na atenção geral do utilizador. Os dados recolhidos confirmam esta relação. Utilizadores que reportaram níveis elevados de fadiga algorítmica registaram uma média de atenção geral significativamente inferior ($M = 1,96$; $DP = 0,52$) em comparação com os utilizadores com baixa fadiga ($M = 4,08$; $DP = 0,56$), $t(32) = 11,452$, $p < .001$.

Estes resultados corroboram a evidência empírica que associa a fadiga algorítmica (caracterizada pela saturação cognitiva, previsibilidade excessiva e opacidade do sistema) à deterioração da capacidade atencional geral. A literatura indica que este tipo de fadiga interfere com a autorregulação e o foco sustentado, dificultando o envolvimento significativo com os conteúdos digitais (Yang, Li & Hu, 2024); (Chandrakumar, 2024).

| Grupo | Média Atenção a Conteúdos Patrocinados | Desvio Padrão | t | gl | p (2-tailed) | Diferença entre grupos | Resultado da H6b |
|--------------------------|--|---------------|-------|----|--------------|--|----------------------------------|
| Alta Fadiga Algorítmica | 1,96 | 0,57 | 9,948 | 32 | < .001 | Atenção a conteúdos patrocinados significativamente inferior | Confirmada para Alta Fadiga |
| Baixa Fadiga Algorítmica | 3,86 | 0,53 | | | | Atenção a conteúdos patrocinados significativamente superior | Não confirmada para Baixa Fadiga |

Tabela 17 – Test-t para comparação dos níveis de atenção a conteúdos patrocinados entre utilizadores com alta e baixa perceção de fadiga algorítmica (H6b).

Com o objetivo de testar a hipótese H6b, foi realizado um teste t para amostras independentes, comparando os níveis médios de atenção a conteúdos patrocinados entre participantes com alta e baixa perceção de fadiga algorítmica.

Os resultados revelaram diferenças estatisticamente significativas entre os dois grupos. Os participantes com baixa perceção de fadiga algorítmica apresentaram níveis significativamente superiores de atenção a conteúdos patrocinados ($M = 3,86$; $DP = 0,53$), em comparação com os participantes com alta perceção de fadiga ($M = 1,96$; $DP = 0,57$), $t(32) = 9,948$, $p < .001$.

Estes resultados corroboram a hipótese H6b, indicando que a fadiga algorítmica influencia negativamente a atenção dedicada a estímulos publicitários em ambientes digitais. Esta evidência está em linha com estudos prévios que demonstram que a fadiga cognitiva reduz a capacidade do utilizador para processar mensagens persuasivas e compromete o envolvimento com conteúdos patrocinados (Boerman et al., 2017; Evans et al., 2017).

Análise de Regressão

Após a caracterização descritiva da amostra e a análise preliminar de associações entre variáveis, procede-se à exploração das relações causais diretas postuladas no modelo conceptual através de regressões lineares simples. Esta abordagem permite avaliar empiricamente a influência da variável independente (intensidade da personalização algorítmica) sobre variáveis mediadoras (perceção de filter bubbles e fadiga algorítmica) e sobre a variável dependente final subdividida em duas partes: atenção geral do utilizador e atenção especificamente a conteúdos patrocinados.

A análise de regressão é uma ferramenta estatística fundamental para examinar relações preditivas entre variáveis contínuas e testar hipóteses com base em modelos teóricos (Field, 2018). A sua aplicação neste contexto é especialmente relevante para compreender como a arquitetura algorítmica influencia a cognição e a experiência de navegação em ambientes digitais, conforme demonstrado em estudos anteriores (Kümpel, 2023; Qiao, Liu, & Xu, 2024).

Cada hipótese será testada individualmente através de modelos lineares simples, sendo reportados os coeficientes de regressão (β), coeficientes de determinação (R^2), valores de significância estatística (p) e intervalos de confiança a 95%. A análise assume particular importância por permitir verificar o alinhamento empírico com a literatura e identificar os efeitos diretos mais relevantes no percurso atencional dos utilizadores expostos a diferentes níveis de personalização algorítmica.

Será feita uma análise por grupo para que permita identificar os efeitos diferenciais da personalização algorítmica, essencial para responder à pergunta de investigação. Como afirmam Hayes (2018) e Field (2018), a análise segmentada por grupos experimentais é recomendada quando se pretende explorar moderação implícita, ou seja, se a força ou direção da relação entre variáveis muda consoante a condição do estudo.

| Hipótese | Grupo | R ² | Coefficiente Beta (B) | p | Resultado |
|---|---------|----------------|-----------------------|--------|----------------|
| H1a. A intensidade da personalização algorítmica tem uma relação negativa com a atenção geral do utilizador. | A vs. B | 0.804 | -2.122 | < .001 | Confirmada |
| H1b. A intensidade da personalização algorítmica tem uma relação negativa com a atenção do utilizador a conteúdos patrocinados. | A vs. B | 0.756 | -1.904 | < .001 | Confirmada |
| H2. A intensidade da personalização algorítmica está positivamente associada à formação de filter bubbles. | A vs. B | 0.976 | 2.511 | < .001 | Confirmada |
| H3. Uma maior intensidade de personalização algorítmica contribuirá para níveis mais elevados de fadiga algorítmica. | A vs. B | 0.835 | 1.795 | < .001 | Confirmada |
| H4. A presença de filter bubbles está positivamente associada à fadiga algorítmica | A | 0,022 | 0,227 | 0,542 | Não confirmada |
| H4. A presença de filter bubbles está positivamente associada à fadiga algorítmica | B | 0,001 | 0,071 | 0,914 | Não confirmada |
| H5a. A presença de filter bubbles afetará negativamente a atenção do utilizador | A | 0,021 | -0,436 | 0,552 | Não confirmada |
| H5a. A presença de filter bubbles afetará negativamente a atenção do utilizador | B | 0,136 | 0,889 | 0,175 | Não confirmada |
| H5b. A presença de filter bubbles afetará negativamente a atenção do utilizador a conteúdos patrocinados | A | 0,103 | -1,061 | 0,18 | Não confirmada |
| H5b. A presença de filter bubbles afetará negativamente a atenção do utilizador a conteúdos patrocinados | B | 0,099 | -0,716 | 0,254 | Não confirmada |
| H6a. A fadiga algorítmica tem um impacto negativo na atenção do utilizador | A | 0,226 | -0,938 | 0,04 | Confirmada |
| H6a. A fadiga algorítmica tem um impacto negativo na atenção do utilizador | B | 0,308 | -0,575 | 0,032 | Confirmada |
| H6b. A fadiga algorítmica tem um impacto negativo na atenção do utilizador a conteúdos patrocinados | A | 0 | -0,042 | 0,937 | Não confirmada |
| H6b. A fadiga algorítmica tem um impacto negativo na atenção do utilizador a conteúdos patrocinados | B | 0,002 | -0,044 | 0,873 | Não confirmada |

Tabela 18 - Resultados das análises de regressão linear simples realizadas para os grupos A (alta personalização algorítmica) e B (baixa personalização), com o objetivo de testar as hipóteses H4, H5a, H5b, H6a e H6b

Procedendo-se à análise e relativamente à hipótese H1a, que propunha uma relação negativa entre a intensidade da personalização algorítmica e a atenção geral do utilizador, os resultados revelaram um efeito estatisticamente significativo e negativo ($B = -2.122$, $p < .001$), com o modelo a explicar 80,4% da variância da variável dependente ($R^2 = .804$). Estes dados confirmam a H1a, sugerindo que níveis mais elevados de personalização algorítmica estão associados a uma redução significativa na atenção geral dos utilizadores, em linha com a literatura que alerta para os efeitos da saturação algorítmica na sobrecarga cognitiva (Zhang et al., 2025; Wang & Scherr, 2023). No que respeita à hipótese H1b, que propunha uma relação negativa entre a intensidade da personalização algorítmica e a atenção a conteúdos patrocinados, os resultados da regressão linear simples confirmam esta relação. O modelo

revelou um efeito negativo estatisticamente significativo ($B = -1.904$, $p < .001$), explicando 75,6% da variância da variável dependente ($R^2 = .756$). Estes resultados indicam que utilizadores expostos a elevada personalização algorítmica (Grupo A) demonstram níveis significativamente inferiores de atenção a conteúdos patrocinados, em comparação com os do Grupo B. Este resultado, alinha-se com estudos que demonstram como a saturação algorítmica pode reduzir a eficácia da publicidade ao limitar a novidade e o envolvimento cognitivo dos utilizadores (Boerman et al., 2017; Zhou & Tian, 2022).

Analisando a H2, que postulava uma associação positiva entre a intensidade da personalização algorítmica e a perceção de *filter bubbles*, os dados confirmam de forma robusta esta relação. A análise de regressão revelou um efeito positivo altamente significativo ($B = 2.511$, $p < .001$), com a variável independente a explicar 97,6% da variância da perceção de *filter bubbles* ($R^2 = .976$). Este resultado indica que os participantes do Grupo A (alta personalização) percebem muito mais intensamente a presença de *filter bubbles* do que os do Grupo B. Estes dados corroboram a literatura que alerta para o papel dos algoritmos na criação de ambientes informativos fechados e previsíveis (Flaxman et al., 2016; Kaluža, 2021). Quanto à H3, que previa uma associação positiva entre a intensidade da personalização algorítmica e a fadiga algorítmica, os resultados confirmam claramente esta relação. A regressão revelou um efeito positivo significativo ($B = 1.795$, $p < .001$), explicando 83,5% da variância na variável dependente ($R^2 = .835$). Estes resultados indicam que a exposição intensiva a conteúdos personalizados está fortemente associada a níveis mais elevados de fadiga cognitiva, o que reforça os pressupostos da literatura sobre a sobrecarga informativa gerada por ambientes digitais altamente personalizados (Zhou & Tian, 2022; Wang & Scherr, 2022).

Com base nas regressões lineares realizadas separadamente para os dois grupos experimentais (Grupo A - elevada personalização algorítmica; Grupo B - baixa personalização algorítmica), procedeu-se à análise das hipóteses H4, H5 e H6, em conformidade com o modelo conceptual previamente delineado.

Relativamente à H4, que postulava uma associação positiva entre a presença de *filter bubbles* e a fadiga algorítmica, os resultados não revelaram efeitos estatisticamente significativos em nenhum dos grupos ($p = .542$ no Grupo A; $p = .914$ no Grupo B). Embora a literatura aponte para a possibilidade de que ambientes informacionais homogéneos e previsíveis possam contribuir para o surgimento de fadiga cognitiva (Kaluža, 2021), os dados empíricos recolhidos não sustentam esta relação direta. Este resultado pode indicar que a fadiga algorítmica não

decorre exclusivamente da exposição repetitiva a conteúdos semelhantes, mas sim de uma combinação mais complexa de fatores, como o volume de estímulos, a duração da exposição ou o envolvimento subjetivo com a plataforma.

No que concerne à H5, que previa um impacto negativo das *filter bubbles* sobre a atenção do utilizador e a atenção a conteúdos patrocinados, os dados também não sustentam a hipótese, em nenhum dos dois grupos. A relação entre *filter bubbles* e atenção geral revelou-se não significativa quer no Grupo A ($p = .552$), quer no Grupo B ($p = .175$). De igual modo, a relação com a atenção a conteúdos patrocinados não alcançou significância estatística (Grupo A: $p = .180$; Grupo B: $p = .254$). Embora se esperasse, com base na literatura (Bright et al., 2015; Boerman et al., 2017), que a previsibilidade e homogeneidade dos conteúdos reduzissem a capacidade de captar a atenção, os resultados obtidos sugerem que a influência das *filter bubbles* pode ser mais subtil ou moderada por outras variáveis, como o conteúdo visual, a motivação do utilizador ou a presença de estímulos concorrentes.

Por fim, no que respeita à H6, que propunha que a fadiga algorítmica compromete negativamente os níveis de atenção, os resultados demonstraram um efeito negativo e estatisticamente significativo sobre a atenção geral (H6a), tanto no Grupo A ($p = .040$) como no Grupo B ($p = .032$). Esta evidência corrobora os pressupostos teóricos de que a saturação cognitiva provocada pela experiência digital repetitiva afeta a capacidade de concentração (Wang & Scherr, 2022). No entanto, no que diz respeito à atenção a conteúdos patrocinados (H6b), os efeitos não foram estatisticamente significativos (Grupo A: $p = .937$; Grupo B: $p = .873$), indicando que este tipo específico de atenção pode ser influenciado por fatores adicionais, nomeadamente o contexto de exposição, a relevância percebida da publicidade ou o seu formato.

Com o objetivo de compreender de forma mais abrangente os fatores que influenciam a atenção geral do utilizador, procedeu-se à realização de uma regressão linear múltipla. Este modelo permitiu testar o efeito simultâneo da perceção de *filter bubbles* e da fadiga algorítmica na atenção geral e na atenção a conteúdos patrocinados, enquanto variáveis preditoras. Esta análise estatística é apropriada quando se pretende avaliar o contributo relativo de múltiplas variáveis independentes sobre uma variável dependente contínua, fornecendo uma visão mais integrada do modelo explicativo. Esta abordagem permite verificar o contributo específico de cada preditor na variabilidade da variável dependente, controlando o efeito do outro.

| Modelo | Variável Independente | Coefficiente B | Erro Padrão (SE) | Beta Padronizado | t | Valor p |
|-----------|-----------------------|----------------|------------------|------------------|--------|---------|
| AGa/AGb | Filter Bubbles | 0,429 | 0,414 | 0,461 | 1,035 | 0,309 |
| AGa/AGb | Fadiga Algorítmica | -0,674 | 0,204 | -0,559 | -3,295 | 0,003 |
| AGa/AGb | Grupo (IPA) | 1,99 | 1,092 | 0,841 | 1,822 | 0,078 |
| ACPa/ACPb | Filter Bubbles | -0,857 | 0,478 | -0,995 | -1,792 | 0,083 |
| ACPa/ACPb | Fadiga Algorítmica | -0,015 | 0,236 | -0,014 | -0,066 | 0,948 |
| ACPa/ACPb | Grupo (IPA) | -0,276 | 1,261 | -0,126 | -0,219 | 0,828 |

Tabela 19 - Regressão Linear Múltipla para teste do Modelo Estrutural Completo

Com o objetivo de testar o modelo estrutural completo proposto, foi realizada uma regressão linear múltipla com três preditores: a intensidade da personalização algorítmica (representada pela variável “Grupo”), a percepção de *filter bubbles* e a fadiga algorítmica. Esta análise foi aplicada a duas variáveis dependentes: atenção geral do utilizador (AG) e atenção a conteúdos patrocinados (ACP).

No modelo com atenção geral como variável dependente, o modelo demonstrou ser estatisticamente significativo, explicando aproximadamente 85,8% da variância ($R^2 = .858$, $p < .001$). A fadiga algorítmica revelou-se um preditor negativo estatisticamente significativo ($B = -0.674$; $p = .003$), reforçando a hipótese de que o esgotamento cognitivo compromete a capacidade de concentração. A variável “Grupo” apresentou um efeito positivo marginalmente significativo ($p = .078$), sugerindo uma possível associação entre a condição experimental e os níveis de atenção geral. A percepção de *filter bubbles*, por sua vez, não demonstrou significância estatística ($p = .309$).

Quanto ao modelo com atenção a conteúdos patrocinados, o modelo também foi significativo ($R^2 = .780$, $p < .001$), embora com menor poder explicativo. Apenas a percepção de *filter bubbles* demonstrou um efeito marginalmente significativo ($B = -0.857$; $p = .083$), sugerindo uma possível tendência de associação negativa entre este fator e a atenção publicitária. Nem a fadiga algorítmica ($p = .948$) nem o grupo (que identifica a Intensidade de Personalização algorítmica) ($p = .828$) contribuíram significativamente para explicar a variância neste tipo de atenção.

Estes resultados indicam que os fatores que predizem a atenção geral nem sempre coincidem com aqueles que influenciam a atenção a conteúdos comerciais, sendo necessário considerar estas dimensões como construtos distintos no âmbito da personalização algorítmica.

Teste de Mediação (com a macro PROCESS – Modelo 6)

Para testar a existência de um efeito indireto da intensidade de personalização algorítmica sobre a atenção, via duas mediadoras sequenciais (percepção de *filter bubbles* e fadiga algorítmica), recorreu-se à macro PROCESS de Hayes (modelo 6).

| Tipo de Efeito | Coefficiente B | Erro Padrão (SE) | IC 95% Inferior | IC 95% Superior | Valor p |
|---|----------------|------------------|-----------------|-----------------|---------|
| Efeito Total | -2,1216 | 0,1853 | -2,499 | -1,7443 | 0 |
| Efeito Direto | -1,9896 | 1,0921 | -4,2201 | 0,2409 | 0,0785 |
| Efeito Indireto Total | -0,132 | 1,3221 | -3,0467 | 2,2629 | |
| Ind1: intalgo → filter → atenção | 1,0773 | 1,2475 | -1,6145 | 3,3142 | |
| Ind2: intalgo → fadiga → atenção | -0,9801 | 0,7091 | -2,6057 | 0,2084 | |
| Ind3: intalgo → filter → fadiga → atenção | -0,2292 | 0,6533 | -1,5482 | 1,1325 | |

Tabela 20 - Efeitos diretos, indiretos e totais da intensidade da personalização algorítmica sobre a atenção geral do utilizador, com mediação sequencial pela percepção de filter bubbles e pela fadiga algorítmica

O efeito total da intensidade da personalização sobre a atenção geral do utilizador revelou-se significativo ($B = -2.122$, $p < .001$), sugerindo que ambientes altamente personalizados reduzem significativamente os níveis de atenção. Contudo, quando incluídas as mediadoras, o efeito direto perdeu significância ($B = -1.990$, $p = .078$), o que sugere a presença de mediação.

No entanto, os efeitos indiretos totais e individuais (através de *filter bubbles* (Ind1), fadiga algorítmica (Ind2) e o caminho em cadeia (Ind3)) não foram estatisticamente significativos, dado que todos os intervalos de confiança incluem o valor zero.

Tendo estes dados em consideração, embora o modelo tenha um elevado poder explicativo ($R^2 = .86$), os dados não sustentam a mediação proposta.

Verificou-se que o maior problema nos resultados da Mediação era a variável mediadora *Filter Bubble*. Posto isto, foi testado um modelo de mediação simples (modelo 4 de Hayes) para avaliar se a fadiga algorítmica media a relação entre a intensidade de personalização algorítmica e a atenção geral do utilizador.

O efeito total da personalização sobre a atenção revelou-se negativo e estatisticamente significativo ($B = -2,1216$, $p < .001$), sugerindo que ambientes altamente personalizados reduzem significativamente os níveis de atenção.

| Tipo de Efeito | Coefficiente B | Erro Padrão (SE) | IC 95% Inferior | IC 95% Superior | Valor p |
|----------------------------|----------------|------------------|-----------------|-----------------|---------|
| Efeito Total | -2,1216 | — | — | — | < .001 |
| Efeito Direto | -0,9378 | 0,4011 | -1,7558 | -0,1197 | 0,026 |
| Efeito indireto via fadiga | -1,1839 | 0,3403 | -1,8334 | -0,4652 | — |

Tabela 21 - Efeitos direto, indireto e total da intensidade da personalização algorítmica sobre a atenção geral do utilizador, com mediação simples pela fadiga algorítmica (Modelo 4 – PROCESS)

Quando incluída a variável mediadora (fadiga algorítmica), o efeito direto permaneceu significativo, embora com menor magnitude ($B = -0,9378$, $p = 0,026$), indicando mediação parcial. O efeito indireto, mediado pela fadiga algorítmica, também foi estatisticamente significativo, como demonstrado pelo intervalo de confiança que não inclui zero (IC 95% = [-1,8334, -0,4652]).

Estes resultados confirmam a existência de um caminho mediado através da fadiga algorítmica, reforçando a evidência teórica de que a saturação cognitiva gerada por ambientes hiperpersonalizados compromete a atenção dos utilizadores (Yang et al., 2024; Dhir et al., 2019).

Seguidamente, foi avaliado se a relação entre a intensidade da personalização algorítmica e a atenção do utilizador a conteúdos patrocinados é mediada, em série, pela perceção de filter bubbles e pela fadiga algorítmica, foi utilizado o modelo 6 da macro PROCESS v4.2 para SPSS (Hayes, 2022), com 5000 reamostragens bootstrap.

| Tipo de Efeito | Coefficiente B | Erro Padrão (SE) | IC 95% Inferior | IC 95% Superior | Valor p |
|--|----------------|------------------|-----------------|-----------------|---------|
| Efeito Total | -2,1801 | 1,1235 | -4,4007 | 0,0999 | |
| Efeito Direto | 0,2764 | 1,2608 | -2,2986 | 2,8513 | 0,828 |
| Efeito Indireto Total | -2,1523 | 1,0548 | -4,2017 | -0,0101 | |
| Ind1: intalgo → filter → atenção a patrocinados | -2,1523 | 1,0548 | -4,2017 | -0,0101 | |
| Ind2: intalgo → fadiga → atenção a patrocinados | -0,0225 | 0,3769 | -0,8373 | 0,7821 | |
| Ind3: intalgo → filter → fadiga → atenção a patrocinados | -0,0053 | 0,2218 | -0,5 | 0,458 | |

Tabela 22 - Efeitos direto, indireto e total da intensidade da personalização algorítmica sobre a atenção do utilizador a conteúdos patrocinados, com mediação em série pela perceção de filter bubbles e pela fadiga algorítmica (Modelo 6 – PROCESS)

Os resultados demonstraram que o efeito total da intensidade da personalização algorítmica na atenção a conteúdos patrocinados é estatisticamente significativo e negativo ($B = -2.12$, $p < .001$), sugerindo que uma maior personalização está associada a menor atenção a conteúdos promocionais.

Contudo, ao analisar o modelo com as variáveis mediadoras, o efeito direto deixou de ser estatisticamente significativo ($B = -1.99$, $p = .079$), o que indica uma possível mediação. No

entanto, o efeito indireto total não foi estatisticamente significativo, uma vez que o intervalo de confiança a 95% inclui o zero (IC 95% = [-3.05, 2.26]). A decomposição dos efeitos indiretos individuais também revelou a não significância estatística de todas as vias.

Assim, os resultados não confirmam a hipótese H7b. Apesar do efeito total ser significativo, os mecanismos mediadores testados (percepção de filter bubbles e fadiga algorítmica) não explicam significativamente essa relação.

| Tipo de Efeito | Coeficiente B | Erro Padrão (SE) | IC 95% Inferior | IC 95% Superior | Valor p |
|------------------------------|---------------|------------------|-----------------|-----------------|---------|
| Efeito Total | -1,9036 | | | | |
| Efeito Direto | -1,8251 | 0,4787 | -2,8015 | -0,8488 | 0,0006 |
| Efeito Indireto (via fadiga) | -0,0785 | 0,4145 | -0,8971 | 0,7463 | |

Tabela 23 - Efeitos total, direto e indireto da intensidade da personalização algorítmica sobre a atenção do utilizador a conteúdos patrocinados, com mediação pela fadiga algorítmica (Modelo 4 – PROCESS)

De modo a aprofundar a análise dos efeitos da personalização algorítmica sobre a atenção do utilizador, foi conduzido um modelo de mediação simples (modelo 4 do PROCESS), em que a fadiga algorítmica foi testada isoladamente como variável mediadora. Esta abordagem permitiu avaliar de forma mais específica o papel desta variável nos dois desdobramentos da atenção: atenção geral e atenção dirigida a conteúdos patrocinados.

No caso da atenção geral do utilizador, os resultados revelaram um efeito indireto significativo da intensidade da personalização algorítmica, mediado pela fadiga algorítmica ($B = -1,1839$; $BootCI\ 95\% [-1,8334; -0,4652]$), bem como um efeito direto também significativo ($B = -0,9378$; $p = 0,0260$), sugerindo um efeito de mediação parcial. Estes resultados indicam que uma maior intensidade de personalização está associada a níveis superiores de fadiga, os quais, por sua vez, reduzem significativamente a atenção geral do utilizador.

Por outro lado, no que diz respeito à atenção a conteúdos patrocinados, embora o efeito direto da personalização algorítmica se tenha mantido significativo ($B = -1,8251$; $p = 0,0006$), o efeito indireto mediado pela fadiga algorítmica não foi estatisticamente significativo ($B = -0,0785$; $BootCI\ 95\% [-0,8971; 0,7463]$). Este resultado sugere que, neste caso, o impacto da personalização sobre a atenção a conteúdos com intenção comercial ocorre de forma direta, sem intermediação clara pela fadiga.

5. DISCUSSÃO

A presente investigação teve como objetivo principal analisar o impacto da intensidade da personalização algorítmica sobre a atenção dos utilizadores, incorporando no modelo conceptual dois mecanismos mediadores: a formação de filter bubbles e a fadiga algorítmica. Sustentada numa fundamentação teórica interdisciplinar, que integra contributos das ciências da comunicação, psicologia cognitiva e estudos sobre inteligência artificial, esta dissertação procurou responder a um problema atual e emergente: os efeitos cognitivos e comportamentais da hiperpersonalização digital.

A hipótese H1, que previa uma relação negativa entre a intensidade da personalização algorítmica e a atenção do utilizador geral (H1a) e específica a conteúdos patrocinados (H1b), foi confirmada com base nos resultados do teste t. Verificou-se que os participantes sujeitos a elevados níveis de personalização (Grupo A) apresentaram níveis de atenção significativamente inferiores aos do grupo com baixa personalização (Grupo B). Estes resultados confirmam a literatura que aponta para o impacto disruptivo da hiperpersonalização sobre os processos atencionais, promovendo fragmentação, saturação informativa e dispersão cognitiva (Campos & Campos, 2024; Boerman et al., 2017). Este resultado é particularmente relevante no contexto da comunicação publicitária, onde a capacidade de captar e manter a atenção do utilizador é essencial.

As hipóteses H2 e H3, avaliadas igualmente através do teste t de amostras independentes, revelaram que o grupo com elevada personalização experienciou níveis superiores de filter bubbles e de fadiga algorítmica. Estes resultados corroboram as teses de Pariser (2011) e Zuiderveen Borgesius et al. (2016) sobre o reforço de preferências e o isolamento informativo promovido por algoritmos, bem como os contributos de Yang et al. (2024) e Chandrakumar (2024), que associam a repetitividade e previsibilidade dos conteúdos à fadiga cognitiva. Importa destacar que estes dois fenómenos afetam a diversidade da experiência mediática, mas também comprometem a motivação e o envolvimento dos utilizadores, com implicações diretas para a eficácia comunicacional.

Contudo, os resultados relativos à H4, que postulava uma relação positiva entre a presença de filter bubbles e a fadiga algorítmica, não se revelaram estatisticamente significativos para nenhum dos grupos. Este resultado, não obstante as evidências teóricas apontarem para uma associação entre homogeneização informativa e esgotamento cognitivo (Kaluža, 2021), sugere

que o efeito poderá depender de variáveis moderadoras não contempladas, como a consciência do utilizador sobre a repetição de conteúdos ou o seu grau de literacia digital. A ausência de significância pode ainda refletir limitações de sensibilidade da medição utilizada para captar perceções subjetivas de fadiga atribuível a *filter bubbles*.

Adicionalmente, importa reconhecer uma limitação metodológica relevante relacionada com a operacionalização da variável "*filter bubbles*". A escala utilizada nesta investigação, a Identity Bubble Reinforcement Scale (Kaakinen et al., 2018), foi originalmente desenvolvida para avaliar a integração voluntária e consciente dos utilizadores em bolhas identitárias (contextos nos quais o utilizador opta ativamente por se expor a conteúdos alinhados com as suas crenças e grupos sociais). No entanto, o conceito de *filter bubble* algorítmica assume uma lógica distinta: trata-se de um processo de personalização automatizado, muitas vezes invisível para o utilizador, em que a exposição seletiva a conteúdos ocorre sem consciência nem intenção. Tendo isto em consideração, é possível que a escala não tenha captado com precisão a perceção dos participantes sobre a sua inserção em *filter bubbles* algorítmicas, o que poderá ter condicionado os resultados das análises estatísticas relativas à variável. Futuros estudos deverão considerar o desenvolvimento ou adoção de instrumentos especificamente desenhados para avaliar perceções não conscientes ou implícitas de personalização algorítmica.

A hipótese H5, testada em duas versões, atenção geral e atenção a conteúdos patrocinados, não obteve confirmação estatística em nenhum dos grupos. A ausência de significância desafia a literatura que defende que ambientes previsíveis e automatizados reduzem a resposta atencional a estímulos publicitários (Bright et al., 2015; Boerman et al., 2017). Esta inconsistência poderá dever-se ao facto de a exposição prolongada a conteúdos personalizados não ser percecionada como negativa de forma consciente ou imediata pelos utilizadores, ou ainda ao papel de outras variáveis mediadoras como o cansaço tecnológico ou a perceção de relevância dos anúncios.

Por sua vez, a hipótese H6, que previa um impacto negativo da fadiga algorítmica na atenção, foi confirmada em relação à atenção geral, tanto no grupo A como no grupo B, através das regressões lineares. O efeito negativo e estatisticamente significativo corrobora os estudos que apontam a fadiga mental como fator que compromete a capacidade de concentração e o processamento contínuo de estímulos digitais (Wang & Scherr, 2022). No entanto, a versão desta hipótese aplicada à atenção a conteúdos patrocinados não obteve apoio empírico, reforçando a ideia de que os mecanismos que afetam a atenção geral nem sempre se traduzem de forma direta em efeitos sobre a atenção publicitária.

Foram também conduzidas análises complementares de regressão linear múltipla com o objetivo de aprofundar a compreensão dos mecanismos que afetam a atenção, considerando simultaneamente as variáveis mediadoras propostas. Os resultados indicaram que, no caso da atenção geral, a fadiga algorítmica revelou-se um preditor estatisticamente significativo e negativo, ao passo que a percepção de *filter bubbles* não atingiu significância. Em contraste, na predição da atenção a conteúdos patrocinados, o padrão foi inverso: a percepção de *filter bubbles* teve um efeito negativo estatisticamente significativo, enquanto a fadiga algorítmica não se revelou relevante. Estes resultados sugerem que os dois tipos de atenção (geral e a conteúdos patrocinados) são impactados por mecanismos distintos, o que reforça a pertinência de os tratar separadamente em análises futuras.

Adicionalmente, tendo em conta as limitações observadas nas análises de mediação com duas variáveis simultâneas (modelo 6), foi conduzido um novo teste de mediação simples (modelo 4) com a variável fadiga algorítmica como único mediador. Nesta versão, o efeito indireto da intensidade de personalização sobre a atenção geral mostrou-se estatisticamente significativo, confirmando o papel mediador da fadiga. Contudo, este efeito não se manteve na variável atenção a conteúdos patrocinados. Esta diferença sugere que a fadiga afeta sobretudo a capacidade de manter atenção de forma ampla, mas não influencia diretamente a resposta do utilizador a estímulos publicitários.

Por fim, a análise de mediação conduzida com recurso à macro PROCESS (modelo 6 de Hayes) não revelou efeitos indiretos significativos da intensidade da personalização sobre a atenção através das mediadoras *filter bubbles* e fadiga algorítmica. Embora o efeito total tenha sido significativo e o efeito direto se aproxime da significância ($p = .0785$), os caminhos mediadores testados (tanto individualmente como em cadeia) não demonstraram robustez estatística. Esta ausência de mediação pode sugerir que os efeitos da personalização sobre a atenção são predominantemente diretos ou mediados por outros fatores contextuais ainda não explorados, como a variabilidade do conteúdo, o tipo de plataforma ou a atitude dos utilizadores perante a tecnologia.

Tendo isto em consideração, foram também conduzidas análises complementares de mediação simples (modelo 4 da macro PROCESS), isolando a variável “fadiga algorítmica” como mediadora da relação entre a intensidade da personalização algorítmica e a atenção (geral e a conteúdos patrocinados). Estes testes revelaram que, no caso da atenção geral, o efeito total da personalização sobre a atenção manteve-se estatisticamente significativo, e o efeito indireto mediado pela fadiga também se revelou significativo (IC 95% [-1.83, -0.47]), confirmando a

existência de um caminho mediador robusto. Já no caso da atenção a conteúdos patrocinados, embora o efeito direto se mantivesse significativo, o efeito indireto não atingiu significância estatística, sugerindo que a fadiga algorítmica tem um impacto mediador mais expressivo sobre a atenção em termos gerais do que sobre estímulos publicitários específicos. Estes resultados reforçam as investigações previamente analisadas e sublinham o papel central da fadiga cognitiva como mecanismo explicativo no efeito da hiperpersonalização sobre os recursos atencionais do utilizador, indo ao encontro das conclusões de Wang e Scherr (2022) sobre a sobrecarga informacional em ambientes digitais personalizados.

6. Conclusão

A presente dissertação constitui um contributo relevante para a compreensão dos impactos cognitivos da personalização algorítmica, ao integrar variáveis mediadoras e testar empiricamente as suas relações num modelo conceptual coerente com a literatura contemporânea. Os resultados obtidos confirmam parcialmente o modelo proposto, evidenciando que a intensidade da personalização tem um impacto direto negativo sobre a atenção dos utilizadores, além de se associar à formação de filter bubbles e ao aumento da fadiga algorítmica.

Apesar de não se ter verificado um efeito mediador robusto das variáveis *filter bubbles* e fadiga algorítmica sobre a atenção, os dados sugerem que os efeitos da personalização não são unívocos e podem depender de fatores individuais, contextuais e tecnológicos. Esta conclusão aponta para a necessidade de futuras investigações explorarem modelos moderados ou mediadores múltiplos, bem como o papel de variáveis como o tempo de exposição, o envolvimento emocional e a perceção de utilidade da personalização.

Do ponto de vista prático, os resultados sustentam a importância de promover práticas algorítmicas mais responsáveis, que não considerem apenas a maximização do engagement, mas também o bem-estar cognitivo dos utilizadores. As plataformas digitais devem equilibrar a relevância do conteúdo com a diversidade informativa, evitando ambientes excessivamente redundantes que conduzam à saturação e à perda de foco.

Os profissionais de marketing devem repensar estratégias baseadas em algoritmos excessivamente personalizados. A saturação informativa pode reduzir significativamente a atenção. Estratégias mais equilibradas podem aumentar a eficácia publicitária.

Em termos teóricos, este estudo reforça a necessidade de abordagens interdisciplinares na análise da personalização algorítmica, integrando perspetivas da psicologia cognitiva, ciências da comunicação e ética da inteligência artificial. A investigação aqui apresentada constitui, assim, um ponto de partida sólido para futuras explorações empíricas mais abrangentes, que possam aprofundar o entendimento sobre os efeitos colaterais da personalização nas esferas da atenção, autonomia e literacia digital.

Os testes adicionais reforçaram a ideia de que a fadiga algorítmica compromete a atenção geral, enquanto a atenção a conteúdos patrocinados é mais afetada pelas filter bubbles, evidenciando que diferentes tipos de atenção são influenciados por mecanismos distintos.

Limitação do Estudo e Sugestões para Investigações Futuras

Apesar da presente investigação ter oferecido contributos significativos para a compreensão dos efeitos da personalização algorítmica na atenção dos utilizadores, é fundamental reconhecer algumas limitações metodológicas e contextuais que devem ser consideradas na interpretação dos resultados.

A primeira limitação refere-se ao tamanho da amostra ($N = 34$), que, embora suficiente para análises preliminares e testes paramétricos básicos, reduz a robustez estatística das inferências, sobretudo em modelos de regressão e mediação com múltiplas variáveis. Uma amostra maior permitiria um maior poder estatístico, maior representatividade e, potencialmente, a identificação de efeitos que aqui não alcançaram significância. Em segundo lugar, a duração da exposição aos estímulos algorítmicos foi relativamente curta (25 minutos para cada Grupo). Os efeitos cognitivos e emocionais da personalização algorítmica tendem a acumular-se ao longo do tempo, como sugerem estudos longitudinais (Yang et al., 2024; Wang & Scherr, 2022). Desta forma, a curta duração do experimento poderá não ter sido suficiente para captar de forma plena o impacto da fadiga algorítmica ou da formação de filter bubbles, fenómenos cuja manifestação exige repetição e continuidade de exposição.

Outra limitação prende-se com o carácter autorreportado das variáveis dependentes e mediadoras, nomeadamente atenção, fadiga e perceção de bolhas informativas. Embora estas escalas apresentem bons níveis de fiabilidade, são sempre suscetíveis a enviesamentos de resposta, como o efeito de desejabilidade social ou a falta de introspeção precisa por parte dos participantes. A inclusão de medidas comportamentais objetivas (como tempo de visualização, cliques ou métricas de scrolling) poderia reforçar a validade dos resultados. O ambiente experimental controlado, ainda que útil para isolar variáveis, limita a generalização dos resultados para contextos reais de uso das redes sociais, mais dinâmicos e suscetíveis a múltiplas distrações.

Por fim, o modelo conceptual proposto centrou-se exclusivamente na intensidade da personalização algorítmica, não considerando outros fatores relevantes, como o tipo de conteúdo, a atitude dos utilizadores perante algoritmos, a literacia digital, ou variáveis sociodemográficas como idade, género ou frequência de uso da plataforma.

Importa também destacar uma limitação específica relacionada com a medição da variável “*filter bubbles*”. A escala utilizada, adaptada de Kaakinen et al. (2018), foi originalmente concebida para contextos de escolha voluntária de bolhas identitárias, e poderá não refletir com

precisão a percepção inconsciente de isolamento algorítmico, mais adequada ao objetivo deste estudo. Esta divergência conceptual poderá ter contribuído para os resultados não significativos associados à variável. Os modelos de mediação testados, embora teoricamente fundamentados, apresentaram limitações estatísticas que recomendam a sua validação futura com amostras maiores e contextos diferenciados.

Por outro lado, a atenção foi tratada como constructo unidimensional, mas os resultados sugerem que diferentes dimensões (como a atenção geral e a atenção a conteúdos patrocinados) podem ser influenciadas por mecanismos distintos. Investigações futuras poderão beneficiar da exploração de tipos específicos de atenção (e.g., seletiva, sustentada, alternada).

A utilização de metodologias mistas (quantitativas e qualitativas) poderá também captar melhor a experiência subjetiva dos utilizadores perante a personalização algorítmica.

Tendo em conta estas limitações, sugerem-se diversas direções para investigações futuras:

1. Expandir a amostra, garantindo maior heterogeneidade e representatividade estatística;
2. Implementar desenhos longitudinais, que permitam observar os efeitos acumulativos da personalização algorítmica ao longo do tempo;
3. Incluir métricas objetivas de atenção e comportamento, como dados de interação com a interface digital;
4. Explorar modelos de moderação, testando o papel de variáveis individuais (e.g., literacia algorítmica, envolvimento com o conteúdo, nível de consciência sobre personalização);
5. Estender o modelo a outras plataformas digitais, de modo a avaliar se os efeitos observados são específicos do tipo de rede social ou generalizáveis a outros ambientes personalizados por IA.
6. Reformular e adaptar escalas de medição, garantindo que o construto “*filter bubbles*” é avaliado em linha com a percepção involuntária e algorítmica, tal como conceptualizado neste estudo.
7. Investigar modelos que combinem diferentes mecanismos mediadores e distintos tipos de atenção, de forma a refletir a complexidade crescente dos ambientes digitais contemporâneos.

Ao reconhecer estas limitações e ao propor novos caminhos de investigação, este estudo contribui para o desenvolvimento de uma agenda crítica sobre os impactos cognitivos da personalização algorítmica, oferecendo bases sólidas para análises futuras mais complexas e contextualizadas.

Referências Bibliográficas

- Aguirre López, E., Roggeveen, A., Grewal, D., & Wetzels, M. G. M. (2016). The personalization–privacy paradox: implications for new media. *Journal of Consumer Marketing*, 33(2), 98–110.
- Ahmed, S. M. M., Owais, M., Raza, M., Nadeem, Q., & Ahmed, B. (2025). The impact of AI-driven personalization on consumer engagement and brand loyalty. *Qlantic Journal of Social Sciences*, 6(1), 311–323.
- Alwafi, F. K., & Fakieh, B. (2024). A machine learning model to predict privacy-fatigued users in social media advertising: A study of personality traits and privacy awareness. *Heliyon*, 10(2), e27112.
- Alwafi, A., & Fakieh, B. (2024). Algorithmic saturation and attention depletion. *Technology in Society*, 79, 101684.
- Anderson, J., Hübener, D., Reinecke, L., & Ziefle, M. (2018). A survey of attention management systems in ubiquitous computing environments. *Journal of Ambient Intelligence and Humanized Computing*, 9(4), 1081–1096.
- Avin, C., Daltrophe, H., & Lotker, Z. (2024). On the impossibility of breaking the echo chamber effect in social media using regulation. *Scientific Reports*, 14, 1107.
- Bakshy, E., Messing, S., & Adamic, L. A. (2015). Exposure to ideologically diverse news and opinion on Facebook. *Science*, 348(6239), 1130–1132.
- Bang, H., Choi, D., Wojdyski, B. W., & Lee, Y.-I. (2019). How the level of personalization affects the effectiveness of personalized ad messages: The moderating role of narcissism. *International Journal of Advertising*, 38(8), 1116–1138.
- Bentes, A. (2019). A gestão algorítmica da atenção: enganchar, conhecer e persuadir. *MediaLab UFRJ*.
- Boeker, M., & Urman, A. (2022). An empirical investigation of personalization factors on TikTok. *Proceedings of the ACM Web Conference 2022*, 2228–2238.

Boerman, S. C., Willemsen, L. M., & Van Der Aa, E. P. (2017). “This post is sponsored”: Effects of sponsorship disclosure on persuasion knowledge and electronic word of mouth in the context of Facebook. *Journal of Interactive Marketing*, 38, 82–92.

Boerman, S. C., Willemsen, L. M., & Van Der Aa, E. P. (2017). Persuasion knowledge and resistance to advertising: The role of awareness of the persuasive intent behind native advertising. *Journal of Advertising*, 46(3), 364–372.

Bozdag, E. (2013). Bias in algorithmic filtering and personalization. *Ethics and Information Technology*, 15(3), 209–227.

Bright, L. F., Kleiser, S. B., & Grau, S. L. (2015). Too much Facebook? An exploratory examination of social media fatigue. *Computers in Human Behavior*, 44, 148–155.

Broeklyn, P., Olukemi, A., & Bell, C. (2024). AI-driven personalization in digital marketing: Effectiveness and ethical considerations. *SSRN Working Paper*.

Brüns, J. D., & Meißner, M. (2023). *Show me that you are advertising: Visual salience of products attenuates detrimental effects of persuasion knowledge activation in influencer advertising*. *Computers in Human Behavior*, 148, Article 107891.

Bunza, M. (2024). Duration-based investigation of user content choices in TikTok. *Mobile Media & Communication*.

Bunza, R. (2024). Duration-based investigation of user content choices in the exit of filter bubbles. *2024 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*.

Campos, J., & Campos, J. R. (2024). Unveiling the nexus of distribution personalization and content decentralization: Exploring brand recall among Gen Z in Region III, Philippines. *International Journal of Entrepreneurship, Business and Creative Economy*.

Cao, Z., & Belo, R. (2024). Effects of explicit sponsorship disclosure on user engagement in social media influencer marketing. *MIS Quarterly*, 48(1), 375–392.

Chandrakumar, H. (2024). The use of AI-driven personalization for enhancing the customer experience for Gen-Z. *Open Journal of Business and Management*, 12(2), 304–320.

Chandrakumar, R. (2024). TikTok fatigue among digital natives: An exploratory study on user disengagement. *Journal of Youth and Media Studies*, 7(1), 45–63.

Cinelli, M., Quattrocioni, W., Galeazzi, A., Valensise, C. M., Brugnoli, E., Schmidt, A. L., ... & Scala, A. (2021). The echo chamber effect on social media. *Proceedings of the National Academy of Sciences*, 118(9), e2023301118.

Cloarec, J. (2020). The personalization–privacy paradox in the attention economy. *Technological Forecasting and Social Change*, 161, 120299.

Coombs, C. (2020). Will COVID-19 be the tipping point for the Intelligent Automation of work? A review of the debate and implications for research. *International Journal of Information Management*, 55, 102182.

Creswell, J. W., & Creswell, J. D. (2018). *Research design: Qualitative, quantitative, and mixed methods approaches* (5th ed.). SAGE Publications.

Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48, 24–42.

Dhir, A., Kaur, P., Chen, S., & Pallesen, S. (2019). Antecedents and consequences of social media fatigue. *International Journal of Information Management*, 48, 193–202.

Dhir, A., Yossatorn, Y., Kaur, P., & Chen, S. (2019). Online social media fatigue and psychological well-being — A study of compulsive use, fear of missing out, fatigue, anxiety and depression. *International Journal of Information Management*, 48, 96–104.

Duffett, R. (2020). Influence of social media marketing communications on young consumers' attitudes. *Technological Forecasting & Social Change*, 151, 119885.

Eg, R., Tønnesen, Ö. D., & Tennfjord, M. (2023). A scoping review of personalized user experiences on social media: The interplay between algorithms and human factors. *Computers in Human Behavior Reports*, 9, 100253.

Epstein, Z., Lin, H., Pennycook, G., & Rand, D. (2022). Quantifying attention via dwell time and engagement in a social media browsing environment. *arXiv*.

Fan, Y., & Liu, X. (2022). Exploring the role of AI algorithmic agents: The impact of algorithmic decision autonomy on consumer purchase decisions. *Frontiers in Psychology, 13*, Article 1009173.

Flaxman, S., Goel, S., & Rao, J. M. (2016). Filter bubbles, echo chambers, and online news consumption. *Public Opinion Quarterly, 80*(S1), 298–320.

Friestad, M., & Wright, P. (1994). The persuasion knowledge model: How people cope with persuasion attempts. *Journal of Consumer Research, 21*(1), 1–31.

Gantois, P., Lima-Junior, D. L., de Sousa Fortes, L., Batista, G. R., & Nakamura, F. Y. (2021). Mental fatigue from smartphone use reduces volume-load in resistance training: A randomized, single-blinded cross-over study. *Perceptual and Motor Skills, 128*(4), 1640–1659.

Gillespie, T. (2014). The relevance of algorithms. In T. Gillespie, P. J. Boczkowski, & K. A. Foot (Eds.), *Media technologies: Essays on communication, materiality, and society* (pp. 167–193). MIT Press.

Giuffredi-Kähr, A., Petrova, A., & Malär, L. (2022). Sponsorship disclosure of influencers – A curse or a blessing? *Journal of Interactive Marketing, 57*, 18–34.

Golbeck, J. (2020). Optimizing for engagement can be harmful. There are alternatives. *IEEE Intelligent Systems, 35*(6), 117–118.

Gupta, R., & Khan, T. (2024). Role of artificial intelligence in customer engagement: A review of opportunities and challenges. *International Journal of Information Management, 74*, 102654.

Haefner, M., Wincent, J., Parida, V., & Gassmann, O. (2021). Artificial intelligence and innovation management: A review, framework, and research agenda. *Technological Forecasting and Social Change, 162*, 120392.

Han, H., Wang, C., Zhao, Y., Shu, M., Wang, W., & Min, Y. (2022). SSLE: A framework for evaluating the “Filter Bubble” effect on the news aggregator and recommenders. *World Wide Web, 25*, 1169–1195.

Harner, J., Ray, L., & Wakoko-Studstill, F. (2022). *An investigation of the effectiveness of Facebook and Twitter algorithms and policies on misinformation and user decision making*. *Journal of Systemics, Cybernetics and Informatics*, 20(5), 118–137.

Hattingh, C., Thakur, R., & Hartmann, M. (2022). The impact of algorithmic fatigue on consumer engagement with digital content. *Journal of Interactive Marketing*, 59, 45–59.

Hayes, A. F. (2018). *Introduction to mediation, moderation, and conditional process analysis: A regression-based approach* (2nd ed.). Guilford Press.

Hobbs, R. (2020). Propaganda in an age of algorithmic personalization: Expanding literacy research and practice. *Reading Research Quarterly*, 55(4), 521–534.

Jiang, Q., & Ma, L. (2024). Swiping more, thinking less: Using TikTok hinders analytic thinking. *Cyberpsychology: Journal of Psychosocial Research on Cyberspace*, 18(3), Article 1

Jung, A. R. (2017). The influence of perceived ad relevance on social media advertising: An empirical examination of a mediating role of privacy concern. *Computers in Human Behavior*, 70, 303–309.

Jung, A.-R., & Heo, J. (2019). *Ad disclosure vs. ad recognition: How persuasion knowledge influences native advertising evaluation*. *Journal of Interactive Advertising*, 19(1), 1–14.

Kaplan, A. M., & Haenlein, M. (2019). Rethinking AI: From Artificial Intelligence to Augmented Intelligence. *Business Horizons*, 62(1), 147–157.

Kaur, P., Islam, T., Van Thanh, T., & Dhir, A. (2021). Social media users' online subjective well-being and fatigue: A stressor–strain–outcome perspective. *Technological Forecasting and Social Change*, 172, 121039.

Kaluža, J. (2021). Habitual generation of filter bubbles: Why is algorithmic personalization reinforcing selective exposure? *Journal of Media Psychology*, 33(4), 267–276.

Kaluža, J. (2021). Habitual generation of filter bubbles: Why is algorithmic personalisation problematic for the democratic public sphere? *Javnost – The Public*, 29(3), 267–283.

Kotler, P., & Keller, K. L. (2016). *Marketing management* (15th ed.). Pearson Education.

- Kotler, P., Kartajaya, H., & Setiawan, I. (2017). *Marketing 4.0: Moving from traditional to digital*. John Wiley & Sons.
- Kotler, P., Kartajaya, H., & Setiawan, I. (2016). *Marketing 4.0: Moving from traditional to digital*. John Wiley & Sons.
- Köster, M., RÜth, M., Hamborg, K.-C., & Kaspar, K. (2015). Effects of personalized banner ads on visual attention and recognition memory. *Applied Cognitive Psychology, 29*(2), 181–192.
- Kumar, V., Rajan, B., Venkatesan, R., & Lecinski, J. (2019). Understanding the role of artificial intelligence in personalized engagement marketing. *California Management Review, 61*(4), 135–155.
- Kümpel, A. S. (2021). Social media information environments and their implications for the uses and effects of news: The PINGS framework. *Communication Theory, 32*(2), 154–178.
- Li, X., Chen, Y., & Zhao, Q. (2024). The impact of algorithmic fatigue on user experience in AI-driven platforms. *Artificial Intelligence Review, 57*(1), 98–123.
- Lim, J., Wu, W.-C., Wang, D. J. J., Detre, J., Dinges, D., & Rao, H. (2010). Imaging brain fatigue from sustained mental workload: An ASL perfusion study of the time-on-task effect. *NeuroImage, 49*(4), 3426–3435.
- Lin, C. A., & Kim, T. (2016). Predicting user response to sponsored advertising on social media via the technology acceptance model. *Computers in Human Behavior, 64*, 710–718.
- Lv, L., Kang, Q., & Liu, G. (2024). Prick “filter bubbles” by enhancing consumers’ novelty-seeking: The role of personalized recommendations of unmentionable products. *Psychology & Marketing*.
- Mishra, P., Pandey, C. M., Singh, U., Gupta, A., Sahu, C., & Keshri, A. (2019). Descriptive statistics and normality tests for statistical data. *Annals of Cardiac Anaesthesia, 22*(1), 67–72.
- Medallia, & Customer Experience Professionals Association. (2024). *The 2024 state of CX personalization report*. Medallia.

Meeker, M. (2018). *Internet trends report 2018*. Kleiner Perkins Caufield & Byers. Recuperado de <https://www.kleinerperkins.com/perspectives/internet-trends-report-2018>

Montag, C., Lachmann, B., Herrlich, M., & Zweig, K. A. (2021). Digital phenotyping in psychological research. *Nature Human Behaviour*, 5(4), 398–403.

Mustak, M., Salminen, J., Plé, L., & Wirtz, J. (2021). Artificial intelligence in marketing: Topic modeling, scientometric analysis, and research agenda. *Journal of Business Research*, 124, 389–404.

Nazir, M., Khadim, S., & Mushtaq, R. (2022). Exploring the influence of artificial intelligence on social media marketing: A strategic perspective. *Journal of Marketing Analytics*, 10(2), 102–116.

Obiegbu, J., & Larsen, G. (2024). Algorithmic personalization and brand loyalty: An experiential perspective. *Marketing Theory*, 25(2), 199–219.

Pariser, E. (2011). *The filter bubble: What the Internet is hiding from you*. Penguin Press.

Pasca, A. (2023). Enhancing awareness of filter bubbles and echo chambers. *University of Twente Bachelor Thesis*.

Perakakis, E., Mastorakis, N. E., & Bazinas, C. (2019). Social media monitoring: An innovative intelligent system for corporate reputation analysis. *WSEAS Transactions on Systems and Control*, 14, 158–164.

Perra, N., & Rocha, L. E. C. (2018). Modelling opinion dynamics in the age of algorithmic personalisation. *Scientific Reports*, 8, 12349.

Plume, C. J., & Slade, E. L. (2018). *Sharing of sponsored advertisements on social media: A uses and gratifications perspective*. *Information Systems Frontiers*, 20(3), 471–483.

Pradana, F., & Efendi, E. (2024). Filter bubble trap: The effect of TikTok media on language use and interaction among communication science students. *JKOMDIS: Jurnal Ilmu Komunikasi Dan Media Sosial*, 4(2).

Puntoni, S., Reczek, R. W., Giesler, M., & Botti, S. (2021). Consumers and artificial intelligence: An experiential perspective. *Journal of Marketing*, 85(1), 131–151.

Qiao, R., Liu, C., & Xu, J. (2024). Making algorithmic app use a virtuous cycle: Influence of user gratification and fatigue on algorithmic app dependence. *Humanities and Social Sciences Communications*, 11(1), Article 775.

Rauch, W. A., & Schmitt, K. (2009). Fatigue of cognitive control in the Stroop-task. In *Proceedings of the Annual Meeting of the Cognitive Science Society*.

Razali, N. M., & Wah, Y. B. (2011). Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests. *Journal of Statistical Modeling and Analytics*, 2(1), 21–33.

Reuters. (2025, 7 de maio). *Zalando uses AI to speed up marketing campaigns, cut costs*. Reuters.

Rydenfelt, H., Haapanen, L., & Huovila, M. (2022). Personalisation in journalism: Ethical insights and empirical explorations. *Journalism Studies*, 23(8), 1032–1050.

Sheng, J., Amankwah-Amoah, J., Wang, X., & Khan, Z. (2019). Managerial Responses to Online Reviews: A Text Analytics Approach. *British Journal of Management*, 30(2), 315–327.

Shcherbakova, O., & Nikiforchuk, S. (2022). Social media and filter bubbles. *Scientific Journal of Polonia University*, 54, Article 11.

Stevenson, D. M., & Pasek, J. (2015). Privacy concern, trust, and desire for content personalization. *SSRN Working Paper*.

Sweller, J., Ayres, P., & Kalyuga, S. (2011). *Cognitive load theory*. Springer.

Tan, Y., & Yoon, S. (2024). Testing the effects of personalized recommendation service, filter bubble and big data attitude on continued use of TikTok. *Asia Pacific Journal of Marketing and Logistics*.

Tanaka, M., Ishii, A., & Watanabe, Y. (2014). Neural effects of mental fatigue caused by continuous attention load: A magnetoencephalography study. *Brain Research*, 1561, 60–66.

Teixeira, T., Wedel, M., & Pieters, R. (2012). Emotion-induced engagement in Internet video advertisements. *Journal of Marketing Research*, 49(2), 144–159.

Vohs, K. D., Baumeister, R. F., Schmeichel, B. J., Twenge, J. M., Nelson, N. M., & Tice, D. M. (2008). *Making choices impairs subsequent self-control: A limited-resource account of decision making, self-regulation, and active initiative*. *Journal of Personality and Social Psychology*, 94(5), 883–898.

Tønnesen, Ø., & Tennfjord, B. S. (2023). Personalized news and the perception of control: Exploring algorithmic power and autonomy in digital media environments. *Journal of Digital Media & Policy*, 14(1), 1–18.

Wang, K., & Scherr, S. (2023). Dance the night away: How automatic TikTok use creates pre-sleep cognitive arousal and daytime fatigue. *Journal of Social and Personal Relationships*, 40(12), 485–506.

Wang, X., Yu, X., Feng, F., & Song, P. (2022). Impact of product customization level on consumer's word-of-mouth behaviors and contents: A field study. *Information Technology & People*.

Yang, C., & Hu, L. (2025). Algorithmic fatigue and user responses to personalized content: Evidence from social video platforms. *Computers in Human Behavior*, 137, 107407.

Yang, H., Li, D., & Hu, P. (2024). Decoding algorithm fatigue: The role of algorithmic literacy, information cocoons, and algorithmic opacity. *Technology in Society*, 102749.

Yang, Y., Xu, W., Ma, M., & Lin, Y. (2023). Bubbles bursting: Investigating and measuring the psychological effects of filter bubbles in personalized media environments. *Telematics and Informatics*, 83, 102004.

Zanathy, A. (2021). Burst the bubble: How to defend freedom of expression from algorithmic personalization. *International Journal of Scientific and Research Publications (IJSRP)*, 11(7).

Zhang, K., Xie, Y., He, Y., & Wang, J. (2025). Emotional influences on user continuous use intention in recommended news apps: A study of algorithm appreciation and fatigue within the cognition-affect-conation framework. *Acta Psychologica*, 256, 105002.

Zhang, L., Zhao, J., & Xu, K. (2021). Who creates trends in online social media: The crowd or opinion leaders? *Journal of Computer-Mediated Communication*, 26(1), 1–18.

Zhang, S., Shen, D., & Collignon, S. (2021). The development and validation of a social media fatigue scale: Scale development and construct validation. *Journal of Computer-Mediated Communication*, 26(3), 169–185.

Zhou, L., & Tian, X. (2022). Digital fatigue and content overload: Implications for consumer attention in personalized environments. *Journal of Consumer Psychology*, 32(1), 73–88.

Zuboff, S. (2019). *The age of surveillance capitalism: The fight for a human future at the new frontier of power*. Profile Books.

Zuiderveen Borgesius, F. J., Trilling, D., Möller, J., Bodó, B., de Vreese, C. H., & Helberger, N. (2016). Should we worry about filter bubbles? *Internet Policy Review*, 5(1).

Apêndices

Inquérito Pré-Exposição – Estudo Experimental TikTok

Recolha de Participantes: Dados de Identificação e Consentimento

1. Nome:
2. Email:
3. Idade:
4. Comprometo-me a estar presente para Participar neste Grupo Experimental no dia X de maio de 2025 às X:00h:
5. Sou utilizador ativo da Plataforma TikTok (pelo menos 3x por semana): Sim; Não
6. Autorizo a Recolha de Dados Pessoais única e exclusivamente para fins relacionados com a presente Investigação? Sim; Não

Inquérito Pós-Exposição – Estudo Grupo Experimental TikTok

Objetivo: Medir os efeitos da personalização algorítmica no TikTok sobre filter bubbles, fadiga algorítmica e atenção percebida.

Dados Demográficos

1. Idade

Perceção de Filter Bubbles

5 pontos Likert (Discordo totalmente – Concordo totalmente):

2. Durante a utilização do TikTok, senti que pertencia a uma comunidade ou grupo que é uma parte importante da minha identidade.
3. Durante o tempo que estive no TikTok, senti orgulho em pertencer às comunidades com as quais me envolvo.
4. Senti que pertenço a uma comunidade no TikTok com a qual me posso comprometer.
5. No TikTok, prefiro interagir com pessoas semelhantes a mim.
6. Durante a experiência, senti que todos os vídeos que vi refletiam os meus valores.
7. Tive a perceção de que a maioria das pessoas com quem interajo no TikTok pensa como eu.
8. Durante a sessão no TikTok, confiei nas informações partilhadas nos vídeos que me foram mostrados.

9. Dei mais atenção a conteúdos que reforçavam opiniões com as quais já concordava.
10. Senti que conseguia manter-me bem informado(a), apenas com base nos vídeos sugeridos.

Fadiga Algorítmica

11. Senti-me sobrecarregado(a) pela quantidade de conteúdos mostrados no TikTok durante esta sessão.
12. Durante a navegação, tive vontade de desistir de procurar conteúdos, por haver demasiada informação no feed.
13. Tive a perceção de estar a receber recomendações a mais enquanto utilizava o TikTok.
14. Evitei interagir com alguns vídeos por me sentir saturado(a) com o volume de conteúdos.
15. Durante a utilização do TikTok, senti que o tempo passou sem que eu me apercebesse.
16. Reparei que interagira com os vídeos sem pensar muito no que estava a fazer.
17. Durante a sessão, senti que perdi o foco ou me distraí da tarefa que estava a realizar.
18. Senti algum desconforto quando o TikTok me mostrava conteúdos muito semelhantes repetidamente.
19. Senti-me mentalmente cansado(a) após a sessão de uso.

Atenção Percebida

20. Senti-me perdido(a) na experiência de ver vídeos no TikTok.
21. Estava tão envolvido(a) na utilização do TikTok que perdi a noção do tempo.
22. Ignorei o que estava à minha volta enquanto usava o TikTok.
23. Quando estava a usar o TikTok, perdi a noção do mundo à minha volta (a minha atenção esteve totalmente focada nos vídeos).
24. O tempo passou rapidamente enquanto usava o TikTok.
25. Durante a experiência, deixei-me levar pelo conteúdo do TikTok.

Atenção Percebida especificamente a Conteúdos Patrocinados

26. Reparei em conteúdos patrocinados durante a sessão.
27. Prestei atenção aos conteúdos patrocinados que surgiram durante a minha utilização do TikTok.
28. Lembro-me de pelo menos uma marca que apareceu nos conteúdos patrocinados enquanto utilizava o TikTok.
29. Os conteúdos patrocinados pareciam relevantes para mim.
30. Achei que os conteúdos patrocinados interferiram com a minha experiência.

31. Consegui distinguir claramente o que era conteúdo patrocinado e o que era conteúdo orgânico.
32. Achei os conteúdos patrocinados visualmente apelativos.
33. Lembro-me do nome de pelo menos um produto ou serviço patrocinado durante a sessão no TikTok.
34. Achei que os conteúdos patrocinados se integravam bem com os restantes vídeos.
35. Durante a sessão, senti curiosidade em saber mais sobre algum conteúdo patrocinado.
36. Após a sessão, fiquei com vontade de procurar mais informações sobre alguma marca que vi.

Notas técnicas para implementação:

Escalas de 1 a 5, com as opções:

1. Discordo totalmente | 2. Discordo | 3. Neutro | 4. Concordo | 5. Concordo totalmente

O inquérito deve ser aplicado imediatamente após a experiência experimental, para garantir validade percetiva.

ANEXOS

Outputs SPSS

Descriptives Statistics

| | GRUPO | Statistic | |
|----------------------|-------|----------------|--------|
| filter_bubbles | 1 | Mean | 4.4737 |
| | | Std. Deviation | .17309 |
| | | Minimum | 4.22 |
| | | Maximum | 4.78 |
| | 2 | Mean | 1.9630 |
| | | Std. Deviation | .23256 |
| fadiga_algoritmica | 1 | Mean | 4.0468 |
| | | Std. Deviation | .26272 |
| | | Minimum | 3.33 |
| | | Maximum | 4.44 |
| | 2 | Mean | 2.5219 |
| | | Std. Deviation | .54021 |
| atenção | 1 | Mean | 1.9561 |
| | | Std. Deviation | .51772 |
| | | Minimum | 1.00 |
| | | Maximum | 2.83 |
| | 2 | Mean | 4.0778 |
| | | Std. Deviation | .55943 |
| atenção_patrocinados | 1 | Mean | 1.9569 |
| | | Std. Deviation | .57205 |
| | | Minimum | 1.09 |
| | | Maximum | 2.91 |
| | 2 | Mean | 3.8606 |
| | | Std. Deviation | .52994 |
| | | Minimum | 3.00 |
| | | Maximum | 4.73 |

Descriptives

| Variable | Mean | Std. Deviation | N |
|----------------------|--------|----------------|----|
| filter_bubbles | 2.7187 | .33371 | 36 |
| fadiga_algoritmica | 3.2843 | .40422 | 36 |
| atenção | 3.0161 | .54372 | 36 |
| atenção_patrocinados | 2.9086 | .52499 | 36 |

Group Statistics

| | GRUPO | N | Mean | Std. Deviation | Std. Error Mean |
|----------------------|-------|----|--------|----------------|-----------------|
| filter_bubbles | 1 | 19 | 4.4737 | .17309 | .03971 |
| | 2 | 15 | 1.9630 | .23256 | .06005 |
| fadiga_algoritmica | 1 | 19 | 4.0468 | .26272 | .06027 |
| | 2 | 15 | 2.5219 | .54021 | .13948 |
| atenção | 1 | 19 | 1.9561 | .51772 | .11877 |
| | 2 | 15 | 4.0778 | .55943 | .14444 |
| atenção_patrocinados | 1 | 19 | 1.9569 | .57205 | .13124 |
| | 2 | 15 | 3.8606 | .52994 | .13683 |

Independent Samples Test

| | | t | Sig. | df | One-Sided p | Two-Sided p | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | Lower | Upper |
|----------------------|-----------------------------|--------|-------|---------|-------------|-------------|-----------------|-----------------------|---|----------|----------|
| filter_bubbles | Equal variances assumed | 1.577 | .218 | 36.113 | .32 | <.001 | 2.51072 | .06952 | 2.36911 | 2.65234 | 2.65234 |
| | Equal variances not assumed | | | 34.876 | 25.178 | <.001 | 2.51072 | .07199 | 2.36251 | 2.65289 | 2.65289 |
| fadiga_algoritmica | Equal variances assumed | 17.844 | <.001 | 32.216 | .02 | <.001 | 1.52491 | .09699 | 1.33085 | 1.71897 | 1.71897 |
| | Equal variances not assumed | | | 31.818 | 23.106 | <.001 | 1.52491 | .10191 | 1.31974 | 1.71712 | 1.71712 |
| atenção | Equal variances assumed | .279 | .616 | -11.452 | .92 | <.001 | -2.10384 | .05106 | -2.49800 | -1.74008 | -1.74008 |
| | Equal variances not assumed | | | -11.249 | 29.003 | <.001 | -2.10384 | .05106 | -2.49410 | -1.73919 | -1.73919 |
| atenção_patrocinados | Equal variances assumed | .550 | .585 | -8.548 | .93 | <.001 | -1.93527 | .05136 | -2.20245 | -1.53380 | -1.53380 |
| | Equal variances not assumed | | | -10.043 | 31.121 | <.001 | -1.93527 | .05136 | -2.28018 | -1.53300 | -1.53300 |

Correlations

| GRUPO | | filter_bubbles | fadiga_algoritmica | atenção | atenção_patrocinados | |
|---------|----------------------|---------------------|--------------------|---------|----------------------|-------|
| 1 | filter_bubbles | Pearson Correlation | 1 | .149 | -.146 | -.321 |
| | | Sig. (2-tailed) | | .542 | .552 | .180 |
| | | N | 19 | 19 | 19 | 19 |
| | fadiga_algoritmica | Pearson Correlation | .149 | 1 | -.476* | -.019 |
| | | Sig. (2-tailed) | | .542 | .040 | .937 |
| | N | 19 | 19 | 19 | 19 | |
| atenção | Pearson Correlation | -.146 | -.476* | 1 | .184 | |
| | Sig. (2-tailed) | | .552 | .040 | .452 | |
| | N | 19 | 19 | 19 | 19 | |
| | atenção_patrocinados | Pearson Correlation | -.321 | -.019 | .184 | 1 |
| | Sig. (2-tailed) | | .180 | .937 | .452 | |
| | N | 19 | 19 | 19 | 19 | |
| 2 | filter_bubbles | Pearson Correlation | 1 | .030 | -.369 | -.314 |
| | | Sig. (2-tailed) | | .914 | .175 | .254 |
| | | N | 15 | 15 | 15 | 15 |
| | fadiga_algoritmica | Pearson Correlation | .030 | 1 | -.555* | -.045 |
| | Sig. (2-tailed) | | .914 | .032 | .873 | |
| | N | 15 | 15 | 15 | 15 | |
| atenção | Pearson Correlation | .369 | -.555* | 1 | .309 | |
| | Sig. (2-tailed) | | .175 | .032 | .262 | |
| | N | 15 | 15 | 15 | 15 | |
| | atenção_patrocinados | Pearson Correlation | -.314 | -.045 | .309 | 1 |
| | Sig. (2-tailed) | | .254 | .873 | .262 | |
| | N | 15 | 15 | 15 | 15 | |

*. Correlation is significant at the 0.05 level (2-tailed).

Tests of Normality

| | GRUPO | Kolmogorov-Smirnov ^a | | | Shapiro-Wilk | | |
|----------------------|-------|---------------------------------|----|-------|--------------|----|------|
| | | Statistic | df | Sig. | Statistic | df | Sig. |
| filter_bubbles | 1 | .170 | 19 | .152 | .914 | 19 | .086 |
| | 2 | .120 | 15 | .200* | .964 | 15 | .756 |
| fadiga_algoritmica | 1 | .166 | 19 | .177 | .929 | 19 | .167 |
| | 2 | .213 | 15 | .066 | .913 | 15 | .152 |
| atenção | 1 | .133 | 19 | .200* | .963 | 19 | .634 |
| | 2 | .143 | 15 | .200* | .934 | 15 | .317 |
| atenção_patrocinados | 1 | .133 | 19 | .200* | .949 | 19 | .386 |
| | 2 | .132 | 15 | .200* | .960 | 15 | .687 |

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Reliability Statistics

| Cronbach's Alpha | N of Items |
|------------------|------------|
| .955 | 9 |

Reliability Statistics

| Cronbach's Alpha | N of Items |
|------------------|------------|
| .783 | 10 |

Reliability Statistics

| Cronbach's Alpha | N of Items |
|------------------|------------|
| .925 | 5 |

Reliability Statistics

| Cronbach's Alpha | N of Items |
|------------------|------------|
| .939 | 11 |

Independent Samples Effect Sizes

| | Standardizer ^a | Point Estimate | 95% Confidence Interval | | |
|--------|---------------------------|----------------|-------------------------|-------|--------|
| | | Lower | Upper | | |
| filter | Cohen's d | .20129 | 12.473 | 9.351 | 15.581 |
| | Hedges' correction | .20616 | 12.178 | 9.130 | 15.212 |
| | Glass's delta | .23256 | 10.796 | 6.782 | 14.799 |

a. The denominator used in estimating the effect sizes. Cohen's d uses the pooled standard deviation. Hedges' correction uses the pooled standard deviation, plus a correction factor. Glass's delta uses the sample standard deviation of the control (i.e., the second) group.

Independent Samples Test

| Levene's Test for Equality of Variances | | | | t-test for Equality of Means | | | | | | | |
|---|-----------------------------|-------|------|------------------------------|--------|--------------|-------------|-----------------|-----------------------|---|---------|
| | | F | Sig. | t | df | Significance | | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | One-Sided p | Two-Sided p | | | Lower | Upper |
| filter | Equal variances assumed | 1.577 | .218 | 36.113 | 32 | <.001 | <.001 | 2.51072 | .06952 | 2.36911 | 2.65234 |
| | Equal variances not assumed | | | 34.876 | 25.178 | <.001 | <.001 | 2.51072 | .07199 | 2.36251 | 2.65894 |

Group Statistics

| | GRUPO | N | Mean | Std. Deviation | Std. Error Mean |
|---------|-------|----|--------|----------------|-----------------|
| atencao | 1 | 19 | 1.9561 | .51772 | .11877 |
| | 2 | 15 | 4.0778 | .55943 | .14444 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | 95% Confidence Interval of the Difference | | | |
|---------|-----------------------------|---|------|------------------------------|--------|--------------------------|-------------|---|-----------------------|----------|----------|
| | | F | Sig. | t | df | Significance One-Sided p | Two-Sided p | Mean Difference | Std. Error Difference | Lower | Upper |
| atencao | Equal variances assumed | .229 | .636 | -11.452 | 32 | <.001 | <.001 | -2.12164 | .18526 | -2.49900 | -1.74428 |
| | Equal variances not assumed | | | -11.345 | 29.015 | <.001 | <.001 | -2.12164 | .18701 | -2.50410 | -1.73918 |

Independent Samples Effect Sizes

| | | Standardizer ^a | Point Estimate | 95% Confidence Interval | |
|---------|--------------------|---------------------------|----------------|-------------------------|--------|
| | | | | Lower | Upper |
| atencao | Cohen's d | .53637 | -3.956 | -5.123 | -2.766 |
| | Hedges' correction | .54936 | -3.862 | -5.002 | -2.701 |
| | Glass's delta | .55943 | -3.792 | -5.325 | -2.234 |

a. The denominator used in estimating the effect sizes. Cohen's d uses the pooled standard deviation. Hedges' correction uses the pooled standard deviation, plus a correction factor. Glass's delta uses the sample standard deviation of the control (i.e., the second) group.

Group Statistics

| | GRUPO | N | Mean | Std. Deviation | Std. Error Mean |
|----------------------|-------|----|--------|----------------|-----------------|
| atencao_patrocinados | 1 | 19 | 1.9569 | .57205 | .13124 |
| | 2 | 15 | 3.8606 | .52994 | .13683 |

Independent Samples Effect Sizes

| | | Standardizer ^a | Point Estimate | 95% Confidence Interval | |
|----------------------|--------------------|---------------------------|----------------|-------------------------|--------|
| | | | | Lower | Upper |
| atencao_patrocinados | Cohen's d | .55402 | -3.436 | -4.502 | -2.348 |
| | Hedges' correction | .56744 | -3.355 | -4.396 | -2.292 |
| | Glass's delta | .52994 | -3.592 | -5.059 | -2.099 |

a. The denominator used in estimating the effect sizes. Cohen's d uses the pooled standard deviation. Hedges' correction uses the pooled standard deviation, plus a correction factor. Glass's delta uses the sample standard deviation of the control (i.e., the second) group.

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | 95% Confidence Interval of the Difference | | | |
|----------------------|-----------------------------|---|------|------------------------------|--------|--------------------------|-------------|---|-----------------------|----------|----------|
| | | F | Sig. | t | df | Significance One-Sided p | Two-Sided p | Mean Difference | Std. Error Difference | Lower | Upper |
| atencao_patrocinados | Equal variances assumed | .356 | .555 | -9.948 | 32 | <.001 | <.001 | -1.90367 | .19136 | -2.29345 | -1.51705 |
| | Equal variances not assumed | | | -10.041 | 31.121 | <.001 | <.001 | -1.90367 | .18959 | -2.29029 | -1.51705 |

Group Statistics

| | | Grupo de Alta e Baixa Percepção de Fadiga Algoritmica | | Std. Error Mean | |
|---------|------|---|--------|-----------------|--------|
| | | N | Mean | Std. Deviation | |
| atencao | 1.00 | 15 | 4.0778 | .55943 | .14444 |
| | 2.00 | 19 | 1.9561 | .51772 | .11877 |

Independent Samples Effect Sizes

| | | Standardizer ^a | Point Estimate | 95% Confidence Interval | |
|---------|--------------------|---------------------------|----------------|-------------------------|-------|
| | | | | Lower | Upper |
| atencao | Cohen's d | .53637 | 3.956 | 2.766 | 5.123 |
| | Hedges' correction | .54936 | 3.862 | 2.701 | 5.002 |
| | Glass's delta | .51772 | 4.098 | 2.596 | 5.576 |

a. The denominator used in estimating the effect sizes. Cohen's d uses the pooled standard deviation. Hedges' correction uses the pooled standard deviation, plus a correction factor. Glass's delta uses the sample standard deviation of the control (i.e., the second) group.

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | 95% Confidence Interval of the Difference | | | |
|---------|-----------------------------|---|------|------------------------------|--------|--------------------------|-------------|---|-----------------------|---------|---------|
| | | F | Sig. | t | df | Significance One-Sided p | Two-Sided p | Mean Difference | Std. Error Difference | Lower | Upper |
| atencao | Equal variances assumed | .229 | .636 | 11.452 | 32 | <.001 | <.001 | 2.12164 | .18526 | 1.74428 | 2.49900 |
| | Equal variances not assumed | | | 11.345 | 29.015 | <.001 | <.001 | 2.12164 | .18701 | 1.73918 | 2.50410 |

Group Statistics

| | | Grupo de Alta e Baixa Percepção de Fadiga Algoritmica | | Std. Error Mean | |
|-----------|------|---|--------|-----------------|--------|
| | | N | Mean | Std. Deviation | |
| atencaoap | 1.00 | 15 | 3.8606 | .52994 | .13683 |
| | 2.00 | 19 | 1.9569 | .57205 | .13124 |

Independent Samples Effect Sizes

| | | Standardizer ^a | Point Estimate | 95% Confidence Interval | |
|-----------|--------------------|---------------------------|----------------|-------------------------|-------|
| | | | | Lower | Upper |
| atencaoap | Cohen's d | .55402 | 3.436 | 2.348 | 4.502 |
| | Hedges' correction | .56744 | 3.355 | 2.292 | 4.396 |
| | Glass's delta | .57205 | 3.328 | 2.041 | 4.587 |

a. The denominator used in estimating the effect sizes. Cohen's d uses the pooled standard deviation. Hedges' correction uses the pooled standard deviation, plus a correction factor. Glass's delta uses the sample standard deviation of the control (i.e., the second) group.

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | 95% Confidence Interval of the Difference | | | |
|-----------|-----------------------------|---|------|------------------------------|--------|--------------------------|-------------|---|-----------------------|---------|---------|
| | | F | Sig. | t | df | Significance One-Sided p | Two-Sided p | Mean Difference | Std. Error Difference | Lower | Upper |
| atencaoap | Equal variances assumed | .356 | .555 | 9.948 | 32 | <.001 | <.001 | 1.90367 | .19136 | 1.51389 | 2.29345 |
| | Equal variances not assumed | | | 10.041 | 31.121 | <.001 | <.001 | 1.90367 | .18959 | 1.51705 | 2.29029 |

Group Statistics

| Grupo de Percepção de Filter Bubbles | | N | Mean | Std. Deviation | Std. Error Mean |
|--------------------------------------|------|----|--------|----------------|-----------------|
| atencao | 1.00 | 15 | 4.0778 | .55943 | .14444 |
| | 2.00 | 19 | 1.9561 | .51772 | .11877 |

Independent Samples Effect Sizes

| | Standardizer ^a | Point Estimate | 95% Confidence Interval | |
|---------|---------------------------|----------------|-------------------------|-------|
| | | | Lower | Upper |
| atencao | Cohen's d | .51637 | 3.956 | 5.123 |
| | Hedges' correction | .54916 | 3.862 | 5.002 |
| | Glass's delta | .51772 | 4.098 | 5.576 |

a. The denominator used in estimating the effect sizes. Cohen's d uses the pooled standard deviation. Hedges' correction uses the pooled standard deviation, plus a correction factor. Glass's delta uses the sample standard deviation of the control (i.e., the second) group.

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | 95% Confidence Interval of the Difference | | | |
|---------|-----------------------------|---|------|------------------------------|--------|--------------------------|-------------|---|-----------------------|---------|---------|
| | | F | Sig. | t | df | Significance One-Sided p | Two-Sided p | Mean Difference | Std. Error Difference | Lower | Upper |
| atencao | Equal variances assumed | .229 | .636 | 11.452 | 32 | <.001 | <.001 | 2.12164 | .18526 | 1.74428 | 2.49900 |
| | Equal variances not assumed | | | 11.345 | 29.015 | <.001 | <.001 | 2.12164 | .18701 | 1.73918 | 2.50410 |

Group Statistics

| Grupo de Percepção de Filter Bubbles | | N | Mean | Std. Deviation | Std. Error Mean |
|--------------------------------------|------|----|--------|----------------|-----------------|
| atencao_patrocinados | 1.00 | 15 | 3.8606 | .52994 | .13683 |
| | 2.00 | 19 | 1.9569 | .57205 | .13124 |

Independent Samples Effect Sizes

| | Standardizer ^a | Point Estimate | 95% Confidence Interval | |
|----------------------|---------------------------|----------------|-------------------------|-------|
| | | | Lower | Upper |
| atencao_patrocinados | Cohen's d | .55402 | 3.436 | 4.502 |
| | Hedges' correction | .56744 | 3.355 | 4.396 |
| | Glass's delta | .57205 | 3.328 | 4.587 |

a. The denominator used in estimating the effect sizes. Cohen's d uses the pooled standard deviation. Hedges' correction uses the pooled standard deviation, plus a correction factor. Glass's delta uses the sample standard deviation of the control (i.e., the second) group.

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | 95% Confidence Interval of the Difference | | | |
|----------------------|-----------------------------|---|------|------------------------------|--------|--------------------------|-------------|---|-----------------------|---------|---------|
| | | F | Sig. | t | df | Significance One-Sided p | Two-Sided p | Mean Difference | Std. Error Difference | Lower | Upper |
| atencao_patrocinados | Equal variances assumed | .356 | .555 | 9.948 | 32 | <.001 | <.001 | 1.90367 | .19136 | 1.51389 | 2.29345 |
| | Equal variances not assumed | | | 10.041 | 31.121 | <.001 | <.001 | 1.90367 | .18959 | 1.51705 | 2.29029 |

Descriptive Statistics

| GRUPO | | Mean | Std. Deviation | N |
|-------|--------------------|--------|----------------|----|
| 1 | fadiga_algoritmica | 4.0468 | .26272 | 19 |
| | filter_bubbles | 4.4737 | .17309 | 19 |
| 2 | fadiga_algoritmica | 2.2519 | .54021 | 15 |
| | filter_bubbles | 1.9630 | .23256 | 15 |

Variables Entered/Removed^a

| GRUPO | Model | Variables Entered | Variables Removed | Method |
|-------|-------|-----------------------------|-------------------|--------|
| 1 | 1 | filter_bubbles ^b | | Enter |
| 2 | 1 | filter_bubbles ^b | | Enter |

- a. Dependent Variable: fadiga_algoritmica
b. All requested variables entered.

Correlations

| GRUPO | | fadiga_algoritmica | | filter_bubbles |
|-------|---------------------|---------------------|-----------------|----------------|
| | | Pearson Correlation | Sig. (1-tailed) | |
| 1 | Pearson Correlation | fadiga_algoritmica | 1.000 | .149 |
| | | filter_bubbles | .149 | 1.000 |
| | Sig. (1-tailed) | fadiga_algoritmica | . | .271 |
| | | filter_bubbles | .271 | . |
| N | fadiga_algoritmica | 19 | 19 | |
| | filter_bubbles | 19 | 19 | |
| 2 | Pearson Correlation | fadiga_algoritmica | 1.000 | .030 |
| | | filter_bubbles | .030 | 1.000 |
| | Sig. (1-tailed) | fadiga_algoritmica | . | .457 |
| | | filter_bubbles | .457 | . |
| N | fadiga_algoritmica | 15 | 15 | |
| | filter_bubbles | 15 | 15 | |

Model Summary

| GRUPO | Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|-------|-------------------|----------|-------------------|----------------------------|
| 1 | 1 | .149 ^a | .022 | -.035 | .26731 |
| 2 | 1 | .030 ^a | .001 | -.076 | .56034 |

- a. Predictors: (Constant), filter_bubbles

ANOVA^a

| GRUPO | Model | Sum of Squares | df | Mean Square | F | Sig. | |
|-------|-------|----------------|-------|-------------|------|------|-------------------|
| 1 | 1 | Regression | .028 | 1 | .028 | .387 | .542 ^b |
| | | Residual | 1.215 | 17 | .071 | | |
| | | Total | 1.242 | 18 | | | |
| 2 | 1 | Regression | .004 | 1 | .004 | .012 | .914 ^b |
| | | Residual | 4.082 | 13 | .314 | | |
| | | Total | 4.086 | 14 | | | |

- a. Dependent Variable: fadiga_algoritmica
b. Predictors: (Constant), filter_bubbles

Coefficients^a

| GRUPO | Model | | Unstandardized Coefficients | | Standardized Coefficients | | t | Sig. | 95.0% Confidence Interval for B | |
|-------|-------|----------------|-----------------------------|------------|---------------------------|------|-------|------|---------------------------------|-------------|
| | | | B | Std. Error | Beta | t | | | Sig. | Lower Bound |
| 1 | 1 | (Constant) | 3.033 | 1.630 | | | 1.862 | .080 | -.405 | 6.471 |
| | | filter_bubbles | .227 | .364 | .149 | .622 | .542 | | -.541 | .994 |
| | | (Constant) | 2.113 | 1.272 | | | 1.661 | .121 | -.635 | 4.862 |
| 2 | 1 | filter_bubbles | .071 | .644 | .030 | .110 | .914 | | -1.321 | 1.462 |

- a. Dependent Variable: fadiga_algoritmica

Descriptive Statistics

| GRUPO | | Mean | Std. Deviation | N |
|-------|----------------|--------|----------------|----|
| 1 | atenção | 1.9561 | .51772 | 19 |
| | filter_bubbles | 4.4737 | .17309 | 19 |
| 2 | atenção | 4.0778 | .55943 | 15 |
| | filter_bubbles | 1.9630 | .23256 | 15 |

Variables Entered/Removed^a

| GRUPO | Model | Variables Entered | Variables Removed | Method |
|-------|-------|-----------------------------|-------------------|--------|
| 1 | 1 | filter_bubbles ^b | . | Enter |
| 2 | 1 | filter_bubbles ^b | . | Enter |

- a. Dependent Variable: atenção
b. All requested variables entered.

Model Summary

| GRUPO | Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|-------|-------------------|----------|-------------------|----------------------------|
| 1 | 1 | .146 ^a | .021 | -.036 | .52705 |
| 2 | 1 | .369 ^a | .136 | .070 | .53949 |

- a. Predictors: (Constant), filter_bubbles

ANOVA^a

| GRUPO | Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|-------|------------|----------------|----|-------------|-------|-------------------|
| 1 | 1 | Regression | .102 | 1 | .102 | .368 | .552 ^b |
| | | Residual | 4.722 | 17 | .278 | | |
| | | Total | 4.825 | 18 | | | |
| 2 | 1 | Regression | .598 | 1 | .598 | 2.054 | .175 ^b |
| | | Residual | 3.784 | 13 | .291 | | |
| | | Total | 4.381 | 14 | | | |

- a. Dependent Variable: atenção
b. Predictors: (Constant), filter_bubbles

Descriptive Statistics

| GRUPO | | Mean | Std. Deviation | N |
|-------|----------------------|--------|----------------|----|
| 1 | atenção_patrocinados | 1.9569 | .57205 | 19 |
| | filter_bubbles | 4.4737 | .17309 | 19 |
| 2 | atenção_patrocinados | 3.8606 | .52994 | 15 |
| | filter_bubbles | 1.9630 | .23256 | 15 |

Variables Entered/Removed^a

| GRUPO | Model | Variables Entered | Variables Removed | Method |
|-------|-------|-----------------------------|-------------------|--------|
| 1 | 1 | filter_bubbles ^b | . | Enter |
| 2 | 1 | filter_bubbles ^b | . | Enter |

- a. Dependent Variable: atenção_patrocinados
b. All requested variables entered.

ANOVA^a

| GRUPO | Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|-------|------------|----------------|----|-------------|-------|-------------------|
| 1 | 1 | Regression | .607 | 1 | .607 | 1.952 | .180 ^b |
| | | Residual | 5.284 | 17 | .311 | | |
| | | Total | 5.890 | 18 | | | |
| 2 | 1 | Regression | .388 | 1 | .388 | 1.424 | .254 ^b |
| | | Residual | 3.544 | 13 | .273 | | |
| | | Total | 3.932 | 14 | | | |

- a. Dependent Variable: atenção_patrocinados
b. Predictors: (Constant), filter_bubbles

Correlations

| GRUPO | | atenção | filter_bubbles |
|-------|---------------------|----------------|----------------|
| 1 | Pearson Correlation | atenção | 1.000 |
| | | filter_bubbles | -.146 |
| | Sig. (1-tailed) | atenção | .276 |
| N | | atenção | 19 |
| | | filter_bubbles | 19 |
| | | atenção | .088 |
| 2 | Pearson Correlation | atenção | 1.000 |
| | | filter_bubbles | .369 |
| | Sig. (1-tailed) | atenção | .088 |
| N | | atenção | 15 |
| | | filter_bubbles | 15 |
| | | atenção | .088 |

Coefficients^a

| GRUPO | Model | Unstandardized Coefficients | | Standardized Coefficients | | t | Sig. | 95.0% Confidence Interval for B | |
|-------|-------|-----------------------------|------------|---------------------------|-------------|-------|-------|---------------------------------|--------|
| | | B | Std. Error | Beta | Lower Bound | | | Upper Bound | |
| 1 | 1 | (Constant) | 5.905 | 5.213 | | 1.215 | .241 | -2.874 | 10.683 |
| | | filter_bubbles | -.436 | .718 | -.146 | -.607 | .552 | -1.950 | 1.079 |
| | | | 2.334 | 1.225 | | 1.905 | .079 | -.313 | 4.980 |
| 2 | 1 | (Constant) | .889 | 6.021 | | .369 | 1.433 | -.175 | 4.511 |
| | | | | | | | | | |
| | | | | | | | | | |

- a. Dependent Variable: atenção

Correlations

| GRUPO | | atenção_patrocinados | filter_bubbles |
|-------|---------------------|----------------------|----------------|
| 1 | Pearson Correlation | atenção_patrocinados | 1.000 |
| | | filter_bubbles | -.321 |
| | Sig. (1-tailed) | atenção_patrocinados | .090 |
| N | | atenção_patrocinados | 19 |
| | | filter_bubbles | 19 |
| | | atenção_patrocinados | .127 |
| 2 | Pearson Correlation | atenção_patrocinados | 1.000 |
| | | filter_bubbles | -.314 |
| | Sig. (1-tailed) | atenção_patrocinados | .127 |
| N | | atenção_patrocinados | 15 |
| | | filter_bubbles | 15 |
| | | atenção_patrocinados | .127 |

Model Summary

| GRUPO | Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|-------|-------------------|----------|-------------------|----------------------------|
| 1 | 1 | .321 ^a | .103 | .050 | .55750 |
| 2 | 1 | .314 ^a | .099 | .029 | .52210 |

- a. Predictors: (Constant), filter_bubbles

Coefficients^a

| GRUPO | Model | Unstandardized Coefficients | | Standardized Coefficients | | t | Sig. | 95.0% Confidence Interval for B | |
|-------|-------|-----------------------------|------------|---------------------------|-------------|--------|-------|---------------------------------|--------|
| | | B | Std. Error | Beta | Lower Bound | | | Upper Bound | |
| 1 | 1 | (Constant) | 8.262 | 9.209 | | 1.071 | .085 | -.688 | 13.872 |
| | | filter_bubbles | -1.081 | .759 | -.321 | -1.597 | .180 | -2.882 | .721 |
| | | | 3.286 | 1.185 | | 4.442 | 1.091 | 2.795 | 7.827 |
| 2 | 1 | (Constant) | -2.216 | 5.008 | | -.314 | 1.181 | -5.544 | 2.112 |
| | | | | | | | | | |
| | | | | | | | | | |

- a. Dependent Variable: atenção_patrocinados

Descriptive Statistics

| GRUPO | | Mean | Std. Deviation | N |
|-------|----------------------|--------|----------------|----|
| 1 | atenção_patrocinados | 1.9569 | .57205 | 19 |
| | fadiga_algoritmica | 4.0468 | .26272 | 19 |
| 2 | atenção_patrocinados | 3.8606 | .52994 | 15 |
| | fadiga_algoritmica | 2.2519 | .54021 | 15 |

Correlations

| GRUPO | | atenção_patrocinados | fadiga_algoritmica |
|-------|---------------------|----------------------|--------------------|
| 1 | Pearson Correlation | atenção_patrocinados | 1.000 |
| | | fadiga_algoritmica | -.019 |
| | Sig. (1-tailed) | atenção_patrocinados | .468 |
| | | fadiga_algoritmica | .468 |
| 2 | Pearson Correlation | atenção_patrocinados | 1.000 |
| | | fadiga_algoritmica | -.045 |
| | Sig. (1-tailed) | atenção_patrocinados | .437 |
| | | fadiga_algoritmica | .437 |
| N | | atenção_patrocinados | 19 |
| | | fadiga_algoritmica | 19 |
| | | atenção_patrocinados | 15 |
| | | fadiga_algoritmica | 15 |

Variables Entered/Removed^a

| GRUPO | Model | Variables Entered | Variables Removed | Method |
|-------|-------|--------------------|-------------------|--------|
| 1 | 1 | fadiga_algoritmica | | Enter |
| 2 | 1 | fadiga_algoritmica | | Enter |

a. Dependent Variable: atenção_patrocinados
b. All requested variables entered.

Model Summary

| GRUPO | Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|-------|-------------------|----------|-------------------|----------------------------|
| 1 | 1 | .019 ^a | .000 | -.058 | .58853 |
| 2 | 1 | .045 ^a | .002 | -.075 | .54938 |

a. Predictors: (Constant), fadiga_algoritmica

Coefficients^a

| GRUPO | Model | | Unstandardized Coefficients | | Standardized Coefficients | | t | Sig. | 95.0% Confidence Interval for B | |
|-------|-------|--------------------|-----------------------------|------------|---------------------------|-------|-------|------|---------------------------------|-------------|
| | | | B | Std. Error | Beta | t | | | Sig. | Lower Bound |
| 1 | 1 | (Constant) | 2.128 | 2.141 | | .994 | .334 | | -2.389 | 6.645 |
| | | fadiga_algoritmica | -.042 | .528 | -.019 | -.080 | .937 | | -1.156 | 1.072 |
| 2 | 1 | (Constant) | 3.960 | .628 | | 6.303 | <.001 | | 2.803 | 5.317 |
| | | fadiga_algoritmica | -.044 | .272 | -.045 | -.163 | .873 | | -.631 | .543 |

a. Dependent Variable: atenção_patrocinados

ANOVA^a

| GRUPO | Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|-------|------------|----------------|----|-------------|------|-------------------|
| 1 | 1 | Regression | .002 | 1 | .002 | .006 | .937 ^b |
| | | Residual | 5.888 | 17 | .346 | | |
| | | Total | 5.890 | 18 | | | |
| 2 | 1 | Regression | .008 | 1 | .008 | .026 | .873 ^b |
| | | Residual | 3.924 | 13 | .302 | | |
| | | Total | 3.932 | 14 | | | |

a. Dependent Variable: atenção_patrocinados
b. Predictors: (Constant), fadiga_algoritmica

Descriptive Statistics

| GRUPO | | Mean | Std. Deviation | N |
|-------|--------------------|--------|----------------|----|
| 1 | atenção | 1.9561 | .51772 | 19 |
| | fadiga_algoritmica | 4.0468 | .26272 | 19 |
| 2 | atenção | 4.0778 | .55943 | 15 |
| | fadiga_algoritmica | 2.2519 | .54021 | 15 |

Variables Entered/Removed^a

| GRUPO | Model | Variables Entered | Variables Removed | Method |
|-------|-------|---------------------------------|-------------------|--------|
| 1 | 1 | fadiga_algoritmica ^a | | Enter |
| 2 | 1 | fadiga_algoritmica ^a | | Enter |

a. Dependent Variable: atenção
b. All requested variables entered.

Model Summary

| GRUPO | Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|-------|-------------------|----------|-------------------|----------------------------|
| 1 | 1 | .476 ^a | .226 | .181 | .46858 |
| 2 | 1 | .555 ^a | .308 | .255 | .48282 |

a. Predictors: (Constant), fadiga_algoritmica

ANOVA^a

| GRUPO | Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|-------|------------|----------------|----|-------------|-------|-------------------|
| 1 | 1 | Regression | 1.092 | 1 | 1.092 | 4.973 | .040 ^b |
| | | Residual | 3.733 | 17 | .220 | | |
| | | Total | 4.825 | 18 | | | |
| 2 | 1 | Regression | 1.351 | 1 | 1.351 | 5.795 | .032 ^b |
| | | Residual | 3.030 | 13 | .233 | | |
| | | Total | 4.381 | 14 | | | |

a. Dependent Variable: atenção
b. Predictors: (Constant), fadiga_algoritmica

Correlations

| GRUPO | | atenção | fadiga_algoritmica |
|-------|---------------------|--------------------|--------------------|
| 1 | Pearson Correlation | atenção | 1.000 |
| | | fadiga_algoritmica | -.476 |
| | Sig. (1-tailed) | atenção | .020 |
| | | fadiga_algoritmica | .020 |
| 2 | Pearson Correlation | atenção | 1.000 |
| | | fadiga_algoritmica | -.555 |
| | Sig. (1-tailed) | atenção | .016 |
| | | fadiga_algoritmica | .016 |
| N | | atenção | 19 |
| | | fadiga_algoritmica | 19 |
| | | atenção | 15 |
| | | fadiga_algoritmica | 15 |

ANOVA^a

| GRUPO | Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|-------|------------|----------------|----|-------------|------|-------------------|
| 1 | 1 | Regression | .002 | 1 | .002 | .006 | .937 ^b |
| | | Residual | 5.888 | 17 | .346 | | |
| | | Total | 5.890 | 18 | | | |
| 2 | 1 | Regression | .008 | 1 | .008 | .026 | .873 ^b |
| | | Residual | 3.924 | 13 | .302 | | |
| | | Total | 3.932 | 14 | | | |

a. Dependent Variable: atenção_patrocinados
b. Predictors: (Constant), fadiga_algoritmica

Coefficients^a

| GRUPO | Model | | Unstandardized Coefficients | | Standardized Coefficients | | t | Sig. | 95.0% Confidence Interval for B | |
|-------|-------|--------------------|-----------------------------|------------|---------------------------|--------|-------|------|---------------------------------|-------------|
| | | | B | Std. Error | Beta | t | | | Sig. | Lower Bound |
| 1 | 1 | (Constant) | 5.750 | 1.705 | | 3.373 | .004 | | 2.154 | 9.346 |
| | | fadiga_algoritmica | -.938 | .420 | -.476 | -2.230 | .040 | | -1.824 | -.051 |
| | | atenção | 5.373 | .552 | .930 | 9.730 | <.001 | | 4.180 | 6.566 |
| 2 | 1 | (Constant) | 5.373 | .552 | | 9.730 | <.001 | | 4.180 | 6.566 |
| | | atenção | 5.373 | .552 | .930 | 9.730 | <.001 | | 4.180 | 6.566 |
| | | fadiga_algoritmica | -.575 | .239 | -.555 | -2.407 | .032 | | -1.091 | -.059 |

a. Dependent Variable: atenção

Coefficients^a

| GRUPO | Model | | Unstandardized Coefficients | | Standardized Coefficients | | t | Sig. | 95.0% Confidence Interval for B | |
|-------|-------|--------------------|-----------------------------|------------|---------------------------|-------|-------|------|---------------------------------|-------------|
| | | | B | Std. Error | Beta | t | | | Sig. | Lower Bound |
| 1 | 1 | (Constant) | 2.128 | 2.141 | | .994 | .334 | | -2.389 | 6.645 |
| | | fadiga_algoritmica | -.042 | .528 | -.019 | -.080 | .937 | | -1.156 | 1.072 |
| 2 | 1 | (Constant) | 3.960 | .628 | | 6.303 | <.001 | | 2.803 | 5.317 |
| | | fadiga_algoritmica | -.044 | .272 | -.045 | -.163 | .873 | | -.631 | .543 |

a. Dependent Variable: atenção_patrocinados

Correlations

| GRUPO | | atenção_patrocinados | fadiga_algoritmica |
|-------|---------------------|----------------------|--------------------|
| 1 | Pearson Correlation | atenção_patrocinados | 1.000 |
| | | fadiga_algoritmica | -.019 |
| | Sig. (1-tailed) | atenção_patrocinados | .468 |
| | | fadiga_algoritmica | .468 |
| 2 | Pearson Correlation | atenção_patrocinados | 1.000 |
| | | fadiga_algoritmica | -.045 |
| | Sig. (1-tailed) | atenção_patrocinados | .437 |
| | | fadiga_algoritmica | .437 |
| N | | atenção_patrocinados | 19 |
| | | fadiga_algoritmica | 19 |
| | | atenção_patrocinados | 15 |
| | | fadiga_algoritmica | 15 |

Descriptive Statistics

| GRUPO | | Mean | Std. Deviation | N |
|-------|----------------------|--------|----------------|----|
| 1 | atenção_patrocinados | 1.9569 | .57205 | 19 |
| | fadiga_algoritmica | 4.0468 | .26272 | 19 |
| 2 | atenção_patrocinados | 3.8606 | .52994 | 15 |
| | fadiga_algoritmica | 2.2519 | .54021 | 15 |

Variables Entered/Removed^a

| Model | Variables Entered | Variables Removed | Method |
|-------|----------------------|-------------------|--------|
| 1 | intalgo ^b | | Enter |

a. Dependent Variable: atencao
b. All requested variables entered.

Model Summary

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|-------------------|----------|-------------------|----------------------------|
| 1 | .897 ^a | .804 | .798 | .53637 |

a. Predictors: (Constant), intalgo

ANOVA^a

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|------------|----------------|----|-------------|---------|--------------------|
| 1 | Regression | 37.732 | 1 | 37.732 | 131.155 | <.001 ^b |
| | Residual | 9.206 | 32 | .288 | | |
| Total | | 46.938 | 33 | | | |

a. Dependent Variable: atencao
b. Predictors: (Constant), intalgo

Coefficients^a

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. |
|-------|------------|-----------------------------|------------|---------------------------|---------|-------|
| | | B | Std. Error | | | |
| 1 | (Constant) | 4.078 | .138 | | 29.445 | <.001 |
| | intalgo | -2.122 | .185 | -.897 | -11.452 | <.001 |

a. Dependent Variable: atencao

Variables Entered/Removed^a

| Model | Variables Entered | Variables Removed | Method |
|-------|----------------------|-------------------|--------|
| 1 | intalgo ^b | | Enter |

a. Dependent Variable: atencao
b. All requested variables entered.

Model Summary

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|-------------------|----------|-------------------|----------------------------|
| 1 | .869 ^a | .756 | .748 | .55402 |

a. Predictors: (Constant), intalgo

ANOVA^a

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|------------|----------------|----|-------------|--------|--------------------|
| 1 | Regression | 30.377 | 1 | 30.377 | 98.968 | <.001 ^b |
| | Residual | 9.822 | 32 | .307 | | |
| Total | | 40.199 | 33 | | | |

a. Dependent Variable: atencao
b. Predictors: (Constant), intalgo

Coefficients^a

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. |
|-------|------------|-----------------------------|------------|---------------------------|--------|-------|
| | | B | Std. Error | | | |
| 1 | (Constant) | 3.861 | .143 | | 26.988 | <.001 |
| | intalgo | -1.904 | .191 | -.869 | -9.948 | <.001 |

a. Dependent Variable: atencao

Variables Entered/Removed^a

| Model | Variables Entered | Variables Removed | Method |
|-------|----------------------|-------------------|--------|
| 1 | intalgo ^b | | Enter |

a. Dependent Variable: filterb
b. All requested variables entered.

Model Summary

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|-------------------|----------|-------------------|----------------------------|
| 1 | .988 ^a | .976 | .975 | .20129 |

a. Predictors: (Constant), intalgo

ANOVA^a

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|------------|----------------|----|-------------|----------|--------------------|
| 1 | Regression | 52.840 | 1 | 52.840 | 1304.176 | <.001 ^b |
| | Residual | 1.297 | 32 | .041 | | |
| Total | | 54.137 | 33 | | | |

a. Dependent Variable: filterb
b. Predictors: (Constant), intalgo

Coefficients^a

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. |
|-------|------------|-----------------------------|------------|---------------------------|--------|-------|
| | | B | Std. Error | | | |
| 1 | (Constant) | 1.963 | .052 | | 37.770 | <.001 |
| | intalgo | 2.511 | .070 | .988 | 36.113 | <.001 |

a. Dependent Variable: filterb

Variables Entered/Removed^a

| Model | Variables Entered | Variables Removed | Method |
|-------|----------------------|-------------------|--------|
| 1 | intalgo ^b | | Enter |

a. Dependent Variable: fadiga
b. All requested variables entered.

Model Summary

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|-------------------|----------|-------------------|----------------------------|
| 1 | .914 ^a | .835 | .830 | .40804 |

a. Predictors: (Constant), intalgo

ANOVA^a

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|------------|----------------|----|-------------|---------|--------------------|
| 1 | Regression | 27.006 | 1 | 27.006 | 162.200 | <.001 ^b |
| | Residual | 5.328 | 32 | .166 | | |
| Total | | 32.334 | 33 | | | |

a. Dependent Variable: fadiga
b. Predictors: (Constant), intalgo

Coefficients^a

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. |
|-------|------------|-----------------------------|------------|---------------------------|--------|-------|
| | | B | Std. Error | | | |
| 1 | (Constant) | 2.252 | .105 | | 21.374 | <.001 |
| | intalgo | 1.795 | .141 | .914 | 12.735 | <.001 |

a. Dependent Variable: fadiga

Run MTEC procedure: MTEC Procedure for SPSS Version 4.3

Written by Andrew F. Hayes, Ph.D. www.afhayes.com
Documentation available at Hayes (2002), www.afhayes.com/SPSS43

Model Summary

| Model | R | R Square | Adjusted R Square | F | df1 | df2 | Sig. |
|-------|------|----------|-------------------|---------|-----|-----|-------|
| 1 | .914 | .835 | .830 | 162.200 | 1 | 32 | <.001 |

ANOVA

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|------------|----------------|----|-------------|---------|-------|
| 1 | Regression | 27.006 | 1 | 27.006 | 162.200 | <.001 |
| | Residual | 5.328 | 32 | .166 | | |
| Total | | 32.334 | 33 | | | |

Coefficients

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. |
|-------|------------|-----------------------------|------------|---------------------------|--------|-------|
| | | B | Std. Error | | | |
| 1 | (Constant) | 2.252 | .105 | | 21.374 | <.001 |
| | intalgo | 1.795 | .141 | .914 | 12.735 | <.001 |

Model Summary

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|------|----------|-------------------|----------------------------|
| 1 | .914 | .835 | .830 | .40804 |

ANOVA

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|------------|----------------|----|-------------|---------|-------|
| 1 | Regression | 27.006 | 1 | 27.006 | 162.200 | <.001 |
| | Residual | 5.328 | 32 | .166 | | |
| Total | | 32.334 | 33 | | | |

Coefficients

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. |
|-------|------------|-----------------------------|------------|---------------------------|--------|-------|
| | | B | Std. Error | | | |
| 1 | (Constant) | 2.252 | .105 | | 21.374 | <.001 |
| | intalgo | 1.795 | .141 | .914 | 12.735 | <.001 |

Model Summary

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate |
|-------|------|----------|-------------------|----------------------------|
| 1 | .914 | .835 | .830 | .40804 |

ANOVA

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|------------|----------------|----|-------------|---------|-------|
| 1 | Regression | 27.006 | 1 | 27.006 | 162.200 | <.001 |
| | Residual | 5.328 | 32 | .166 | | |
| Total | | 32.334 | 33 | | | |

Coefficients

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. |
|-------|------------|-----------------------------|------------|---------------------------|--------|-------|
| | | B | Std. Error | | | |
| 1 | (Constant) | 2.252 | .105 | | 21.374 | <.001 |
| | intalgo | 1.795 | .141 | .914 | 12.735 | <.001 |