



Lisbon School  
of Economics  
& Management  
Universidade de Lisboa

**MESTRADO EM**  
**MÉTODOS QUANTITATIVOS PARA A DECISÃO**  
**ECONÓMICA E EMPRESARIAL**

**TRABALHO FINAL DE MESTRADO**  
**DISSERTAÇÃO**

**FATORES DE ADOÇÃO E UTILIZAÇÃO DE INTELIGÊNCIA**  
**ARTIFICIAL GENERATIVA**

**TELMO EMANUEL MARQUES FERNANDES**

**ORIENTAÇÃO:**

PROFESSOR DOUTOR CARLOS MANUEL JORGE DA COSTA

DOCUMENTO ESPECIALMENTE ELABORADO PARA OBTENÇÃO DO GRAU DE MESTRE

**OUTUBRO – 2024**

## **Agradecimentos**

Em primeiro lugar quero agradecer à minha família, nomeadamente aos meus pais pelo apoio que sempre me deram e por me oferecerem todas as condições para frequentar este mestrado, e, conseqüentemente, realizar esta dissertação. Também ao meu irmão e à Adriana por se mostrarem sempre disponíveis para ajudar com o que eu precisasse. Sem o vosso suporte teria sido bastante mais difícil.

Deixo igualmente uma palavra de agradecimento a todos os meus amigos pelo apoio constante e pela importante ajuda na partilha do questionário. Um agradecimento especial à Sofia pela paciência e por me encorajar nos momentos mais difíceis.

Agradeço também ao meu orientador Professor Doutor Carlos Manuel Jorge da Costa pelas inúmeras reuniões e pela disponibilidade que sempre mostrou para me ajudar ao longo destes meses.

Por último, agradecer ao Instituto Superior de Economia e Gestão (ISEG) por todo o conhecimento oferecido que culminou na realização deste trabalho.

## Resumo

A inteligência artificial (IA), com origem na década de 1950, surge como uma das áreas mais transformadoras da atualidade, impactando setores como a medicina, educação e negócios. A inteligência artificial generativa, um dos ramos da IA, permite a criação de conteúdo novo, seja em formato texto, áudio ou imagens. O seu rápido crescimento, evidenciado pelo sucesso do ChatGPT, reflete a velocidade com que as pessoas adotaram este tipo de tecnologia, muito pela sua simplicidade e por facilmente retirarem benefícios práticos da sua utilização. No entanto, preocupações relacionadas com a perda de empregos e a ética levam à necessidade de equilibrar o potencial desta tecnologia com o respeito a valores fundamentais.

Este trabalho procura perceber quais são os fatores que levam à adoção e utilização de inteligência artificial generativa, tendo em conta os principais temas de debate em torno desta. Para tal, foi desenvolvido um modelo de adoção que, além de se basear em modelos já existentes, incorpora também novas dimensões como a insegurança no emprego e as atitudes éticas. Obtiveram-se dados através de um questionário online, de forma a ser possível testar e validar o modelo através do Modelo das Equações Estruturais (SEM).

Os resultados mostram que, das dez hipóteses existentes, apenas a hipótese relativa à influência da expectativa de esforço na intenção comportamental foi rejeitada. A intenção comportamental de utilizar a inteligência artificial generativa resulta da expectativa de desempenho e da confiança dos utilizadores. Por sua vez, a confiança é determinada pelas atitudes éticas e pela influência social. Já a expectativa de desempenho é influenciada pela segurança no emprego, motivação hedónica e expectativa de esforço. A motivação hedónica impacta ainda a expectativa de esforço.

**Palavras-chave:** Adoção, Inteligência Artificial Generativa

## **Abstract**

Artificial intelligence (AI), with origins in the 1950s, has emerged as one of the most transformative areas today, impacting sectors such as medicine, education, and business. Generative AI, a subset of AI, enables the creation of new content, whether in text, audio, or image formats. Its rapid growth, evidenced by the success of ChatGPT, reflects how quickly people have adopted this technology, largely due to its simplicity and the practical benefits it offers. However, concerns regarding job displacement and ethics raise the need to balance the potential of this technology with respect for fundamental values.

This study seeks to understand the factors that drive the adoption and use of generative AI, considering the main debates surrounding it. To this end, an adoption model was developed that, in addition to being based on existing models, also incorporates new constructs such as job insecurity and ethical attitudes. Data were collected through an online survey to test and validate the model using Structural Equation Model (SEM).

The results show that, of the ten existing hypotheses, only the one related to the influence of effort expectancy on behavioural intention was rejected. The behavioral intention to use generative artificial intelligence results from performance expectancy and users' trust. In turn, trust is determined by ethical attitudes and social influence. Performance expectancy is influenced by job security, hedonic motivation, and effort expectancy. Additionally, hedonic motivation impacts effort expectancy.

**Keywords:** Adoption, Generative Artificial Intelligence

# Índice

Agradecimentos .....	ii
Resumo .....	iii
Abstract.....	iv
Índice de Tabelas .....	vii
Índice de Figuras .....	viii
Lista de Anexos .....	ix
Siglas .....	x
1. Introdução.....	1
1.1 Enquadramento.....	1
1.2 Questão de Investigação e Objetivos.....	2
1.3 Estrutura do Relatório.....	3
2. Revisão da Literatura.....	4
2.1 Inteligência Artificial.....	4
2.1.1 História .....	4
2.1.2 Aprendizagem Automática ( <i>Machine Learning</i> ).....	6
2.1.3 <i>Deep Learning</i> .....	7
2.1.4 Inteligência Artificial Generativa .....	8
2.2 Adoção.....	9
3. Modelo Proposto .....	12
4. Método.....	19
4.1 Instrumento de Medida.....	19
4.2 Recolha de Dados .....	19
5. Resultados e Discussão.....	21
5.1 Avaliação do Modelo de Medida.....	21

5.2	Avaliação do Modelo Estrutural.....	23
5.3	Discussão.....	27
6.	Conclusão .....	30
	Referências Bibliográficas.....	32
	Anexos .....	41

## **Índice de Tabelas**

Tabela I. Dimensões do Modelo Proposto .....	13
Tabela II. Critério de Fornell-Larcker .....	23
Tabela III. Inner VIF .....	24
Tabela IV. Betas, P-Values, F <sup>2</sup> , Efeito e Decisão das Hipóteses.....	26

## **Índice de Figuras**

Figura 1. Modelo Proposto .....	18
Figura 2. Modelo de Adoção de Inteligência Artificial Generativa .....	25

## **Lista de Anexos**

Anexo 1. Questionário .....	41
Anexo 2. Resultados do Questionário .....	42
Anexo 3. <i>Outer Loadings, Composite Reliability</i> e AVE .....	43
Anexo 4. <i>Cross-loadings</i> .....	44

## **Siglas**

IA – Inteligência Artificial

TAM – *Technology Acceptance Model*

UTAUT - *Unified theory of acceptance and use of technology*

JI – *Job Insecurity*

HM – *Hedonic Motivation*

SI – *Social Influence*

EA – *Ethical Attitudes*

PE – *Performance Expectancy*

EE – *Effort Expectancy*

T - *Trust*

BI – *Behavioural Intention*

SEM – *Structural Equation Modeling*

PLS – *Partial Least Squares*

VIF – *Variance Inflation Factor*

AVE – *Average Variance Extracted*

# 1. Introdução

## 1.1 Enquadramento

A inteligência artificial tem sido um dos conceitos mais transformadores do século XXI, mas as suas raízes remontam à década de 1950 quando Alan Turing descreveu a ideia de usar computadores para simular a inteligência e o pensamento crítico (Kaul et al., 2020). Desde então, esta ciência passou por muitos estados de evolução até aos dias de hoje, onde está presente em múltiplos setores, desde a medicina (Ramesh et al., 2004), passando pela educação (Chen et al., 2020), até aos negócios e à indústria (Bharadiya et al., 2023).

Uma das áreas da inteligência artificial mais relevantes e populares atualmente é a inteligência artificial generativa. As ferramentas de inteligência artificial generativa têm a capacidade de criar conteúdo aparentemente novo, seja em formato texto, imagem ou até áudio, e a difusão deste tipo de tecnologia, como o Dall-E 2, GPT-4 e Copilot, veio alterar a maneira como trabalhamos e comunicamos entre nós (Feuerriegel et al., 2024). Dois meses após o seu lançamento, o ChatGPT chegou aos 100 milhões de utilizadores ativos mensais, tornando-se a aplicação com um crescimento mais rápido da história (Hu, 2023), mostrando a velocidade com que as pessoas aceitaram e adotaram este tipo de tecnologia. Este rápido sucesso da inteligência artificial generativa deve-se, em grande parte, ao facto de até mesmo pessoas sem qualquer conhecimento prévio sobre IA ou experiência em programação reconhecerem rapidamente os benefícios da sua utilização e sua simplicidade, adotando assim esta tecnologia (Sætra, 2023).

Atualmente, a inteligência artificial generativa é vista como uma ferramenta com um potencial infinito, capaz de transformar as empresas e a sociedade. Surgem diversas oportunidades de utilização em campos como o marketing, saúde, recursos humanos, educação e serviços bancários, o que é um convite ao investimento por parte das empresas, bem como à sua utilização pelo público em geral (Ooi et al., 2023).

No entanto, como acontece na maior parte das tecnologias de inteligência artificial, existe um grande debate em torno da utilização deste tipo de ferramentas. Relatórios, como o da Goldman Sachs (2023), sugerem que a inteligência artificial generativa tem o

potencial de aumentar a produtividade na indústria, mas, por outro lado, pode substituir inúmeros empregos. Outra das preocupações está relacionada com questões éticas, nomeadamente a preservação de valores como privacidade, justiça, transparência e responsabilidade no uso destas tecnologias (Kirova et al., 2023).

Posto isto, não existe um consenso quanto à utilização ou não deste tipo de ferramentas. É amplamente reconhecido o enorme potencial desta tecnologia e não existem dúvidas de que tem a capacidade de melhorar a vida das pessoas. Acredita-se, no entanto, que a inteligência artificial generativa deve contribuir para uma boa sociedade, promovendo e não prejudicando valores fundamentais (Sætra, 2023).

## **1.2 Questão de Investigação e Objetivos**

Observando a popularidade e o alto nível de utilização que a inteligência artificial generativa tem nos dias que correm, faz todo o sentido investigar o que leva tantas pessoas a adotar este tipo de tecnologia, mesmo existindo alguma preocupação e insegurança à sua volta. Desta forma, propõe-se a seguinte questão de investigação: quais são os fatores que levam à adoção e utilização de inteligência artificial generativa na sociedade atual?

Esta dissertação tem como principal objetivo o desenvolvimento de um modelo de adoção de inteligência artificial generativa, que, além de se basear em modelos já existentes, tenha a capacidade de incluir dimensões que traduzam as principais preocupações em torno desta tecnologia, como o impacto no emprego das pessoas e questões a nível ético. Será elaborado um questionário e partilhado com pessoas dos mais diversos setores, sendo depois aplicado o modelo de equações estruturais. Desta forma será possível verificar e validar a estrutura do modelo proposto, bem como testar as hipóteses de investigação definidas.

Este trabalho contribui para a teoria ao criar um modelo que explica a adoção de inteligência artificial generativa, conseguindo incluir nesse modelo variáveis que refletem os principais temas que são debatidos em torno desta tecnologia. Os resultados mostram a importância da expectativa de desempenho e da confiança na adoção deste tipo de ferramentas.

### **1.3 Estrutura do Relatório**

Será apresentada, em primeiro lugar, uma revisão da literatura que compreende a explicação de conceitos relevantes relacionados com a inteligência artificial e a sua adoção. Na parte 3, é demonstrado o modelo proposto, sendo igualmente explicadas as várias hipóteses nele presentes. De seguida, é apresentado o método utilizado para a recolha de dados para o presente estudo. A parte 5 compreende a análise dos resultados, que inclui a avaliação do modelo de medida e modelo estrutural, e a consequente discussão do que foi obtido. Por último, são apresentadas as conclusões a retirar deste estudo, bem como limitações e direções de pesquisa futuras.

## **2. Revisão da Literatura**

Neste capítulo vão ser apresentados temas importantes e relevantes no âmbito do estudo que foi desenvolvido. Primeiro, serão abordados aspetos relacionados com a Inteligência Artificial, nomeadamente a sua definição e história, bem como a explicação de conceitos como Aprendizagem Automática (*Machine Learning*), *Deep Learning* e Inteligência Artificial Generativa. De seguida, vão ser expostas algumas das teorias e modelos mais relevantes no contexto da adoção de tecnologias.

### **2.1 Inteligência Artificial**

Existem várias definições de Inteligência Artificial (IA) que foram surgindo ao longo do tempo. No teste de Turing, a inteligência artificial é definida como a habilidade de um dispositivo comunicar com os humanos sem revelar a identidade de que não são humanos. Já Marvin Minsky, um dos pioneiros nesta área, referiu que a inteligência artificial significa permitir que um determinado sistema ou tecnologia realize tarefas que exigem a inteligência humana. No entanto, acredita-se que a base da IA seja o conjunto das teorias de pesquisa, métodos, tecnologias e aplicações que procuram simular, ampliar e expandir a inteligência humana (Jiang et al., 2022).

Para John McCarthy (2004), é possível definir a Inteligência Artificial como a ciência e a engenharia de criar sistemas inteligentes, especialmente programas computacionais inteligentes. Está relacionada com o uso de computadores para entender a inteligência humana, mas a IA não precisa de se restringir a métodos que sejam biologicamente observáveis.

#### **2.1.1 História**

O termo “Inteligência Artificial” surgiu oficialmente em 1956, ano em que Marvin Minsky e John McCarthy organizaram um workshop de oito semanas denominado Dartmouth Summer Research Project on Artificial Intelligence (DSRPAI) na Universidade de Dartmouth em New Hampshire. Estiveram aqui reunidos aqueles que mais tarde viriam a ser considerados os “pais” da Inteligência Artificial, incluindo

Nathaniel Rochester, que posteriormente concebeu o IBM 701, o primeiro computador científico comercial, e Claude Shannon, que fundou a teoria da informação. O objetivo deste projeto passou por reunir investigadores de forma a criar uma área de investigação destinada à construção de tecnologias capazes de simular a inteligência humana (Haenlein & Kaplan, 2019).

Seguiram-se duas décadas de sucesso no ramo da inteligência artificial. Surgiu o programa de computador ELIZA, criado no MIT entre 1964 e 1966 por Joseph Weizenbaum, que permitia simular a conversa com um humano. Outro exemplo deste progresso foi o General Problem Solver, programa desenvolvido pelo vencedor do prémio Nobel, Herbert Simon, e pelos cientistas da RAND Corporation, Cliff Shaw e Allen Newell, que era capaz de resolver, de forma automática, problemas simples como o da Torre de Hanói. No entanto, este período de crescimento da inteligência artificial foi travado devido ao aparecimento de críticas em torno desta área, tanto por parte do Congresso dos Estados Unidos da América em relação aos gastos que já tinham sido feitos, como outras provenientes do matemático inglês James Lighthill que, comissionado pelo Instituto de Pesquisa e Ciência Britânico, publicou um relatório questionando o otimismo em torno da inteligência artificial. Com isto, os governos destes dois países reduziram o apoio dado à pesquisa nesta área (Haenlein & Kaplan, 2019).

Um motivo para o atraso inicial no progresso da Inteligência Artificial foi o facto dos primeiros sistemas, como a ELIZA e o General Problem Solver, serem considerados *Expert Systems*, ou seja, conjuntos de regras que pressupõem que a inteligência humana pode ser reconstruída e formalizada numa abordagem de cima para baixo como uma sequência de instruções *if-then*. Estes sistemas funcionam bem em áreas que obedecem a tal formalização, como o xadrez, onde o programa Deep Blue da IBM venceu o campeão mundial Gary Kasparov em 1997. No entanto, programas como este não são capazes de interpretar dados externos de forma correta, aprender a partir desses dados e usar o que aprenderam para alcançar determinados objetivos e tarefas através de uma adaptação flexível, pelo que não podem ser considerados uma verdadeira inteligência artificial (Haenlein & Kaplan, 2019).

As tentativas de alcançar a verdadeira IA começaram ainda nos anos 40, quando o psicólogo canadiano Donald Hebb desenvolveu a teoria da aprendizagem Hebbiana que

replica o processo dos neurónios no cérebro humano. Isto conduziu à introdução do conceito de redes neuronais artificiais e a pesquisas em torno deste. Contudo, em 1969, os desenvolvimentos nesta área acabaram por estagnar devido à demonstração de que os computadores não tinham poder de processamento suficiente para lidar com as redes (Haenlein & Kaplan, 2019).

As redes neuronais artificiais voltaram a surgir na forma de *deep learning* quando, em 2015, o AlphaGo, um programa desenvolvido pela Google, foi capaz de derrotar o campeão mundial do jogo de tabuleiro Go, bastante mais complexo que o xadrez. Atualmente, as redes neuronais artificiais e o *deep learning* formam a base da maioria das aplicações que conhecemos na área da inteligência artificial (Haenlein & Kaplan, 2019).

### **2.1.2 Aprendizagem Automática (*Machine Learning*)**

A Aprendizagem Automática, de acordo com Arthur Samuel, famoso por ter criado o programa do jogo de damas, é definida como o campo de estudo que providencia aos computadores a habilidade de aprender sem serem explicitamente programados para tal, permitindo que estes sistemas lidem com os dados de uma forma mais eficiente (Mahesh, 2020).

A Aprendizagem Automática, considerada um subconjunto da Inteligência Artificial, tem a capacidade de aprender e melhorar as suas análises através de algoritmos computacionais. Estes algoritmos usam grandes conjuntos de dados para reconhecer padrões e efetivamente aprender, de maneira que o sistema em questão consiga fazer recomendações ou tomar decisões de forma autónoma no futuro. Após repetições suficientes do processo e modificações no algoritmo, o sistema torna-se capaz de receber um *input* e prever um *output* (Helm et al., 2020)

Alguns dos algoritmos mais usados em *machine learning* podem dividir-se em dois tipos de modelos de aprendizagem: supervisionada e não-supervisionada. A aprendizagem supervisionada consiste em inferir uma função que faça corresponder um *input* a um *output* com base em exemplos de pares *input-output* (dados de treino). Os algoritmos aprendem alguns tipos de padrões do conjunto de dados de treino e aplicam-nos ao conjunto de dados de teste para previsão ou classificação. Já na aprendizagem não-

supervisionada o processo é diferente visto que os algoritmos são deixados à sua própria sorte para descobrir e apresentar a estrutura dos dados, não havendo neste caso respostas corretas. São aprendidas determinadas características relativamente aos dados apresentados e, quando novos dados são introduzidos, esses atributos anteriormente aprendidos são usados para reconhecer a classe dos novos dados (Mahesh, 2020).

Um exemplo do uso da Aprendizagem Automática pode ser um programa de computador que aprende a detetar / prever o cancro a partir dos relatórios médicos de um paciente. O programa irá melhorar a sua performance à medida que acumula mais experiência através da análise de relatórios de uma população mais ampla de pacientes. O seu desempenho será medido pela contagem de previsões e deteções corretas de casos de cancro validadas por um oncologista experiente (Ray, 2019) .

### **2.1.3 *Deep Learning***

*Deep learning* refere-se às redes neuronais profundas, que é uma configuração específica onde os neurónios são organizados em várias camadas sucessivas. O aumento destas camadas permite aumentar a performance destes métodos (Chassagnon et al., 2020).

Os métodos de *deep learning*, ao contrário de outros métodos de *machine learning*, conseguem trabalhar diretamente com os dados brutos e descobrir automaticamente as representações necessárias para tarefas como deteção ou classificação. Esses métodos utilizam vários níveis de representação, onde cada nível transforma a informação em algo mais abstrato. Ao combinar várias dessas transformações, os modelos conseguem aprender funções complexas (LeCun et al., 2015).

Os algoritmos de *deep learning* realizam a extração de características de forma automática, permitindo que quem pesquisa extraia características discriminativas com o mínimo conhecimento do domínio e esforço humano. Estes algoritmos incluem uma arquitetura em camadas de representação de dados, onde características de alto nível podem ser extraídas das últimas camadas das redes, enquanto características de baixo nível são extraídas das camadas inferiores. Este tipo de arquitetura foi originalmente

inspirado na inteligência artificial, simulando o processo das principais áreas sensoriais no cérebro humano. Os nossos cérebros podem extrair automaticamente a representação de dados de diferentes cenários. O *input* é a informação recebida pelos olhos, enquanto o *output* são os objetos classificados. Conclui-se então que o *deep learning* imita o funcionamento do cérebro humano (Pouyanfar et al., 2019).

#### **2.1.4 Inteligência Artificial Generativa**

O conceito de Inteligência Artificial Generativa já é discutido há largos anos, mas foi apenas mais próximo do final da década de 2010 que ganhou reconhecimento generalizado. Esse aumento ocorreu em sintonia com a ascensão e aceitação de modelos generativos como as GANs (*Generative Adversarial Networks*) na comunidade de pesquisa sobre IA. No entanto, apesar desses modelos generativos existirem há mais tempo, este termo apenas ganhou um maior reconhecimento para o público em geral há relativamente pouco tempo, devido ao lançamento do ChatGPT e de outras ferramentas comerciais (García-Peñalvo & Vázquez-Ingelmo, 2023).

A inteligência artificial generativa refere-se a técnicas computacionais que são capazes de gerar conteúdo aparentemente novo e significativo como texto, imagens e áudio a partir de dados de treino (Feuerriegel et al., 2024).

Esta tecnologia utiliza modelos de *deep learning* para gerar conteúdo semelhante ao humano como palavras ou imagens, em resposta a instruções complexas e variadas que lhe são dadas (Lim et al., 2023).

Atualmente, este tema é alvo de grande debate em torno das possíveis vantagens e desvantagens da sua utilização em diversas áreas, como na educação ou no campo do desenvolvimento de software. Na área da educação, a inteligência artificial pode ter a capacidade de, por exemplo, criar métodos de aprendizagem e sistemas de avaliação, promovendo um ambiente de aprendizagem mais diferenciado e inclusivo. Por outro lado, são levantadas preocupações a nível ético, nomeadamente no que diz respeito à integridade académica e à privacidade dos dados. Já na área do desenvolvimento de software, a narrativa é semelhante dado que a IA tem a capacidade de acelerar processos de desenvolvimento e automatizar tarefas, mas existe apreensão relativamente a

potenciais perdas de emprego e questões éticas como responsabilidade e transparência (García-Peñalvo & Vázquez-Ingelmo, 2023).

## **2.2 Adoção**

Existem várias teorias e modelos que ao longo do tempo procuraram explicar a aceitação de novas tecnologias por parte dos consumidores e a sua intenção de uso. Vão ser abordadas neste ponto a Teoria da Difusão de Inovações, o Ajuste entre Tarefa e Tecnologia, a Teoria da Ação Racional, Teoria do Comportamento Planeado, Decomposição da Teoria do Comportamento Planeado, o Modelo de Aceitação de Tecnologia (TAM) e a Teoria Unificada de Aceitação e Uso da Tecnologia (UTAUT).

Começando pela Teoria da Difusão de Inovações, esta teve como objetivo sintetizar várias pesquisas que já tinham sido feitas na área. A teoria tem como base o processo de difusão de uma inovação dentro de um sistema social através de certos canais ao longo do tempo. A adoção da inovação ocorre após passar por várias etapas tais como a compreensão, persuasão, decisão, implementação e confirmação. Estas levaram ao desenvolvimento da curva de adoção de Rogers em forma de S, que divide os adotantes em inovadores, primeiros adotantes, maioria inicial, maioria tardia e retardatários (Lai, 2017)

Desenvolvida por Goodhue e Thompson, surge outra teoria que diz respeito ao Ajuste entre Tarefa e Tecnologia. Esta teoria foca-se mais no impacto individual, isto é, o aumento da eficiência, eficácia e/ou maior qualidade. Um bom ajuste entre a tarefa e a tecnologia aumenta a probabilidade de utilização e melhora o desempenho, uma vez que a tecnologia em questão atende mais de perto às necessidades e desejos dos consumidores em relação à tarefa (Lai, 2017).

A Teoria da Ação Racional, concebida por Fishbein e Ajzen, procura explicar que a intenção comportamental de um indivíduo é determinada pelas suas atitudes em relação a esse comportamento e pelas normas subjetivas da comunidade em seu redor. A atitude é definida nesta teoria como a avaliação da pessoa sobre um objeto, enquanto a crença resulta de uma ligação entre o objeto e um atributo. O comportamento é descrito como o resultado ou a intenção. Assim sendo, as atitudes são baseadas num conjunto de crenças

sobre o objeto do comportamento, e as normas subjetivas retratam a percepção do indivíduo sobre as atitudes da sua comunidade relativamente a esse comportamento (Lai, 2017).

Ajzen (1991) desenvolveu a Teoria do Comportamento Planeado, que acrescenta um fator aos dois que estão presentes na Teoria da Ação Racional explicada anteriormente. Esse fator extra é denominado de controlo comportamental percebido, e é definido como a percepção de um indivíduo sobre as limitações que podem afetar o seu comportamento (Lai, 2017).

Tayler e Todd, em 1995, introduziram uma decomposição da Teoria do Comportamento Planeado, que, tal como a teoria original, consiste em três fatores principais que afetam a intenção comportamental e a adoção do comportamento, que são a atitude, as normas subjetivas e o controlo comportamental percebido. No entanto, é feita a decomposição destes componentes principais em subcomponentes mais específicos que permitem uma análise mais detalhada. No caso da atitude, esta é decomposta noutros três fatores: vantagem relativa, complexidade e compatibilidade. As normas subjetivas são apenas decompostas numa única subcomponente, as influências normativas. Por último, o controlo comportamental percebido é decomposto em dois fatores: eficácia e condições facilitadoras (Lai, 2017).

A primeira versão do Modelo de Aceitação de Tecnologia (TAM) foi introduzida por Fred Davis em 1986, e tinha como objetivo testar o efeito que determinadas características de um sistema têm na aceitação por parte dos utilizadores de sistemas de informação ou tecnologias (Lai, 2017). Após algumas reformulações, a versão final do TAM surge em 1996, formulada por Davis em conjunto com Venkatesh. Este modelo utiliza duas crenças específicas: a facilidade de uso percebida, que se refere à percepção da quantidade de esforço necessário para utilizar o sistema, e a utilidade percebida, que diz respeito à percepção do grau em que um indivíduo entende que o uso do sistema vai melhorar a sua performance no trabalho. Estas duas dimensões são determinantes da intenção comportamental que, por sua vez, leva ao uso atual do sistema. São ainda referidas neste modelo variáveis externas, como as características do sistema, treino, design, e a natureza do processo de implementação, que influenciam tanto a utilidade como a facilidade de uso percebidas (Davis et al., 1989; Venkatesh & Davis, 1996).

Posteriormente, outras adaptações do TAM, como o TAM2 (Venkatesh & Davis, 2000) e o TAM3 (Venkatesh & Bala, 2008), procuraram especificar as variáveis que explicam tanto a facilidade de uso percebida como a utilidade percebida.

Venkatesh et al. (2003) desenvolveram a Teoria Unificada de Aceitação e Uso da Tecnologia (UTAUT). Este modelo contém dimensões como a expectativa de desempenho, a expectativa de esforço, a influência social, as condições facilitadoras, a intenção comportamental e o comportamento de uso. A expectativa de desempenho refere-se ao grau em que um indivíduo acredita que o uso do sistema o vai ajudar a obter benefícios no desempenho no trabalho, enquanto a expectativa de esforço simboliza o grau de facilidade associada ao uso do sistema. No caso da influência social, esta diz respeito ao grau em que uma pessoa entende que outras pessoas próximas acreditam que ele ou ela deve utilizar o sistema. Estas primeiras três dimensões são apresentadas como determinantes da intenção comportamental, enquanto as condições facilitadoras, variável definida como o grau em que um indivíduo acredita que existe uma infraestrutura organizacional e técnica para apoiar a utilização do sistema, influenciam diretamente o comportamento de uso. Tal como no TAM, a intenção comportamental é vista como um determinante do uso. Mais tarde, foi desenvolvido o modelo UTAUT2 (Venkatesh et al., 2012), que integra outras três variáveis que afetam diretamente a intenção comportamental. A primeira, motivação hedónica, é definida como a diversão ou prazer derivado do uso da tecnologia. Surge também o valor do preço, que simboliza a ideia de que o custo do uso de uma dada tecnologia impacta o seu uso. Por último, o hábito foi integrado no modelo, sendo definido como o grau com que as pessoas tendem a realizar comportamentos automaticamente com base no que já aprenderam.

### **3. Modelo Proposto**

A construção do modelo utilizado neste estudo teve como base a análise feita da literatura existente sobre a adoção de tecnologias. Posto isto, decidiu-se integrar no modelo seis dimensões provenientes do modelo UTAUT2: motivação hedónica, influência social, expectativa de desempenho, expectativa de esforço, intenção comportamental e comportamento de uso.

Foram igualmente incorporadas variáveis que refletem dois temas centrais no debate em torno da inteligência artificial: atitudes éticas e insegurança no emprego. Estas dimensões foram adaptadas de estudos prévios que as investigaram em contextos distintos da adoção de tecnologias.

Por último, a variável confiança foi incluída no modelo devido ao seu papel central na adoção de tecnologias, já estudado por outros autores no contexto da inteligência artificial.

Na Tabela I encontram-se as definições de todas as variáveis utilizadas, assim como os autores que as exploraram.

**Tabela I. Dimensões do Modelo Proposto**

<b>Dimensão</b>	<b>Definição</b>	<b>Autor</b>
<b>Insegurança no Emprego (JI)</b>	Percepção de impotência para manter a continuidade desejada numa situação em que existe uma ameaça ao trabalho.	(Greenhalgh & Rosenblatt, 1984)
<b>Motivação Hedônica (HM)</b>	Diversão ou prazer derivado do uso de uma tecnologia.	(Venkatesh et al., 2012)
<b>Influência Social (SI)</b>	Grau em que um indivíduo percebe que outras pessoas acreditam que ele ou ela deve utilizar um dado sistema.	(Venkatesh et al., 2003)
<b>Atitudes Éticas (EA)</b>	Julgamento de uma prática por parte das pessoas, considerando as suas normas e valores.	(Chan et al., 2008)
<b>Expectativa de Desempenho (PE)</b>	Grau em que um indivíduo acredita que o uso de um sistema o ajudará a alcançar melhorias no seu desempenho no trabalho.	(Venkatesh et al., 2003)
<b>Expectativa de Esforço (EE)</b>	Grau de facilidade que está associado ao uso de um sistema.	(Venkatesh et al., 2003)
<b>Confiança (T)</b>	Crença de um indivíduo de que uma tecnologia ou sistema pode ser confiável para funcionar conforme o esperado e proteger os seus interesses.	(Albayati, 2024)
<b>Intenção Comportamental (BI)</b>	Expectativa da intenção do utilizador em tomar uma decisão relacionada com o uso da tecnologia.	(Venkatesh et al., 2003)
<b>Uso (USE)</b>	Uso efetivo da tecnologia.	(Venkatesh et al., 2003)

A insegurança no emprego pode ser definida como a percepção de impotência para manter a continuidade desejada numa situação em que existe uma ameaça ao trabalho (Greenhalgh & Rosenblatt, 1984). Atualmente, os sucessivos avanços nas tecnologias, nomeadamente no ramo da inteligência artificial, têm impacto na segurança das pessoas no seu emprego. Em resposta a estes desenvolvimentos, os indivíduos avaliam a possibilidade e a maneira com que a inteligência artificial os pode substituir, comparando as características do seu emprego com as atuais capacidades da IA. Este tipo de comparação pode levar a sentimentos como a insegurança no atual emprego (Cao & Song, 2024).

Segundo a visão de outros autores (Autor, 2015; Bessen, 2019), o surgimento de novas tecnologias não vai necessariamente tirar empregos, mas sim complementá-los. Desta forma, pessoas que não se encontrem numa posição de insegurança no seu emprego derivada da aparição de novas tecnologias, tendem a olhar para elas apenas como algo que pode complementar o seu trabalho, melhorar o desempenho, e, em último caso, trazer benefícios à pessoa.

Por conseguinte, será testada a seguinte hipótese:

**H1. A segurança no emprego afeta positivamente a expectativa de desempenho.**

A motivação hedónica é definida por Venkatesh et al. (2012) como a diversão ou prazer derivado do uso de uma tecnologia, e esta dimensão foi utilizada como um previsor da intenção comportamental de usar um dado sistema.

A motivação hedónica pode ainda influenciar a expectativa de esforço, na medida em que atividades que geram prazer tendem a ser percebidas como menos exigentes cognitivamente. O conceito de absorção cognitiva refere que quando um indivíduo está envolvido numa atividade e dela disfruta, são alocados mais recursos cognitivos para essa tarefa e o esforço é percebido como menor (Agarwal & Karahanna, 2000). Também para Venkatesh (2000), indivíduos motivados intrinsecamente, ou seja, que encontram prazer e satisfação na realização de uma tarefa, tendem a subestimar a dificuldade do processo.

Também é possível encontrar uma relação entre a motivação hedónica e a expectativa de desempenho, visto que essas sensações de prazer e satisfação ao interagir com determinado software podem servir de justificação para o tempo investido, sendo atribuído um valor prático, com o objetivo de reduzir a dissonância cognitiva. Essa racionalização leva a pessoa a perceber a atividade como útil (Agarwal & Karahanna, 2000).

Tendo em conta o que foi explicado, as seguintes hipóteses serão testadas:

**H2a. A motivação hedónica influencia positivamente a expectativa de desempenho.**

**H2b. A motivação hedónica impacta positivamente a expectativa de esforço.**

A dimensão da influência social é definida como o grau em que um indivíduo percebe que outras pessoas acreditam que ele ou ela deve utilizar um dado sistema (Venkatesh et al., 2003). Este fator está presente na Teoria da Ação Racional e na Teoria do Comportamento Planeado como um determinante direto da intenção comportamental, como foi descrito anteriormente no ponto 2.2.

No entanto, alguns estudos relatam que a Influência Social também afeta o nível de confiança que um indivíduo tem num dado sistema (Li et al., 2008; Zhang et al., 2020). Em determinados casos em que alguém não tem conhecimento prévio ou experiência com uma nova tecnologia, a confiança de outras pessoas nesse sistema pode ter um impacto nas crenças de quem não tinha contacto com esse mesmo sistema. (Li et al., 2008).

Considerando o que foi apresentado, será avaliada a seguinte hipótese:

### **H3. A influência social afeta positivamente a confiança.**

As atitudes éticas podem desempenhar um papel crucial na tomada de decisão. Vários estudos já comprovaram a hipótese de que indivíduos que consideram uma ação como ética são mais propensos a ter a intenção comportamental de realizar essa ação (Qian et al., 2023).

A Ética desempenha ainda um papel central na construção da confiança na IA. Quando as pessoas entendem que uma tecnologia segue certos princípios éticos, como a transparência, responsabilidade, respeito pela privacidade e se alinha com normas e valores sociais, sentem-se mais seguras, o que tende a aumentar a confiança (Omran et al., 2022).

Tendo em consideração que existe um grande debate em torno da ética da inteligência artificial generativa (Zohny et al., 2023), faz todo o sentido analisar esta dimensão neste contexto.

Portanto, será testada a seguinte hipótese:

### **H4. As atitudes éticas afetam positivamente a confiança.**

A expectativa de desempenho é definida por Venkatesh et al. (2003) como o grau em que um indivíduo acredita que o uso de um sistema o ajudará a alcançar melhorias no seu desempenho no trabalho. Esta dimensão é um forte preditor da intenção comportamental de um indivíduo usar uma dada tecnologia.

No contexto da inteligência artificial, já foi comprovado por diversos autores que este é um fator determinante para a intenção comportamental de usar este tipo de ferramentas (Veiga & Costa, 2024), como no caso inteligência artificial generativa (Camilleri, 2024).

Desta forma, a seguinte hipótese será avaliada:

**H5. A expectativa de desempenho impacta positivamente a intenção comportamental.**

A expectativa de esforço é definida como o grau de facilidade que está associado ao uso de um sistema. (Venkatesh et al., 2003). Uma aplicação que seja considerada mais fácil de usar que outra, tende a ser mais aceita pelos utilizadores (Davis, 1989). No entanto, esta é uma dimensão que por norma tem uma influência mais fraca na aceitação de tecnologias visto que há cada vez mais uma maior familiaridade com o uso destas no dia a dia (Kelly et al., 2023).

Por outro lado, foi igualmente demonstrado que a expectativa de esforço pode impactar positivamente a expectativa de desempenho de um sistema (Albayati, 2024; Utomo et al., 2021). Quando o utilizador sente que precisa de menos esforço para usar uma tecnologia, este vai ter a percepção de que a tecnologia o ajuda nas suas atividades do dia a dia e lhe traz benefícios (Utomo et al., 2021). A facilidade de uso leva a uma redução do esforço e da carga cognitiva necessária para utilizar a tecnologia, tornando-a mais útil aos olhos dos utilizadores (Albayati, 2024).

Levando em consideração as razões apresentadas, serão testadas as seguintes hipóteses:

**H6a. A expectativa de esforço influencia positivamente a expectativa de desempenho.**

#### **H6b. A expectativa de esforço impacta positivamente a intenção comportamental.**

A confiança pode ser definida como a disposição de uma parte em colocar-se numa posição vulnerável em relação às ações de outra parte, com base na expectativa de que essa outra parte realizará uma ação particular que é importante para quem confia, independentemente da capacidade de controlar essa outra parte (Mayer & Davis, 1995).

No contexto da inteligência artificial, o facto desta tecnologia ter a capacidade de funcionar de forma autónoma cria riscos e incertezas nos seus utilizadores. A forma como estes sistemas aprendem e chegam a uma determinada resposta muitas vezes não é de fácil compreensão para as pessoas. Este ambiente de incerteza e imprevisibilidade faz com que a confiança assuma grande importância em toda a experiência dos utilizadores (Choung et al., 2023).

Diversos estudos já demonstraram inclusive que a confiança influencia a intenção comportamental de usar ferramentas de inteligência artificial generativa (Albayati, 2024).

Posto isto, proceder-se-á ao teste da hipótese que se segue:

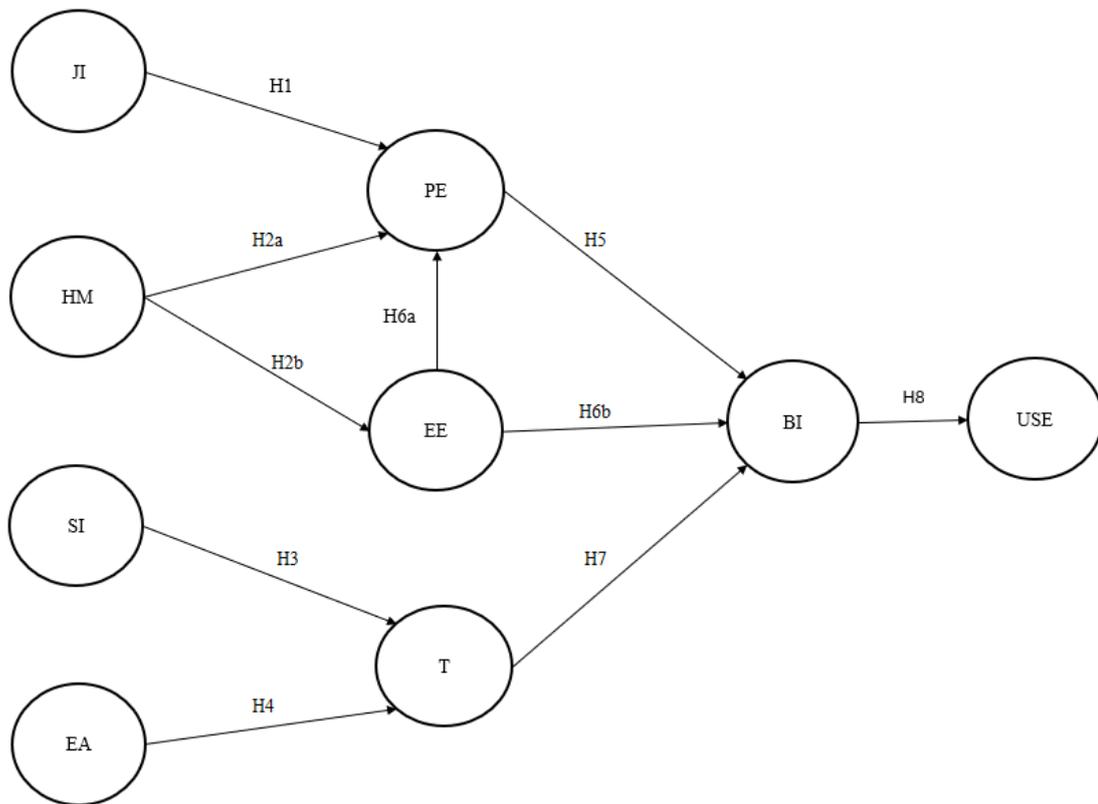
#### **H7. A confiança impacta positivamente a intenção comportamental.**

A intenção comportamental diz respeito à expectativa da intenção do utilizador em tomar uma decisão relacionada com o uso da tecnologia (Venkatesh et al., 2003). Esta dimensão foi integrada no modelo UTAUT como um previsor do uso efetivo de uma tecnologia.

Consequentemente, será testada a seguinte hipótese:

#### **H8. Existe uma relação consequencial entre a intenção comportamental e o uso de inteligência artificial generativa.**

Atendendo às dimensões apresentadas e às hipóteses de investigação desenvolvidas, foi proposto o modelo presente na Figura 1.



**Figura 1. Modelo Proposto**

## **4. Método**

### **4.1 Instrumento de Medida**

Os dados foram recolhidos através de um questionário online, criado no website Google Forms. Os itens associados a cada dimensão presentes no questionário foram adaptados de outros estudos empíricos efetuados e, em cada um, foi feita referência ao ChatGPT por ser a ferramenta de IA generativa mais reconhecida atualmente. A medição de maior parte destes itens foi feita utilizando a escala de Likert com valores de 1 a 7, onde 1 significa “Discordo totalmente” e 7 “Concordo totalmente”. No caso dos itens relativos às atitudes éticas, a escala foi adaptada de maneira a captar as perceções das pessoas quanto à utilização da IA generativa: o primeiro item é relativo à aceitabilidade onde 1 significa “Inaceitável” e 7 significa “Aceitável”; o segundo aborda a ética, sendo que 1 significa “Antiético” e 7 refere-se a “Ético”; o último item questiona se o uso é ou não correto, onde 1 significa “Errado” e 7 significa “Certo”. Foi questionada ainda a frequência de uso do ChatGPT, onde a escala varia de “Nunca” até “Várias vezes por dia”. No anexo 1 encontram-se os itens utilizados neste estudo.

Foi utilizado o método de questionário online tanto por providenciar um alcance de um maior número de pessoas de forma relativamente rápida, como por permitir acompanhar as respostas à medida que são recebidas. Além disso, permite ainda que haja uma análise dos dados mais eficaz por possibilitar a exportação dos mesmos para softwares apropriados.

### **4.2 Recolha de Dados**

A pesquisa incidiu em utilizadores de ferramentas de inteligência artificial, selecionados de forma aleatória. O questionário foi partilhado principalmente nas redes sociais, o que permitiu alcançar uma maior variedade de pessoas. O objetivo passou por perceber as perspetivas de utilizadores com diferentes perfis, variando em idade, habilitações literárias e profissão, procurando obter um reflexo da sociedade atual.

O questionário, presente no anexo 1, inclui também inicialmente perguntas sobre género, idade, habilitações literárias, profissão e setor de atividade / área de estudo. No

fim, existe ainda uma pergunta de resposta aberta na qual a pessoa pode expor a sua perspectiva em relação ao futuro da inteligência artificial.

Os dados foram retirados de um total de 157 respostas obtidas a partir do questionário apresentado no anexo 1. Os resultados desse mesmo questionário estão presentes no anexo 2. Dos 157 inquiridos, verifica-se que 96 são homens, o que equivale a 61,15% da amostra, sendo que o restante equivale ao género feminino (38,85%). Observando a idade, constata-se que a média se situa nos 32 anos. Analisando as habilitações literárias, conclui-se que 50,3% dos inquiridos possui o grau de Licenciatura, 25,5% possui o Ensino Secundário ou inferior, 21,7% têm um Mestrado / Pós-Graduação e, por último, apenas 4 inquiridos (2,5%) possuem o grau de Doutoramento. Em relação à profissão, destacam-se os trabalhadores por conta de outrem, que representam 50,96% da amostra, e os estudantes, que constituem 44,59% da amostra.

## 5. Resultados e Discussão

Com o intuito de analisar as relações entre as variáveis do modelo proposto, foi utilizado o modelo de equações estruturais (SEM) com mínimos quadrados parciais (PLS). PLS é apropriado para testar o modelo de medida e validar a causalidade do modelo estrutural. Permite também minimizar as variâncias residuais das variáveis dependentes, sendo que é adequado para amostras com distribuição não normal (Hair et al., 2013).

De forma a implementar o método PLS, foi utilizado o software SmartPLS. Este software possui a capacidade de modelar relações entre variáveis latentes, oferecendo também ferramentas para avaliar a qualidade do modelo de medida bem como para analisar o modelo estrutural.

A análise dos resultados compreende desta forma tanto a avaliação do modelo de medida como do modelo estrutural. Posteriormente, a discussão incide no balanço e interpretação dos resultados, e na comparação com os resultados obtidos noutros estudos semelhantes.

### 5.1 Avaliação do Modelo de Medida

A avaliação do modelo de medida passa por analisar a sua fiabilidade e validade. Habitualmente, o primeiro aspeto a ser analisado é a consistência interna através do Alpha de Cronbach, que oferece uma estimativa para fiabilidade baseada nas correlações entre todos os indicadores. Outra medida considerada mais precisa para avaliar a consistência interna é a *composite reliability*. Esta, ao contrário do Alpha de Cronbach, tem em conta que os indicadores podem ter diferentes *loadings*, o que vai de encontro à forma como funciona o algoritmo PLS-SEM, visto que este prioriza indicadores de acordo com a sua fiabilidade individual. Valores superiores a 0,7 destas medidas são considerados adequados (Henseler et al., 2009).

Olhando para os valores do Alpha de Cronbach e da *composite reliability* presentes no Anexo 3, verifica-se que, para estas duas medidas, todas as dimensões apresentam valores altos (superiores a 0,8), garantindo uma ótima fiabilidade.

Tendo em conta que a fiabilidade dos indicadores varia, é relevante analisar a fiabilidade de cada um deles. Esta é garantida verificando o valor dos *outer loadings*, que demonstram a correlação entre cada indicador e a dimensão correspondente. O valor desta medida deve ser superior a 0,7 de forma a ser possível considerar que o item em questão é confiável (Henseler et al., 2009).

Averiguando os dados presentes no Anexo 3, conclui-se que todos os valores da coluna *Outer Loading* são superiores a 0,7, pelo que é possível concluir que todos os indicadores possuem fiabilidade.

De forma a avaliar a validade do modelo de medida é necessário analisar dois tipos: validade convergente e validade discriminante. A validade convergente significa que um conjunto de indicadores representa a mesma dimensão subjacente (Henseler et al., 2009). Para haver validade convergente é necessário que cada indicador tenha um *outer loading* superior a 0,7 e que o valor de *Average Variance Extracted* (AVE) de cada dimensão seja maior ou igual que 0,5. O AVE é equivalente à comunalidade de cada construto. Um valor de 0,50 desta medida indica que o construto explica mais de metade da variância dos seus indicadores (Hair et al., 2014).

Posto isto, e pela observação dos valores presentes também no Anexo 3, é possível referir que todos os indicadores têm um *outer loading* superior a 0,7, como já tinha sido previamente mencionado, e os valores de *Average Variance Extracted* (AVE) são superiores a 0,5, garantindo assim a existência de validade convergente.

Em relação à validade discriminante, esta representa a medida em que os construtos são empiricamente distintos entre si. Um dos métodos para avaliar a existência de validade discriminante é o critério de Fornell-Larcker (1981). De acordo com este, para haver validade discriminante é necessário que cada construto partilhe mais variância com os respetivos indicadores do que com qualquer outro construto. Para isso é necessário que o AVE de cada dimensão seja superior ao quadrado das correlações com as restantes. O outro método para avaliar a validade discriminante está relacionado com a análise dos *cross-loadings* dos indicadores. Neste critério é esperado que os *loadings* de cada indicador sejam maiores que os seus *cross-loadings* (Hair et al., 2014).

Através da análise dos valores da Tabela II, verifica-se que os valores que estão na diagonal, correspondentes à raiz quadrada da medida AVE, são superiores aos valores

das correlações desses construtos com os restantes (equivalente a comparar o AVE de cada dimensão com o quadrado das correlações com as restantes). Ao averiguar também a tabela de *cross-loadings* presente no Anexo 4, constata-se que o segundo método para avaliar a validade discriminante também se verifica. Torna-se então possível afirmar, com base tanto no critério de Fornell-Larcker como na análise dos *cross-loadings*, que existe validade discriminante.

**Tabela II. Critério de Fornell-Larcker**

	<b>BI</b>	<b>EE</b>	<b>EA</b>	<b>HM</b>	<b>JI</b>	<b>PE</b>	<b>SI</b>	<b>T</b>	<b>USE</b>
<b>BI</b>	<b>0,938</b>								
<b>EE</b>	0,543	<b>0,930</b>							
<b>EA</b>	0,689	0,464	<b>0,930</b>						
<b>HM</b>	0,674	0,502	0,595	<b>0,951</b>					
<b>JI</b>	0,455	0,298	0,383	0,395	<b>0,932</b>				
<b>PE</b>	0,804	0,595	0,588	0,639	0,511	<b>0,916</b>			
<b>SI</b>	0,640	0,335	0,555	0,590	0,379	0,626	<b>0,938</b>		
<b>T</b>	0,650	0,512	0,620	0,666	0,376	0,665	0,607	<b>0,849</b>	
<b>USE</b>	0,714	0,455	0,489	0,422	0,393	0,706	0,515	0,437	<b>1,000</b>

## 5.2 Avaliação do Modelo Estrutural

A avaliação do modelo estrutural começa pela análise da colinearidade, visto que problemas de colinearidade podem prejudicar os resultados da regressão. Para analisar esta medida é utilizado o *Variance Inflation Factor* (VIF) e este valor deve ser inferior a 5 de modo a não existir colinearidade entre os construtos (Sarstedt et al., 2017).

Os resultados indicam que não existe colinearidade entre os construtos visto que todos os valores de VIF são inferiores a 2,2 (Tabela III), o que não ultrapassa o limite de 5.

**Tabela III. Inner VIF**

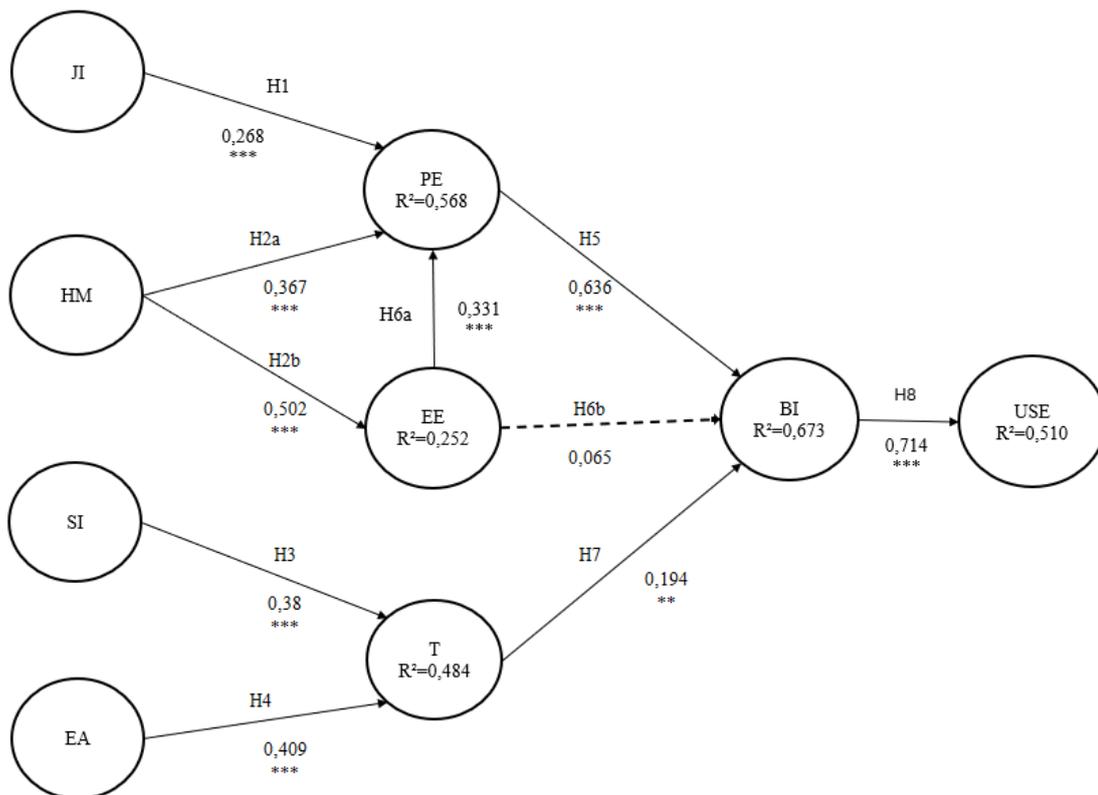
	BI	EE	Ethic	Hed	Opt	PE	SI	Trust	USE
BI									1,000
EE	1,608					1,358			
Ethic								1,444	
Hed		1,000				1,467			
Opt						1,204			
PE	2,128								
SI								1,444	
Trust	1,862								
USE									

O próximo passo desta avaliação passa por analisar o Coeficiente de Determinação, que demonstra a variância explicada em cada uma das variáveis endógenas do modelo. Esta medida varia entre 0 e 1, onde um valor de 0,75 pode ser considerado elevado, 0,5 equivale a um valor médio e 0,25 indica um valor baixo (Sarstedt et al., 2017).

Analisando o modelo estrutural presente na Figura 2, é possível referir que a segurança no emprego ( $\hat{\beta} = 0,268$ ,  $p < 0,001$ ), a motivação hedónica ( $\hat{\beta} = 0,367$ ,  $p < 0,001$ ) e a expectativa de esforço ( $\hat{\beta} = 0,331$ ,  $p < 0,001$ ) explicam 56,8% da variância da expectativa de desempenho. Por outro lado, 25,2% da expectativa de esforço pode ser explicada pela motivação hedónica ( $\hat{\beta} = 0,502$ ,  $p < 0,001$ ). Ainda a confiança pode ser explicada (48,4%) pela influência social ( $\hat{\beta} = 0,380$ ,  $p < 0,001$ ) e pelas atitudes éticas ( $\hat{\beta} = 0,409$ ,  $p < 0,001$ ). Constata-se também que a expectativa de desempenho ( $\hat{\beta} = 0,636$ ,  $p < 0,001$ ) e a confiança ( $\hat{\beta} = 0,194$ ,  $p < 0,01$ ) explicam 67,3% da intenção comportamental.

Por último, 51% da variância do uso pode ser explicada pela intenção comportamental ( $\hat{\beta} = 0,714$ ,  $p < 0,001$ ).

Conclui-se então, através dos valores dos Coeficientes de Determinação, que o modelo é capaz de explicar todas as variáveis latentes presentes, visto que todos os valores são maiores que 0,25.



**Figura 2. Modelo de Adoção de Inteligência Artificial Generativa**

\* significância com  $p < 0,05$ ; \*\* significância com  $p < 0,01$ ; \*\*\* significância com  $p < 0,001$

A medida  $F^2$  mede a contribuição das variáveis exógenas nas variáveis endógenas, e é possível classificar esse efeito em três tipos: efeito grande ( $F^2 > 0,350$ ), efeito médio ( $0,350 > F^2 > 0,150$ ) e efeito pequeno ( $0,150 > F^2 > 0,020$ ) (Aparicio et al., 2021).

Através da observação da Tabela IV é possível referir que a hipótese 8 é a que apresenta um maior valor de  $F^2$  (1,042), pelo que indica um efeito grande ( $F^2 > 0,350$ ) da intenção comportamental no uso da inteligência artificial generativa. Também H5 possui

um valor que simboliza um efeito grande (0,582), desta vez entre a expectativa de desempenho e a intenção comportamental. Por outro lado, é de notar que H1 e H7 apresentam valores de 0,138 e 0,062 respetivamente, o que demonstra um efeito pequeno, no primeiro caso entre a segurança no emprego e a expectativa de desempenho, e no segundo entre a confiança e a intenção comportamental. A hipótese 6b foi rejeitada, visto que apresenta um valor de  $F^2$  igual a 0,008, inferior ao limite definido para o efeito mais baixo. Nas restantes hipóteses os valores desta medida variam entre 0,187 e 0,337, o que revela um efeito médio entre as dimensões presentes em cada uma das hipóteses.

**Tabela IV. Betas, P-Values,  $F^2$ , Efeito e Decisão das Hipóteses**

Hipóteses	Beta	P-Values	$F^2$	Efeito	Decisão
H1. A Segurança no Emprego afeta positivamente a Expectativa de Desempenho	0,268	0	0,138	Pequeno	Aceite
H2a. A Motivação Hedónica influencia positivamente a Expectativa de Desempenho.	0,367	0	0,213	Médio	Aceite
H2b. A Motivação Hedónica impacta positivamente a Expectativa de Esforço.	0,502	0	0,337	Médio	Aceite
H3. A Influência Social afeta positivamente a Confiança.	0,380	0	0,194	Médio	Aceite
H4. As Atitudes Éticas afetam positivamente a Confiança.	0,409	0	0,224	Médio	Aceite
H5. A Expectativa de Desempenho impacta positivamente a Intenção Comportamental.	0,636	0	0,582	Grande	Aceite
H6a. A Expectativa de Esforço influencia positivamente a Expectativa de Desempenho.	0,331	0	0,187	Médio	Aceite
H6b. A Expectativa de Esforço impacta positivamente a Intenção Comportamental.	0,065	0,290	0,008	Rejeitado	Não Aceite
H7. A Confiança impacta positivamente a Intenção Comportamental.	0,194	0,004	0,062	Pequeno	Aceite
H8. Existe uma relação consequential entre a Intenção Comportamental e o Uso de Inteligência Artificial Generativa.	0,714	0	1,042	Grande	Aceite

### 5.3 Discussão

Olhando para os resultados obtidos, podemos verificar que todas as hipóteses do modelo foram aceites, com exceção da hipótese 6b, que apresenta um *p-value* de 0,290 ( $p > 0,05$ ) e um valor de  $F^2$  igual a 0,008 e por isso é rejeitada.

Relativamente à hipótese 1, não foram encontrados outros estudos que tenham comparado estas duas dimensões, sendo assim impossível estabelecer uma comparação com outros resultados obtidos. No entanto, os resultados deste estudo permitem comprovar a hipótese de que a segurança no emprego afeta positivamente a expectativa de desempenho ( $p < 0,001$ ), ainda que com um efeito pequeno ( $0,138 > F^2 < 0,02$ ). É possível assim referir que pessoas que não sintam insegurança no emprego derivada do surgimento da inteligência artificial generativa, tendem a reconhecer mais benefícios na utilização desse tipo de tecnologia.

Em relação às hipóteses referentes à motivação hedónica (2a e 2b), ambas foram confirmadas ( $p < 0,001$ ), apresentando um efeito médio ( $0,350 > F^2 < 0,150$ ). É assim possível concluir que a motivação hedónica tem um efeito positivo tanto na expectativa de desempenho como na expectativa de esforço. Embora no contexto de outras tecnologias de inteligência artificial, os resultados deste estudo vão de encontro aos de Gursoy et al. (2019), onde também foi validada a relação da motivação hedónica tanto com a expectativa de desempenho como com a expectativa de esforço ( $p < 0,001$ ), com um  $\hat{\beta}$  também relativamente alto ( $\hat{\beta} > 0,350$ ) em ambas as hipóteses.

A hipótese de que a influência social afeta positivamente a confiança foi comprovada neste estudo ( $p < 0,001$ ), sendo ainda possível referir que existe um efeito médio ( $0,350 > F^2 < 0,150$ ) da primeira dimensão na segunda. Estes resultados estão de acordo com outros estudos feitos no âmbito de tecnologias distintas (Li et al., 2008; Zhang et al., 2020) onde foi também revelado um impacto positivo da dimensão da influência social na confiança.

Os resultados mostram ainda que as atitudes éticas influenciam a confiança ( $p < 0,001$ ), havendo um efeito médio ( $0,350 > F^2 < 0,150$ ) entre as duas dimensões. Confirma-se assim a importância das dimensões éticas na explicação da confiança na inteligência

artificial, o que também foi demonstrado por Omrani et al. (2022) no seu estudo relativo à confiança em sistemas baseados em inteligência artificial.

Existem ainda evidências de que a expectativa de desempenho impacta positivamente a intenção comportamental ( $p < 0,001$ ). Por outro lado, é importante realçar que existe um efeito grande ( $F^2 > 0,350$ ) do primeiro em relação ao segundo construto. Esta já é uma hipótese amplamente estudada no contexto da adoção de tecnologias, e a expectativa de desempenho pode ser encarada como o mais forte preditor da intenção de utilizar uma tecnologia (Venkatesh et al., 2003). Comparando os resultados obtidos neste estudo com outros realizados no âmbito da utilização de inteligência artificial generativa, de Camilleri (2024) e de Strzelecki (2023), observa-se que nestes últimos a hipótese em questão tem um  $\hat{\beta}$  mais baixo (0,236 e 0,261, respetivamente) comparativamente ao  $\hat{\beta}$  presente neste estudo (0,636).

Das duas hipóteses referentes à expectativa de esforço (6a e 6b), apenas a primeira foi aceite visto que apresenta um *p-value* inferior a 0,001, sendo ainda apresentado um efeito médio ( $0,350 > F^2 < 0,150$ ) da expectativa de esforço na expectativa de desempenho. Estes resultados estão em concordância com os encontrados por Camilleri (2024) onde inclusive o valor de  $\hat{\beta}$  (0,311) é semelhante ao encontrado no presente estudo (0,331). Em relação à hipótese de que a expectativa de esforço impacta positivamente a intenção comportamental, esta foi rejeitada por apresentar um *p-value* superior a 0,05. Este resultado contraria o que foi encontrado por Camilleri (2024) e Ma et al. (2024) tendo em consideração que nos estudos destes autores verificou-se que a expectativa de esforço é um determinante da intenção comportamental de utilizar o ChatGPT.

Relativamente à hipótese 7, confirma-se que a confiança afeta positivamente a intenção comportamental ( $p < 0,01$ ), onde ainda é observável um efeito pequeno ( $0,138 > F^2 < 0,02$ ) da confiança em relação à intenção comportamental. É assim possível referir que uma maior confiança na tecnologia em causa leva a uma maior intenção comportamental de a utilizar. Esta hipótese foi também corroborada por outros autores como Albayati (2024) e Choudhury & Shamszare (2023). No entanto, neste último estudo foi encontrado um valor de  $\hat{\beta}$  bastante mais alto (0,711).

Por último, o *p-value* relativo à hipótese 8, sendo inferior a 0,001, apoia a ideia de que a intenção comportamental influencia positivamente o uso da inteligência artificial

generativa. É ainda apresentado um efeito grande da primeira dimensão relativamente à segunda. Foi deste modo demonstrado que quanto maior a intenção de um indivíduo utilizar uma tecnologia de inteligência artificial generativa, mais provável será a utilização dessa tecnologia. Esta hipótese já foi comprovada por diversos outros estudos como o de Venkatesh et al (2012).

## 6. Conclusão

A inteligência artificial generativa é, efetivamente, uma das tecnologias em maior destaque nos dias que correm. Esta ferramenta tem o potencial de continuar a moldar o futuro de forma positiva nas mais diversas áreas, no entanto, o seu desenvolvimento deve estar sempre alinhado com valores fundamentais da sociedade. O medo de substituição no emprego e questões éticas como a privacidade, transparência e responsabilidade surgem como os maiores obstáculos a serem ultrapassados para que haja um maior consenso em torno da utilização desta tecnologia.

Deste modo, este estudo procurou clarificar quais são os principais fatores que levam à adoção e utilização da inteligência artificial generativa, desenvolvendo um modelo com 9 dimensões, no qual estão presentes 10 hipóteses de investigação. Este modelo foi validado através de um questionário, que permitiu entender as opiniões de utilizadores da tecnologia.

A análise das relações das variáveis, através do modelo de equações estruturais (SEM) com mínimos quadrados parciais (PLS), mostrou que, das dez hipóteses existentes, apenas a hipótese 6b, relativa ao impacto da expectativa de esforço na intenção comportamental, foi rejeitada.

Os resultados obtidos permitem afirmar, em primeiro lugar, que existe uma influência positiva tanto da segurança no emprego (H1) como da expectativa de esforço (H6a) na expectativa de desempenho. Comprovou-se também que a motivação hedónica tem um impacto positivo tanto na expectativa de desempenho como na expectativa de esforço (H2a e H2b). Foi demonstrado ainda que a confiança é influenciada positivamente tanto pela influência social como pelas atitudes éticas (H3 e H4). Tanto a expectativa de desempenho como a confiança são considerados determinantes da intenção comportamental (H5 e H7), apesar de haver um efeito bastante superior da primeira dimensão. Por último, foi validada a relação consequencial entre a intenção comportamental e o uso da tecnologia (H8).

Percebe-se então a influência de diversos fatores na adoção da inteligência artificial generativa. Dimensões como a motivação hedónica, influência social, expectativa de desempenho, expectativa de esforço e a confiança já haviam sido

exploradas por outros autores no âmbito da aceitação de tecnologias, e este estudo torna-se mais uma contribuição no sentido de entender a importância destas variáveis no contexto da adoção da inteligência artificial generativa. A integração no modelo de dimensões como a insegurança no emprego e as atitudes éticas permite perceber de que forma duas das principais preocupações em torno desta tecnologia podem afetar as outras variáveis e consequentemente o uso desta ferramenta.

Relativamente às limitações deste trabalho, o facto de cerca de 63% dos inquiridos terem uma idade igual ou inferior a 30 anos pode interferir nos resultados, no entanto, é nesta faixa etária que provavelmente se encontra a maior parte dos utilizadores desta tecnologia. Além disso, verifica-se que quase metade dos indivíduos que constituem a amostra são estudantes, não havendo desta forma um reflexo fiável da sociedade em geral.

Para possíveis trabalhos futuros, poderá ser interessante estabelecer comparações entre grupos distintos nomeadamente a nível de profissões/áreas profissionais ou de faixas etárias, visto que cada grupo poderia apresentar resultados distintos, dos quais seria possível retirar conclusões. Outra abordagem possível diz respeito à análise da adoção deste tipo de tecnologia em áreas mais específicas, como em organizações ou em escolas/faculdades, considerando que cada um destes casos apresenta especificidades e desafios próprios que poderiam ser aferidos.

## Referências Bibliográficas

- Agarwal, R., & Karahanna, E. (2000). Time Flies When You're Having Fun: Cognitive Absorption and Beliefs about Information Technology Usage. *MIS Quarterly*, 24(4), 665. <https://doi.org/10.2307/3250951>
- Ajzen, I. (1991). The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, 50(2), 179–211. [https://doi.org/10.1016/0749-5978\(91\)90020-T](https://doi.org/10.1016/0749-5978(91)90020-T)
- Albayati, H. (2024). Investigating undergraduate students' perceptions and awareness of using ChatGPT as a regular assistance tool: A user acceptance perspective study. *Computers and Education: Artificial Intelligence*, 6, 100203. <https://doi.org/10.1016/j.caeai.2024.100203>
- Aparicio, M., Costa, C. J., & Moises, R. (2021). Gamification and reputation: Key determinants of e-commerce usage and repurchase intention. *Heliyon*, 7(3), e06383. <https://doi.org/10.1016/j.heliyon.2021.e06383>
- Autor, D. H. (2015). Why Are There Still So Many Jobs? The History and Future of Workplace Automation. *Journal of Economic Perspectives*, 29(3), 3–30. <https://doi.org/10.1257/jep.29.3.3>
- Bessen, J. (2019). *Automation and Jobs: When Technology Boosts Employment*.
- Bharadiya, J. P., Thomas, R. K., & Ahmed, F. (2023). Rise of Artificial Intelligence in Business and Industry. *Journal of Engineering Research and Reports*, 25(3), 85–103. <https://doi.org/10.9734/jerr/2023/v25i3893>
- Camilleri, M. A. (2024). Factors affecting performance expectancy and intentions to use ChatGPT: Using SmartPLS to advance an information technology acceptance

- framework. *Technological Forecasting and Social Change*, 201, 123247.  
<https://doi.org/10.1016/j.techfore.2024.123247>
- Cao, J., & Song, Z. (2024). An incoming threat: The influence of automation potential on job insecurity. *Asia-Pacific Journal of Business Administration*.  
<https://doi.org/10.1108/APJBA-07-2022-0328>
- Chan, R. Y. K., Wong, Y. H., & Leung, T. K. P. (2008). Applying Ethical Concepts to the Study of “Green” Consumer Behavior: An Analysis of Chinese Consumers’ Intentions to Bring their Own Shopping Bags. *Journal of Business Ethics*, 79(4), 469–481. <https://doi.org/10.1007/s10551-007-9410-8>
- Chassagnon, G., Vakalopolou, M., Paragios, N., & Revel, M.-P. (2020). Deep learning: Definition and perspectives for thoracic imaging. *European Radiology*, 30(4), 2021–2030. <https://doi.org/10.1007/s00330-019-06564-3>
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial Intelligence in Education: A Review. *IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/ACCESS.2020.2988510>
- Choudhury, A., & Shamszare, H. (2023). Investigating the Impact of User Trust on the Adoption and Use of ChatGPT: Survey Analysis. *Journal of Medical Internet Research*, 25, e47184. <https://doi.org/10.2196/47184>
- Choung, H., David, P., & Ross, A. (2023). Trust in AI and Its Role in the Acceptance of AI Technologies. *International Journal of Human–Computer Interaction*, 39(9), 1727–1739. <https://doi.org/10.1080/10447318.2022.2050543>
- Costa, C & Aparicio, M. (2018). Gamification: Software usage ecology. *Gamification: software usage ecology*, (1), 92-100.
- Costa, C., Aparicio, M, Aparicio, S. & Aparicio, J. (2017). Gamification usage ecology. In *Proceedings of the 35th ACM International Conference on the Design of*

- Communication (SIGDOC '17). Association for Computing Machinery, New York, NY, USA, Article 2, 1–9. <https://doi.org/10.1145/3121113.3121205>
- Davis, F. D. (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *MIS Quarterly*, 13(3), 319. <https://doi.org/10.2307/249008>
- Davis, F. D., Bagozzi, R. P., & Warshaw, P. R. (1989). User Acceptance of Computer Technology: A Comparison of Two Theoretical Models. *Management Science*, 35(8), 982–1003. <https://doi.org/10.1287/mnsc.35.8.982>
- Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2024). Generative AI. *Business & Information Systems Engineering*, 66(1), 111–126. <https://doi.org/10.1007/s12599-023-00834-7>
- Fornell, C., & Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39. <https://doi.org/10.2307/3151312>
- García-Peñalvo, F., & Vázquez-Ingelmo, A. (2023). What Do We Mean by GenAI? A Systematic Mapping of The Evolution, Trends, and Techniques Involved in Generative AI. *International Journal of Interactive Multimedia and Artificial Intelligence*, 8(4), 7. <https://doi.org/10.9781/ijimai.2023.07.006>
- Goldman Sachs (2023). Generative AI could raise global GDP by 7%. <https://www.goldmansachs.com/insights/articles/generative-ai-could-raise-global-gdp-by-7-percent>
- Greenhalgh, L., & Rosenblatt, Z. (1984). Job Insecurity: Toward Conceptual Clarity. *The Academy of Management Review*, 9(3), 438. <https://doi.org/10.2307/258284>

- Gursoy, D., Chi, O. H., Lu, L., & Nunkoo, R. (2019). Consumers acceptance of artificially intelligent (AI) device use in service delivery. *International Journal of Information Management*, *49*, 157–169.  
<https://doi.org/10.1016/j.ijinfomgt.2019.03.008>
- Haenlein, M., & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, *61*(4), 5–14. <https://doi.org/10.1177/0008125619864925>
- Hair, J. F., Ringle, C. M., & Sarstedt, M. (2013). Partial Least Squares Structural Equation Modeling: Rigorous Applications, Better Results and Higher Acceptance. *Long Range Planning*, *46*(1–2), 1–12.  
<https://doi.org/10.1016/j.lrp.2013.01.001>
- Hair, J. F., Sarstedt, M., Hopkins, L., & G. Kuppelwieser, V. (2014). Partial least squares structural equation modeling (PLS-SEM): An emerging tool in business research. *European Business Review*, *26*(2), 106–121.  
<https://doi.org/10.1108/EBR-10-2013-0128>
- Helm, J. M., Swiergosz, A. M., Haeberle, H. S., Karnuta, J. M., Schaffer, J. L., Krebs, V. E., Spitzer, A. I., & Ramkumar, P. N. (2020). Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions. *Current Reviews in Musculoskeletal Medicine*, *13*(1), 69–76.  
<https://doi.org/10.1007/s12178-020-09600-8>
- Henseler, J., Ringle, C. M., & Sinkovics, R. R. (2009). The use of partial least squares path modeling in international marketing. Em R. R. Sinkovics & P. N. Ghauri (Eds.), *Advances in International Marketing* (Vol. 20, pp. 277–319). Emerald

- Group Publishing Limited. [https://doi.org/10.1108/S1474-7979\(2009\)0000020014](https://doi.org/10.1108/S1474-7979(2009)0000020014)
- Hu, K. (2023, fevereiro 2). ChatGPT sets record for fastest-growing user base—Analyst note. *Reuters*. <https://www.reuters.com/technology/chatgpt-sets-record-fastest-growing-user-base-analyst-note-2023-02-01/>
- Jalali, A., Jaafar, M., & Hidzir, N. I. (2020). Indirect effect of workplace bullying on emotional exhaustion through job insecurity among Malaysian workers: The buffering role of religion. *Journal of Islamic Accounting and Business Research*, *11*(7), 1325–1342. <https://doi.org/10.1108/JIABR-11-2018-0182>
- Jiang, Y., Li, X., Luo, H., Yin, S., & Kaynak, O. (2022). Quo vadis artificial intelligence? *Discover Artificial Intelligence*, *2*(1), 4. <https://doi.org/10.1007/s44163-022-00022-8>
- Kaul, V., Enslin, S., & Gross, S. A. (2020). History of artificial intelligence in medicine. *Gastrointestinal Endoscopy*, *92*(4), 807–812. <https://doi.org/10.1016/j.gie.2020.06.040>
- Kelly, S., Kaye, S.-A., & Oviedo-Trespalacios, O. (2023). What factors contribute to the acceptance of artificial intelligence? A systematic review. *Telematics and Informatics*, *77*, 101925. <https://doi.org/10.1016/j.tele.2022.101925>
- Kirova, V. D., Ku, C. S., Laracy, J. R., & Marlowe, T. J. (2023). The Ethics of Artificial Intelligence in the Era of Generative AI. *Journal of Systemics, Cybernetics and Informatics*, *21*(4), 42–50. <https://doi.org/10.54808/JSCI.21.04.42>
- Lai, P. (2017). The literature review of technology adoption models and theories for the novelty technology. *Journal of Information Systems and Technology Management*, *14*(1), 21–38. <https://doi.org/10.4301/S1807-17752017000100002>

- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Li, X., Hess, T. J., & Valacich, J. S. (2008). Why do we trust new technology? A study of initial trust formation with organizational information systems. *The Journal of Strategic Information Systems*, *17*(1), 39–71.  
<https://doi.org/10.1016/j.jsis.2008.01.001>
- Lim, W. M., Gunasekara, A., Pallant, J. L., Pallant, J. I., & Pechenkina, E. (2023). Generative AI and the future of education: Ragnarök or reformation? A paradoxical perspective from management educators. *The International Journal of Management Education*, *21*(2), 100790.  
<https://doi.org/10.1016/j.ijme.2023.100790>
- Ma, J., Wang, P., Li, B., Wang, T., Pang, X. S., & Wang, D. (2024). Exploring User Adoption of ChatGPT: A Technology Acceptance Model Perspective. *International Journal of Human–Computer Interaction*, 1–15.  
<https://doi.org/10.1080/10447318.2024.2314358>
- Mahesh, B. (2020). Machine Learning Algorithms—A Review. *International Journal of Science and Research (IJSR)*, *9*(1), 381–386.  
<https://doi.org/10.21275/ART20203995>
- Mayer, R. C., & Davis, J. H. (1995). *An Integrative Model of Organizational Trust*.
- McCarthy, J. (2004). *WHAT IS ARTIFICIAL INTELLIGENCE?*
- Omrani, N., Rivieccio, G., Fiore, U., Schiavone, F., & Agreda, S. G. (2022). To trust or not to trust? An assessment of trust in AI-based systems: Concerns, ethics and contexts. *Technological Forecasting and Social Change*, *181*, 121763.  
<https://doi.org/10.1016/j.techfore.2022.121763>

- Ooi, K.-B., Tan, G. W.-H., Al-Emran, M., Al-Sharafi, M. A., Capatina, A., Chakraborty, A., Dwivedi, Y. K., Huang, T.-L., Kar, A. K., Lee, V.-H., Loh, X.-M., Micu, A., Mikalef, P., Mogaji, E., Pandey, N., Raman, R., Rana, N. P., Sarker, P., Sharma, A., ... Wong, L.-W. (2023). The Potential of Generative Artificial Intelligence Across Disciplines: Perspectives and Future Directions. *Journal of Computer Information Systems*, 1–32.  
<https://doi.org/10.1080/08874417.2023.2261010>
- Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., Reyes, M. P., Shyu, M.-L., Chen, S.-C., & Iyengar, S. S. (2019). A Survey on Deep Learning: Algorithms, Techniques, and Applications. *ACM Computing Surveys*, 51(5), 1–36.  
<https://doi.org/10.1145/3234150>
- Qian, L., Yin, J., Huang, Y., & Liang, Y. (2023). The role of values and ethics in influencing consumers' intention to use autonomous vehicle hailing services. *Technological Forecasting and Social Change*, 188, 122267.  
<https://doi.org/10.1016/j.techfore.2022.122267>
- Ramesh, A., Kambhampati, C., Monson, J., & Drew, P. (2004). Artificial intelligence in medicine. *Annals of The Royal College of Surgeons of England*, 86(5), 334–338.  
<https://doi.org/10.1308/147870804290>
- Ray, S. (2019). *A Quick Review of Machine Learning Algorithms*.
- Sætra, H. S. (2023). Generative AI: Here to stay, but for good? *Technology in Society*, 75, 102372. <https://doi.org/10.1016/j.techsoc.2023.102372>
- Sarstedt, M., Ringle, C. M., & Hair, J. F. (2017). Partial Least Squares Structural Equation Modeling. Em C. Homburg, M. Klarmann, & A. Vomberg (Eds.),

- Handbook of Market Research* (pp. 1–40). Springer International Publishing.  
[https://doi.org/10.1007/978-3-319-05542-8\\_15-1](https://doi.org/10.1007/978-3-319-05542-8_15-1)
- Strzelecki, A. (2023). To use or not to use ChatGPT in higher education? A study of students' acceptance and use of technology. *Interactive Learning Environments*, 1–14. <https://doi.org/10.1080/10494820.2023.2209881>
- Utomo, P., Kurniasari, F., & Purnamaningsih, P. (2021). The Effects of Performance Expectancy, Effort Expectancy, Facilitating Condition, and Habit on Behavior Intention in Using Mobile Healthcare Application. *International Journal of Community Service & Engagement*, 2(4), 183–197.  
<https://doi.org/10.47747/ijcse.v2i4.529>
- Veiga, M & Costa, C (2024) Ethics and Artificial Intelligence Adoption, arXiv:2412.00330 <https://doi.org/10.48550/arXiv.2412.00330>
- Venkatesh, Morris, Davis, & Davis. (2003). User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, 27(3), 425.  
<https://doi.org/10.2307/30036540>
- Venkatesh, Thong, & Xu. (2012). Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology. *MIS Quarterly*, 36(1), 157. <https://doi.org/10.2307/41410412>
- Venkatesh, V. (2000). Determinants of Perceived Ease of Use: Integrating Control, Intrinsic Motivation, and Emotion into the Technology Acceptance Model. *Information Systems Research*, 11(4), 342–365.  
<https://doi.org/10.1287/isre.11.4.342.11872>

- Venkatesh, V., & Bala, H. (2008). Technology Acceptance Model 3 and a Research Agenda on Interventions. *Decision Sciences*, 39(2), 273–315.  
<https://doi.org/10.1111/j.1540-5915.2008.00192.x>
- Venkatesh, V., & Davis, F. D. (1996). A Model of the Antecedents of Perceived Ease of Use: Development and Test. *Decision Sciences*, 27(3), 451–481.  
<https://doi.org/10.1111/j.1540-5915.1996.tb01822.x>
- Venkatesh, V., & Davis, F. D. (2000). A Theoretical Extension of the Technology Acceptance Model: Four Longitudinal Field Studies. *Management Science*, 46(2), 186–204. <https://doi.org/10.1287/mnsc.46.2.186.11926>
- Zhang, T., Tao, D., Qu, X., Zhang, X., Zeng, J., Zhu, H., & Zhu, H. (2020). Automated vehicle acceptance in China: Social influence and initial trust are key determinants. *Transportation Research Part C: Emerging Technologies*, 112, 220–233. <https://doi.org/10.1016/j.trc.2020.01.027>
- Zohny, H., McMillan, J., & King, M. (2023). Ethics of generative AI. *Journal of Medical Ethics*, 49(2), 79–80. <https://doi.org/10.1136/jme-2023-108909>

## Anexos

### Anexo 1. Questionário

Construtos	Itens	Literatura
<b>Intenção Comportamental (BI)</b>	BI1. Pretendo continuar a usar o ChatGPT no futuro. BI2. Tentarei sempre usar o ChatGPT nos meus estudos. BI3. Pretendo continuar a usar o ChatGPT com frequência.	(Venkatesh et al., 2012)
<b>Atitudes Éticas (EA)</b>	EA1. Usar o ChatGPT é: (1= Inaceitável, ..., 7= Aceitável) EA2. Usar o ChatGPT é: (1= Antiético ..., 7= Ético) EA3. Usar o ChatGPT é: (1= Errado, ..., 7= Certo)	(Qian et al., 2023)
<b>Expectativa de Esforço (EE)</b>	EE1. Aprender a utilizar o ChatGPT é fácil para mim. EE2. A minha interação com o ChatGPT é clara e compreensível. EE3. Considero o ChatGPT fácil de utilizar.	(Venkatesh et al., 2012)
<b>Motivação Hedônica (HM)</b>	HM1. É divertido para mim usar o ChatGPT. HM2. O ChatGPT é agradável / prazeroso. HM3. Sinto-me animada/o a usar o ChatGPT.	(Venkatesh et al., 2012)
<b>Insegurança no Emprego (JI)</b>	JI4. Com o surgimento da Inteligência Artificial Generativa, as minhas oportunidades de carreira futuras são favoráveis. JI5. Com o surgimento da Inteligência Artificial Generativa, a minha evolução salarial é promissora.	(Jalali et al., 2020)
<b>Expectativa de Desempenho (PE)</b>	PE1. Considero o ChatGPT útil no meu dia-a-dia. PE2. A utilização do ChatGPT aumenta as minhas chances de realizar tarefas que são importantes para mim. PE3. A utilização do ChatGPT ajuda-me a realizar tarefas mais rapidamente. PE4. A utilização do ChatGPT aumenta a minha produtividade.	(Venkatesh et al., 2012)
<b>Influência Social (SI)</b>	SI1. As pessoas que são importantes para mim pensam que deveria utilizar o ChatGPT. SI2. As pessoas que influenciam o meu comportamento consideram que deveria utilizar o ChatGPT. SI3. As pessoas cujas opiniões eu valorizo preferem que eu use o ChatGPT.	(Venkatesh et al., 2012)
<b>Confiança (T)</b>	T1. Eu acredito que o ChatGPT é eficaz e seguro no que é desenhado para fazer. T2. Eu acredito que o ChatGPT permite-me fazer o que eu preciso. T3. Eu acredito que os utilizadores de ChatGPT são confiáveis. T4. Eu acredito que o ChatGPT é feito numa organização confiável.	(Albayati, 2024)
<b>Uso (USE)</b>	USE1. Frequência de uso do ChatGPT: (Frequência varia de “Nunca” até “Várias Vezes por dia”)	(Venkatesh et al., 2012)

## Anexo 2. Resultados do Questionário

	<b>Tipo</b>	<b>Quantidade</b>	<b>Percentagem</b>
Género	Masculino	96	61,15%
	Feminino	61	38,85%
	<b>Total</b>	157	100%
Idade	< = 30	99	63,06%
	> 30	58	36,94%
	<b>Total</b>	157	100%
Habilitações Literárias	Ensino Secundário	40	25,5%
	Licenciatura	79	50,3%
	Mestrado / Pós-Graduação	34	21,7%
	Doutoramento	4	2,5%
	<b>Total</b>	157	100%
Profissões frequentes	Trabalhador por conta de outrem	80	50,96%
	Estudante	70	44,59%
	Trabalhador por conta própria	13	8,28%

**Anexo 3. Outer Loadings, Composite Reliability e AVE**

<b>Dimensão</b>	<b>Item</b>	<b>Outer Loading</b>	<b>Composite Reliability</b>	<b>Cronbach's Alpha</b>	<b>AVE</b>
<b>BI</b>	BI1	0,936	0,935	0,932	0,881
	BI2	0,919			
	BI3	0,960			
<b>EA</b>	EA1	0,918	0,930	0,922	0,864
	EA2	0,932			
	EA3	0,938			
<b>EE</b>	EE1	0,942	0,924	0,922	0,865
	EE2	0,917			
	EE3	0,931			
<b>HM</b>	HM1	0,939	0,948	0,948	0,905
	HM2	0,964			
	HM3	0,952			
<b>JI</b>	J14	0,929	0,849	0,848	0,868
	J15	0,935			
<b>PE</b>	PE1	0,901	0,936	0,936	0,839
	PE2	0,937			
	PE3	0,910			
	PE4	0,916			
<b>SI</b>	SI1	0,934	0,935	0,932	0,881
	SI2	0,949			
	SI3	0,933			
<b>T</b>	T1	0,788	0,884	0,871	0,721
	T2	0,849			
	T3	0,874			
	T4	0,881			
<b>USE</b>	U1	1,000			

**Anexo 4. Cross-loadings**

	<b>BI</b>	<b>EE</b>	<b>EA</b>	<b>HM</b>	<b>JI</b>	<b>PE</b>	<b>SI</b>	<b>T</b>	<b>USE</b>
<b>BI1</b>	<b>0,936</b>	0,593	0,707	0,672	0,414	0,773	0,590	0,638	0,693
<b>BI2</b>	<b>0,919</b>	0,453	0,582	0,593	0,411	0,717	0,626	0,570	0,619
<b>BI3</b>	<b>0,960</b>	0,477	0,646	0,631	0,455	0,771	0,589	0,619	0,696
<b>EA1</b>	0,698	0,453	<b>0,918</b>	0,617	0,367	0,607	0,572	0,631	0,490
<b>EA2</b>	0,599	0,433	<b>0,932</b>	0,528	0,352	0,519	0,499	0,573	0,404
<b>EA3</b>	0,614	0,401	<b>0,938</b>	0,501	0,346	0,501	0,464	0,509	0,467
<b>EE1</b>	0,492	<b>0,942</b>	0,398	0,440	0,257	0,529	0,263	0,431	0,436
<b>EE2</b>	0,520	<b>0,917</b>	0,469	0,516	0,317	0,580	0,345	0,494	0,437
<b>EE3</b>	0,501	<b>0,931</b>	0,423	0,439	0,252	0,547	0,322	0,500	0,395
<b>HM1</b>	0,651	0,494	0,568	<b>0,939</b>	0,329	0,606	0,551	0,607	0,462
<b>HM2</b>	0,638	0,489	0,589	<b>0,964</b>	0,396	0,610	0,568	0,672	0,368
<b>HM3</b>	0,636	0,449	0,540	<b>0,952</b>	0,403	0,608	0,563	0,622	0,374
<b>JI4</b>	0,432	0,286	0,374	0,392	<b>0,929</b>	0,466	0,344	0,347	0,337
<b>JI5</b>	0,417	0,269	0,340	0,345	<b>0,935</b>	0,486	0,362	0,354	0,394
<b>PE1</b>	0,734	0,530	0,553	0,507	0,453	<b>0,901</b>	0,542	0,595	0,695
<b>PE2</b>	0,737	0,507	0,513	0,602	0,500	<b>0,937</b>	0,594	0,633	0,644
<b>PE3</b>	0,732	0,636	0,553	0,622	0,399	<b>0,910</b>	0,543	0,618	0,614
<b>PE4</b>	0,742	0,505	0,535	0,607	0,521	<b>0,916</b>	0,615	0,589	0,637
<b>SI1</b>	0,565	0,313	0,480	0,526	0,315	0,560	<b>0,934</b>	0,547	0,451
<b>SI2</b>	0,611	0,340	0,551	0,567	0,379	0,594	<b>0,949</b>	0,549	0,517
<b>SI3</b>	0,623	0,292	0,529	0,565	0,371	0,606	<b>0,933</b>	0,607	0,481
<b>T1</b>	0,424	0,433	0,423	0,498	0,252	0,418	0,372	<b>0,788</b>	0,207
<b>T2</b>	0,643	0,525	0,534	0,630	0,383	0,750	0,564	<b>0,849</b>	0,442
<b>T3</b>	0,545	0,394	0,593	0,565	0,313	0,534	0,560	<b>0,874</b>	0,435
<b>T4</b>	0,563	0,385	0,534	0,555	0,314	0,513	0,531	<b>0,881</b>	0,358
<b>USE1</b>	0,714	0,455	0,489	0,422	0,393	0,706	0,515	0,437	<b>1,000</b>