

MESTRADO
MESTRADO EM MARKETING

TRABALHO FINAL DE MESTRADO
DISSERTAÇÃO

**IMAGENS DE ROUPA EM SEGUNDA-MÃO GERADAS POR
IA EM P2P: REALISMO, DECEÇÃO, DESCONFIANÇA E
EWOM NEGATIVO**

ANA RITA GAIMOTA FÉLIX

JUNHO - 2026

MESTRADO EM MESTRADO EM MARKETING

TRABALHO FINAL DE MESTRADO DISSERTAÇÃO

**IMAGENS DE ROUPA EM SEGUNDA-MÃO GERADAS
POR IA EM P2P: REALISMO, DECEÇÃO,
DESCONFIANÇA E EWOM NEGATIVO**

ANA RITA GAIMOTA FÉLIX

ORIENTAÇÃO:

**PROFESSORA DOUTORA SUSANA CATARINA DE JESUS
FERNANDES DOS SANTOS**

JÚRI:

PRESIDENTE: PROF. DRA. HELENA DO CARMO MILAGRE
MARTINS GONÇALVES

VOGAL: PROF. DR. RICARDO MARINO FRANCISCO
RODRIGUES

ORIENTADOR: PROF. DRA. SUSANA CATARINA DE JESUS
FERNANDES DOS SANTOS

JUNHO - 2026

AGRADECIMENTOS

Em primeiro lugar, agradeço todo o apoio e disponibilidade da professora Susana Santos, que demonstrou tanta preocupação e profissionalismo na sua orientação não só desta dissertação como das restantes orientandas. Sem dúvida, este trabalho só foi possível com o seu apoio. Muito obrigada, professora!

Aos meus pais, obrigada por me apoiarem em todos os meus altos e baixos, por se sacrificarem por mim e por acreditarem sempre que sou capaz. Ao meu irmão, obrigada por me fazeres rir todos os dias e pela tua paciência infinita. Aos meus gatinhos, obrigada pela companhia incansável.

Ao meu namorado Hugo, obrigada por todo o apoio e amor que me dás, e por me fazeres tão feliz. Tu és a minha inspiração em tudo o que faço e é contigo que quero partilhar todas as minhas vitórias.

Às minhas amigas, Ana, Inês e Oxana, obrigada por me acompanharem nos últimos 11 anos e por me fazerem sentir como uma adolescente feliz sempre que estou convosco. À minha amiga Beatriz, obrigada por ouvires todas as minhas queixas e por seres o melhor que um outro curso tinha para dar. Aos meus amigos da licenciatura, um enorme abraço e obrigada por todas as vossas palavras de encorajamento e garra à última do grupo a acabar o mestrado.

Uma longa viagem de 20 anos de estudo começou num dia de setembro em 2006 com uma mochila cor-de-rosa das Winx e culmina neste documento. Obrigada a todos os que fizeram parte dela.

RESUMO

A propagação da inteligência artificial (IA) generativa em contextos de *e-commerce* tem facilitado o uso de imagens sintéticas em plataformas *peer-to-peer* de compra e venda de roupas em segunda-mão (P2P-SM), levantando preocupações quanto a práticas potencialmente enganadoras. O presente estudo investiga o efeito do realismo percebido de imagens de roupas geradas por IA na decepção percebida, na desconfiança no vendedor e na plataforma P2P-SM, e na intenção de *electronic word-of-mouth* (eWOM) negativo, analisando ainda três variáveis moderadoras: literacia de IA, propensão para desconfiar e responsabilidade percebida da plataforma (RPP). O modelo conceptual assenta no modelo *Stimulus-Organism-Response* (SOR) e numa adaptação da Teoria da Transferência de Confiança ao construto da desconfiança. Os dados foram recolhidos através de um questionário *online* com estímulo visual de anúncios da Vinted com imagens geradas por IA, obtendo-se 338 respostas válidas de utilizadores de P2P-SM. As variáveis foram medidas com escalas de Likert de 7 pontos adaptadas e os dados analisados com SPSS e SmartPLS 4 via PLS-SEM. Os resultados confirmam que o baixo realismo percebido aumenta a decepção percebida, o que eleva a desconfiança no vendedor e na plataforma. Verifica-se uma transferência de desconfiança do vendedor para a plataforma, sendo que apenas a desconfiança na plataforma influencia diretamente a intenção de eWOM negativo. Das três variáveis moderadoras, apenas a RPP se revelou significativa, amplificando o efeito de transferência de desconfiança. Numa análise adicional, observa-se ainda uma mediação em cadeia entre as variáveis do modelo, sugerindo um processo psicológico que começa no baixo realismo percebido e termina na intenção de eWOM negativo. Este estudo contribui para a literatura ao colmatar uma lacuna explorando um fenómeno emergente nas P2P-SM, considerando o construto da desconfiança e alertando as plataformas para a necessidade de regulação e transparência face ao conteúdo gerado por IA.

Palavras-chave: Inteligência Artificial Generativa; Plataformas *Peer-to-Peer*; Roupas em Segunda-Mão; Desconfiança; eWOM Negativo.

ABSTRACT

The proliferation of generative artificial intelligence (AI) in e-commerce contexts has facilitated the use of synthetic images on peer-to-peer second-hand clothing platforms (P2P-SM), raising concerns about potentially deceptive practices. This study investigates the effect of the perceived realism of AI-generated clothing images on perceived deception, distrust in the seller and the P2P-SM platform, and negative electronic word-of-mouth (eWOM) intention, while also examining three moderating variables: AI literacy, propensity to distrust, and perceived platform responsibility (PPR). The conceptual model is grounded in the Stimulus-Organism-Response (SOR) model and an adaptation of the Trust Transfer Theory to the distrust construct. Data were collected through an online questionnaire with a visual stimulus comprising Vinted listings featuring AI-generated images, yielding 338 valid responses from P2P-SM users. Variables were measured using 7-point Likert scales and data were analysed with SPSS and SmartPLS 4 via PLS-SEM. The results confirm that low perceived realism increases perceived deception, which in turn heightens distrust in both the seller and the platform. A distrust transfer effect from the seller to the platform is observed, with only platform distrust directly influencing negative eWOM intention. Of the three moderating variables, only PPR proved significant, amplifying the distrust transfer effect. In an additional analysis, a chain mediation effect is also found across the model's variables, suggesting a psychological process that begins with low perceived realism and culminates in negative eWOM intention. This study contributes to the literature by addressing a gap through the exploration of an emerging phenomenon in P2P-SM platforms, considering the distrust construct, and alerting platforms to the need for regulation and transparency regarding AI-generated content.

Keywords: Generative Artificial Intelligence; Peer-to-Peer Platforms; Second-Hand Clothing; Distrust; Negative eWOM.

DECLARAÇÃO

Durante a realização deste trabalho, a autora utilizou as ferramentas de inteligência artificial Claude e ChatGPT com o propósito de auxílio à análise dos dados recolhidos e uniformização das imagens utilizadas no questionário, respetivamente. Após o uso destas ferramentas, a autora reviu e editou o conteúdo conforme necessário e assume total responsabilidade pelo conteúdo do trabalho.

LISTA DE ABREVIATURAS E SIGLAS

B2C	<i>Business-to-consumer</i>
C2C	<i>Consumer-to-consumer</i>
<i>e-WOM</i>	<i>Electronic word-of-mouth</i>
IA	Inteligência Artificial
P2P	<i>Peer-to-peer</i>
P2P-SM	Plataformas <i>peer-to-peer</i> de compra e venda de roupa em segunda-mão
RPP	Responsabilidade percebida da plataforma
SM	Segunda-mão
SOR	<i>Stimulus-Organism-Response</i>
TTT	<i>Theory of trust transfer</i>
UE	União Europeia

ÍNDICE

AGRADECIMENTOS	III
RESUMO.....	IV
ABSTRACT	V
DECLARAÇÃO	VI
LISTA DE ABREVIATURAS E SIGLAS	VII
1. INTRODUÇÃO	1
1.1 Contextualização teórica.....	1
1.2. Objetivos de investigação	2
1.3. Relevância académica.....	3
1.4. Relevância prática.....	3
1.5. Estrutura da dissertação	4
2. REVISÃO DE LITERATURA	4
2.1. Inteligência artificial generativa	4
2.2. Inteligência artificial na indústria da moda	5
2.3. Plataformas <i>online</i> de venda de roupa em segunda-mão.....	6
2.4. Plataformas P2P e imagens de roupa em <i>e-commerce</i>	7
2.5. Modelo SOR.....	8
2.6. Imagens de roupa geradas por IA nas plataformas P2P.....	9
2.7. Decepção percebida.....	10
2.8. Desconfiança no vendedor e na plataforma P2P-SM	11
2.9. Transferência de desconfiança.....	13
2.10. Intenção de eWOM negativo.....	14
2.11. Variáveis moderadoras	15
2.11.1. Literacia de IA como variável moderadora	15
2.11.2. Propensão para desconfiar como variável moderadora	16
2.11.3. Responsabilidade percebida da plataforma	17
3. MODELO CONCEPTUAL	18
4. METODOLOGIA.....	18
4.1. Tipo de estudo.....	18
4.2. População e amostragem	19
4.3. Recolha de dados	19

4.4. Questionário	20
4.5. Escalas de medida.....	21
4.6. Tratamento e análise preliminar dos dados	21
5. ANÁLISE DE RESULTADOS.....	22
5.1. Caracterização da amostra	22
5.2. Análise de Componentes Principais e Fiabilidade.....	23
5.3. Análise do Modelo de Medida.....	25
5.4. Análise do Modelo Estrutural	26
6. DISCUSSÃO DE RESULTADOS E CONCLUSÃO	29
6.1. Discussão de Resultados.....	29
6.2. Conclusão	31
6.3. Contributos Académicos.....	32
6.4. Contributos Práticos	32
6.5. Limitações e Sugestões de Pesquisa Futura	33
7. REFERÊNCIAS	35
ANEXOS	45
Anexo A – Inquérito	45
Anexo B – Imagens utilizadas no inquérito.....	50
Anexo C – Escalas do inquérito	51
Anexo D – Amostra de estudo (frequências).....	53
Anexo E – ACP e Análise de Fiabilidade	54
Anexo F – Índices sintéticos.....	55
Anexo G – Critério de Fornell-Larcker	55

ÍNDICE DE TABELAS

Tabela 1: Modelo de Medida	26
Tabela 2: Modelo Estrutural	28

1. INTRODUÇÃO

1.1 Contextualização teórica

As plataformas *peer-to-peer* (P2P) *online* de compra e venda de bens em segunda-mão (SM) – doravante denominadas P2P-SM – têm vindo a crescer devido ao aumento do custo de vida e à tendência de consumo mais sustentável (Butler, 2023). O relatório *Resale Report 2025* da empresa americana de revenda de moda *online* ThredUp revela que o mercado global de segunda-mão (que inclui doações e revenda, i.e., um sortido de peças de roupas e acessórios selecionados e disponíveis primariamente *online*) cresceu 15% em 2024 face ao ano anterior, atingindo um total de 227 mil milhões de dólares americanos em vendas, e prevê que o seu valor aumente a uma taxa de crescimento anual de 10% até ao final da década (ThredUp, 2026). O mercado *online* europeu de moda em segunda-mão apresentou um lucro de 29,7 mil milhões de dólares americanos em 2025, tendo crescido exponencialmente após o início da pandemia (Statista, 2026a).

Numa plataforma P2P-SM, onde são anunciados produtos usados ou semi-novos, é de significativa importância para o consumidor poder avaliar o estado em que estes se encontram, como as peças assentam no corpo e todos os aspetos relevantes à mesma (como cor, corte, textura, tecido, etc.) antes de tomar a decisão de compra (Lou & Copeland, 2025). O fenómeno que se tem observado recentemente nestas plataformas é a utilização de imagens geradas por inteligência artificial (IA) dos artigos – estas destacam-se dos restantes anúncios por serem uniformes entre si em termos de qualidade e composição, com texturas e iluminações mais suavizadas e com uma paleta de tons neutra (Teoh, 2025). Alguns autores argumentam que o uso de conteúdos sintéticos, i.e., gerados por IA, ajudam a melhorar a atratividade dos produtos na sua representação gráfica (Tang & Chen, 2024). No entanto, existe também uma vertente de fraude associada a esta prática – os vendedores utilizam estas imagens para anunciar roupas baratas de baixa qualidade compradas em lojas *online* de *dropshipping*, como a Shein ou Temu, e ocultam a origem da peça ao utilizar imagens geradas por IA, fazendo-as passar por peças de melhor qualidade, e pedindo por estas um preço mais elevado que o original (CE Noticias Financieras, 2025). Nem todos os casos têm a intenção de enganar o comprador da plataforma P2P-SM, mas torna-se relevante investigar se este percebe esta ação como uma decepção e se isso afeta a sua relação com a plataforma e posteriores respostas.

Segundo o EU Artificial Intelligence Act (European Union, 2025), que vigora sobre a União Europeia (UE) desde 2024, o uso de conteúdo gerado por IA deve ser divulgado através de um rótulo. Sendo esta legislação aplicável a todas as entidades coletivas da UE, as plataformas P2P-SM deveriam aplicar esta norma aos seus utilizadores e ter a responsabilidade ética de controlar o conteúdo carregado nas mesmas para evitar fraudes ou insatisfação por parte dos compradores. No entanto, tendo em conta que, na sua maioria, os vendedores não cumprem a lei europeia nem os termos e condições das plataformas ao submeterem os anúncios com imagens geradas por IA sem divulgação do uso da mesma, o comprador encontra-se numa situação de desvantagem pela informação assimétrica que tem sobre o artigo e por incerteza se está perante uma imagem verdadeira ou falsa (Hanson et al., 2025).

Apesar de já existir alguma literatura sobre o impacto das experiências negativas com vendedores na confiança do consumidor em plataformas P2P (Chen et al., 2009; Grüner et al., 2024), esta incide sobretudo sobre uma visão unidimensional do construto da confiança, resultando na reduzida abordagem ao da desconfiança. Existe assim uma lacuna na investigação sobre imagens geradas por IA, a perceção de decepção pelo comprador e o seu impacto na relação de desconfiança com o vendedor e a plataforma P2P-SM e as eventuais respostas posteriores.

1.2. Objetivos de investigação

Com base na contextualização teórica anterior, o objetivo geral da presente investigação é compreender o efeito das imagens de roupa em segunda-mão geradas por IA no realismo percebido e o seu efeito na decepção percebida, na desconfiança no vendedor e na desconfiança na plataforma P2P-SM, e consequentemente na intenção *electronic word-of-mouth* (eWOM) negativo. Assim, procura responder-se às seguintes questões de investigação:

Q1: De que forma o realismo percebido de imagens de roupa geradas por IA numa plataforma P2P-SM influencia a decepção percebida e como é que esta posteriormente influencia a desconfiança no vendedor, a desconfiança na plataforma e a intenção de eWOM negativo?

Q2: De que forma a literacia de IA modera a relação entre o realismo percebido das imagens de roupa geradas por IA e a decepção percebida?

Q3: De que forma a propensão para desconfiar modera a relação entre a decepção percebida e a desconfiança no vendedor e a desconfiança na plataforma?

Q4: De que forma a responsabilidade percebida da plataforma (RPP) modera a relação entre a desconfiança no vendedor e a desconfiança na plataforma?

1.3. Relevância acadêmica

A presente investigação pretende colmatar uma lacuna teórica na literatura, uma vez que a investigação atual sobre a aplicação de IA generativa no setor da moda ainda é limitada, abrindo espaço a investigações futuras (Kiper & Liang, 2025). Na ótica da indústria de moda, as investigações sobre IA e IA generativa têm-se centrado no desenvolvimento da tecnologia e da sua aplicação nos diversos ramos, como o *design* de peças de roupa (Shi et al., 2025). Só nos últimos anos, após a democratização da tecnologia ao público-geral (nomeadamente, após 2022 com o lançamento do ChatGPT), a literatura começou a centrar-se mais no consumidor (Kiper & Liang, 2025). No entanto, devido ao rápido desenvolvimento da tecnologia e de todas as condicionantes que esta traz, o estudo da IA aplicada à moda ainda permanece pouco explorado.

O impacto das imagens de roupa geradas por IA no contexto do mercado *consumer-to-consumer* (C2C), nomeadamente em plataformas P2P, ainda não foi alvo de estudo. Devido à rápida expansão e aumento na popularidade do mercado C2C (Zhao, Fang et al., 2020) e também à necessidade de estudo da decepção no *e-commerce* e dos seus constantes desenvolvimentos (Mustak et al., 2023), torna-se fundamental desenvolver estudos que acompanhem os fenómenos apresentados.

1.4. Relevância prática

No contexto prático, a presente investigação pretende fornecer *insights* valiosos à indústria da moda, nomeadamente na ótica do *e-commerce* C2C. O alvo de estudo são as plataformas P2P-SM, que ainda permanecem relativamente pouco estudadas, apesar da sua complexidade. Neste contexto, as relações entre vendedor e comprador têm benefícios e malefícios mútuos, e as interações entre as partes ditam as ações e percepções que os compradores têm das plataformas, afetando diretamente os seus comportamentos. São os utilizadores e as suas relações que garantem o sucesso ou o declínio destas plataformas. As possíveis intenções negativas dos vendedores que adotam tecnologia de IA de forma a enganar os compradores deve ser considerado como um alerta para as plataformas P2P-SM, que vêem este fenómeno a propagar-se pelos seus *websites*.

1.5. Estrutura da dissertação

O presente estudo é composto por seis capítulos. A introdução aborda a contextualização teórica da investigação, expõe os objetivos da mesma e, por fim, a relevância académica e prática do estudo. No capítulo da revisão de literatura, mencionam-se os principais conceitos teóricos e publicações relacionados com o tema em questão. A partir da literatura analisada, apresenta-se o modelo conceptual que é adotado para a realização do estudo. No capítulo da metodologia, são detalhados o tipo de estudo, a amostra, o método da recolha de dados e o processo de tratamento destes. No capítulo seguinte, faz-se a análise dos resultados, que dão resposta às perguntas de investigação estabelecidas. No capítulo final, são discutidos os resultados apresentados, seguidos das conclusões da investigação, limitações e sugestões de pesquisa futura.

2. REVISÃO DE LITERATURA

2.1. Inteligência artificial generativa

O termo *Inteligência artificial* (IA) foi cunhado em 1956, sendo definido como a tecnologia e desenvolvimento de sistemas de computadores capazes de realizar tarefas para as quais é necessária inteligência humana (Huang & Rust, 2021; Saponaro et al., 2018). Esta veio a sofrer transformações e desenvolvimentos nos últimos anos, passando de uma matéria inicialmente puramente conceptual para uma tecnologia com múltiplas aplicações, que se infiltrou nos mais variados campos (Belanche et al., 2025). Dentro da IA, surge a IA generativa, que dá origem a novos conteúdos gerados automaticamente através do uso da tecnologia, podendo tomar a forma de texto, áudio, vídeo ou imagem, e que veio transformar o paradigma da criação de conteúdo no marketing e publicidade (Lou & Copeland, 2025). O uso da tecnologia de IA generativa tem-se tornado mais comum nos últimos anos – após o lançamento do modelo mais popular ChatGPT da OpenAI no final de 2022 –, devido à sua facilidade de uso, eficiência e acessibilidade (Osadchaya et al., 2024).

O uso de IA generativa no contexto de marketing tem as suas vantagens e desvantagens. Ao utilizar estas ferramentas, os *marketeers* conseguem produzir e comunicar maiores quantidades de conteúdo com o público, de forma mais personalizada, eficaz e eficiente (Huh et al., 2023), cortando nos custos de desenvolvimento destas comunicações (Campbell et al., 2022). Este tipo de conteúdo pode estimular reações de maior *engagement* por parte dos consumidores (Kshetri et al., 2024). No entanto, pode

também levar a que estes sintam que a comunicação falha na transmissão de autenticidade, refletindo-se negativamente nas ações e atitudes tomadas em relação às marcas que utilizam este tipo de ferramentas na sua estratégia de comunicação (Brüns & Meißner, 2024).

Os consumidores nem sempre conseguem distinguir quando o conteúdo foi gerado por IA ou criado por humanos (Brüns & Meißner, 2024; Dwivedi et al., 2023), sobretudo em casos onde o uso de IA não é devidamente divulgado (Karpinska-Krakiowiak & Eisend, 2025). A decisão de divulgação do conteúdo como sendo gerado por IA (ou *disclosure* de IA) leva a um paradoxo – a transparência que a marca pretende transmitir ao divulgar o uso da tecnologia pode levar a que o consumidor se sinta enganado ao ver que o conteúdo não foi obra humana; no entanto, esconder o uso de IA pode também trazer consequências negativas para a reputação da marca e levantar questões éticas, se tal for descoberto (Zhang & Hur, 2025).

2.2. Inteligência artificial na indústria da moda

O uso de IA na indústria da moda tem vindo a crescer e a importância de estudar a forma como os consumidores percecionam o uso desta tecnologia também (Lou & Copeland, 2025). O desenvolvimento da IA levou a que muitas marcas se adaptassem a esta nova forma de abordar o marketing, utilizando a tecnologia para criar conteúdo realista e que cria *engagement* com o consumidor, proporcionando assim uma melhor experiência para este e garantindo uma maior eficiência para a marca (Wu & Wen, 2021).

A investigação existente que incide sobre a temática da IA aplicada à indústria da moda foca-se no impacto do uso da tecnologia para diferentes funções dos diversos *stakeholders* – para *design* de moda em modelos virtuais 3D e gerar padrões de costura (Shi et al., 2025), para provedores virtuais (*virtual try-on*) (Islam et al., 2024), como assistente algorítmico para a análise de dados (Huang & Rust, 2021) ou para criação de conteúdos em agências de comunicação (Chaisatitkul et al., 2024; Demsar et al., 2025). Nos últimos anos, com o desenvolvimento e maior adoção da tecnologia, a investigação passou a focar-se mais no consumidor final e nas suas perceções relativamente ao uso desta tecnologia no mercado da moda (Liang et al., 2020). Ainda assim, existe uma lacuna na investigação sobre o impacto desta tecnologia no consumidor do mercado C2C, nomeadamente em plataformas de *e-commerce* P2P.

2.3. Plataformas *online* de venda de roupa em segunda-mão

As P2P-SM classificam-se como um tipo de plataforma P2P, onde existe um vendedor e um comprador que são pares (ou iguais, isto é, qualquer indivíduo pode assumir qualquer um dos papéis) e que trocam a propriedade de itens por um valor monetário (Murtas & Pedeliento, 2025). As interações que ocorrem nestas plataformas são definidas de forma mais geral como trocas C2C, i.e., são interações cooperativas entre consumidores fora dos canais e cadeias de valor tradicionais (Plouffe, 2008).

A literatura tende a agrupar os conceitos de plataformas P2P, onde se inserem as plataformas P2P-SM (Perren & Kozinets, 2018), com o conceito de economia de partilha (Styvén & Mariani, 2020). Belk (2007) inicialmente definiu economia de partilha como a alternativa à propriedade privada, onde duas ou mais pessoas podem usufruir dos benefícios (ou custos) associados a possuir um ativo. Huurne et al. (2017) discordam desta definição, por omitir a reciprocidade destas interações e assumir que os bens se tornam propriedade de ambas as partes. Assim, os autores propõem que a economia de partilha é "um modelo económico com base na partilha de ativos subutilizados entre pares sem a transferência de posse, desde espaços, capacidades a objetos, por benefícios monetários ou não, através de uma plataforma *online*" (p. 486). Esta definição, porém, exclui as plataformas P2P-SM como integrantes da economia de partilha, pelo facto de os artigos vendidos passarem a ser propriedade do comprador.

Perren e Kozinets (2018) reconhecem a indecisão geral sobre como classificar plataformas P2P, expondo as disparidades entre definições na literatura. Belk (2014) classifica os *marketplaces* P2P como fazendo parte da economia de partilha, enquanto Arnould e Rose (2016) contrapõem que o termo *umbrella* da partilha é redutor para o tipo de transações económicas que são feitas nestas plataformas. Perren e Kozinets (2018) definem que plataformas P2P se inserem em mercados de trocas laterais, i.e., "mercados formados através de intermediação tecnológica por parte de uma plataforma que facilita as atividades de troca entre uma rede de atores com posições económicas equivalentes" (p. 22), onde pode ou não existir a transferência de posse e excluindo a partilha ou doação de ativos.

Enquanto que, em *marketplaces* tradicionais, o ativo à venda é propriedade da empresa, nos mercados P2P, a empresa (plataforma) é simplesmente um intermediário, assumindo apenas funções de controlo e coordenação (Marth et al., 2022). Dada esta

característica, as interações P2P têm riscos específicos associados para o comprador, nomeadamente o oportunismo do vendedor (a crença que este age apenas em benefício próprio; Jones & Leonard, 2014) ou a informação assimétrica partilhada pelo mesmo (Park & Tussyadiah, 2020).

2.4. Plataformas P2P e imagens de roupa em *e-commerce*

A apresentação do produto no contexto de plataformas de *e-commerce* é a principal forma de comunicação entre o vendedor e o consumidor (Zhang et al., 2025), sendo as imagens do produto o primeiro ponto de contacto (Xia et al., 2020). Elementos visuais são de extrema importância no contexto C2C (Ūsas et al., 2024). Os vendedores *online* têm a desvantagem de o consumidor não poder verificar o aspeto e estado dos produtos como se estivessem numa loja física, dependendo bastante da representação visual para comunicar a qualidade, funcionalidade e desejabilidade do produto, através de imagens, descrições, vídeos ou outros meios não-físicos (Hou & Jansen, 2023; Xia et al., 2020).

No caso dos vendedores de plataformas P2P-SM, a importância do conteúdo visual é ainda mais relevante, tendo em conta a natureza dos bens que estão a anunciar. Os anúncios de produtos em segunda-mão têm de seguir os termos e condições previstos pelas plataformas de venda, onde é indicado que as imagens utilizadas devem ser fotografias próprias que indiquem claramente o estado das peças e eventuais danos, não podendo ser utilizadas imagens com direitos de autor (como imagens de *websites* onde as roupas tenham sido inicialmente compradas; Vinted, 2026).

Slaton (2025) propõe que as plataformas de venda de produtos em segunda-mão se dividem em duas categorias: *company-controlled* (como a ThredUp ou Levi's SecondHand), onde a própria marca salvaguarda a autenticação das peças, seleciona e vende-as, garantindo o controlo dos conteúdos anunciados na plataforma; e as plataformas P2P, ou *seller-controlled* (onde se inserem as P2P-SM, como a Vinted, Wallapop ou OLX), onde qualquer utilizador se pode tornar um vendedor e/ou comprador. Nestas últimas plataformas, é o vendedor que está encarregue de anunciar os seus produtos, que são sujeitos a sistemas de reputação, validação e denúncia pelos compradores (Slaton, 2025). Desta forma, não existe um controlo de todos os anúncios e das imagens utilizadas; o controlo por parte da plataforma é feito apenas quando há uma denúncia por parte de um comprador. Para o mercado P2P funcionar corretamente, devido

à sua natureza comunitária, é necessário que exista confiança interpessoal, provas sociais e eWOM (Ilmalhaq et al., 2024).

2.5. Modelo SOR

O modelo *Stimulus-Organism-Response* (SOR) propõe que um estímulo (S) molda um estado cognitivo e emocional orgânico no indivíduo (O), que resulta em respostas comportamentais (R) (Slaton, 2025). Inicialmente, o *framework* foi utilizado no contexto *offline*, sendo mais tarde aplicado ao contexto *online* para entender como estímulos envolventes afetam o comportamento do consumidor digital (Kaur, 2017). No *e-commerce* C2C, os compradores desistem de comprar se perceberem que o risco associado é muito alto, nomeadamente graças a fraudes ou produtos mal descritos e/ou representados (Zhao, Fang et al., 2020), logo, sendo o realismo das imagens geradas por IA considerado estímulo (Lou & Copeland, 2025), propõe-se que estas possam ter efeito na decepção e desconfiança face ao vendedor e à plataforma e consequentemente nas respostas comportamentais.

Neste estudo, baseado no modelo SOR, o estímulo (S) estudado é o realismo percebido associado à imagem gerada por IA pelos consumidores de plataformas P2P-SM. Os consumidores interagem com as imagens *online* de forma cognitiva, sendo influenciados pelas suas expectativas, intenções e pelo estímulo em si (Lou & Copeland, 2025). Estes não têm acesso ao produto fisicamente, pelo que necessitam de avaliar o mesmo através de imagens para formar impressões iniciais e avaliações sobre a informação observada (Chaudhuri et al., 2026; Zhao, Fang et al., 2020). Uma imagem gerada por IA pode tentar emular uma fotografia real, com elevado detalhe e realismo, mas a tecnologia não permite ainda criar uma cópia totalmente fiel à realidade (Miskolczi, 2026). O organismo (O) do modelo SOR descreve o processo interno acionado pelo estímulo (Lou & Copeland, 2025). Neste estudo, este é representado pela decepção percebida e as percepções de desconfiança face ao vendedor e à plataforma. Por fim, a resposta comportamental (R) é definida pelo resultado do processamento do estímulo, que inclui comportamentos de aproximação e evitação (Slaton, 2025). Na presente investigação, estuda-se o efeito do estímulo nos comportamentos de evitação (intenção de eWOM negativo).

2.6. Imagens de roupa geradas por IA nas plataformas P2P

Para que os anúncios de roupa em plataformas P2P vão de encontro às normas impostas pelas mesmas e incitem respostas de confiança positivas no consumidor (Kazantsev et al., 2023), é necessário que as informações do anúncio, nomeadamente as imagens utilizadas, sejam precisas, i.e., claras, completas e consistentes (Alyahya et al., 2023). Como ponto de primeiro contacto entre o comprador e o anúncio (Xia et al., 2020), as imagens devem refletir exatamente o produto que está a ser anunciado, de modo a evitar que o comprador perceba que está a ser enganado, o que levará a respostas negativas no que toca à confiança (Slaton, 2025). Tratando-se da venda de peças de roupa em segunda-mão, o realismo das imagens utilizadas nos anúncios torna-se ainda mais importante para o comprador, devido à necessidade de informação precisa sobre as condições exatas do artigo, nomeadamente o possível desgaste ou defeito da peça (Murtas & Pedeliento, 2025).

Karpinska-Krakowiak e Eisend (2025) definem realismo percebido como uma avaliação subjetiva do grau de retrato fiel à realidade de uma imagem. Neste mesmo estudo, focado na perceção de verdade associada a *deepfakes*, os autores argumentam que o uso de *disclosure* nas imagens/vídeos não altera a perceção de realismo por parte do consumidor. Hartmann et al. (2025) afirmam que os melhores modelos de IA generativa são capazes de gerar versões sintéticas a partir de fotografias reais com tanto realismo percebido como as imagens originais, e com maior qualidade e apelo estético. Este aspeto é relevante para os vendedores de P2P, que querem destacar os seus anúncios dos demais na página de pesquisa do *website* (Wu et al., 2016). No entanto, mesmo os modelos mais avançados de IA generativa podem dar origem a imagens de roupa com padrões errados, irregulares ou repetitivos, com superfícies de textura aveludada e com proporções e detalhes incorretos (Miskolczi, 2026).

Nem sempre os consumidores são capazes de distinguir que uma imagem de moda foi gerada por IA, sobretudo quando esta não tem um rótulo de *disclosure* (Lou & Copeland, 2025), como é o caso nas plataformas P2P-SM. Nestes casos, apesar de não haver uma indicação da origem da imagem e do consumidor ter dificuldade em identificá-la corretamente, este ainda é capaz de reconhecer que existem elementos visuais que apontam para um menor realismo percebido em imagens geradas por IA comparadas com fotografias (Velásquez-Salamanca et al., 2025). Desta forma, é possível argumentar que

o consumidor, perante imagens geradas por IA em plataformas P2P-SM, pode ter uma percepção de menor realismo.

2.7. Deceção percebida

Miller (1983) define decepção (ou engano) inicialmente como "uma mensagem distorcida como resultado de falsificação ou omissão deliberada de informação por um comunicador com o intuito de estimular num outro, ou outros, uma crença em que o comunicador não acredita" (citado em Aditya (2001); p.738). Román (2010) define decepção percebida como "um ato não-ético perpetuado por vendedores *online* que manipulam a informação ou apresentação do conteúdo do produto com o intuito de induzir mudanças de comportamento no consumidor em seu detrimento" (p.377). Grazioli e Jarvenpaa (2003) aprofundam a temática e definem o termo *relabeling* como uma tática que envolve a descrição por parte de um vendedor das características de um produto de forma questionavelmente favorável, afetando mais frequentemente consumidores individuais. Os autores afirmam que, pelo carácter virtual das interações em *e-commerce*, o *relabeling* é usado como tática de decepção por vendedores, que descrevem o artigo de uma forma aparentemente verdadeira, mas com o intuito de enganar. O uso de IA na replicação de fotografias de peças de roupa em segunda-mão pode ser considerado como *relabeling*, dado que, por característica dos atuais modelos de IA generativa, as imagens parecerem demasiado perfeitas e polidas, não contendo todos os detalhes e condições das peças (Lou & Copeland, 2025).

Pollay (1986) foi um dos primeiros autores a propor que o efeito de decepção provocado por anúncios enganadores se refletia na adoção de uma postura negativa por parte dos consumidores. Sendo a honestidade na comunicação um dos principais fatores nas transações comerciais, o consumidor que sinta uma quebra de confiança pode sentir a sua relação com a marca afetada (Pollay, 1986) e diminuir também a confiança no mercado no geral (Darke & Ritchie, 2007; Mustak et al., 2023). Já no *e-commerce*, Xiao e Benbasat (2011) propõem que a decepção engloba a apresentação do produto e o conteúdo associado ao anúncio. Um anúncio em P2P que utilize conteúdo gerado por IA em vez de uma fotografia real pode ser utilizado como uma forma de representar informação falsa e tentar enganar o consumidor (Liu et al., 2025), o que pode levar a que este sinta decepção ao sentir que está a ser manipulado (Xiao & Benbasat, 2011). Assim, é lógico assumir que a percepção do uso de IA num anúncio P2P pode ter efeito direto na percepção de decepção, elaborando-se a hipótese H1:

H1: O realismo percebido tem um efeito negativo na decepção percebida.

2.8. Desconfiança no vendedor e na plataforma P2P-SM

Sitkin e Roth (1993) definem que a desconfiança ocorre quando a parte que confia percebe que a parte confiada não é capaz ou não tenciona ir ao encontro das suas expectativas. A desconfiança tem sido alvo de menor atenção na literatura por se assumir que esta é apenas o nível mais baixo do espectro da confiança (Chang & Fang, 2013; Cheng & Chen, 2021). A distinção entre os construtos foi abordada por Lewicki et al. (1998), que propõem que a desconfiança representa as "expectativas negativas relativamente à conduta de outra parte", enquanto a confiança é definida pelas "expectativas positivas relativamente à conduta da outra parte" (p. 444). Os autores argumentam que, apesar dos termos poderem ser recíprocos, baixa desconfiança não equivale necessariamente a alta confiança e vice versa (Zhao, Jiang & Su, 2020). A desconfiança não é, então, apenas a ausência de confiança, mas sim a expectativa de que a outra parte irá agir de forma a comprometer o bem-estar ou segurança do indivíduo (Kramer, 1999). Os construtos coexistem como duas dimensões diferentes, mas relacionadas (Cheng & Chen, 2021; Moody et al., 2014). Este estudo foca-se apenas na dimensão da desconfiança, associada ao comportamento oportunista motivado pelo uso de IA generativa para dececionar os compradores de plataformas P2P-SM.

A desconfiança baseia-se na necessidade humana de sobrevivência e de segurança que o indivíduo sente, tendo um efeito direto nas suas escolhas e comportamentos (Chang & Fang, 2013). McKnight et al. (2004) aplicam o conceito de desconfiança ao contexto do *e-commerce*, definindo-a como "a tendência para não estar disposto a depender ou ser vulnerável a outros, acompanhada de sentimentos de preocupação, medo ou receio" (p. 41). Os potenciais compradores, antes de fazerem uma decisão de compra *online*, têm como maior preocupação saber se o vendedor entregará o produto tal como se encontra descrito no *website* (Teo & Liu, 2007).

A desconfiança no vendedor são as expectativas negativas que o comprador tem relativamente aos comportamentos deste (McKnight et al., 2004; Moody et al., 2017). O mercado de segunda-mão, pela natureza dos bens comercializados, é propício a gerar desconfiança no vendedor por parte dos compradores (Negash & Akhbar, 2024). Ao se adicionar a vertente *online* das plataformas P2P-SM, onde o comprador e o vendedor não interagem pessoalmente e onde informação pode ser mais facilmente escondida ou

omitida, estas podem espoliar a desconfiança no vendedor (Lee et al., 2018). Os autores destacam também o alto potencial para comportamentos oportunistas dos vendedores que as plataformas P2P-SM permitem, o que pode agravar a desconfiança sentida.

Moody et al. (2014) enumeram a anormalidade situacional percebida (que engloba os erros de informação do artigo anunciado), a suspeição e a propensão para desconfiar como antecedentes da desconfiança no vendedor. Na situação em que o comprador se depara com um anúncio com uma imagem gerada por IA, que não constitui a representação real de uma peça de roupa em segunda-mão (Lou & Copeland, 2025), é proposto que este pode percecionar a ação do vendedor como uma decepção, por estar a esconder informações exatas do artigo, podendo resultar em desconfiança face ao vendedor (Cheng & Chen, 2021; Lee et al., 2018). Os consumidores de *e-commerce* sentem-se menos satisfeitos e mostram maior desconfiança em relação aos vendedores quando experienciam decepção ou práticas de venda pouco éticas (Román & Ruiz, 2005). Robles (2019) conclui que a informação exata em plataformas de *e-commerce* C2C é um fator que mitiga a desconfiança no vendedor.

Por outro lado, a desconfiança na plataforma define-se pelas expectativas negativas que o comprador sente em relação a esta (Lewicki et al., 1998), que pode exibir um comportamento imprevisível (Moody et al., 2017). A plataforma age como um intermediário na relação entre comprador e vendedor, proporcionando a infraestrutura digital que lhes permite realizar a transação, intervindo minimamente e atribuindo a responsabilidade da troca a ambos os indivíduos (Lee et al., 2018).

Riquelme e Róman (2014) definem a desconfiança na plataforma na ótica da ética, sendo esta a "crença subjetiva ou expectativa de que o retalhista é motivado pelos seus próprios interesses (ao invés dos do consumidor) e agirá de forma a tirar partido do contexto (ambiente virtual) ou do consumidor, utilizando táticas enganosas para induzi-lo a acreditar em informações falsas sobre a natureza dos produtos e serviços que realmente oferece" (p. 141). Esta definição aborda as percepções negativas em relação às plataformas *online* que os consumidores sentem quando estão perante situações que provocam decepção. Pela menor atenção prestada ao construto da desconfiança na literatura (Cheng & Chen, 2021), ao se adotar uma visão unidimensional da relação confiança-desconfiança, em que a desconfiança é o nível mais baixo na escala de confiança (Schoorman, 2007), alguns autores identificam o efeito da decepção percebida na diminuição da confiança em plataformas de *e-commerce* (Grazioli & Jarvenpaa, 2000).

Riquelme e Róman (2014) argumentam que estes autores falham na identificação do construto da desconfiança, mas que se pode assumir um igual efeito de aumento da mesma por se identificarem antecedentes à decepção relacionados com desconfiança (McKnight et al., 2004). Desta forma, elaboram-se as hipóteses H2 e H3:

H2: A decepção percebida faz crescer a desconfiança no vendedor.

H3: A decepção percebida faz crescer a desconfiança na plataforma.

2.9. Transferência de desconfiança

A relação entre membros de plataformas P2P, i.e., um vendedor e um comprador, pode afetar a relação entre o comprador e a própria plataforma (Chen et al., 2009). Zhao et al. (2019) estudaram o caso das plataformas de *social commerce* C2C, i.e., plataformas de redes sociais onde as transações são feitas entre utilizadores que já têm laços anteriores na vida real. Neste caso, a confiança entre utilizadores é de alta importância e tem um maior impacto na confiança que é transferida para a marca comprada.

A Teoria da Transferência de Confiança (*Trust Transfer Theory*, ou TTT), desenvolvida por Stewart (2003), descreve um processo cognitivo em que a confiança sentida num contexto familiar é transferida para uma outra entidade. Esta teoria envolve três participantes: o principal (quem confia), o confiado e a terceira entidade confiada – se o principal confia no confiado e existir uma relação próxima entre o confiado e a terceira entidade, então a confiança pode ser transferida para esta última parte (Zhao et al., 2019).

No contexto do mercado P2P de alojamento, Moon et al. (2019) aplicam a TTT e afirmam que, apesar das experiências negativas serem causadas por utilizadores individuais, o consumidor considera que a plataforma também tem responsabilidade pelo incidente por permitir que este aconteça. Grüner et al. (2024) investigam o efeito das experiências negativas (quebra de confiança) dos utilizadores na transferência de confiança no vendedor para confiança na plataforma, descobrindo que o efeito negativo da TTT se verifica quando a confiança no vendedor decresce e, por consequência, a confiança na plataforma também. Os autores acrescentam que este efeito é mais proeminente quando a quebra de confiança é motivada por experiências negativas relacionadas com os resultados (ao invés dos processos), como, por exemplo, o produto ou serviço prometido pelo vendedor não ir ao encontro do que é oferecido.

Ainda dentro do mesmo contexto, Jin et al. (2025) propõem a aplicação do *framework* da TTT ao construto da desconfiança, denominando este efeito como a propagação de desconfiança (ou *distrust spillover*). Os autores estudam a transferência da desconfiança entre hóspedes, em que um hóspede é afetado por uma experiência negativa com um hospedeiro que espoleta desconfiança – esta desconfiança causa desconfiança num próximo hospedeiro e, por levar à partilha da experiência (através de eWOM negativo), propaga a desconfiança para outros hóspedes. Lee et al. (2018) descobrem também o efeito de transferência de desconfiança de vendedor para plataforma no contexto mais abrangente de *e-commerce*.

No presente estudo, pretende-se investigar se a perceção de imagens geradas por IA como artificiais leva à perceção de decepção por parte do consumidor de P2P-SM, se este efeito afeta negativamente a desconfiança sentida pelo vendedor e, posteriormente, se esta desconfiança se transfere para a plataforma. A TTT é aplicada apenas ao construto da confiança, no entanto, será aplicada a lógica apresentada por Stewart (2003) para testar o mesmo efeito com o construto da desconfiança. Assim, elabora-se a hipótese H4:

H4: A desconfiança no vendedor faz crescer a desconfiança na plataforma, existindo um efeito de transferência de desconfiança.

2.10. Intenção de eWOM negativo

O eWOM é definido como “qualquer afirmação positiva ou negativa feita por um potencial, atual ou antigo cliente sobre um produto ou empresa, disponibilizada para uma multitude de pessoas e instituições através da *internet*” (Hennig-Thurau et al., 2004, p. 39). Este tipo de comunicação tem influência significativa noutros consumidores, por ser de cariz credível ao expor situações pessoais sem enviesamento e não ter qualquer compromisso financeiro com a entidade mencionada (Bhandari et al., 2021; Bueno & Gallego, 2021; Ilmalhaq et al., 2024). Quando potenciais consumidores leem eWOM negativo, a sua desconfiança no vendedor ou na plataforma pode ser espoletada (Zhao, Jiang & Su, 2020), tendo consequências negativas para a reputação da empresa (Román, 2010). O estudo de Kramer (1999) mostra que as respostas e crenças dos indivíduos são mais afetadas pelos sentimentos de desconfiança ao invés de confiança, logo têm maior tendência a partilhar uma experiência negativa.

Mohammad et al. (2021) utilizam o modelo SOR para medir o impacto do eWOM no comportamento de compra de roupa em segunda-mão, descobrindo que este efeito é

positivo. Já Riquelme et al. (2016) investigam o efeito da decepção percebida no contexto de *e-commerce* no eWOM, concluindo que, quando se deparam com uma situação onde se sentem enganados, os consumidores tendem a participar em eWOM negativo sobre a plataforma que os dececionou, tendo consequências bastante negativas para a mesma, pela difusão e atenção que estas publicações e comentários recebem. Numa destas situações, o comprador que experiencia engano por parte do vendedor sente uma quebra de confiança, tentando equilibrar o dano causado através de ações como eWOM negativo (Román, 2010). No contexto do mercado P2P de alojamento, Sthapit et al. (2025) concluem que existe uma relação entre a desconfiança no vendedor e a intenção de eWOM negativo. Já Kirk e Givi (2025) abordam o efeito negativo que o conteúdo gerado por IA tem na intenção do consumidor de fazer eWOM positivo. A existência de eWOM negativo sobre um vendedor ou uma plataforma pode demover outros consumidores de utilizar a mesma ou de comprar, ao partilhar os riscos associados (Wu et al., 2023). Aplicando a lógica anterior ao contexto P2P, elaboram-se as hipóteses H5 e H6:

H5: A desconfiança no vendedor faz crescer a intenção de eWOM negativo.

H6: A desconfiança na plataforma faz crescer a intenção de eWOM negativo.

2.11. Variáveis moderadoras

2.11.1. Literacia de IA como variável moderadora

A literacia de IA é o conhecimento objetivo que um indivíduo possui sobre IA (Tully et al., 2023). Os autores afirmam que as pessoas com um grau mais baixo de literacia de IA vêem esta tecnologia como uma ferramenta mágica e sentem um maior fascínio pelo seu *output*, exibindo forte receptividade em relação ao conteúdo sintético. Carolus et al. (2023) desenvolvem escalas para avaliar a literacia de IA dos inquiridos, onde o nível mais básico corresponde ao entendimento e conhecimento da tecnologia. Atualmente, observa-se uma acentuada disparidade no que toca à literacia de IA, com uma divisória a ser criada entre os benefícios que cada grupo pode retirar do seu conhecimento relativo à tecnologia (Wang et al., 2025). Estas diferenças, provenientes da heterogeneidade de literacia, influenciam como os consumidores percecionam e interpretam conteúdos sintéticos (Liu et al., 2025).

Köbis et al. (2021) avaliam como utilizadores reagem a manipulações hiper-realistas de conteúdo áudio-visual e a influência da literacia de IA na distinção de conteúdo verdadeiro ou manipulado, concluindo que consumidores com menor literacia

digital são mais suscetíveis à decepção. Os consumidores com esta capacidade cognitiva menos desenvolvida podem estar numa posição mais vulnerável a fraudes ou informação falsa (Mustak et al., 2023). Wang et al. (2025) propõem que literacia de IA se divide em conhecimento de IA – o conhecimento factual do indivíduo sobre como IA funciona e a lógica operacional inerente – e capacidades de IA – a capacidade do indivíduo reconhecer e interagir com IA. A literacia de IA influencia as respostas cognitivas dos indivíduos que percecionam conteúdos sintéticos (Li & Yuan, 2026). Quanto maior for a literacia em IA do consumidor, maior será a sua capacidade de identificar as potenciais limitações de conteúdos gerados por ela (Zhai et al., 2025), como por exemplo a sua incapacidade atual de fielmente retratar um objeto da mesma forma que uma fotografia (Lou & Copeland, 2025), e menor será o seu deslumbre com o conteúdo sintético (Tully et al., 2023). Sendo uma capacidade inerente ao indivíduo, a literacia de IA pode moderar a perceção de realismo da imagem de IA e a decepção percebida. Desta forma, elabora-se a hipótese H7:

H7: A literacia de IA tem um efeito moderador positivo na relação entre o realismo percebido e a decepção percebida. Quanto maior a literacia em IA, maior será o efeito do realismo percebido na decepção percebida.

2.11.2. Propensão para desconfiar como variável moderadora

A propensão para desconfiar (ou disposição para desconfiar) é definida como "a propensão [de um indivíduo] para atribuir intenções sinistras e o desejo de se proteger dos efeitos da conduta de outra parte" (Lewicki et al., 1998). Reimann et al. (2017) propõem que a propensão para desconfiar é desenvolvida pelo ambiente em que o indivíduo se insere e pelas suas vivências, mas que não é uma característica herdada geneticamente ao contrário da propensão para confiar. McKnight et al. (2004) afirmam que a disposição para desconfiar de uma pessoa pode tornar-se mais ou menos negativa com o decorrer do tempo, por se tratar do resultado de uma amálgama de experiências pessoais.

Os indivíduos com maior nível de propensão para desconfiar são mais relativistas, tendo maior tendência a ceticismo face a questões éticas e a questionar a integridade do retalhista ou vendedor (Riquelme & Román, 2014). Estes indivíduos tendem a adotar uma postura defensiva ao interagir com outros, de forma a evitar o risco, tendo um efeito positivo na desconfiança que sentem em relação a estes (Min & Zickar, 2023). Lee et al. (2018) estudam o efeito da variável moderadora da propensão para desconfiar na

desconfiança tanto no vendedor como na plataforma de *e-commerce*, descobrindo que esta tem um efeito positivo em ambas.

Sendo a relação entre comprador-vendedor e entre comprador-plataforma das características mais proeminentes das interações no mercado C2C (Zhao, Fang et al., 2020), é lógico assumir que um indivíduo com maior propensão para desconfiar poderá sentir a sua desconfiança face ao vendedor e à plataforma agravar numa situação eticamente questionável, como após a decepção percebida relativamente à ocultação de informação num anúncio. Desta forma, elaboram-se as seguintes hipóteses H8 e H9:

H8: A propensão para desconfiar modera a relação entre a decepção percebida e a desconfiança no vendedor. Quanto maior a propensão para desconfiar, maior o efeito da decepção percebida na desconfiança no vendedor.

H9: A propensão para desconfiar modera a relação entre a decepção percebida e a desconfiança na plataforma. Quanto maior a propensão para desconfiar, maior o efeito da decepção percebida na desconfiança na plataforma.

2.11.3. Responsabilidade percebida da plataforma

Yu et al. (2025) definem a RPP como as expectativas dos utilizadores sobre o controlo por parte das plataformas de *e-commerce* em relação aos seus conteúdos, nomeadamente à identificação de conteúdos de IA, transparência e correção de incidentes. Os autores afirmam que, num ambiente onde esta tecnologia é cada vez mais utilizada e nem sempre existe transparência quanto ao seu uso, os consumidores destas plataformas preocupam-se mais com as suas capacidades de supervisão, correção e sanções quando situações de informações falsas ou enganosas ocorrem.

A RPP pode levar a uma maior confiança por parte dos consumidores (Stanaland et al., 2011). Esta dimensão, ligada à ética e transparência, afeta o sentido de segurança moral dos utilizadores e as suas intenções (Yu et al., 2025). Os autores propõem também que, no contexto do uso de IA, os consumidores têm maior propensão a atribuir a responsabilidade de falhas no conteúdo à falta de controlo da plataforma em vez de aos vendedores que criaram o conteúdo. A RPP representa um julgamento subjetivo por parte do comprador (Yang et al., 2024). A desconfiança que este sente pela plataforma, espoletada por uma imagem sintética que o dececiona, pode ser mitigada se a plataforma identificar o conteúdo como gerado por IA, estabelecer mecanismos de *feedback* e de

correções, resultando numa maior receptividade a aceitar conteúdo sintético tendo em conta que a plataforma assume estas responsabilidades (Liu et al., 2025).

Assim, aplicando o raciocínio anterior ao contexto das plataformas P2P-SM, propõe-se que a RPP pode ter um efeito negativo na desconfiança que o consumidor sente em relação à plataforma, quando se depara com conteúdo gerado por IA anunciado por um vendedor. Elabora-se, então, a hipótese H10:

H10: A RPP modera a relação entre a desconfiança no vendedor e a desconfiança na plataforma. Quanto maior a RPP, maior o efeito de transferência de desconfiança do vendedor para a plataforma.

3. MODELO CONCEPTUAL

O modelo conceptual presente na Figura 1 é proposto com apoio da literatura exposta no capítulo anterior (Grüner et al., 2024; Lee et al., 2018; Lou & Copeland, 2025; Moriuchi & Takahashi, 2022). Desta forma, pretende-se responder às questões de investigação expostas no capítulo 1. As hipóteses de investigação baseadas nas questões de investigação e na revisão de literatura são representadas na figura abaixo.




Figura 1: Modelo conceptual (Fonte: Elaboração própria)

4. METODOLOGIA

4.1. Tipo de estudo

O presente estudo tem uma filosofia positivista, ao observar uma realidade social de forma objetiva e neutra (Saunders et al., 2023). A abordagem de pesquisa adotada é dedutiva, partindo de teoria existente para o desenvolvimento das hipóteses, tendo em conta o problema do estudo, que posteriormente são testadas através de dados empíricos

(Saunders et al., 2023). O objetivo do estudo visa compreender a forma como as imagens geradas por IA em plataformas P2P-SM afetam a desconfiança que os compradores sentem pelo vendedor e pela plataforma, e o seu efeito na intenção de partilhar eWOM negativa sobre estes. A forma de recolha de dados passa por uma metodologia quantitativa monométrica através de um inquérito *online* sob forma de questionário, que permite recolher dados de forma eficiente (Saunders et al., 2023). O estudo tem um horizonte temporal *cross-sectional*, estando a recolha de dados limitada a um só período de tempo específico (Saunders et al., 2023).

4.2. População e amostragem

A presente pesquisa tem como população-alvo todos os indivíduos cuja idade seja superior a 18 anos (não descartando qualquer outra característica sociodemográfica) e que já tivessem visitado uma plataforma P2P-SM, para o qual foi aplicada a pergunta filtro “Já alguma vez visitou uma plataforma *online* de compra e venda de roupa em segunda-mão (ex: Vinted, OLX, Wallapop, Depop)?”. Desta forma, é possível garantir uma maior e mais diversa amostra, de modo a obter uma análise mais abrangente das perceções dos utilizadores de plataformas P2P-SM quanto a imagens geradas por IA.

Para a determinação da amostra, adotou-se a técnica de amostragem não-probabilística por conveniência e efeito bola de neve (Saunders et al., 2023), visto que a partilha do questionário foi feita através de redes sociais (Instagram, Whatsapp e LinkedIn), de *QR codes* impressos e distribuídos em 6 faculdades da Universidade de Lisboa e de “passa-a-palavra”. Por esta mesma razão, salienta-se que esta amostra não é representativa da população geral, estando a investigação sujeita a enviesamentos.

4.3. Recolha de dados

Este estudo contou com uma fase inicial de recolha de dados secundários, nomeadamente artigos científicos, livros e *websites*, com o objetivo de definir as questões de investigação e as hipóteses. Posteriormente, para responder a estas questões e testar as hipóteses definidas, optou-se por um questionário como instrumento de recolha de dados primários, autoadministrado pelos inquiridos através da *internet* (Saunders et al., 2023). Este foi partilhado através de redes sociais e *QR codes* impressos distribuídos em faculdades entre os dias 11 de maio e 2 de junho de 2026, resultando numa amostra total de 578 respostas.

4.4. Questionário

O questionário foi estruturado em 8 secções, organizado de modo a conduzir o inquirido através da experiência de forma natural e sem enviesar as suas respostas (ver [Anexo A](#)). A primeira secção é constituída pela pergunta que filtra a amostra válida para o estudo – os utilizadores de plataformas P2P-SM. A segunda secção recolhe informação sobre os hábitos de compra *online* e de utilização de plataformas P2P-SM, com o objetivo de caracterizar o perfil comportamental da amostra e identificar o grau de familiaridade dos inquiridos com este tipo de plataformas. A terceira secção conta com outra pergunta filtro sobre o género com o qual o inquirido mais se identifica, para que a imagem apresentada na secção seguinte seja mais adequada à sua experiência real na plataforma. Nesta secção, é apresentada a imagem (ver [Anexo B](#)), que consiste numa captura de ecrã de um anúncio real de uma camisola em segunda-mão na aplicação móvel da Vinted, onde a imagem do anúncio foi gerada por IA; o anúncio tem a descrição “*vintage shirt*”, da marca Vintage Dressing, corresponde ao tamanho M/38, em estado muito bom e tem um custo de 6,50€. O anúncio tem apenas uma imagem publicada e esta é gerada por IA, sendo que o inquirido é informado à partida do carácter sintético da mesma, apesar desta não ter rótulo na própria imagem ou plataforma, à semelhança da utilização real da aplicação. A imagem apresentada variava conforme o género do inquirido, sendo apresentada a mesma imagem para os respondentes que escolhessem a opção “Não-binário/Outro” e “Prefiro não responder”. Ainda na quarta secção, o inquirido é convidado a confirmar que visualizou a imagem e a responder às perguntas sobre o realismo percebido, a decepção percebida, a desconfiança sentida em relação ao vendedor e à plataforma e, por fim, à sua intenção de partilhar eWOM negativo. As três secções seguintes contam cada uma com as perguntas relativamente às variáveis moderadoras – RPP, Literacia de IA e Propensão para Desconfiar, respetivamente. A oitava e última secção recolhe os dados sociodemográficos dos inquiridos, nomeadamente a idade, habilitações literárias, situação profissional, rendimento mensal e nacionalidade.

As imagens utilizadas como estímulo foram selecionadas com base em critérios de representatividade do fenómeno a ser estudado: tratam-se de imagens com características visuais tipicamente associadas ao conteúdo gerado por IA (uniformidade de composição, iluminação suavizada e paleta de tons neutra; Miskolczi, 2026), publicadas no contexto de um anúncio de roupa em segunda-mão numa plataforma P2P-

SM real. Foi utilizado o *layout* da aplicação móvel da Vinted como o exemplo de anúncio por esta ser a plataforma P2P-SM mais popular em Portugal (Statista, 2026b).

Foi realizado um pré-teste a 10 inquiridos do público-alvo, com o objetivo de avaliar a clareza das instruções, a adequação das escalas ao contexto e o tempo médio de preenchimento, estimado em cerca de 6 minutos. Com base no *feedback* recolhido, foram aplicados os ajustamentos considerados necessários antes da distribuição final do questionário, nomeadamente à formatação visual das opções e erros ortográficos.

4.5. Escalas de medida

Relativamente à medição dos construtos, utilizaram-se escalas traduzidas e adaptadas ao contexto da presente investigação (ver [Anexo C](#)). As perguntas relativas ao realismo percebido da imagem gerada por IA foram adaptadas de Hartmann et al. (2025). A perceção de decepção foi medida através dos itens de Román (2010). O construto da desconfiança no vendedor foi adaptado de Zhao, Jiang & Su (2020) e o da desconfiança na plataforma foi adaptado de Lee et al. (2018) (tal como o da variável moderadora da propensão para desconfiar), com o objetivo de se compreender o impacto do realismo e da decepção percebidos na relação que o utilizador tem com estas entidades e se se verifica uma transferência de desconfiança. O construto da intenção de eWOM negativo provém da escala de Sthapit et al. (2025), que permite aferir a tendência do utilizador em partilhar publicamente uma má experiência no contexto das P2P-SM. A variável moderadora da literacia de IA foi adaptada de Carolus et al. (2023) e a da RPP é medida através dos itens de Yu et al. (2025). Todas as questões foram medidas através de uma escala concordância do tipo Likert de 7 pontos, em que 1 corresponde a “Discordo totalmente” e 7 corresponde a “Concordo totalmente”.

4.6. Tratamento e análise preliminar dos dados

Após a recolha de dados, procedeu-se ao tratamento e à análise preliminar das respostas, através do *software* IBM SPSS Statistics. Obtiveram-se 578 respostas no total, mas destas apenas 338 foram válidas e consideradas para análise. A amostra total contou com 169 respostas não terminadas, que foram eliminadas. Além destas, 65 dos inquiridos responderam "Não" à pergunta "Já alguma vez visitou uma plataforma online de compra e venda de roupa em segunda-mão (ex: Vinted, OLX, Wallapop, Depop)?", tendo sido desconsideradas para análise por não se enquadrarem na amostra procurada de utilizadores de plataformas P2P-SM. Outras 5 respostas foram eliminadas por se observar

mais de 80% de opções iguais nas respostas. Finalmente, uma outra resposta foi também desconsiderada por representar um *outlier* na maioria dos dados sociodemográficos (99 anos; doutoramento; nacionalidade chinesa; género não-binário).

Para garantir uma maior fiabilidade e facilidade na análise e tratamento dos dados, realizaram-se alguns procedimentos, como a codificação de variáveis e a verificação dos dados. Em perguntas com possibilidade de seleção de duas ou mais opções, as opções não-selecionadas apareciam com um ponto (.) no SPSS, pelo que se decidiu substituir o valor por 0 para uniformizar a codificação. Foi feita também a análise de mínimos e máximos de todos os itens para verificar se existiam valores impossíveis ou inconsistentes. Foi ainda feita a recodificação do item RP6 (sexto item da variável Realismo Percebido), cuja escala era invertida no artigo de origem (Hartmann et al., 2025), atribuindo-se assim o nome RP6_Reversed. Através da função de *visual binning*, a variável Idade foi ainda dividida em três faixas etárias: "Dos 18 aos 25 anos", "26 aos 40 anos" e "Mais de 40 anos".

5. ANÁLISE DE RESULTADOS

5.1. Caracterização da amostra

A amostra do estudo é constituída por 338 inquiridos, sendo 62,7% do género feminino, 34,9% do género masculino e cerca de 2,4% não-binário/outro ou preferiu não partilhar essa informação. No que diz respeito ao grupo etário, a faixa etária entre os 18 e os 25 anos foi a mais representada, representando 80,8% da amostra, seguindo-se a faixa entre os 26 e os 40 anos, com 16,2%, e, por fim, os inquiridos com idade superior a 41 anos com apenas 3%. Relativamente às habilitações literárias, a licenciatura/bacharelato foi o grau académico com maior representatividade, com 40,3% das respostas, seguida do 12.º ano ou equivalente, com 36%, e do Mestrado, com 18%. No que diz respeito à situação profissional, a maioria dos inquiridos afirmou ser estudante, representando mais de metade da amostra, com 57,4% – esta representatividade é consistente com os locais de distribuição do questionário. Adicionalmente, 24% são trabalhadores por conta de outrem e cerca de 13,8% são trabalhadores-estudantes. Em relação ao rendimento mensal líquido individual, 9,5% dos inquiridos optaram por não indicar o seu rendimento, tendo sido registados como valores omissos. Considerando as respostas válidas, 45,9% dos inquiridos afirmaram não auferir rendimentos, o que é consistente com a elevada percentagem de estudantes na amostra. Seguem-se aqueles que auferem entre 1001€ e

2000€ por mês, representando 23,3% da amostra, e os que auferem entre 500€ e 1000€ por mês, correspondendo a 9,5% das respostas. No que diz respeito à nacionalidade, a grande maioria dos inquiridos é de nacionalidade portuguesa, com 93,8% das respostas, sendo os restantes de outras nacionalidades, destacando-se a brasileira, com 2,1%.

Relativamente aos hábitos de consumo dos inquiridos, pôde apurar-se que 10,9% dos utilizadores quase nunca visitam estas plataformas. A frequência mais comum entre os inquiridos é visitar raramente (menos de 1 vez por mês), correspondendo a 47,7% da amostra. Os motivos pelos quais os inquiridos mais procuram roupa em segunda-mão nestas plataformas são o preço mais baixo (47,3%), encontrar peças únicas (21,9%) e o consumo consciente e sustentável (16,9%). Quanto às plataformas utilizadas pelos inquiridos, verificou-se que a Vinted é a plataforma mais popular, sendo utilizada por 83,7% dos participantes. Segue-se o OLX como a segunda plataforma mais utilizada, com 26,9% das respostas, seguida do Facebook Marketplace, utilizado por 10,9% dos inquiridos. Quando questionados relativamente à importância que atribuem às imagens dos anúncios de artigos nas plataformas P2P-SM, 94,3% dos inquiridos respondeu "Importante" ou "Muito importante". No [Anexo D](#), encontra-se a caracterização da amostra mais detalhada.

5.2. Análise de Componentes Principais e Fiabilidade

Após o tratamento preliminar dos dados e a análise da amostra, procedeu-se à Análise dos Componentes Principais (ACP), à análise do Alfa de Cronbach dos itens de cada escala e a sua validação, seguida da criação de índices sintéticos para uma análise mais resumida descritiva e de normalidade. No [Anexo E](#), encontra-se a tabela com os valores detalhados.

Para reduzir a dimensionalidade e identificar o número mínimo de fatores que representam as relações entre as variáveis, realizou-se a ACP. Para isso, foi analisado o critério de Kaiser-Meyer-Olkin (KMO) para averiguar se os dados são adequados para a análise fatorial (Pallant, 2010). O critério varia entre 0 e 1, devendo ser superior a 0,6 para se considerarem adequados (Pallant, 2010), o que se verifica em todos os itens das variáveis, pelo que a análise fatorial é adequada aos dados. De seguida, efetuou-se o Teste de Esfericidade de Bartlett, onde o *p-value* deve ser inferior a 0,05, o que se verifica, mais uma vez, para todos os itens, concluindo-se que a análise de fatores é considerada apropriada (Pallant, 2010). Ainda dentro da ACP, é avaliada a Variância Total Explicada,

cujos valores das escalas variam entre 54,113 e 74,069, o que indica que estas estão suficientemente correlacionadas (Pallant, 2010). Verificaram-se ainda as comunalidades de cada item, que devem apresentar valores superiores a 0,5 (Sarstedt & Mooi, 2019), onde apenas dois itens apresentaram valores inferiores a este valor, RP6_Reversed (com 0,258) e RPP4 (com 0,083).

De seguida, procedeu-se à Análise de Fiabilidade, através do cálculo do coeficiente do Alfa de Cronbach, que indica a consistência interna das variáveis, que deve apresentar valor superior a 0,7 para se considerar como aceitável (Pallant, 2010). Todas as variáveis apresentaram valores do Alfa de Cronbach entre 0,794 e 0,911, com exceção da variável RPP, com um Alfa de Cronbach de 0,552. Este é um valor fraco, explicado pela baixa correlação de item total corrigida do item RPP4, que, se apagado, aumentaria o Alfa de Cronbach da variável para 0,782, pelo que foi removido da escala. Após a exclusão deste item, procedeu-se a uma nova ACP com a escala com apenas três itens. Os resultados mostram a adequação dos dados à análise fatorial (KMO = 0,681; Teste de Esfericidade de Bartlett: $\chi^2 = 331,199$; $p < 0,001$). A solução obtida explicou 70,607% da variância total do construto e a consistência interna da escala revelou-se aceitável, com um Alfa de Cronbach de 0,782. Assim, a escala final de Responsabilidade Percebida da Plataforma ficou constituída por três itens (RPP1, RPP2 e RPP3).

O outro item que demonstrou uma comunalidade abaixo de 0,5, correspondente ao último item de escala invertida da variável Realismo Percebido, mostrou também que, apesar do Alfa de Cronbach da variável ser bom (0,898), se este fosse eliminado, levaria à sua melhoria do Alfa de Cronbach (0,928), visto também se observar que o valor da correlação de item total corrigida é mais baixo em relação aos outros itens da escala. Procedeu-se à sua eliminação e à elaboração de uma nova ACP com a escala com apenas cinco itens. Os resultados mostram a adequação dos dados à análise fatorial (KMO = 0,869; Teste de Esfericidade de Bartlett: $\chi^2 = 1334,173$; $p < 0,001$). A solução obtida explicou 77,808% da variância total do construto e a consistência interna da escala revelou-se aceitável, com um Alfa de Cronbach de 0,928. Assim, a escala final de Realismo Percebido ficou constituída por cinco itens (RP1, RP2, RP3, RP4 e RP5).

Com os itens validados através da ACP e da Análise de Fiabilidade, procedeu-se à criação de índices sintéticos de forma a testar a normalidade de cada construto de forma mais resumida. Os dados estão detalhados na tabela do [Anexo F](#). Os índices sintéticos correspondem à média aritmética dos itens de cada construto. Em relação às suas

estatísticas descritivas, verifica-se que o índice com maior média é o da RPP ($M=6,5118$; $DP=0,72509$) e com a menor média é o da Desconfiança na Plataforma ($M=4,7293$; $DP=1,35411$). O índice mais heterogéneo é o Realismo Percebido, por ter o maior desvio-padrão ($DP=1,5161$), ou seja, existe maior dispersão na resposta aos itens desta variável. Quanto à normalidade das variáveis, esta é determinada através de valores absolutos de curtose inferiores a 7 e de assimetria inferiores a 2 (Kline, 2015), o que se verifica para todos os índices. No entanto, pelo teste de Kolmogorov-Smirnov, onde um $p < 0,05$ significa a rejeição da normalidade (Pallant, 2010), é possível verificar que todos os índices apresentam um $p < 0,001$, logo as variáveis não seguem uma distribuição normal.

5.3. Análise do Modelo de Medida

A análise do modelo de medida passa pela análise da fiabilidade da consistência e dos indicadores, bem como a análise da validade convergente e discriminante (Hair et al., 2011). Para isto, foi utilizado o SmartPLS 4, que permite a modelagem de equações estruturais de mínimos quadrados parciais. A utilização deste *software* é adequada a modelos complexos, sem necessidade de uma amostra de grande dimensão e de uma distribuição normal, focando-se na explicação da variação das variáveis dependentes do modelo de medida (Hair et al., 2011). Inicialmente, foi corrido o algoritmo de PLS-SEM para aferir os resultados detalhados na Tabela 1.

Enquanto a ACP e a análise da fiabilidade do subcapítulo anterior serviram para validar e apurar os itens antes de os transferir para o SmartPLS 4, a presente análise serve como confirmação do modelo de medida já com os itens finais. Para isso, volta-se a avaliar a fiabilidade dos construtos agora através do segundo *software*. A análise de fiabilidade consiste na análise do Alfa de Cronbach, que deve ser superior a 0,6, e na análise da fiabilidade composta (*ou composite reliability*) (CR), que deve ser superior a 0,7 (Pallant, 2010). Verifica-se que o Alfa de Cronbach (já analisado anteriormente através do SPSS), através de PLS-SEM, confirma os valores superiores a 0,791 de todas as variáveis. Quanto à fiabilidade composta, é possível observar que as variáveis apresentam valores de CR superiores a 0,873. A fiabilidade de cada indicador é determinada pelo valor dos *outerloadings*, que devem ser superiores a 0,7 (Hair et al., 2011). Isto verificou-se para a maioria dos indicadores, exceto os itens LIA5, LIA6 e PPD2, que apresentavam cargas fatoriais abaixo de 0,4, sendo eliminadas automaticamente para não prejudicarem a fiabilidade dos seus respetivos construtos.

Através da análise da variância média extraída (ou *average variance extracted*) (AVE), é possível avaliar a validade convergente, que expressa a convergência entre indicadores comparativamente a uma das variáveis latentes (Hair et al., 2011). A AVE deve apresentar valores superiores a 0,5, o que se verifica para todos os construtos. Quanto à validade discriminante, esta permite analisar a correlação entre construtos para aferir que não existem medidas iguais entre estes (Hair et al., 2011). Através do critério de Fornell-Larcker, é possível averiguar a validade discriminante ao verificar que a raiz quadrada da AVE de uma variável latente é superior à sua relação com as restantes (Hair et al., 2011), o que se verifica para todas as variáveis (ver [Anexo G](#)). Desta forma, o modelo de medida é validado e pode prosseguir-se com a análise do modelo estrutural.

Construto	Variável	Outerloading	Alfa de Cronbach	CR	AVE
Realismo Percebido	RP1	0,8552	0,929	0,946	0,778
	RP2	0,8869			
	RP3	0,8852			
	RP4	0,8979			
	RP5	0,8833			
Deceção Percebida	DEC1	0,7828	0,858	0,904	0,702
	DEC2	0,8950			
	DEC3	0,8294			
	DEC4	0,8405			
Desconfiança no Vendedor	VEN1	0,8194	0,801	0,883	0,715
	VEN2	0,8696			
	VEN3	0,8476			
Desconfiança na Plataforma	PLA1	0,8359	0,911	0,931	0,691
	PLA2	0,8296			
	PLA3	0,8139			
	PLA4	0,8787			
	PLA5	0,8188			
	PLA6	0,8079			
Intenção de eWOM negativo	EWOM1	0,7513	0,800	0,881	0,713
	EWOM2	0,8922			
	EWOM3	0,8831			
Responsabilidade Percebida da Plataforma	RPP1	0,7705	0,791	0,873	0,696
	RPP2	0,8501			
	RPP3	0,8790			
Literacia de IA	LIA1	0,7408	0,835	0,642	0,334
	LIA2	0,6101			
	LIA3	0,7546			
	LIA4	0,7087			
	LIA5	-0,0567			
	LIA6	-0,0804			
Propensão para Desconfiar	PPD1	0,9425	0,828	0,784	0,499
	PPD2	0,3541			
	PPD3	0,7156			
	PPD4	0,6844			

Tabela 1: Modelo de Medida (Fonte: Elaboração Própria)

5.4. Análise do Modelo Estrutural

Para analisar o modelo estrutural, utilizou-se, mais uma vez, o *software* SmartPLS 4 e a técnica de *bootstrapping* de forma a testar as suas hipóteses, através de uma amostra maior composta por 5000 subamostras. Os resultados do teste encontram-se detalhados na Tabela 2. Antes de se analisar o modelo estrutural, é necessário verificar os níveis de colinearidade de forma a garantir que não existem resultados ou conclusões enviesadas. Para isto, utiliza-se o fator de inflação de variância (ou *variance inflation factor*) (VIF),

cujo valor deve ser inferior a 5 (Hair et al., 2011), o que se verificou para todos os itens. Para analisar o modelo estrutural e para que as hipóteses sejam suportadas, o *p-value* dos *path coefficients* deve ser inferior a 0,05, significando que as relações entre construtos sejam significativas (Hair et al., 2011).

Relativamente aos efeitos diretos entre as variáveis, é possível verificar que o Realismo Percebido tem uma relação estatisticamente significativa com a Deceção Percebida ($p < 0,001$), sendo esta negativa ($\beta = -0,448$), pelo que a H1 é suportada. Quanto ao efeito direto entre a Deceção Percebida e a Desconfiança no Vendedor, verifica-se que estas apresentam uma relação estatisticamente significativa ($p < 0,001$) e que esta é positiva ($\beta = 0,573$). Esta é a relação mais forte apurada pelo *bootstrapping*. Assim, valida-se a H2. De forma semelhante, a relação entre a Deceção Percebida e a Desconfiança na Plataforma também se revela como estatisticamente significativa e positiva ($p < 0,001$; $\beta = 0,271$), embora com uma força menor, suportando a H3. Os resultados do *bootstrapping* permitem observar o efeito de transferência de desconfiança, isto é, a relação entre a Desconfiança no Vendedor e a Desconfiança na Plataforma é estatisticamente significativa e positiva ($p < 0,001$; $\beta = 0,548$), sendo esta a segunda relação mais forte entre os coeficientes, o que significa que a H4 é suportada. A relação entre a Desconfiança no Vendedor e a Intenção de eWOM Negativo segue um padrão diferente das anteriores ao não se verificar estatisticamente significativa ($p = 0,093$; $\beta = 0,133$), pelo que a H5 não é suportada. Já a relação entre a Desconfiança na Plataforma e a Intenção de eWOM Negativo é estatisticamente significativa e positiva ($p < 0,001$; $\beta = 0,271$), pelo que a H6 é suportada.

Relativamente aos efeitos moderadores, é possível observar que a Literacia de IA não é estatisticamente significativa a moderar o efeito do Realismo Percebido na Deceção Percebida ($p = 0,975$; $\beta = -0,001$), pelo que a H7 não é suportada. Da mesma forma se observa que a Propensão para Desconfiar não é estatisticamente significativa a moderar a relação entre a Deceção Percebida e a Desconfiança no Vendedor ($p = 0,068$; $\beta = -0,093$) nem a relação entre a Deceção Percebida e a Desconfiança na Plataforma ($p = 0,662$; $\beta = 0,016$), pelo que tanto a H8 como a H9 não são suportadas. Por fim, e ao contrário das anteriores, a RPP apresenta-se como estatisticamente significativa a moderar a relação entre a Desconfiança no Vendedor e Desconfiança na Plataforma ($p < 0,001$), sendo esta relação positiva ($\beta = 0,170$), logo a H10 é suportada.

Apesar de não ser o objetivo da investigação, numa análise adicional observa-se um efeito indireto significativo da Desconfiança no Vendedor na Intenção de eWOM Negativo, mediado pela Desconfiança na Plataforma ($\beta=0,149$; $p<0,001$), o que complementa o facto da H5 não ser suportada. Isto sugere que a desconfiança no vendedor por si só não é suficiente para espoletar a intenção de partilhar eWOM negativo, mas sim quando existe a transferência de desconfiança para a plataforma. Também numa análise adicional aos objetivos de investigação, observa-se que o modelo evidencia um efeito de mediação em cadeia entre o Realismo Percebido e a Intenção de eWOM Negativo, que operam sequencialmente através da Deceção Percebida e da Desconfiança no Vendedor e na Plataforma ($\beta=-0,038$; $p=0,001$). Este resultado sugere que o realismo das imagens geradas por IA influencia o comportamento de partilha de eWOM negativo não de forma direta, mas através de um processo sequencial psicológico, onde a perceção de menor realismo aumenta a decepção, que por sua vez aumenta a desconfiança no vendedor, que se transfere para a plataforma e resulta no aumento da intenção de eWOM negativo.

Ainda de ressaltar são os valores do R^2 (ou o coeficiente de determinação), que representa a capacidade explicativa do modelo através dos construtos (Hair et al., 2011). A Deceção Percebida apresenta uma capacidade explicativa fraca ($R^2=0,220$), isto é, 22% da Deceção Percebida é explicada pelo Realismo Percebido. Já a Desconfiança no Vendedor, por sua vez, explica 35,3% ($R^2=0,353$) da Desconfiança no Vendedor e 54,5% ($R^2=0,545$) da Desconfiança na Plataforma, o que Hair et al. (2011) consideram como valores de capacidade explicativa altos (superiores a 0,2), no âmbito de investigação do comportamento do consumidor. Por fim, a Desconfiança no Vendedor e na Plataforma explicam 13,6% ($R^2=0,136$) da Intenção de eWOM Negativo, o que é considerado uma capacidade explicativa fraca.

Hipótese	Efeito Direto	β	Teste-t	p-value	Resultado
H1	Realismo Percebido $\rightarrow$ Deceção Percebida	-0,448	10,872	<0,001	Suportada
H2	Deceção Percebida $\rightarrow$ Desconfiança no Vendedor	0,573	13,393	<0,001	Suportada
H3	Deceção Percebida $\rightarrow$ Desconfiança na Plataforma	0,243	5,103	<0,001	Suportada
H4	Desconfiança no Vendedor $\rightarrow$ Desconfiança na Plataforma	0,548	12,853	<0,001	Suportada
H5	Desconfiança no Vendedor $\rightarrow$ Intenção de eWOM negativo	0,133	1,681	0,093	Não Suportada
H6	Desconfiança na Plataforma $\rightarrow$ Intenção de eWOM negativo	0,271	3,861	<0,001	Suportada
H7	Literacia de IA $\times$ Realismo Percebido $\rightarrow$ Deceção Percebida	-0,001	0,031	0,975	Não Suportada
H8	Propensão para Desconfiar $\times$ Deceção Percebida $\rightarrow$ Desconfiança no Vendedor	-0,093	1,822	0,068	Não Suportada
H9	Propensão para Desconfiar $\times$ Deceção Percebida $\rightarrow$ Desconfiança na Plataforma	0,016	0,437	0,662	Não Suportada
H10	Responsabilidade Percebida da Plataforma $\times$ Desconfiança no Vendedor $\rightarrow$ Desconfiança na Plataforma	0,170	4,491	<0,001	Suportada

Tabela 2: Modelo Estrutural (Fonte: Elaboração Própria)

6. DISCUSSÃO DE RESULTADOS E CONCLUSÃO

6.1. Discussão de Resultados

A presente dissertação teve como objetivo compreender o efeito das imagens de roupa em segunda-mão geradas por Inteligência Artificial (IA) na intenção de eWOM negativo no contexto das plataformas de compra e venda de roupa em segunda-mão (P2P-SM), através da análise da decepção percebida e do seu efeito na desconfiança que o comprador sente face ao vendedor e à plataforma. Ao estudo foram ainda acrescentadas três variáveis moderadoras – Literacia de IA, Propensão para Desconfiar e Responsabilidade Percebida da Plataforma (RPP). Com base na literatura, desenvolveu-se o modelo conceptual que analisou estes efeitos diretos e moderadores. Os resultados obtidos revelam que a ausência de realismo percebido nas imagens geradas por IA aumenta a decepção percebida dos compradores (Hausken, 2024; Velásquez-Salamanca et al., 2025). Este resultado vai ao encontro da literatura relativa à necessidade de informação precisa no contexto do mercado de roupa em segunda-mão, bem como no contexto das interações C2C (Robles, 2019), que, pela sua natureza, têm maior propensão a originar comportamentos enganadores e não-éticos por parte dos vendedores pela informação assimétrica que dá vantagem a este (Hanson et al., 2025; Liu et al., 2025). Estudos como o de Kim et al. (2019) concluem que, em situações onde a estratégia de comunicação de um produto passe por minimizar as desvantagens do mesmo, o uso de imagens artificiais ou estilizadas ao invés de realistas pode ter um impacto positivo na percepção do consumidor. No entanto, os resultados da presente investigação provam que o contexto onde a imagem sintética é utilizada muda significativamente o efeito da mesma no consumidor. Assim, um utilizador de plataformas P2P-SM prioriza a informação precisa que consta das imagens dos anúncios de roupa.

Os resultados apontam também que a decepção percebida pelos utilizadores das plataformas P2P-SM leva a que se crie um sentimento de desconfiança no vendedor e na plataforma. O consumidor que se sinta enganado por lhe ser transmitida informação falsa através de imagens geradas por IA por parte do vendedor, passa a sentir desconfiança por este. Como o mercado C2C não é abrangido pelas mesmas legislações e práticas que o mercado B2C, a proteção do consumidor em relação a práticas desonestas ou enganadoras é mais facilmente posta em causa e existe uma maior incerteza (Huurne et al., 2017). Esta incerteza manifesta-se também em relação à plataforma em si – os resultados mostram que o comprador que experiencia decepção na interação com a imagem gerada por IA sente

desconfiança também pela plataforma, o que vai ao encontro da literatura (Grazioli & Jarvenpaa, 2000; Riquelme & Román, 2014). Além do efeito direto que a decepção percebida tem no desenvolvimento da desconfiança em ambas as entidades, observa-se também um efeito de transferência de desconfiança entre as duas. Assim, quando este experienciar a decepção ao visualizar conteúdos que percebe como enganadores, a desconfiança que sente pelo vendedor que criou o conteúdo propaga-se para a desconfiança que sente pela plataforma, que falha na identificação, regulação e eliminação de conteúdos sintéticos. Na literatura, este efeito já tinha sido abordado por Lee et al. (2018), embora fosse o efeito de transferência contrário, isto é, a desconfiança na plataforma ser transferida para a desconfiança no vendedor, e também por Grüner et al. (2024), mas, pela perspectiva unidimensional de confiança adotada na maioria dos estudos, este reconhece que existe um efeito de quebra de confiança no vendedor que se transfere para a plataforma no contexto de experiências P2P negativas.

Os resultados indicam ainda que a desconfiança na plataforma tem um efeito direto no aumento da intenção de partilhar eWOM negativo em redes sociais ou outros fóruns *online*, não se verificando o mesmo quando motivado pela desconfiança no vendedor. Estes resultados indicam que, apesar do comprador sentir que a sua relação com o vendedor é afetada ao perceber que este o tenta enganar com uma imagem gerada por IA, o comprador não sente a necessidade de espalhar esta informação com o seu círculo próximo ou em redes sociais ou fóruns *online*. Esta inação pode ser justificada pelo facto de o vendedor ser um indivíduo ao mesmo nível do comprador e que, por serem pares, este reconheça que o mesmo não tem a mesma responsabilidade para com o consumidor que a plataforma tem. Assim, o comprador mostra intenção de partilhar a sua experiência negativa relativamente à plataforma na sua rede *online*, com o intuito de demover outros potenciais ou atuais compradores de visitar a plataforma, o que vai ao encontro do estudo de Wu et al. (2023).

Contrariamente ao expectável, a literacia de IA não mostrou ter efeito moderador na relação entre o realismo percebido e a decepção percebida. Isto pode ser explicado pelo facto de que a literacia de IA pode influenciar a capacidade de deteção do conteúdo como sendo sintético, mas não ser tão eficaz quando esta informação já é transmitida ao consumidor. Após o *disclosure* de IA, o conhecimento que o indivíduo tem sobre esta irá informar sobretudo a sua percepção de realismo, atuando mais como um antecedente a esta variável do que como um moderador (Liu et al., 2025).

Em relação à propensão para desconfiar dos utilizadores, esta não revelou um efeito moderador na relação entre a decepção percebida e a desconfiança tanto no vendedor como na plataforma. O construto da desconfiança é ainda pouco estudado na literatura, o que implica que a propensão para desconfiar também seja pouco abordada. Pode especular-se que o resultado possa estar relacionado com a propensão para desconfiar se tratar de um antecedente geral à desconfiança ao invés de um moderador neste contexto específico, como a propensão para confiar é identificada na literatura do construto da confiança (Huurne et al., 2017). Darke e Ritchie (2007) concluem também que, apesar de uma postura defensiva de um indivíduo com maior propensão para desconfiar o possa prevenir de ser enganado, a desconfiança exagerada pode também limitá-lo no usufruto das oportunidades que encontra.

Finalmente, o efeito de transferência de desconfiança revelou ser moderado pela responsabilidade percebida que o indivíduo atribui à plataforma. Desta forma, o comprador espera que a plataforma P2P-SM, como reguladora das transações entre pares, o proteja de visualizar conteúdos enganadores, como os gerados por IA, que tentem levar à compra através de informações exageradas ou estilizadas. Este efeito é também observado na literatura, onde é concluído que os compradores tendem a atribuir erros no conteúdo não aos vendedores, mas sim às plataformas que falham na sua identificação ou na responsabilidade perante o consumidor (Yu et al., 2025), o que resulta numa perda de confiança que se transfere do vendedor para a plataforma (Grüner et al., 2024).

6.2. Conclusão

O presente estudo teve como objetivo a resposta à pergunta de investigação "De que forma o realismo percebido de imagens de roupa geradas por IA numa plataforma P2P-SM influencia a decepção percebida e como é que esta posteriormente influencia a desconfiança no vendedor, a desconfiança na plataforma e a intenção de eWOM negativo?". Através dos resultados expostos, é possível perceber que existe um processo psicológico que acontece quando o comprador observa uma imagem gerada por IA, em que o estímulo da falta de realismo percebido leva a que o comprador processe esta informação como uma decepção e posteriormente na desconfiança no vendedor e na plataforma, que culmina no aumento da intenção de partilhar a experiência negativa *online*, como teorizado através do modelo SOR. Em relação às restantes questões de investigação, relativas às variáveis moderadoras, confirmou-se que apenas a responsabilidade percebida da plataforma tem um efeito moderador significativo,

mostrando que a percepção de maior responsabilidade da plataforma aumenta a transferência de desconfiança do vendedor para a mesma.

Concluindo, a presente investigação sugere fortes evidências de que as imagens geradas por IA têm um efeito negativo para as plataformas P2P-SM. O modelo propõe e estabelece relações que ainda não foram abordadas na literatura, não havendo estudos anteriores suficientes para estabelecer comparações diretas com os presentes resultados.

6.3. Contributos Acadêmicos

O presente estudo contribuiu para abordar as lacunas presentes na literatura através de um modelo conceptual com relações entre variáveis que ainda não tinham sido exploradas até à data. A partir deste modelo, provou-se que, no contexto do mercado *online* de segunda-mão, as imagens de roupa geradas por IA são percebidas como pouco realistas, o que espoleta a percepção de decepção no comprador, desenvolvendo um sentimento de desconfiança face ao vendedor que se transfere também para a plataforma, resultando na intenção de eWOM negativo relativamente a esta última entidade, constituindo novos *insights* para a literatura. Além destas relações, foi também provada estatisticamente a moderação positiva da variável RPP no efeito de transferência de desconfiança no vendedor para a plataforma, que agrava o sentimento face a esta última. Este é um efeito ainda pouco explorado, tal como o construto da desconfiança, contribuindo esta investigação para complementar a literatura que adota a visão bidimensional da confiança-desconfiança. O comportamento do consumidor do *mercado online* de segunda-mão revela-se ainda pouco explorado, pelo que este estudo permitiu alargar o conhecimento teórico neste domínio, contribuindo também para a temática emergente e rapidamente em desenvolvimento da IA.

6.4. Contributos Práticos

Relativamente aos contributos práticos, esta investigação permite ajudar as empresas que detêm as plataformas P2P-SM a compreenderem melhor as relações entre comprador, vendedor e plataforma, e também o comportamento do comprador e possíveis consequências associadas à sua decepção. A relevância da variável moderadora RPP como agravadora da transferência de desconfiança no vendedor para a plataforma, mostra a esta que a sua responsabilidade perante o consumidor passa não só pela resolução de incidentes e intermediação passiva nas transações, mas também pela identificação e regulação do conteúdo visual anunciado nesta, de forma a não contarem apenas com a

denúncia por parte dos utilizadores que reconhecem o conteúdo de IA para tomar ações relativamente a estes anúncios. É de urgente importância que as plataformas atualizem os seus termos e condições de uso para refletirem o avanço tecnológico e abranjam as novas práticas observadas nos seus vendedores. O desenvolvimento de tecnologias passíveis de serem utilizadas para enganar os compradores deve ser acompanhado de perto pelas plataformas, sob o risco de utilizadores terceiros mancharem a sua reputação e denegrirem a experiência do comprador.

O acompanhamento do conteúdo visual submetido deve ser feito de início, tendo a plataforma a responsabilidade de rotular as imagens como geradas por IA caso os seus vendedores não o façam. Os resultados heterogêneos à escala da variável Realismo Percebido permitem concluir que os indivíduos percecionam as imagens geradas por IA de forma divisiva, em que muitos acreditam que esta é uma representação fiel da peça em segunda-mão quando, na verdade, é uma reprodução pouco fiável. Sugere-se então que a plataforma deve informar os seus clientes de que as imagens destes anúncios não são fotorrealistas e que a IA pode distorcer o aspeto verdadeiro da peça.

De forma a mitigar a intenção de eWOM negativo por parte do comprador, a plataforma pode ainda incluir, nos seus mecanismos de denúncia, uma opção que permita denunciar diretamente o anúncio com imagens geradas por IA como uma violação da legislação europeia (AI Act) ou como imagens falsificadas ou fraudulentas. Além disso, é importante que a plataforma garanta que as suas denúncias são corretamente processadas e que existam consequências negativas para os utilizadores que sejam denunciados.

6.5. Limitações e Sugestões de Pesquisa Futura

A amostragem não-probabilística por conveniência e bola de neve constitui uma das principais limitações do estudo ao impedir a generalização dos resultados obtidos. Desta forma, a amostra não é representativa da população, pelo seu número reduzido de respostas válidas e por ser constituída maioritariamente jovens estudantes de ensino superior. O estudo pode estar sujeito a enviesamentos por esta razão. Seria interessante, no futuro, abordar esta investigação numa vertente geracional, onde se comparam as diferentes reações de cada uma destas às variáveis em estudo.

Este estudo teve uma abordagem de pesquisa dedutiva, tendo sido escolhida uma metodologia quantitativa, o que permitiu validar a maioria das hipóteses, mas que falhou

em validar sobretudo os efeitos moderadores. Sugere-se, numa pesquisa futura, abordar esta temática de forma qualitativa de forma a apurar diferentes variáveis moderadoras que possam influenciar cada um destes construtos, bem como os antecedentes aos mesmos.

Este estudo focou-se apenas na fase de pré-compra do utilizador de plataformas P2P-SM, o que levou a conclusões ligadas às consequências para a plataforma enquanto marca, sendo alvo de eWOM negativo. Seria também interessante, numa investigação futura, abordar a fase de pós-compra, onde o cliente compra um artigo anunciado com imagens geradas por IA, e onde se podem investigar respostas como a lealdade, o abandono da plataforma, a intenção de recompra, de denúncia do vendedor ou até de reclamação da plataforma.

Outra limitação do estudo é o foco no utilizador da plataforma P2P-SM como apenas comprador. Pela natureza da plataforma, qualquer utilizador pode assumir o papel de comprador, vendedor ou ambos. Uma sugestão de pesquisa futura passa por adicionar uma outra variável que abranja o papel do utilizador e compare as diferenças de perceção de cada um destes perfis.

7. REFERÊNCIAS

- Aditya, R. N. (2001). The psychology of deception in marketing: A conceptual framework for research and practice. *Psychology & Marketing*, 18(7), 735–761. <https://doi.org/10.1002/mar.1028>
- Alayhya, M., Agag, G., Aliedan, M., & Abdelmoety, Z. H. (2023). Understanding the factors affecting consumers' behaviour when purchasing refurbished products: A chaotic perspective. *Journal of Retailing and Consumer Services*, 75, 103492. <https://doi.org/10.1016/j.jretconser.2023.103492>
- Arnould, E. J., & Rose, A. S. (2016). Mutuality: Critique and substitute for Belk's "sharing". *Marketing Theory*, 16(1), 75–99. <https://doi.org/10.1177/1470593115572669>
- Belanche, D., Ibáñez-Sánchez, S., Jordán, P., & Matas, S. (2025). Customer reactions to generative AI vs. Real images in high-involvement and hedonic services. *International Journal of Information Management*, 85, 102954. <https://doi.org/10.1016/j.ijinfomgt.2025.102954>
- Belk, R. (2007). Why not share rather than own? *The ANNALS of the American Academy of Political and Social Science*, 611(1), 126–140. <https://doi.org/10.1177/0002716206298483>
- Belk, R. (2014). You are what you can access: Sharing and collaborative consumption online. *Journal of Business Research*, 67(8), 1595–1600. <https://doi.org/10.1016/j.jbusres.2013.10.001>
- Bhandari, M., Rodgers, S., & Pan, P.-L. (2021). Brand feedback to negative eWOM messages: Effects of stability and controllability of problem causes on brand attitudes and purchase intentions. *Telematics and Informatics*, 58, 101522. <https://doi.org/10.1016/j.tele.2020.101522>
- Brüns, J. D., & Meißner, M. (2024). Do you create your content yourself? Using generative artificial intelligence for social media content creation diminishes perceived brand authenticity. *Journal of Retailing and Consumer Services*, 79, 103790. <https://doi.org/10.1016/j.jretconser.2024.103790>
- Bueno, S., & Gallego, M. D. (2021). eWOM in C2C platforms: combining iam and customer satisfaction to examine the impact on purchase intention. *Journal of Theoretical and Applied Electronic Commerce Research*, 16(5), 1612–1630. <https://doi.org/10.3390/jtaer16050091>
- Butler, S. (2023). *Online marketplaces report surge in sales of secondhand goods*. The Guardian. <https://www.theguardian.com/business/2023/nov/29/online-marketplaces-report-surge-in-sales-of-secondhand-goods>
- Campbell, C., Plangger, K., Sands, S., Kietzmann, J., & Bates, K. (2022). How deepfakes and artificial intelligence could reshape the advertising industry: the coming reality of ai fakes

- and their potential impact on consumer behavior. *Journal of Advertising Research*, 62(3), 241–251. <https://doi.org/10.2501/JAR-2022-017>
- Carolus, A., Koch, M. J., Straka, S., Latoschik, M. E., & Wienrich, C. (2023). MAILS - Meta AI literacy scale: Development and testing of an AI literacy questionnaire based on well-founded competency models and psychological change- and meta-competencies. *Computers in Human Behavior: Artificial Humans*, 1(2), 100014. <https://doi.org/10.1016/j.chbah.2023.100014>
- CE Noticias Financieras. (2025). *Vinted scams: low-quality clothes from Temu and Shein found to be selling for three times their price on the app*. <https://www.proquest.com/wire-feeds/vinted-scams-low-quality-clothes-temu-shein-found/docview/3282539843/se-2>
- Chaisatitkul, A., Luangngamkhum, K., Noulpum, K., & Kerdvibulvech, C. (2024). The power of AI in marketing: Enhancing efficiency and improving customer perception through AI-generated storyboards. *International Journal of Information Technology*, 16(1), 137–144. <https://doi.org/10.1007/s41870-023-01661-5>
- Chang, Y.-S., & Fang, S.-R. (2013). Antecedents and distinctions between online trust and distrust: Predicting high- and low-risk Internet behaviors. *Journal of Electronic Commerce Research*, 14(2), 149–166.
- Chaudhuri, N., Gupta, G., & Lim, W. M. (2026). A stimulus-organism-response eye-tracking survey of how background-foreground images drive image appeal, product perception, and willingness to pay in e-commerce. *Journal of Retailing and Consumer Services*, 88, 104508. <https://doi.org/10.1016/j.jretconser.2025.104508>
- Chen, J., Zhang, C., & Xu, Y. (2009). The role of mutual trust in building members' loyalty to a C2C platform provider. *International Journal of Electronic Commerce*, 14(1), 147–171. <https://doi.org/10.2753/JEC1086-4415140105>
- Cheng, Y., & Chen, Z. F. (2021). Encountering misinformation online: Antecedents of trust and distrust and their impact on the intensity of Facebook use. *Online Information Review*, 45(2), 372–388. <https://doi.org/10.1108/OIR-04-2020-0130>
- Darke, P. R., & Ritchie, R. J. B. (2007). The defensive consumer: advertising deception, defensive processing, and distrust. *Journal of Marketing Research*, 44(1), 114–127. <https://doi.org/10.1509/jmkr.44.1.114>
- Demsar, V., Ferraro, C., Sands, S., & Kohn, A. (2025). Harmony or discord? The intersection of generative AI and human creativity in advertising. *Journal of Advertising Research*, 65(2), 150–166. <https://doi.org/10.1080/00218499.2025.2464305>
- Dwivedi, Y. K., Kshetri, N., Hughes, L., Slade, E. L., Jeyaraj, A., Kar, A. K., Baabdullah, A. M., Koohang, A., Raghavan, V., Ahuja, M., Albanna, H., Albashrawi, M. A., Al-Busaidi, A. S., Balakrishnan, J., Barlette, Y., Basu, S., Bose, I., Brooks, L., Buhalis, D., ... Wright, R. (2023). Opinion Paper: “So what if ChatGPT wrote it?” Multidisciplinary perspectives

- on opportunities, challenges and implications of generative conversational AI for research, practice and policy. *International Journal of Information Management*, 71, 102642. <https://doi.org/10.1016/j.ijinfomgt.2023.102642>
- European Union. (2025). *The EU Artificial Intelligence Act*. The Artificial Intelligence Act. <https://artificialintelligenceact.eu/>
- Grazioli, S., & Jarvenpaa, S. (2003). Consumer and business deception on the internet: content analysis of documentary evidence. *International Journal of Electronic Commerce*, 7(4), 93–118. <https://doi.org/10.1080/10864415.2003.11044283>
- Grazioli, S., & Jarvenpaa, S. L. (2000). Perils of internet fraud: An empirical investigation of deception and trust with experienced internet consumers. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 30(4), 395–410. <https://doi.org/10.1109/3468.852434>
- Grüner, A., Postel, L., & Schumann, J. H. (2024). Sharing is caring? The effect of negative peer-to-peer experiences on loyalty intentions in the sharing economy. *Journal of Business Research*, 181, 114757. <https://doi.org/10.1016/j.jbusres.2024.114757>
- Hair, J. F., Ringle, C. M., & Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. *Journal of Marketing Theory and Practice*, 19(2), 139–152. <https://doi.org/10.2753/MTP1069-6679190202>
- Hanson, S., Carlson, J., & Pressler, H. (2025). The differential impact of AI salience on advertising engagement and attitude: scary good AI advertising. *Journal of Advertising Research*, 65(2), 190–201. <https://doi.org/10.1080/00218499.2025.2464307>
- Hartmann, J., Exner, Y., & Domdey, S. (2025). The power of generative marketing: Can generative AI create superhuman visual marketing content? *International Journal of Research in Marketing*, 42(1), 13–31. <https://doi.org/10.1016/j.ijresmar.2024.09.002>
- Hausken, L. (2024). Photorealism versus photography. AI-generated depiction in the age of visual disinformation. *Journal of Aesthetics & Culture*, 16(1), 2340787. <https://doi.org/10.1080/20004214.2024.2340787>
- Hennig-Thurau, T., Gwinner, K. P., Walsh, G., & Gremler, D. D. (2004). Electronic word-of-mouth via consumer-opinion platforms: What motivates consumers to articulate themselves on the Internet? *Journal of Interactive Marketing*, 18(1), 38–52. <https://doi.org/10.1002/dir.10073>
- Hou, F., & Jansen, S. (2023). A systematic literature review on trust in the software ecosystem. *Empirical Software Engineering*, 28(1), 8. <https://doi.org/10.1007/s10664-022-10238-y>
- Huang, M.-H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49(1), 30–50. <https://doi.org/10.1007/s11747-020-00749-9>

- Huh, J., Nelson, M. R., & Russell, C. A. (2023). ChatGPT, AI advertising, and advertising research and education. *Journal of Advertising*, 52(4), 477–482. <https://doi.org/10.1080/00913367.2023.2227013>
- Huurne, M. ter, Ronteltap, A., Corten, R., & Buskens, V. (2017). Antecedents of trust in the sharing economy: A systematic review. *Journal of Consumer Behaviour*, 16(6), 485–498. <https://doi.org/10.1002/cb.1667>
- Ilmalhaq, A., Pradana, M., & Rubiyanti, N. (2024). Indonesian local second-hand clothing: Mindful consumption with stimulus-organism-response (SOR) model. *Discover Sustainability*, 5(1), 251. <https://doi.org/10.1007/s43621-024-00481-2>
- Islam, T., Miron, A., Nandy, M., Choudrie, J., Liu, X., & Li, Y. (2024). Transforming digital marketing with generative AI. *Computers*, 13(7), 168. <https://doi.org/10.3390/computers13070168>
- Jin, X., Wang, B., & Ma, N. (2025). Distrust spillover in sharing accommodation: Evidence from Airbnb in Beijing. *Sage Open*, 15(1), 21582440251316146. <https://doi.org/10.1177/21582440251316146>
- Jones, K., & Leonard, L. N. K. (2014). Factors influencing buyer's trust in consumer-to-consumer e commerce. *Journal of Computer Information Systems*, 54(4), 71–79. <https://doi.org/10.1080/08874417.2014.11645724>
- Karpinska-Krakiwicz, M. (Mags), & Eisend, M. (2025). Realistic portrayals of untrue information: The effects of deepfaked ads and different types of disclosures. *Journal of Advertising*, 54(3), 432–442. <https://doi.org/10.1080/00913367.2024.2306415>
- Kaur, S. (2017). Do vendor cues influence purchase intention of online shoppers? An empirical study using S-O-R frame. *Journal of Internet Commerce*, 16(4), 343–363. <https://doi.org/10.1080/15332861.2017.1347861>
- Kazantsev, N., Islam, N., Zwiegelhaar, J., Brown, A., & Maull, R. (2023). Data sharing for business model innovation in platform ecosystems: From private data to public good. *Technological Forecasting and Social Change*, 192, 122515. <https://doi.org/10.1016/j.techfore.2023.122515>
- Kim, B. K., Choi, J., & Wakslak, C. J. (2019). The image realism effect: The effect of unrealistic product images in advertising. *Journal of Advertising*, 48(3), 251–270. <https://doi.org/10.1080/00913367.2019.1597787>
- Kiper, E., & Liang, Y. (2025). Do AI-generated fashion ads work as effectively as real fashion ads? An eye-tracking comparison of consumers' visual attention. *Journal of Global Fashion Marketing*, 17(1), 1–17. <https://doi.org/10.1080/20932685.2025.2548548>
- Kirk, C. P., & Givi, J. (2025). The AI-authorship effect: Understanding authenticity, moral disgust, and consumer responses to AI-generated marketing communications. *Journal of Business Research*, 186, 114984. <https://doi.org/10.1016/j.jbusres.2024.114984>

- Kline, R. B. (2015). *Principles and practice of structural equation modeling*. Guilford publications.
- Köbis, N. C., Doležalová, B., & Soraperra, I. (2021). Fooled twice: People cannot detect deepfakes but think they can. *iScience*, 24(11), 103364. <https://doi.org/10.1016/j.isci.2021.103364>
- Kramer, R. M. (1999). Trust and distrust in organizations: Emerging Perspectives, enduring questions. *Annual Review of Psychology*, 50(1), 569–598. <https://doi.org/10.1146/annurev.psych.50.1.569>
- Kshetri, N., Dwivedi, Y. K., Davenport, T. H., & Panteli, N. (2024). Generative artificial intelligence in marketing: Applications, opportunities, challenges, and research agenda. *International Journal of Information Management*, 75, 102716. <https://doi.org/10.1016/j.ijinfomgt.2023.102716>
- Lee, S.-J., Ahn, C., Song, K. M., & Ahn, H. (2018). Trust and distrust in e-commerce. *Sustainability*, 10(4), 1015. <https://doi.org/10.3390/su10041015>
- Lewicki, R. J., McCallister, D. J., & Bies, R. J. (1998). Trust and distrust: new relationships and realities. *The Academy of Management Review*, 23(3), 438–458. <https://doi.org/10.2307/259288>
- Li, J., & Yuan, Q. (2026). The impact of AI-generated knowledge on user knowledge avoidance in OKCs: The moderating role of AI literacy and platform trust. *Journal of Knowledge Management*, 30(2), 584–608. <https://doi.org/10.1108/JKM-02-2025-0231>
- Liang, Y., Lee, S.-H., & Workman, J. E. (2020). Implementation of artificial intelligence in fashion: Are consumers ready? *Clothing and Textiles Research Journal*, 38(1), 3–18. <https://doi.org/10.1177/0887302X19873437>
- Liu, Q., Osman, L. H., Lian, Z., Wel, C. A. C., & Hamid, S. N. Ab. (2025). From perception to purchase: How AI literacy shapes consumer decisions in AI-generated sponsored vlogs across products and services. *Journal of Theoretical and Applied Electronic Commerce Research*, 20(4), 302. <https://doi.org/10.3390/jtaer20040302>
- Lou, X., & Copeland, L. (2025). Gen Z and AI-generated fashion ads: A qualitative study to understanding female consumer perceptions and reactions. *Journal of Internet Commerce*, 24(3), 131–152. <https://doi.org/10.1080/15332861.2025.2520194>
- Marth, S., Hartl, B., & Penz, E. (2022). Sharing on platforms: Reducing perceived risk for peer-to-peer platform consumers through trust building and regulation. *Journal of Consumer Behaviour*, 21(6), 1255–1267. <https://doi.org/10.1002/cb.2075>
- McKnight, D. H., Kacmar, C. J., & Choudhury, V. (2004). Dispositional trust and distrust distinctions in predicting high- and low-risk internet expert advice site perceptions. *e-Service Journal*, 3(2), 35–58.

- Miller, G.R. (1983). Telling it like it isn't and not telling it like it is: Some thoughts on deceptive communication. *J. Sisco (Ed.), The Jensen lectures: Contemporary communication studies*.
- Min, H., & Zickar, M. J. (2023). The development and validation of an interpersonal distrust scale. *Journal of Business and Psychology, 38*(5), 1099–1120. <https://doi.org/10.1007/s10869-022-09854-8>
- Miskolczi, M. (2026). The illusion of reality: How AI-generated images (AIGIs) are fooling social media users. *Computers in Human Behavior, 176*, 108876. <https://doi.org/10.1016/j.chb.2025.108876>
- Mohammad, J., Quoquab, F., & Mohamed Sadom, N. Z. (2021). Mindful consumption of second-hand clothing: The role of eWOM, attitude and consumer engagement. *Journal of Fashion Marketing and Management: An International Journal, 25*(3), 482–510. <https://doi.org/10.1108/JFMM-05-2020-0080>
- Moody, G. D., Galletta, D. F., & Lowry, P. B. (2014). When trust and distrust collide online: The engenderment and role of consumer ambivalence in online consumer behavior. *Electronic Commerce Research and Applications, 13*(4), 266–282. <https://doi.org/10.1016/j.elerap.2014.05.001>
- Moody, G. D., Lowry, P. B., & Galletta, D. F. (2017). It's complicated: Explaining the relationship between trust, distrust, and ambivalence in online transaction relationships using polynomial regression analysis and response surface analysis. *European Journal of Information Systems, 26*(4), 379–413. <https://doi.org/10.1057/s41303-016-0027-9>
- Moon, H., Wei, W., & Miao, L. (2019). Complaints and resolutions in a peer-to-peer business model. *International Journal of Hospitality Management, 81*, 239–248. <https://doi.org/10.1016/j.ijhm.2019.04.026>
- Moriuchi, E., & Takahashi, I. (2022). The role of perceived value, trust and engagement in the C2C online secondary marketplace. *Journal of Business Research, 148*, 76–88. <https://doi.org/10.1016/j.jbusres.2022.04.029>
- Murtas, G., & Pedeliento, G. (2025). Investigating the customer journey in second-hand fashion platforms: Implications for luxury brand management. *Journal of Consumer Behaviour, 24*(2), 655–672. <https://doi.org/10.1002/cb.2442>
- Mustak, M., Salminen, J., Mäntymäki, M., Rahman, A., & Dwivedi, Y. K. (2023). Deepfakes: Deceptions, mitigations, and opportunities. *Journal of Business Research, 154*, 113368. <https://doi.org/10.1016/j.jbusres.2022.113368>
- Negash, Y. T., & Akhbar, T. (2024). Building consumer trust in secondhand fashion: A signaling theory perspective on how consumer orientation and environmental awareness shape engagement. *Cleaner and Responsible Consumption, 14*, 100211. <https://doi.org/10.1016/j.clrc.2024.100211>

- Osadchaya, E., Marder, B., Yule, J. A., Yau, A., Lavertu, L., Stylos, N., Oliver, S., Angell, R., Regt, A. D., Gao, L., Qi, K., Zhang, W. Z., Zhang, Y., Li, J., & AlRabiah, S. (2024). To ChatGPT, or not to ChatGPT: Navigating the paradoxes of generative AI in the advertising industry. *Business Horizons*, 67(5), 571–581. <https://doi.org/10.1016/j.bushor.2024.05.002>
- Pallant, J. (2010). *SPSS Survival Manual: A Step by Step Guide to Data Analysis Using SPSS* (4th ed (Online-Ausg.)). McGraw-Hill Education.
- Park, S., & Tussyadiah, I. P. (2020). How guests develop trust in hosts: An Investigation of trust formation in P2P accommodation. *Journal of Travel Research*, 59(8), 1402–1412. <https://doi.org/10.1177/0047287519884654>
- Perren, R., & Kozinets, R. V. (2018). Lateral exchange markets: How social platforms operate in a networked economy. *Journal of Marketing*, 82(1), 20–36. <https://doi.org/10.1509/jm.14.0250>
- Plouffe, C. R. (2008). Examining “peer-to-peer” (P2P) systems as consumer-to-consumer (C2C) exchange. *European Journal of Marketing*, 42(11/12), 1179–1202. <https://doi.org/10.1108/03090560810903637>
- Pollay, R. (1986). The distorted mirror: Reflections on the unintended consequences of advertising. *Journal of Marketing*, 50(2), 18–36. <https://doi.org/https://doi.org/10.1353/asr.2000.0012>
- Reimann, M., Schilke, O., & Cook, K. S. (2017). Trust is heritable, whereas distrust is not. *Proceedings of the National Academy of Sciences*, 114(27), 7007–7012. <https://doi.org/10.1073/pnas.1617132114>
- Riquelme, I. P., & Román, S. (2014). The relationships among consumers’ ethical ideology, risk aversion and ethically-based distrust of online retailers and the moderating role of consumers’ need for personal interaction. *Ethics and Information Technology*, 16(2), 135–155. <https://doi.org/10.1007/s10676-014-9341-x>
- Riquelme, I. P., Román, S., & Iacobucci, D. (2016). Consumers’ perceptions of online and offline retailer deception: A moderated mediation analysis. *Journal of Interactive Marketing*, 35(1), 16–26. <https://doi.org/10.1016/j.intmar.2016.01.002>
- Robles, V. D. (2019). Caveat emptor: How lay technical and professional communicators sell technical products in C2C e-commerce. *IEEE Transactions on Professional Communication*, 62(4), 364–384. <https://doi.org/10.1109/TPC.2019.2946940>
- Román, S. (2010). Relational consequences of perceived deception in online shopping: The moderating roles of type of product, consumer’s attitude toward the internet and consumer’s demographics. *Journal of Business Ethics*, 95(3), 373–391. <https://doi.org/10.1007/s10551-010-0365-9>

- Román, S., & Ruiz, S. (2005). Relationship outcomes of perceived ethical sales behavior: The customer's perspective. *Journal of Business Research*, 58(4), 439–445. <https://doi.org/10.1016/j.jbusres.2003.07.002>
- Saponaro, M., Le Gal, D., Gao, M., Guisiano, M., & Maniere, I. C. (2018). Challenges and opportunities of artificial intelligence in the fashion world. *2018 International Conference on Intelligent and Innovative Computing Applications (ICONIC)*, 1–5. <https://doi.org/10.1109/ICONIC.2018.8601258>
- Sarstedt, M., & Mooi, E. (2019). *A Concise Guide to Market Research: The Process, Data, and Methods Using IBM SPSS Statistics*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-662-56707-4>
- Saunders, M., Lewis, P., & Thornhill, A. (2023). *Research methods for business students* (9th ed.). Pearson Education Limited.
- Schoorman, F. D., Mayer, R. C., & Davis, J. H. (2007). An integrative model of organizational trust: Past, present, and future. *The Academy of Management Review*, 32(2), 344–354. <http://www.jstor.org/stable/20159304>
- Shi, W., Wong, W., & Zou, X. (2025). Generative AI in Fashion: Overview. *ACM Transactions on Intelligent Systems and Technology*, 3718098. <https://doi.org/10.1145/3718098>
- Sitkin, S. B., & Roth, N. L. (1993). Explaining the limited effectiveness of legalistic “remedies” for trust/ distrust. *Organization Science*, 4(3), 367–392. <http://www.jstor.org/stable/2634950>
- Slaton, K. (2025). Company-controlled vs. seller-controlled resale platforms: Consumer trust, risk, and purchase intention in circular fashion. *Sustainability*, 17(21), 9847. <https://doi.org/10.3390/su17219847>
- Stanaland, A. J. S., Lwin, M. O., & Murphy, P. E. (2011). Consumer perceptions of the antecedents and consequences of corporate social responsibility. *Journal of Business Ethics*, 102(1), 47–55. <https://doi.org/10.1007/s10551-011-0904-z>
- Statista. (2026a). *Revenue of the second-hand e-commerce market in the Europe from 2019 to 2030, by category (in billion U.S. dollars)*. <https://www.statista.com/statistics/1412517/europe-second-hand-e-commerce-revenue-category/>
- Statista. (2026b). *Most popular online stores in the fashion segment in Portugal in 2025, by e-commerce net sales (in million U.S. dollars)*. <https://www.statista.com/statistics/988473/top-online-stores-portugal-fashion-ecommercedb/>
- Stewart, K. J. (2003). Trust transfer on the world wide web. *Organization Science*, 14(1), 5–17. <https://doi.org/10.1287/orsc.14.1.5.12810>

- Sthapit, E., Prayag, G., Rasoolimanesh, S. M., & Björk, P. (2025). Value co-destruction in Airbnb: Antecedents and outcomes. *Journal of Vacation Marketing*, 31(3), 647–664. <https://doi.org/10.1177/13567667231223556>
- Styvén, M., & Mariani, M. M. (2020). Understanding the intention to buy secondhand clothing on sharing economy platforms: The influence of sustainability, distance from the consumption system, and economic motivations. *Psychology & Marketing*, 37(5), 724–739. <https://doi.org/10.1002/mar.21334>
- Tang, Y., & Chen, C. (2024). Can stylized products generated by AI better attract user attention? Using eye-tracking technology for research. *Applied Sciences*, 14(17), 7729. <https://doi.org/10.3390/app14177729>
- Teoh, F. (2025). *What you see is (not) what you get: genAI-powered scams on Vinted*. Science Feedback. <https://science.feedback.org/genai-powered-dropshipping-scams-vinted/>
- Teo, T., & Liu, J. (2007). Consumer trust in e-commerce in the United States, Singapore and China. *Omega*, 35(1), 22–38. <https://doi.org/10.1016/j.omega.2005.02.001>
- ThredUp. (2026). *Resale Report 2025*. <https://www.thredup.com/resale>
- Tully, S. M., Longoni, C. & Appel, G. (2025). Lower artificial intelligence literacy predicts greater AI receptivity. *Journal of Marketing*, 89(5), 1-20. <https://doi.org/10.1177%2F00222429251314491>
- Ūsas, A., Jasinskas, E., & Štreimikienė, D. (2024). Impact of website quality and user satisfaction on consumer loyalty in Lithuanian C2C e-commerce platforms. *Management & Marketing*, 19(4), 710–724. <https://doi.org/10.2478/mmcks-2024-0032>
- Velásquez-Salamanca, D., Martín-Pascual, M. Á., & Andreu-Sánchez, C. (2025). Interpretation of AI-generated vs. human-made images. *Journal of Imaging*, 11(7), 227. <https://doi.org/10.3390/jimaging11070227>
- Vinted (2026). *Regras do catálogo*. <https://www.vinted.pt/catalog-rules>
- Wang, C., Boerman, S. C., Kroon, A. C., Möller, J., & H De Vreese, C. (2025). The artificial intelligence divide: Who is the most vulnerable? *New Media & Society*, 27(7), 3867–3889. <https://doi.org/10.1177/14614448241232345>
- Wu, K., Vassileva, J., Zhao, Y., Noorian, Z., Waldner, W., & Adaji, I. (2016). Complexity or simplicity? Designing product pictures for advertising in online marketplaces. *Journal of Retailing and Consumer Services*, 28, 17–27. <https://doi.org/10.1016/j.jretconser.2015.08.009>
- Wu, L., & Wen, T. J. (2021). Understanding AI advertising from the consumer perspective: What factors determine consumer appreciation of AI-created advertisements? *Journal of Advertising Research*, 61(2), 133–146. <https://doi.org/10.2501/JAR-2021-004>
- Wu, L., Liu, S. & Ma, S. & Hanks, L. (2023). Platform-centric vs. multi-party service failure: an examination of consumers’ negative word of mouth about sharing economy platforms.

- International Journal of Contemporary Hospitality Management*, 35(4), 1332-1375.
<https://doi.org/10.1108/ijchm-12-2021-1559>.
- Xia, H., Pan, X., Zhou, Y., & Zhang, Z. (Justin). (2020). Creating the best first impression: Designing online product photos to increase sales. *Decision Support Systems*, 131, 113235. <https://doi.org/10.1016/j.dss.2019.113235>
- Xiao, B., & Benbasat, I. (2011). Product-related deception in e-commerce: A theoretical perspective. *MIS Quarterly*, 35(1), 169–195. <https://doi.org/10.2307/23043494>
- Yang, F., Abedin, M. Z., Qiao, Y., & Ye, L. (2024). Toward trustworthy governance of AI-generated content (AIGC): A blockchain-driven regulatory framework for secure digital ecosystems. *IEEE Transactions on Engineering Management*, 71, 14945–14962. <https://doi.org/10.1109/TEM.2024.3472292>
- Yu, T., Pan, Y., & Jang, W. (2025). Modeling consumer reactions to AI-generated content on e-commerce platforms: A trust–risk dual pathway framework with ethical and platform responsibility moderators. *Journal of Theoretical and Applied Electronic Commerce Research*, 20(4), 257. <https://doi.org/10.3390/jtaer20040257>
- Zhai, X., Nyaaba, M. and Ma, W. (2024), “Can generative AI and ChatGPT outperform humans on cognitive-demanding problem-solving tasks in science?”, *Science & Education*, 34, 1-22. <https://doi.org/10.1007/s11191-024-00496-1>
- Zhang, L., & Hur, C. (2025). The impact of generative AI images on consumer attitudes in advertising. *Administrative Sciences*, 15(10), 395. <https://doi.org/10.3390/admsci15100395>
- Zhang, L., Wang, X., Majeed, S., & Zhou, Z. (2025). How do sales promotions, communication agents, and psychological contracts determine purchase hesitation? Evidence from live stream influencers’ fan groups. *Journal of Retailing and Consumer Services*, 84, 104193. <https://doi.org/10.1016/j.jretconser.2024.104193>
- Zhao, H., Jiang, L., & Su, C. (2020). To defend or not to defend? How responses to negative customer review affect prospective customers’ distrust and purchase intention. *Journal of Interactive Marketing*, 50(1), 45–64. <https://doi.org/10.1016/j.intmar.2019.11.001>
- Zhao, J.-D., Huang, J.-S., & Su, S. (2019). The effects of trust on consumers’ continuous purchase intentions in C2C social commerce: A trust transfer perspective. *Journal of Retailing and Consumer Services*, 50, 42–49. <https://doi.org/10.1016/j.jretconser.2019.04.014>
- Zhao, S., Fang, Y., Zhang, W., & Jiang, H. (2020). Trust, perceived benefit, and purchase intention in C2C e-commerce: an empirical examination in China. *Journal of Global Information Management*, 28(1), 121–141. <https://doi.org/10.4018/JGIM.2020010107>

ANEXOS

Anexo A – Inquérito

0%

100%

ISEG

Lisbon School of Economics & Management

UNIVERSIDADE DE LISBOA

Português

O presente questionário faz parte de uma investigação académica sobre **imagens de roupa geradas por inteligência artificial (IA) em plataformas de compra e venda de artigos em segunda-mão**. A participação é voluntária, anónima e confidencial, sendo os dados apenas utilizados para fins académicos. Não existem respostas certas ou erradas. O tempo estimado de preenchimento é de cerca de 7 minutos. Obrigada pela sua colaboração!

Aceita participar e confirma ter 18 anos ou mais?

☐ Sim, aceito participar e confirmo ter 18 anos ou mais.

☐ Não aceito participar.

→

0%

100%

ISEG

Lisbon School of Economics & Management

UNIVERSIDADE DE LISBOA

Português

Por favor, indique a sua experiência com plataformas online de compra e venda de roupa em segunda-mão.

Já alguma vez visitou uma plataforma *online* de compra e venda de roupa em segunda-mão (ex: Vinted, OLX, Wallapop, Depop)?

☐ Sim

☐ Não

→

Português

Com que frequência utiliza estas plataformas?

☐ Nunca

☐ Raramente (menos de 1 vez por mês)

☐ Às vezes (1 a 3 vezes por mês)

☐ Frequentemente (mais de 3 vezes por mês)

→

0%

100%

ISEG

Lisbon School of Economics & Management

UNIVERSIDADE DE LISBOA

Português

Qual é o principal motivo que o/a leva a procurar roupa em segunda-mão nestas plataformas?

☐ Preço mais baixo

☐ Sustentabilidade / consumo consciente

☐ Encontrar peças únicas ou vintage

☐ Conveniência

☐ Outro (especifique):

Que plataforma(s) utiliza habitualmente?

☐ Vinted

☐ OLX

☐ Wallapop

☐ Facebook Marketplace

☐ Depop

☐ Outra (especifique):

Ao avaliar um anúncio de um artigo de roupa em segunda-mão numa plataforma online, qual a importância que atribui às imagens do artigo?

Nada importante

☐ ☐ ☐ ☐ ☐

Muito importante

→

Imagens de Roupa em Segunda-Mão Geradas por IA em P2P:
Realismo, Deceção, Desconfiança e eWOM Negativo

0%100%



Português

Para lhe ser atribuída uma imagem mais adequada para as perguntas seguintes, indique o género com o qual mais se identifica.

☐ Feminino

☐ Masculino

☐ Não-binário / Outro

☐ Prefiro não responder



Português

Por favor, observe com atenção a imagem abaixo. Esta **imagem foi gerada por Inteligência Artificial (IA)** e foi retirada de um anúncio real publicado na plataforma Vinted, onde um vendedor publicita uma **camisola em segunda-mão**. Tenha esta imagem presente ao responder às questões seguintes.



Confirma que visualizou a imagem apresentada acima?

☐ Sim

☐ Não

Com base na **imagem gerada por IA** apresentada anteriormente, indique o seu grau de concordância com cada uma das afirmações abaixo (1 = Discordo Totalmente; 7 = Concordo Totalmente).

	1. Discordo totalmente	2. Discordo	3. Discordo parcialmente	4. Nem concordo nem discordo	5. Concordo parcialmente	6. Concordo	7. Concordo totalmente
Os elementos visuais da imagem de roupa gerada por IA são realistas .	☐	☐	☐	☐	☐	☐	☐
A imagem gerada por IA representa o artigo de roupa de forma realista .	☐	☐	☐	☐	☐	☐	☐
Considero que os elementos de produção (ex: peças de roupa, acessórios, cenário, modelo) da imagem gerada por IA são, no geral, realistas .	☐	☐	☐	☐	☐	☐	☐
A imagem gerada por IA apresenta uma representação coerente do artigo de roupa.	☐	☐	☐	☐	☐	☐	☐
O artigo de roupa na imagem gerada por IA é apresentado de forma consistente .	☐	☐	☐	☐	☐	☐	☐
Alguns aspectos da imagem gerada por IA contradizem-se entre si.	☐	☐	☐	☐	☐	☐	☐

Com base na **imagem gerada por IA** apresentada anteriormente, indique o seu grau de concordância com cada uma das afirmações abaixo (1 = Discordo Totalmente; 7 = Concordo Totalmente).

	1. Discordo totalmente	2. Discordo	3. Discordo parcialmente	4. Nem concordo nem discordo	5. Concordo parcialmente	6. Concordo	7. Concordo totalmente
A imagem gerada por IA exagera as características e o estado do artigo de roupa .	☐	☐	☐	☐	☐	☐	☐
A imagem gerada por IA utiliza representações enganosas para convencer-me a comprar o artigo.	☐	☐	☐	☐	☐	☐	☐
A imagem gerada por IA não é totalmente fiel ao estado real do artigo de roupa.	☐	☐	☐	☐	☐	☐	☐
A imagem gerada por IA tenta persuadir-me a comprar um artigo que poderá não corresponder às minhas expectativas .	☐	☐	☐	☐	☐	☐	☐

Imagens de Roupa em Segunda-Mão Geradas por IA em P2P:
Realismo, Deceção, Desconfiança e eWOM Negativo

Suponha que tem interesse na peça de roupa apresentada. Com base na **imagem gerada por IA** apresentada anteriormente, indique o seu grau de concordância com cada uma das afirmações abaixo (1 = Discordo Totalmente; 7 = Concordo Totalmente).

	1. Discordo totalmente	2. Discordo	3. Discordo parcialmente	4. Nem concordo nem discordo	5. Concordo parcialmente	6. Concordo	7. Concordo totalmente
Receio que o vendedor não me enviará o artigo de roupa igual à imagem gerada por IA.	☐	☐	☐	☐	☐	☐	☐
Preocupa-me que o vendedor possa não se importar com a minha compra.	☐	☐	☐	☐	☐	☐	☐
Suspeito que o vendedor vá reagir ao meu interesse no artigo com más Intenções .	☐	☐	☐	☐	☐	☐	☐

Suponha que tem interesse na peça de roupa apresentada. Com base na **imagem gerada por IA** apresentada anteriormente, indique o seu grau de concordância com cada uma das afirmações abaixo (1 = Discordo Totalmente; 7 = Concordo Totalmente).

	1. Discordo totalmente	2. Discordo	3. Discordo parcialmente	4. Nem concordo nem discordo	5. Concordo parcialmente	6. Concordo	7. Concordo totalmente
Partilharia uma má experiência com o vendedor/plataforma em redes sociais ou num website.	☐	☐	☐	☐	☐	☐	☐
Contaria aos meus amigos nas redes sociais e websites sobre a minha insatisfação com o vendedor/plataforma .	☐	☐	☐	☐	☐	☐	☐
Informaria os meus amigos através de redes sociais e websites que o vendedor/plataforma é um mau prestador de serviços .	☐	☐	☐	☐	☐	☐	☐



Suponha que tem interesse na peça de roupa apresentada. Com base na **imagem gerada por IA** apresentada anteriormente, indique o seu grau de concordância com cada uma das afirmações abaixo (1 = Discordo Totalmente; 7 = Concordo Totalmente).

	1. Discordo totalmente	2. Discordo	3. Discordo parcialmente	4. Nem concordo nem discordo	5. Concordo parcialmente	6. Concordo	7. Concordo totalmente
Receio que a conduta empresarial da plataforma possa causar danos futuros .	☐	☐	☐	☐	☐	☐	☐
Suspeito que a plataforma possa reagir ao meu interesse no artigo com más Intenções .	☐	☐	☐	☐	☐	☐	☐
Preocupa-me que a plataforma possa não se importar com a minha compra.	☐	☐	☐	☐	☐	☐	☐
Receio que esta plataforma não seja confiável nem comprometida com os seus clientes.	☐	☐	☐	☐	☐	☐	☐
Teria receio de caracterizar esta plataforma como honesto .	☐	☐	☐	☐	☐	☐	☐
A plataforma não é de confiança nem fiável .	☐	☐	☐	☐	☐	☐	☐

Imagens de Roupa em Segunda-Mão Geradas por IA em P2P:
Realismo, Deceção, Desconfiança e eWOM Negativo

0% 100%



Português

Com base na sua **experiência com este tipo de plataforma**, indique o seu grau de concordância com cada uma das afirmações abaixo (1 = Discordo Totalmente; 7 = Concordo Totalmente).

	1. Discordo totalmente	2. Discordo	3. Discordo parcialmente	4. Nem concordo nem discordo	5. Concordo parcialmente	6. Concordo	7. Concordo totalmente
A plataforma tem a responsabilidade de informar claramente os utilizadores sobre imagens geradas por IA.	☐	☐	☐	☐	☐	☐	☐
A plataforma deve estabelecer mecanismos para monitorizar a precisão e aplicabilidade das imagens geradas por IA.	☐	☐	☐	☐	☐	☐	☐
Quando surgem problemas relacionados com imagens geradas por IA, a plataforma deve proativamente fornecer explicações .	☐	☐	☐	☐	☐	☐	☐
O facto de a plataforma assumir responsabilidade afeta a minha aceitação das imagens geradas por IA.	☐	☐	☐	☐	☐	☐	☐



Português

Com base na sua experiência com **inteligência artificial**, indique o seu grau de concordância com cada uma das afirmações abaixo (1 = Discordo Totalmente; 7 = Concordo Totalmente).

	1. Discordo totalmente	2. Discordo	3. Discordo parcialmente	4. Nem concordo nem discordo	5. Concordo parcialmente	6. Concordo	7. Concordo totalmente
Conheço os conceitos mais importantes do tema 'Inteligência Artificial' (IA) .	☐	☐	☐	☐	☐	☐	☐
Sei definir o que é IA .	☐	☐	☐	☐	☐	☐	☐
Consigo avaliar as limitações e oportunidades da utilização de IA.	☐	☐	☐	☐	☐	☐	☐
Consigo avaliar as vantagens e desvantagens da utilização de inteligência artificial.	☐	☐	☐	☐	☐	☐	☐
Consigo pensar em novas utilizações para a IA.	☐	☐	☐	☐	☐	☐	☐
Consigo imaginar possíveis utilizações futuras da IA.	☐	☐	☐	☐	☐	☐	☐



Português

Com base na sua **experiência pessoal**, indique o seu grau de concordância com cada uma das afirmações abaixo (1 = Discordo Totalmente; 7 = Concordo Totalmente).

	1. Discordo totalmente	2. Discordo	3. Discordo parcialmente	4. Nem concordo nem discordo	5. Concordo parcialmente	6. Concordo	7. Concordo totalmente
Tenho sempre cuidado em confiar nas pessoas à primeira interação .	☐	☐	☐	☐	☐	☐	☐
Quando conheço uma pessoa pela primeira vez , tendo a ficar atento(a) às suas ações.	☐	☐	☐	☐	☐	☐	☐
Suspeito sempre de novos conhecidos até que me mostrem que são confiáveis .	☐	☐	☐	☐	☐	☐	☐
Hesito em acreditar em pessoas até que provem que são confiáveis .	☐	☐	☐	☐	☐	☐	☐



Imagens de Roupas em Segunda-Mão Geradas por IA em P2P:
Realismo, Deceção, Desconfiança e eWOM Negativo



Lisbon School
of Economics
& Management
Universidade de Lisboa

Português

Por fim, preencha os seguintes dados para efeitos de
caracterização da amostra.

Idade (ex: 25):

Carateres restantes: 2

Situação profissional:

☐ Estudante

☐ Trabalhador(a)-estudante

☐ Trabalhador(a) por conta de outrem

☐ Trabalhador(a) por conta própria

☐ Desempregado(a)

☐ Reformado(a)

Habilitações literárias (nível mais elevado concluído):

☐ Inferior ao 12ºano

☐ 12ºano ou equivalente

☐ Licenciatura/Bacharelato

☐ Pós-graduação

☐ Mestrado

☐ Doutoramento

Rendimento mensal líquido individual:

☐ Não aufero rendimentos

☐ Até 500€

☐ 500€ - 1000€

☐ 1001€ - 2000€

☐ 2001€ - 3000€

☐ Mais de 3001€

☐ Prefiro não responder

Nacionalidade:

☐ Portuguesa

☐ Outra:

0%100%



Lisbon School
of Economics
& Management
Universidade de Lisboa

Agradeço a sua participação e disponibilidade.

A sua resposta foi registada.

Anexo B – Imagens utilizadas no inquérito



vintage shirt
M / 38 / 10 · Muito bom · [Vintage Dressing](#) ·
Carregado há 15 minutos
6,50 €
7,53 € Inclui Proteção do Comprador

Descrição

Fazer uma proposta

Comprar

Género feminino



vintage shirt
M / 38 / 10 · Muito bom · [Vintage Dressing](#) ·
Carregado há 15 minutos
6,50 €
7,53 € Inclui Proteção do Comprador

Descrição

Fazer uma proposta

Comprar

Género masculino



vintage shirt
M / 38 / 10 · Muito bom · [Vintage Dressing](#) ·
Carregado há 15 minutos
6,50 €
7,53 € Inclui Proteção do Comprador

Descrição

Fazer uma proposta

Comprar

Género não-binário/outro/
Preferiu não responder

Anexo C – Escalas do inquérito

Variável original	Autores	Itens escala original	Escala medição original	Variável adaptada	Itens escala adaptada
Perceived Realism	Hartmann et al. (2025)	- PR1: The visual elements of the ad are realistic - PR2: The scene in the ad is realistic - PR3: I feel that the overall production elements of the ad are realistic - PR4: The post shows a coherent advertisement - PR5: The ad portrayed in this post is consistent - PR6: Some parts of the ad are contradicting each other (reversed)	Likert de 7 pontos (1=strongly disagree; 7=strongly agree)	Realismo Percebido	RP1: Os elementos visuais da imagem de roupa gerada por IA são realistas. RP2: A imagem gerada por IA representa o artigo de roupa de forma realista. RP3: Considero que os elementos de produção da imagem gerada por IA são, no geral, realistas. RP4: A imagem gerada por IA apresenta uma representação coerente do artigo de roupa. RP5: O artigo de roupa retratado na imagem gerada por IA é apresentado de forma consistente. RP6: Alguns aspetos da imagem gerada por IA contradizem-se entre si. (<i>escala invertida</i>)
Perceived Deception	Román (2010)	- PD1: The site exaggerates the benefits and characteristics of its offerings - PD2: The site uses misleading tactics to convince consumers to buy its products - PD3: It is not entirely truthful about its offerings - PD4: This site attempts to persuade you to buy things that you do not need	Likert de 5 pontos (1=strongly disagree; 5=strongly agree)	Deceção Percebida	DEC1: A imagem gerada por IA exagera as características e o estado do artigo de roupa. DEC2: A imagem gerada por IA utiliza representações enganosas para convencer-me a comprar o artigo. DEC3: A imagem gerada por IA não é inteiramente fiel ao estado real do artigo de roupa. DEC4: A imagem gerada por IA tenta persuadir-me a comprar um artigo que poderá não corresponder às minhas expectativas.
Distrust [in Seller]	Zhao, Jiang & Su (2020)	- D1: I am afraid the seller will not offer me the right product/service. - D2: I am worried that this seller might not care about my business. - D3: I am suspicious that the seller will respond to my interest in this product/ service with vicious intentions.	Likert de 7 pontos (1=strongly disagree; 7=strongly agree)	Desconfiança no Vendedor	VEN1: Receio que o vendedor não me enviará o artigo de roupa igual à imagem gerada por IA. VEN2: Preocupa-me que o vendedor possa não se importar com a minha compra. VEN3: Suspeito que o vendedor vá responder ao meu interesse no artigo com más intenções.
Distrust in Intermediary	Lee et al. (2018)	- DI1: I feel afraid that this intermediary's business conduct may bring damage in future. - DI2: I have a suspicion that this intermediary will react to my interest in the product with malicious intention. - DI3: I am worried that this intermediary might not be interested in my business. - DI4: I am not comfortable about whether this intermediary is trustworthy and committed. - DI5: I would feel cautious about characterizing this intermediary as honest. - DI6: This intermediary is untrustworthy and unreliable.	Likert de 7 pontos (1=strongly disagree; 7=strongly agree)	Desconfiança na Plataforma	PLA1: Receio que a conduta empresarial da plataforma possa causar danos futuros. PLA2: Suspeito que a plataforma possa reagir ao meu interesse no artigo com más intenções. PLA3: Preocupa-me que a plataforma possa não se importar com a minha compra. PLA4: Receio que esta plataforma não seja confiável nem comprometida com os seus clientes. PLA5: Teria receio de caracterizar esta plataforma como honesta. PLA6: Esta plataforma não é de confiança nem fiável.

Imagens de Roupa em Segunda-Mão Geradas por IA em P2P:
Realismo, Deceção, Desconfiança e eWOM Negativo

eWOM Intention	Sthapit et al. (2025)	● NWOM1: I will share this bad Airbnb service experience online via social networking sites and mobile technology. ● NWOM2: I will tell my friends on social networking sites and mobile technology about my disappointment with the recent Airbnb service experience. ● NWOM3: I will let my friends know via social networking sites and mobile technology about Airbnb as a bad service provider.	Likert de 5 pontos (1=strongly disagree; 5=strongly agree)	Intenção de eWOM Negativo	● EWOM1: Partilharia uma má experiência com o vendedor/plataforma em redes sociais ou num website. ● EWOM2: Contaria aos meus amigos nas redes sociais e websites sobre a minha insatisfação com o vendedor/plataforma. ● EWOM3: Informaria os meus amigos através de redes sociais e websites que o vendedor/plataforma é um mau prestador de serviços.
Natural Propensity to Distrust	Lee et al. (2018)	● NPD1: I am always careful about trusting people when I first work with them. ● NPD2: When I first meet people, I have a tendency of keeping a close eye on their actions. ● NPD3: I am always suspicious about new acquaintances until they show me that I can believe them/they are reliable. ● NPD4: I hesitate to believe people until they have proved themselves to be trustworthy.	Likert de 7 pontos (1=strongly disagree; 7=strongly agree)	Propensão para Desconfiar	● PPD1: Tenho sempre cuidado em confiar nas pessoas à primeira interação. ● PPD2: Quando conheço uma pessoa pela primeira vez, tendo a ficar atento(a) às suas ações. ● PPD3: Suspeito sempre de novos conhecidos até que me mostrem que são confiáveis. ● PPD4: Hesito acreditar em pessoas até que provem que são confiáveis.
AI Literacy	Carolus et al. (2023)	● AIL1: I know the most important concepts of the topic "artificial intelligence". ● AIL2: I know definitions of artificial intelligence. ● AIL3: I can assess what the limitations and opportunities of using an AI are. ● AIL4: I can assess what advantages and disadvantages the use of an artificial intelligence entails. ● AIL5: I can think of new uses for AI. ● AIL6: I can imagine possible future uses of AI.	Likert de 11 pontos (classificar de 0 a 10 as próprias habilidades)	Literacia de IA	● LIA1: Conheço os conceitos mais importantes do tema “Inteligência Artificial”. ● LIA2: Sei definir o que é IA. ● LIA3: Consigo avaliar as limitações e oportunidades da utilização de IA. ● LIA4: Consigo avaliar as vantagens e desvantagens da utilização de inteligência artificial ● LIA5: Consigo imaginar novas utilizações para a IA ● LIA6: Consigo imaginar possíveis utilizações futuras da IA.
Perceived Platform Responsibility	Yu et al. (2025)	● PLR1: The platform has the responsibility to clearly inform users which content is generated by AI. ● PLR2: The platform should establish mechanisms to monitor the accuracy and applicability of AI content. ● PLR3: When issues arise due to AI-generated content, the platform should proactively provide explanations. ● PLR4: Whether the platform takes responsibility affects my acceptance of AI-generated content.	Likert de 7 pontos (não especifica escala)	Responsabilidade Percebida da Plataforma	● RPP1: A plataforma tem a responsabilidade de informar claramente os utilizadores sobre imagens geradas por IA. ● RPP2: A plataforma deve estabelecer mecanismos para monitorizar a precisão e aplicabilidade das imagens geradas por IA. ● RPP3: Quando surgem problemas relacionados com imagens geradas por IA, a plataforma deve proativamente fornecer explicações. ● RPP4: O facto de a plataforma assumir responsabilidade afeta a minha aceitação das imagens geradas por IA.

Anexo D – Amostra de estudo (frequências)

Indicador	Categoria	%	n
Género (N=338)	Feminino	62,7	212
	Masculino	34,9	118
	Não-binário / Outro	1,8	6
	Prefiro não responder	0,6	2
Grupo etário (N=338)	18 aos 25 anos	80,8	273
	26 aos 40 anos	16,2	55
	Mais de 41 anos	3,0	10
Situação profissional (N=338)	Estudante	57,4	194
	Trabalhador(a)-estudante	13,8	47
	Trabalhador(a) por conta de outrem	24,0	81
	Trabalhador(a) por conta própria	3,0	10
	Desempregado(a)	1,8	6
Habilitações literárias (N=338)	Inferior ao 12º ano	0,9	3
	12º ano ou equivalente	36,4	123
	Licenciatura/Bacharelato	40,3	136
	Pós-graduação	4,1	14
	Mestrado	18,0	61
	Doutoramento	0,3	1
Rendimento mensal líquido individual (N=338)	Não aufero rendimentos	45,9	155
	Até 500€	6,8	23
	500€ - 1000€	9,5	32
	1001€ - 2000€	23,3	79
	2001€ - 3000€	4,1	14
	Mais de 3001€	0,9	3
	Prefiro não responder	9,5	32
Nacionalidade (N=338)	Portuguesa	93,8	317
	Outra	6,2	21
Frequência de utilização de plataformas de roupa em segunda-mão (N=338)	Nunca	10,9	37
	Raramente (menos de 1 vez por mês)	47,7	161
	Às vezes (1 a 3 vezes por mês)	22,5	76
	Frequentemente (mais de 3 vezes por mês)	18,9	64
Principal motivo de utilização (N=301)	Preço mais baixo	53,2	160
	Sustentabilidade / consumo consciente	18,9	57
	Encontrar peças únicas ou vintage	24,6	74
	Conveniência	1,0	3
	Outro	2,3	7
Plataformas utilizadas (N=338)	Vinted	83,7	283
	OLX	26,9	91
	Facebook Marketplace	11,0	37
	Wallapop	2,7	9
	Depop	1,5	5
	Outra	0,9	3

Anexo E – ACP e Análise de Fiabilidade

			Análise de Componentes Principais					Análise de Fiabilidade		
			KMO	Teste de Esfericidade de Bartlett		Variância total explicada (% de variância)	Comunalidades (extração)	Alfa de Cronbach	Estatísticas de item-total	
Índice	Item	N		Aprox. χ^2	Sig				Correlação de item total corrigida	Alfa de Cronbach se o item for excluído
Realismo Percebido	RP1	338	0,881	1405,552	<0,001	68,303	0,749	0,898	0,786	0,872
	RP2	338					0,776		0,799	0,868
	RP3	338					0,779		0,806	0,867
	RP4	338					0,779		0,803	0,868
	RP5	338					0,757		0,790	0,870
	RP6	338					0,258		0,406	0,928
Deceção Percebida	DEC1	338	0,798	623,196	<0,001	70,226	0,624	0,856	0,640	0,844
	DEC2	338					0,805		0,796	0,773
	DEC3	338					0,691		0,688	0,821
	DEC4	338					0,690		0,687	0,824
Desconfiança no Vendedor	VEN1	338	0,697	324,227	<0,001	71,563	0,678	0,794	0,609	0,763
	VEN2	338					0,771		0,699	0,650
	VEN3	338					0,698		0,635	0,734
Desconfiança na Plataforma	PLA1	338	0,879	1343,818	<0,001	69,224	0,665	0,911	0,733	0,897
	PLA2	338					0,673		0,738	0,896
	PLA3	338					0,636		0,708	0,901
	PLA4	338					0,792		0,828	0,883
	PLA5	338					0,699		0,753	0,894
	PLA6	338					0,689		0,746	0,895
Intenção de eWOM Negativo	EWOM1	338	0,685	336,614	<0,001	71,509	0,618	0,794	0,561	0,807
	EWOM2	338					0,767		0,689	0,676
	EWOM3	338					0,760		0,675	0,677
Responsabilidade Percebida da Plataforma	RPP1	338	0,681	325,391	<0,001	54,113	0,681	0,552	0,475	0,383
	RPP2	338					0,752		0,499	0,414
	RPP3	338					0,648		0,472	0,408
	RPP4	338					0,083		0,164	0,782
Literacia de IA	LIA1	338	0,772	907,125	<0,001	74,069	0,601	0,823	0,546	0,804
	LIA2	338					0,671		0,609	0,791
	LIA3	338					0,743		0,607	0,793
	LIA4	338					0,731		0,706	0,779
	LIA5	338					0,867		0,586	0,799
	LIA6	338					0,868		0,559	0,804
Propensão para Desconfiar	PPD1	338	0,743	591,589	<0,001	66,372	0,561	0,829	0,574	0,820
	PPD2	338					0,543		0,562	0,826
	PPD3	338					0,809		0,791	0,717
	PPD4	338					0,742		0,726	0,751
Realismo Percebido (sem RP6_Reversed)	RP1	338	0,869	1344,173	<0,001	77,808	0,754	0,928	0,794	0,916
	RP2	338					0,79		0,821	0,91
	RP3	338					0,786		0,817	0,911
	RP4	338					0,795		0,826	0,909
	RP5	338					0,766		0,803	0,914
Responsabilidade Percebida da Plataforma (sem RPP4)	RPP1	338	0,681	331,199	<0,001	70,607	0,687	0,782	0,607	0,733
	RPP2	338					0,78		0,705	0,633
	RPP3	338					0,651		0,574	0,753

Anexo F – Índices sintéticos

											Teste Kolmogorov-Smirnov	
Índice	N	Mínimo	Máximo	Média	Mediana	Moda	Desvio Padrão	Variância	Curtose	Assimetria	Estatística	Sig
Realismo Percebido	338	1	7	4,8083	5,200	6	1,51610	2,299	0,032	-0,867	0,1450	<0,001
Deceção Percebida	338	1	7	5,1834	5,500	7	1,38359	1,914	-0,408	-0,649	0,1100	<0,001
Desconfiança no Vendedor	338	1	7	5,4398	5,667	7	1,27435	1,624	0,300	-0,816	0,1117	<0,001
Desconfiança na Plataforma	338	1	7	4,7293	4,833	4	1,36707	1,869	-0,637	-0,360	0,0718	<0,001
Intenção de eWOM Negativo	338	1	7	5,2742	5,667	6	1,35411	1,834	0,646	-0,913	0,1419	<0,001
Responsabilidade Percebida da Plataforma	338	3,67	7	6,5118	7,000	7	0,72509	0,532	3,792	-1,919	0,2780	<0,001
Literacia de IA	338	1,5	7	5,6908	5,833	6	0,84477	0,714	1,497	-0,839	0,1099	<0,001
Propensão para Desconfiar	338	1	7	5,1568	5,250	6	1,16602	1,360	-0,002	-0,546	0,1206	<0,001

Anexo G – Critério de Fornell-Larcker

	Deceção Percebida	Desconfiança na Plataforma	Desconfiança no Vendedor	Intenção de eWOM Negativo	Literacia de IA	Propensão para Desconfiar	Realismo Percebido	Responsabilidade Percebida da Plataforma
Deceção Percebida	0,838							
Desconfiança na Plataforma	0,577	0,831						
Desconfiança no Vendedor	0,579	0,694	0,846					
Intenção de eWOM Negativo	0,285	0,363	0,321	0,845				
Literacia de IA	0,250	0,134	0,260	0,125	0,578			
Propensão para Desconfiar	0,019	0,081	0,132	0,019	-0,034	0,706		
Realismo Percebido	-0,458	-0,344	-0,293	-0,196	-0,153	0,033	0,882	
Responsabilidade Percebida da Plataforma	0,226	0,228	0,272	0,269	0,308	0,043	-0,079	0,834