



Artur Ricardo Borges Rodrigues

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Coimbra, agosto de 2025



Artur Ricardo Borges Rodrigues

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Dissertação submetida ao Instituto Superior de Contabilidade e Administração de Coimbra para cumprimento dos requisitos necessários à obtenção do grau de **Mestre em Análise de Dados e Sistemas de Apoio à Decisão**, realizada sob a orientação da Professora Doutora Maria do Castelo Gouveia e coorientação da Professora Doutora Carla Henriques.

Coimbra, agosto de 2025

TERMO DE RESPONSABILIDADE

Declaro ser o autor desta dissertação, que constitui um trabalho original e inédito, que nunca foi submetido a outra Instituição de ensino superior para obtenção de um grau académico ou outra habilitação. Atesto ainda que todas as citações estão devidamente identificadas e que tenho consciência de que o plágio constitui uma grave falta de ética, que poderá resultar na anulação da presente dissertação.

PENSAMENTO

"Believe you can and you're halfway there."

Theodore Roosevelt

AGRADECIMENTOS

Gostaria de manifestar o meu sincero agradecimento a todos aqueles que, de alguma forma, tornaram possível a concretização desta dissertação.

Em primeiro lugar, expresso o meu profundo agradecimento à minha orientadora, Professora Doutora Maria do Castelo Gouveia, e à minha coorientadora, Professora Doutora Carla Henriques, pela orientação dedicada, ao longo de todo este percurso. O olhar crítico, mas sempre construtivo, bem como a capacidade de me desafiarem e incentivarem a sair da minha zona de conforto, foram essenciais para a concretização deste trabalho.

À minha irmã e aos meus pais, agradeço por acreditarem sempre em mim. O vosso encorajamento e apoio inabaláveis foram essenciais para que eu pudesse alcançar este objetivo.

Gostaria ainda de agradecer a todos os meus colegas de turma, com um agradecimento especial ao Daniel Matos, com quem tive a oportunidade de partilhar esta caminhada académica.

A todos, o meu sincero obrigado.

RESUMO

O presente estudo teve como propósito avaliar os efeitos da inteligência artificial (IA) no mercado de trabalho em vinte países da União Europeia (UE), ao longo do período de 2019 a 2023. Recorreu-se à metodologia *Value-Based Data Envelopment Analysis* (VBDEA), combinada com a abordagem *Hierarchical Clustering*, com o intuito de contribuir para a consolidação do conhecimento sobre o impacto da IA no emprego europeu, propondo uma abordagem analítica integrada e dinâmica que permite captar as especificidades de cada país. Para conduzir a análise foram selecionados sete indicadores representativos de diferentes dimensões críticas relacionadas com o número de publicações científicas, a migração de talentos em IA, o investimento privado em IA, a definição de especialistas em tecnologias de informação e comunicação, a concentração de talentos em IA, as tendências de procura/oferta de postos de trabalho e a participação dos países em projetos públicos relacionadas com a IA.

Os resultados obtidos revelaram a existência de padrões distintos de preparação e adaptação à IA entre os Estados-Membros, agrupando-se os países em três *clusters*. O primeiro *cluster* é composto por Áustria, Bélgica, Dinamarca, Estónia, Grécia, Hungria, Irlanda, Itália, Lituânia, Polónia, Portugal e Eslovénia. O segundo *cluster* integra a Letónia, Luxemburgo, Países Baixos e a Espanha. Por fim, o terceiro *cluster* conta com a Finlândia, França, Alemanha e Suécia.

A metodologia aplicada permitiu não só efetuar a avaliação do posicionamento atual dos países, mas também a identificação das áreas mais críticas que requerem intervenção prioritária. Ao fazê-lo, oferece um instrumento analítico robusto para o apoio à definição de políticas públicas orientadas para uma transição digital justa, inclusiva e territorialmente equilibrada.

Os resultados reforçam a necessidade de estratégias diferenciadas, em consonância com os princípios do objetivo de desenvolvimento sustentável 8, que tem como princípio promover o crescimento económico inclusivo e sustentável, o emprego pleno e produtivo e o trabalho digno para todos.

Palavras-chave: Inteligência Artificial; União Europeia; VBDEA; *Hierarchical Clustering*

ABSTRACT

The present study aimed to assess the effects of artificial intelligence (AI) on the labor market in twenty European Union (EU) countries over the period from 2019 to 2023. The Value-Based Data Envelopment Analysis (VBDEA) methodology was employed, combined with the Hierarchical Clustering approach, with the objective of contributing to the consolidation of knowledge on the impact of AI on European employment, by proposing an integrated and dynamic analytical framework that captures the specificities of each country. To conduct the analysis, seven indicators were selected, representing different critical dimensions related to the number of scientific publications, AI talent migration, private AI investment, the definition of Information and Communication Technology specialists, AI talent concentration, job market supply/demand trends, and countries' participation in public projects related to AI.

The results revealed the existence of distinct patterns of preparation and adaptation to AI among the Member States, with the countries grouped into three clusters. The first cluster includes Austria, Belgium, Denmark, Estonia, Greece, Hungary, Ireland, Italy, Lithuania, Poland, Portugal, and Slovenia. The second cluster comprises Latvia, Luxembourg, the Netherlands, and Spain. Finally, the third cluster consists of Finland, France, Germany, and Sweden.

The applied methodology allowed not only for the assessment of each country's current positioning but also for the identification of the most critical areas requiring priority intervention. In doing so, it provides a robust analytical tool to support the design of public policies aimed at ensuring a just, inclusive, and territorially balanced digital transition.

The results reinforce the need for differentiated strategies, aligned with the principles of Sustainable Development Goal 8, which seeks to promote inclusive and sustainable economic growth, full and productive employment, and decent work for all.

Keywords: Artificial Intelligence; European Union; VBDEA; Hierarchical Clustering

ÍNDICE GERAL

INTRODUÇÃO.....	1
1 Revisão da Literatura.....	5
1.1 Contextualização e Conceitos.....	5
1.1.1 <i>Machine Learning</i>	7
1.1.2 <i>Deep Learning</i>	8
1.2 Inteligência Artificial na Europa	8
1.3 Impacto da IA no emprego	11
1.4 Desafios éticos e regulamentação da IA.....	18
2 Metodologia.....	21
2.1 O Método <i>Value-Based DEA</i>	24
2.2 <i>Window Analysis Value-Based DEA</i>	26
2.3 <i>Hierarchical Clustering</i>	28
3 Dados.....	30
3.1 Preparação dos dados.....	35
3.2 Dados gerados no modelo DEA	37
3.3 Análise dos Dados	38
3.3.1 <i>Scores</i> médios de eficiência.....	38
3.3.2 Pesos médios dos indicadores	41
3.3.3 <i>Hierarchical Clustering</i>	49
3.3.4 Análise dos pesos por <i>clusters</i>	56
3.3.5 Folgas dos indicadores para a fronteira de eficiência.....	63
3.3.6 Folgas dos indicadores para a fronteira de eficiência por <i>clusters</i>	71
4 Discussão dos Resultados.....	79

CONCLUSÃO.....	88
REFERÊNCIAS BIBLIOGRÁFICAS	92
APÊNDICES	101
Apêndice 1 – <i>Heatmap</i> da Correlação	102
Apêndice 2 – Pesos por janela temporal.....	103
Apêndice 3 – Pesos por anos	112
Apêndice 4 – Estatística descritiva dos pesos por indicador	118
Apêndice 5 – Estatística descritiva <i>clusters</i>	120
Apêndice 6 – Estatística descritiva dos pesos dos <i>clusters</i> por indicador	121
Apêndice 7 – Folgas por janela temporal	124
Apêndice 8 – Folgas por anos.....	129
Apêndice 9 – Estatística descritiva das folgas por indicador	134
Apêndice 10 – Estatística descritiva das folgas dos <i>clusters</i> por indicador	136

ÍNDICE DE TABELAS

Tabela 1 - Indicadores	31
Tabela 2 - Funções de valor dos critérios	35
Tabela 3 - Estatística descritiva dos scores de eficiência do WVBDEA.....	38
Tabela 4 - Pesos por janela – “AI Reserch Productivity”	103
Tabela 5 - Pesos por janela "AI Talent Migration Trends"	104
Tabela 6 - Pesos por janela "Private AI Investments"	105
Tabela 7 - Pesos por janela "ICT Workforce Availability"	106
Tabela 8 - Pesos por janela "AI Workforce Concentration"	108
Tabela 9 - Pesos por janela "AI Hiring Trends"	109
Tabela 10 - Pesos por janela "Contributions to Open AI Projects"	110
Tabela 11 - Pesos por ano “AI Reserch Productivity”	112
Tabela 12 - Pesos por ano “AI Talent Migration Trends”	112
Tabela 13 - Pesos por ano "Private AI Investments"	113
Tabela 14 - Pesos por ano "ICT Workforce Availability"	114
Tabela 15 - Pesos por ano "AI Workforce Concentration"	115
Tabela 16 - Pesos por ano "AI Hiring Trends"	115
Tabela 17 - Pesos por ano "Contributions to Open AI Projects"	116
Tabela 18 - Estatística descritiva “AI Reserch Productivity”	118
Tabela 19 - Estatística descritiva "AI Talent Migration Trends"	118
Tabela 20 - Estatística descritiva - "Private AI Investments"	118
Tabela 21 - Estatística descritiva "ICT Workforce Availability"	118
Tabela 22 - Estatística descritiva "AI Workforce Concentration"	119
Tabela 23 - Estatística descritiva "AI Hiring Trends"	119
Tabela 24 - Estatística descritiva "Contributions to Open AI Projects"	119
Tabela 25 - Estatísticas por cluster	120
Tabela 26 - Estatísticas descritivas por janela temporal e cluster	120
Tabela 27 - Métricas dos pesos por clusters "AI Research Productivity"	121
Tabela 28 - Métricas dos pesos por clusters "AI Talent Migration Trends"	121
Tabela 29 - Métricas dos pesos por clusters "Private AI Investments"	121
Tabela 30 - Métricas dos pesos por clusters "ICT Workforce Availability"	122

Tabela 31 - Métricas dos pesos por clusters "AI Workforce Concentration"	122
Tabela 32 - Métricas dos pesos por clusters "AI Hiring Trends"	122
Tabela 33 - Métricas dos pesos por clusters "Contributions to Open AI Projects"	122
Tabela 34 - Folgas por janela "AI Reserch Productivity"	124
Tabela 35 - Folgas por janela "AI Talent Migration Trends"	124
Tabela 36 - Folgas por janela "Private AI Investments"	125
Tabela 37 - Folgas por janela "ICT Workforce Availability"	126
Tabela 38 - Folgas por janela "AI Workforce Concentration"	126
Tabela 39 - Folgas por janela "AI Hiring Trends"	127
Tabela 40 - Folgas por janela "Contributions to Open AI Projects"	128
Tabela 41 - Folgas por anos "AI Reserch Productivity"	129
Tabela 42 - Folgas por anos "AI Talent Migration Trends"	129
Tabela 43 - Folgas por ano "Private AI Investments"	130
Tabela 44 - Folgas por ano "ICT Workforce Availability"	131
Tabela 45 - Folgas por ano "AI Workforce Concentration"	131
Tabela 46 - Folgas por ano "AI Hiring Trends"	132
Tabela 47 - Folgas por ano "Contributions to Open AI Projects"	133
Tabela 48 - Estatística descritiva "AI Research Productivity"	134
Tabela 49 - Estatística descritiva "AI Talent Migration Trends"	134
Tabela 50 - Estatística descritiva "Private AI Investments"	134
Tabela 51 - Estatística descritiva "ICT Workforce Availability"	134
Tabela 52 - Estatística descritiva "AI Workforce Concentration"	134
Tabela 53 - Estatística descritiva "AI Hiring Trends"	135
Tabela 54 - Estatística descritiva "Contributions to Open AI Projects"	135
Tabela 55 - Métricas das folgas por cluster "AI Research Productivity"	136
Tabela 56 - Métricas das folgas por cluster "AI Talent Migration Trends"	136
Tabela 57 - Métricas das folgas por cluster "Private AI Investments"	136
Tabela 58 - Métricas das folgas por cluster "ICT Workforce Availability"	137
Tabela 59 - Métricas das folgas por cluster "AI Workforce Concentration"	137
Tabela 60 - Métricas das folgas por cluster "AI Hiring Trends"	137
Tabela 61 - Métricas das folgas por cluster "Contributions to Open AI Projects"	138

ÍNDICE DE FIGURAS

Figura 1 – Etapas da Metodologia DEA.....	23
Figura 2 - Pesos "AI Research Productivity"	42
Figura 3 - Pesos "AI Talent Migration Trends"	43
Figura 4 - Pesos "Private AI Investments"	44
Figura 5 - Pesos "ICT Workforce Availability"	46
Figura 6 - Pesos "AI Workforce Concentration"	47
Figura 7 - Pesos "AI Hiring Trends"	48
Figura 8 - Pesos "Contributions to Open AI Projects"	49
Figura 9 - Método do Cotovelo	50
Figura 10 - Dendrograma	50
Figura 11 - Trajetória Média por Cluster.....	52
Figura 12 - Trajetória Cluster 1	53
Figura 13 - Trajetória Cluster 2	54
Figura 14 - Trajetória Cluster 3	55
Figura 15 - Distribuição geográfica por cluster.....	56
Figura 16 - Pesos por cluster "AI Research Productivity"	57
Figura 17 - Pesos por cluster "AI Talent Migration Trends"	58
Figura 18 - Pesos por cluster "Private AI investments"	59
Figura 19 - Pesos por cluster "ICT Workforce Availability"	60
Figura 20 - Pesos por cluster "AI Workforce Concentration"	61
Figura 21 - Pesos por cluster "AI Hiring Trends"	62
Figura 22 - Países por cluster "Contributions to Open AI Projects"	63
Figura 23 - Folgas "AI Research Productivity"	65
Figura 24 - Folgas "AI Talent Migration Trends"	66
Figura 25 - Folgas "Private AI Investments".....	67
Figura 26 - Folgas "ICT Workforce Availability".....	68
Figura 27 - Folgas "AI Workforce Concentration"	69
Figura 28 - Folgas "AI Hiring Trends"	70
Figura 29 - Folgas "Contributions to Open AI Projects"	70
Figura 30 - Folgas por cluster "AI Research Productivity"	72

Figura 31 - Folgas por cluster "AI Talent Migration Trends"	73
Figura 32 - Folgas por cluster "Private AI Investments"	74
Figura 33 - Folgas por cluster "ICT Workforce Availability"	75
Figura 34 - Folgas por cluster "AI Workforce Concentration"	76
Figura 35 - Folgas por cluster "AI Hiring Trends"	77
Figura 36 - Folgas por cluster "Contributions to Open AI Projects"	78
Figura 37 - Heatmapt correlação	102

Lista de abreviaturas, acrónimos e siglas

BCC - Banker, Charnes e Cooper

CCR - Charnes, Cooper e Rhodes

CE - Comissão Europeia

DEA - *Data Envelopment Analysis*

DL - *Deep Learning*

DMU - *Decision-Making Units*

IA - Inteligência Artificial

ICT - *Information and Communication Technology*

IoT - Internet das Coisas

MAUT - *Multi-Attribute Utility Theory*

MAVT - *Multi-Attribute Value Theory*

ML - *Machine Learning*

NUTS - Nomenclatura das Unidades Territoriais para Fins Estatísticos

ODS - Objetivo de Desenvolvimento Sustentável

OECD - *Organisation for Economic Co-operation and Development*

OWID - *Our World in Data*

PIB - Produto Interno Bruto

RGPD - Regulamento Geral da Proteção de Dados

RNA - Redes Neurais Artificiais

UE - União Europeia

VBA - *Visual Basic for Applications*

VBDEA - *Value Based Data Envelopment Analysis*

XAI - *Explainable Artificial Intelligence*

INTRODUÇÃO

A Inteligência Artificial (IA) está a transformar profundamente o tecido empresarial, com especial impacto na dinâmica da procura e oferta de emprego. Este estudo centra a sua análise no contexto europeu, abordando o impacto que esta revolução tecnológica, impulsionada pela IA, está a provocar no emprego.

Com a contínua evolução tecnológica, o mercado de trabalho tem necessidade de reinventar-se. A presença de tecnologias emergentes, como a IA, a Internet das Coisas (IoT) e o *Big Data*, constitui a base desta nova era tecnológica no contexto laboral. Estas inovações estão, assim, a remodelar a estrutura do emprego europeu, ao mesmo tempo que criam novas oportunidades e substituem funções tradicionais.

O Objetivo de Desenvolvimento Sustentável (ODS) 8, que visa promover o emprego pleno e produtivo para toda a população apta a trabalhar, serve de ponto de partida para a pertinência deste estudo. Num contexto cada vez mais impulsionado pela IA, torna-se essencial garantir que as políticas de emprego acompanhem o progresso tecnológico.

Atualmente, existe uma crescente preocupação, não apenas entre os trabalhadores ativos, mas também entre as gerações futuras, quanto ao impacto que a IA poderá ter. Esta apreensão centra-se sobretudo na substituição do trabalho humano e nas desigualdades que daí podem resultar no mercado laboral. Compreender estas dinâmicas é crucial para o desenvolvimento de políticas eficazes, capazes de mitigar, a curto prazo, os efeitos negativos da adoção de ferramentas baseadas em IA e, simultaneamente, potenciar os seus benefícios, promovendo um mercado de trabalho mais justo e igualitário.

A génese da IA remonta à década de 1950, tendo o termo sido oficialmente cunhado por John McCarthy em 1956, num momento que Russel e Norvig descrevem como “o nascimento da IA” (Collins et al., 2021). Desde então, as definições associadas à IA têm evoluído, mas tendem a convergir na noção de sistemas capazes de exibir comportamentos inteligentes. De acordo com a Comissão Europeia, a IA refere-se a “sistemas que apresentam comportamento inteligente ao analisarem o seu ambiente e tomarem ações – com algum grau de autonomia – para alcançar objetivos específicos”¹. Esta definição abrange uma ampla gama de aplicações, desde software, como assistentes

¹ [A Inteligência Artificial e a União Europeia | Eurocid - Informação europeia ao cidadão](#)

Avaliação do impacto da Inteligência Artificial no emprego Europeu

virtuais ou sistemas de reconhecimento facial, até soluções incorporadas em dispositivos físicos.

A transição da IA do ambiente teórico para a sociedade tem conduzido à implementação generalizada de diversas aplicações. Esta disseminação impulsionou a formulação de estratégias nacionais e internacionais em matéria de IA, que, embora inicialmente centradas nas oportunidades económicas e no incremento da produtividade, têm vindo progressivamente a incorporar dimensões sociais e éticas (Sheikh et al., 2023). Contudo Sheikh et al. (2023), consideram que esta integração em larga escala acarreta desafios significativos, nomeadamente no que respeita à segurança dos dados, à proteção da privacidade e às preocupações éticas associadas ao enviesamento algorítmico, à discriminação e à vigilância. A opacidade de certos modelos algorítmicos, frequentemente designada como o problema da "caixa negra", realça a relevância de domínios emergentes como a *Explainable Artificial Intelligence* (XAI), cujo objetivo é tornar compreensíveis e auditáveis as decisões tomadas pelos sistemas de IA (Sarker, 2021). A promoção da transparência, da justiça e da responsabilidade nestes sistemas permanece, assim, um desafio central e inadiável.

No que diz respeito ao impacto da IA no emprego, existe um receio generalizado de que estas novas tecnologias venham a provocar a perda de numerosos postos de trabalho num futuro próximo (Agbaji et al., 2023). Sheikh et al. (2023), defendem que a história tem vindo a demonstrar que a introdução de novas tecnologias tem, recorrentemente, gerado ansiedade quanto à substituição de humanos por máquinas. No entanto, de acordo com Samoili et al. (2020) a perspetiva mais moderna e construtiva centra-se na colaboração entre humanos e máquinas, deslocando o foco de um cenário de "homem *versus* máquina" para um cenário de "homem com máquina". Assim, a IA tem como principal objetivo potenciar a inteligência humana, permitindo que as pessoas se concentrem em tarefas mais complexas e criativas, em vez de as substituir por completo.

Deste modo, o principal objetivo deste estudo é avaliar o impacto atual e futuro da IA no emprego europeu.

Face a este objetivo central, a questão de investigação é: “Qual o impacto que a IA terá no mercado laboral europeu?”

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Para responder a esta questão, torna-se necessário desdobrar o problema em várias vertentes. Em primeiro lugar, é fundamental analisar o impacto da IA na criação e destruição de postos de trabalho em diferentes setores. A avaliação do nível de qualificações dos trabalhadores é igualmente essencial, pois pode influenciar a maior ou menor probabilidade de substituição devido à automação. Além disso, importa investigar se há padrões geográficos associados à implementação da IA na Europa, compreendendo por que razão certos países lideram a sua adoção. Por fim, é crucial considerar as implicações socioeconómicas da IA, com vista à formulação de políticas adaptadas às novas exigências do mercado laboral.

Com a concretização dos objetivos propostos que visam compreender o impacto da IA no emprego na Europa, espera-se que este estudo forneça contributos relevantes em diversas frentes. Em primeiro lugar, a comunidade académica beneficiará de uma base teórica e empírica, útil para trabalhos de investigação futuros sobre tecnologias emergentes. Em segundo lugar, as empresas poderão utilizar os dados obtidos para avaliar de forma mais informada a integração da IA nos seus processos, facilitando uma transição estratégica e eficiente. Para os trabalhadores, atuais e futuros, o estudo constituirá uma fonte de informação valiosa, alertando para as transformações tecnológicas em curso e identificando as competências-chave necessárias para se manterem competitivos no mercado de trabalho. Por fim, espera-se que os resultados contribuam igualmente para a formulação de políticas públicas voltadas para a requalificação e formação dos trabalhadores, assegurando que a força de trabalho esteja preparada para enfrentar os desafios impostos pela era digital.

Esta dissertação organiza-se da seguinte forma: após a presente introdução, segue-se o Capítulo 1 dedicado à revisão da literatura, com uma caracterização dos principais conceitos associados à tecnologia. Será explorado o estado atual da adoção da IA na Europa e uma reflexão sobre os desafios éticos e o enquadramento regulatório que acompanham esta tecnologia.

O Capítulo 2 apresenta o enquadramento metodológico adotado para o desenvolvimento deste estudo. No Capítulo 3 é feita uma análise detalhada dos dados utilizados, incluindo a sua origem e tratamento, onde será dada especial atenção à explicação dos resultados

Avaliação do impacto da Inteligência Artificial no emprego Europeu

obtidos através da aplicação do método *Value-Based Data Envelopment Analysis* (VBDEA).

O Capítulo 4 concentra-se na discussão dos resultados. O trabalho termina com uma síntese das principais conclusões, contributos do estudo, identificando limitações e propostas de trabalho futuro.

1 Revisão da Literatura

1.1 Contextualização e Conceitos

O termo alfabetização é popularmente descrito como a capacidade de ler e escrever. Na era digital em que nos encontramos, o facto de cada vez haver um maior progresso tecnológico implica que toda a sociedade deva ser digitalmente alfabetizada (Ng et al., 2021).

A Primeira Revolução Industrial foi marcada pela transição do trabalho manual para a produção mecanizada. A Segunda Revolução Industrial resultou em melhorias industriais em setores como o da manufatura e agrícola. A Terceira Revolução Industrial foi caracterizada pela mudança das tecnologias mecânicas e analógicas para a eletrónicas digitais, ao utilizar computadores para aumentar a eficiência da produção (Agbaji et al., 2023). Agora com o desencadear da IA podemos assistir a uma Quarta Revolução Industrial que promete revolucionar setores como a saúde, a educação, a indústria, e tantos outros.

Em termos conceptuais, a definição de IA não gera consenso na literatura. Pode ser descrita como a capacidade que uma máquina tem para efetuar operações que, por norma, requerem a compreensão humana (Soori et al., 2023).

Outros autores descrevem a IA de uma forma mais abrangente, como sendo uma tecnologia capaz de fornecer um valor acrescentado para os seus utilizadores (van Noordt & Misuraca, 2022).

A IA teve a sua eclosão na Conferência de Dartmouth, realizada nos Estados Unidos da América, em 1956, no âmbito de um laboratório científico composto por um grupo de cientistas computacionais (Tiwari et al., 2018). O principal objetivo era investigar de que forma as máquinas poderiam ser capazes de superar as limitações humanas na resolução de problemas.

As décadas que se seguiram foram marcadas por divergências entre especialistas, sobretudo da área das ciências computacionais. Enquanto alguns viam na IA a chave para um futuro inimaginável, outros questionavam a viabilidade e os limites dessa mesma ideia. Assim, a trajetória da IA oscilou entre entusiasmo e ceticismo até aproximadamente o ano de 2012 (Tiwari et al., 2018).

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Desde 2015, a IA tem vindo a ganhar destaque nos âmbitos científico, académico e social. A partir desse período, passou-se a compreender com maior clareza não apenas o conceito de IA e as suas capacidades, mas também os diferentes ramos que dela derivam. Um dos mais relevantes é o *Machine Learning* (ML), ou Aprendizagem Automática, que permite aos computadores aprender a partir de exemplos, com a capacidade de extrair padrões de dados e acumular conhecimento ao longo do tempo (Tiwari et al., 2018).

Esta abordagem registou um crescimento significativo nos últimos anos, sobretudo nos domínios da análise de dados e da computação, ao permitir que aplicações executem tarefas quotidianas de forma inteligente, com capacidade de aprendizagem e melhoria contínua com base no histórico de tarefas previamente realizadas (Sarker, 2021). Importa salientar que o objetivo do ML não é necessariamente fornecer previsões absolutamente exatas, mas sim gerar previsões suficientemente úteis e aplicáveis a uma ampla variedade de contextos de investigação (Tiwari et al., 2018).

Outra vertente da IA é o *Deep Learning* (DL), que é considerado um subconjunto do ML e da IA. Esta vertente nos últimos anos tem tido bons resultados no que concerne à solução para a deteção de anomalias, diagnósticos de doenças e em outros âmbitos (Talaie Khoei et al., 2023).

Um conceito fundamental para compreender DL são as Redes Neurais Artificiais (RNA). Estas redes visam desenvolver algoritmos que imitem o processo de raciocínio humano. Assim, as RNA funcionam como modelos computacionais concebidos para simular o processamento de informação do cérebro humano (Ferneda, 2006).

O DL, à semelhança do ML, permite a realização de tarefas rotineiras em diversas áreas. Os desempenhos de algoritmos de ML tendem a tornar-se saturados quando atingem um volume de dados limite, enquanto no DL o desempenho melhora à medida que o volume de dados é crescente (Mathew et al., 2021).

Assim, com o surgimento do DL, aduzido pela crescente aplicação em contextos altamente críticos, aumentou a procura pela transparência nos processos de previsão (Barredo Arrieta et al., 2020). Deste modo tornou-se imperativo compreender os mecanismos subjacentes a estas previsões, já que a opacidade dos modelos poderia comprometer a sua eficácia e aceitação social.

Foi neste contexto que surgiu a XAI, que propõe a criação de um conjunto de técnicas de ML destinadas a produzir modelos mais explicativos. O objetivo é garantir a transparência nos processos decisórios da IA, permitindo que os utilizadores compreendam e confiem nos seus resultados (Barredo Arrieta et al., 2020).

1.1.1 Machine Learning

O ML procura identificar relações complexas e não lineares entre variáveis independentes e variáveis dependentes. Essas relações podem ser utilizadas para prever valores contínuos, num processo conhecido como regressão, ou para classificar dados em categorias específicas, processo designado por classificação (Dol & Geetha, 2021). De acordo com os mesmos autores, enquanto a regressão se centra na estimativa de quantidades numéricas, a classificação tem como objetivo atribuir observações a categorias previamente definidas.

Em contexto prático, um modelo de ML necessita de dados consistentes e robustos, uma vez que a qualidade dos dados pode estar diretamente relacionada com o desempenho do modelo.

Em primeira instância devem-se selecionar os dados de entrada. Como resultado dos dados introduzidos, o modelo de ML vai descobrir padrões e relações entre eles. Este processo é conhecido como o conjunto de treino. Dependendo da natureza dos dados, o modelo pode ser aplicado em diversas tarefas, nomeadamente: classificação, regressão e *clustering* (Dol & Geetha, 2021).

Estes modelos geralmente podem ser divididos em três classes, com base no conjunto de dados: o modelo supervisionado, o modelo não supervisionado e o modelo semi-supervisionado (Dol & Geetha, 2021).

O objetivo dos modelos supervisionados é a aprendizagem a partir da relação já criada, permitindo posteriormente fazer previsões robustas para novos dados.

Os modelos não supervisionados distinguem-se dos anteriores pela não utilização de dados rotulados.

Já os modelos semi-supervisionados são uma combinação dos modelos já mencionados. Nestes modelos o objetivo é identificar padrões nos dados que não se encontram rotulados através dos dados rotulados.

Deste modo, o ML consiste num processo de estudo que visa capacitar as máquinas mediante vários modelos por forma a adquirirem novos conhecimentos, e desenvolverem novas competências e reorganizarem as informações já existentes de forma eficiente (Meng et al., 2020).

1.1.2 Deep Learning

As RNA são algoritmos derivados do ML, inspiradas na estrutura e no funcionamento do cérebro humano, projetadas para identificar padrões e aprender com dados previamente fornecidos. Estas redes imitam as conexões neuronais biológicas, processando informações de forma iterativa (Kariri et al., 2023). A teoria fundamental das RNA baseia-se na ideia de simular o funcionamento do cérebro humano, sendo compostas por uma rede de neurónios artificiais interligados que funcionam como unidades simples de processamento. Cada neurónio artificial recebe dados de entrada, realiza cálculos sobre eles e gera uma saída (Kariri et al., 2023). As conexões entre os neurónios são representadas por pesos, que podem ser ajustados durante o processo de treino, permitindo à rede aprender padrões e adaptar-se a novos dados.

Com base nesta lógica, surge o Deep Learning (DL), entendido como uma evolução do ML que utiliza arquiteturas mais complexas de RNA para processar grandes volumes de dados e adquirir conhecimento de forma autónoma. O DL não depende de regras criadas por humanos, mas recorre a grandes quantidades de dados para mapear entradas em etiquetas específicas. Os modelos de DL são construídos com múltiplas camadas de neurónios artificiais, em que cada camada interpreta os dados de forma distinta, extraíndo progressivamente representações mais abstratas (Taye, 2023). Esta evolução tem demonstrado grande sucesso em diversas áreas, como o processamento de imagens, a análise e previsão de dados e o reconhecimento de voz (Iman et al., 2023).

1.2 Inteligência Artificial na Europa

Na era digital contemporânea, a adoção de tecnologias emergentes constitui um requisito fundamental para se permanecer competitivo. Com o objetivo de tornar exequível a ligação entre IA e inovação, a União Europeia (UE) lançou o programa “Europa Digital”. Esta iniciativa da Comissão Europeia (CE) visa explorar sinergias entre estas duas

Avaliação do impacto da Inteligência Artificial no emprego Europeu

vertentes. Nomeadamente, reforçar competências na utilização de algoritmos e gestão de dados, fortalecer a capacidade de proteção da economia, melhorar a segurança cibernética e desenvolver *know-how* para as empresas dos setores público e privado (Marino et al., 2023). Segundo Mihai et al. (2023), é estimado um aumento de 14% do produto interno bruto (PIB) europeu devido ao desenvolvimento da IA e de tecnologias emergentes.

Países como os Estados Unidos da América e a China, estão na liderança pela implementação de IA no setor industrial. Contudo, a UE tem adotado uma abordagem distinta, privilegiando um equilíbrio entre inovação tecnológica e sustentabilidade ética (Foffano et al., 2023).

Embora existiam vários fatores que influenciam a competência digital, nomeadamente o capital humano, a avaliação dessas mesmas competências tem sido feita de forma insuficiente na UE com base apenas nas competências digitais individuais (Bogoslov et al., 2024). De acordo com o Relatório sobre o Estado da Década Digital 2023² da UE, 30% dos europeus afirmam não se sentir preparados para a nova era digital.

Os atuais 27 Estados-membros da UE encontram-se em diferentes fases de adoção/implementação de tecnologias associadas à IA. Países como Finlândia, Dinamarca, Países Baixos e Suécia são atualmente os mais avançados devido às suas políticas digitais inclusivas voltadas para a população mais idosa (Bogoslov et al., 2024). O mais recente Relatório da Comissão Europeia,³ publicado em 2023, revela que 46% da população europeia — maioritariamente pessoas com idades mais avançadas — não possui competências digitais básicas (Bogoslov et al., 2024). No que diz respeito ao setor empresarial, apenas 11% das empresas europeias estavam, em 2023, suficientemente digitalizadas. De acordo com várias projeções, prevê-se um aumento de 9 pontos percentuais até 2025, o que, ainda assim, se manterá abaixo da meta definida pela UE, que visa alcançar 75% de empresas com elevado nível de digitalização até esse ano (Bianchini Niccolò, 2023).

No entanto, apesar desta informação, os Estados-Membros estão a implementar uma vasta lista de medidas políticas que visam incentivar o desenvolvimento de tecnologias associadas à IA (Jorge Ricart et al., 2022). Paralelamente a este processo, foi lançada a

² [2023 Report on the state of the Digital Decade | Shaping Europe's digital future](#)

³ [A UE em 2023 — Relatório Geral sobre a Atividade da União Europeia](#)

estratégia Europeia que estabelece três pilares fundamentais para a política de IA na UE (Ulnicane, 2022).

O primeiro objetivo passa por impulsionar toda a capacidade tecnológica e industrial da IA nos setores público e privado, prevendo, para o efeito, um aumento de investimento e maior disponibilização de dados. O segundo objetivo passa pela modernização do sistema de ensino, antecipando assim as mudanças no mercado de trabalho. Por fim, o terceiro objetivo assegura a criação de um enquadramento ético e jurídico apropriado, alinhado com os valores da UE e com a Carta dos Direitos Fundamentais.

De acordo com o Plano Coordenado sobre IA de 2018⁴ (revisto em 2021), o CE recomendou aos Estados-Membros a adoção de estratégias nacionais de IA, através de medidas políticas e investimentos que promovessem o desenvolvimento e aplicação desta tecnologia (Jorge Ricart et al., 2022).

Até 2021, 24 Estados-Membros da UE já haviam publicado as suas estratégias, tendo a Finlândia, a Alemanha, a França e o Chipre procedido à atualização das suas versões iniciais. No início do ano de 2022, a Bélgica, a Croácia, a Grécia e a Roménia, mantinham-se como os únicos países que ainda não tinham apresentado as respetivas estratégias (Jorge Ricart et al., 2022).

De acordo com van Noordt et al. (2023), entre os Estados-Membros da UE, a Estónia e a Letónia destacam-se por mencionarem repetidamente investimentos direcionados para a modernização da administração pública através da IA. Em contraste, a maioria dos países restantes raramente refere a existência de financiamento dedicado à adoção de tecnologias IA neste mesmo setor van Noordt et al. (2023). Assim, e conforme o Relatório de 2023⁵ sobre o Estado da Década Digital, uma transição digital bem-sucedida exige um número significativo de especialistas em Tecnologias de Informação e Comunicação (ICT - *Information and Communication Technology* em inglês). Apesar do crescimento gradual de profissionais qualificados, as empresas do setor tecnológico continuam a enfrentar dificuldades no recrutamento destes perfis.

⁴ [Plano Coordenado para a Inteligência Artificial | Shaping Europe's digital future](#)

⁵ [2023 Report on the state of the Digital Decade | Shaping Europe's digital future](#)

1.3 Impacto da IA no emprego

Os sistemas de IA apresentam características distintas dos demais sistemas, podendo tanto potenciar como dificultar as práticas laborais por parte do colaborador (Jarrahi et al., 2023). Esta distinção reside essencialmente na capacidade de DL dos sistemas que resulta na capacidade de autoaprendizagem, contrastando com as gerações anteriores de sistemas, cuja lógica era determinada exclusivamente por código adicionado pelos trabalhadores. Assim, perante esta evolução tecnológica, surgem múltiplas questões sobre o seu impacto no mundo do trabalho. A inevitabilidade desta transformação é corroborada por estimativas da instituição financeira Goldman Sachs, que prevê a potencial afetação de cerca de 300 milhões de empregos nos próximos anos em todo o mundo, com uma taxa de automatização que poderá atingir 25% do mercado laboral global (Trabelsi, 2024). Estes efeitos serão mais visíveis nas economias mais desenvolvidas do que nas economias emergentes. Frank et al. (2019) alertam para o impacto da IA no emprego, com base em dados de dois países europeus: na Finlândia, a automação poderá afetar 35% dos postos de trabalho, enquanto na Alemanha esse impacto poderá atingir 59% do emprego. A nível europeu, as projeções apontam para uma taxa entre 45% a 60%.

É referido por Badet (2021) que cerca de 400 milhões de trabalhadores poderão ser afetados pela automatização de processos industriais no período entre 2016 e 2030. Contudo, o mesmo autor estima que a procura por mão de obra impulsionada pela automação poderá situar-se entre 555 milhões e 890 milhões de empregos até 2030, sugerindo que a criação de emprego poderá compensar amplamente as perdas associadas à automatização. No setor manufatureiro, Călinescu (2023) destaca que a incorporação de sistemas inteligentes de produção não só agiliza os processos como também aumenta significativamente a produtividade, reduzindo simultaneamente os custos operacionais. No setor dos transportes, Călinescu (2023) salienta que a IA pode tornar-se uma ferramenta valiosa para melhorar a segurança rodoviária e otimizar a gestão de tráfego. O autor realça que a futura adoção de veículos autónomos poderá permitir uma circulação com maior eficiência, reduzindo significativamente o consumo de combustível. No setor da saúde, Espina-Romero et al. (2023) sublinham as vantagens da IA no apoio aos profissionais de saúde, nomeadamente na realização de diagnósticos mais precisos e na

Avaliação do impacto da Inteligência Artificial no emprego Europeu

recomendação de tratamentos mais adequados. Os autores destacam ainda a capacidade dos sistemas de DL ao longo do tempo para detetar padrões em dados clínicos, conseguindo antecipar e prevenir enfermidades. No contexto bancário e financeiro, tanto Călinescu (2023) como Espina-Romero et al. (2023) enfatizam a crescente implementação de soluções de IA, particularmente em campos como avaliação do risco em pedidos de crédito, deteção e prevenção de fraudes e na escolha de investimentos.

No setor agrícola, as máquinas têm sido adaptadas ou substituídas de modo a reduzir a carga de trabalho físico dos agricultores, possibilitando a realocação dos trabalhadores para outras tarefas, melhorando assim a sua eficiência laboral (Munnisunker et al., 2022).

No entanto, apesar das oportunidades de evolução trazidas pela IA, persistem desafios significativos. Como salienta Călinescu (2023), os trabalhadores menos qualificados poderão não ter conhecimento/formação suficiente para dar resposta às exigências do mercado de trabalho transformado pela IA, o que poderá resultar em perdas de emprego e, consequentemente, no aumento do desemprego. Zirar et al. (2023) defendem que a aceitação das ferramentas de IA por parte dos trabalhadores depende fundamentalmente da sua compreensão relativamente ao seu funcionamento e benefícios. Para que este obstáculo seja ultrapassado, os gestores devem implementar estratégias que demonstrem claramente o processo de tomada de decisão da IA e os ganhos de produtividade associados à sua adoção.

Porém, há áreas mais vulneráveis à substituição pela IA, sobretudo, aquelas que envolvem tarefas cognitivas repetitivas (Dahlin, 2024). No entanto, profissões como a advocacia e a engenharia, que exigem elevados níveis de criatividade e tomada de decisão complexa, apresentam maior resistência à automatização. Em contraste, existem atividades como manufatura e trabalhos administrativos rotineiros que se encontram, em maior risco de automatização total, podendo vir a desaparecer gradualmente (Dahlin, 2024).

Ainda assim, a implementação de IA no contexto laboral trará consigo a criação de novos postos de trabalho, nomeadamente para especialistas em integração de IA, desenvolvedores de *software* inteligente e perfis técnicos afins (Dahlin, 2024).

Do ponto de vista dos trabalhadores, a manutenção do posto de trabalho face à automação exigirá um investimento contínuo em qualificação profissional. (Cramarenco et al., 2023)

Avaliação do impacto da Inteligência Artificial no emprego Europeu

identificam como competências-chave no curto e médio prazo a análise de dados o ML e a capacidade de tomada de decisão em contextos complexos.

Do lado das empresas, as vantagens associadas à implementação da IA no negócio são múltiplas, como, por exemplo, a redução de custos operacionais através da automação, a melhoria da qualidade na produção, reduzindo assim a maior probabilidade de erro humano (Cramarencio et al., 2023). Todavia, existem também desvantagens a considerar do ponto de vista do negócio com a entrada da IA no contexto empresarial, designadamente: a falta de preparação organizacional para a transição digital e a potencial perda de vantagem competitiva face a concorrentes mais adaptados. Os benefícios e riscos associados à IA podem variar consoante o agente avaliador. O que constitui uma vantagem competitiva para o empregador pode constituir uma ameaça à estabilidade laboral do trabalhador (Cramarencio et al., 2023). No entanto, o risco de desemprego tecnológico depende de múltiplos fatores, nomeadamente das políticas económicas do país, do nível de qualificação da população ativa e do investimento público e privado no domínio da IA (Badet, 2021).

Noutra perspetiva, Savage (2020) aborda a crescente competição na área da IA, tanto ao nível da produção científica como do investimento.

Por sua vez, Trabelsi (2024) indica que nos Estados Unidos da América, a proporção de anúncios de emprego que exigem competências relacionados com a IA aumentou em muitas das profissões, entre 2012 e 2019, particularmente, nas áreas de ciências, engenharia e gestão. O mesmo autor assinala ainda que, nos empregos que envolvem o uso intensivo de computadores, uma maior exposição à IA está associada a um maior crescimento do emprego.

Green e Lamby (2025), no seu estudo fornecem estimativas transversais, representativas e comparáveis da força de trabalho em IA nos países da *Organisation for Economic Co-operation and Development* (OECD). Por força de trabalho em IA entende-se o conjunto de trabalhadores que detêm competências em estatística, informática e ML, e que são capazes de desenvolver e manter aplicações de IA. Compreender esta força de trabalho constitui um passo fundamental para a criação de um *pipeline* de talentos diversificado e representativo, sobretudo para os países que ambicionam assumir um papel de liderança no domínio da IA.

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Para colmatar uma lacuna identificada na literatura, os autores focam-se especificamente nos profissionais que desenvolvem aplicações de IA, distinguindo-os daqueles que simplesmente as utilizam. A metodologia assenta na análise de dados provenientes de ofertas de emprego *online*, disponibilizados pela empresa Lightcast, que permitem identificar as competências exigidas aos candidatos. Estes dados são cruzados com inquéritos às forças de trabalho, o que possibilita estimar não só a dimensão, mas também a composição demográfica da força de trabalho em IA nos países da OECD.

Os resultados do estudo revelam que menos de 0,3% dos trabalhadores possuem competências em IA. No entanto, verifica-se um crescimento rápido do emprego nesta área entre 2011 e 2019, passando de 0,07% para 0,34% do emprego total. Este aumento foi, em grande medida, impulsionado pela procura dessas competências em ocupações já existentes, e não pela criação de novas ocupações específicas de IA (Green e Lamby, 2025).

Além disso, a força de trabalho em IA caracteriza-se por um elevado nível de qualificação e por uma predominância masculina. Cerca de dois terços dos trabalhadores possuem formação superior, sendo que, nas ocupações mais intensivas em IA, esta proporção ultrapassa os 75%. As mulheres representam apenas 35% deste grupo, apesar de constituírem mais de metade da população com formação superior. A idade média destes trabalhadores é semelhante à dos outros profissionais com o mesmo nível de escolaridade, e a percentagem de trabalhadores estrangeiros na área da IA é comparável com a observada noutras áreas com formação superior equivalente (Green e Lamby, 2025).

Green e Lamby (2025) concluíram que relativamente à aquisição de competências em IA, a aprendizagem ao longo da vida não parece constituir o principal canal. Os profissionais da área não apresentam maior propensão a frequentar formação técnica do que outros trabalhadores com formação superior. Apenas 20% da formação contínua que recebem está relacionada com tecnologias digitais, o que sugere que a maior parte das competências em IA é adquirida durante a educação formal ou no local de trabalho, por exemplo, através da experiência em equipas dedicadas ao desenvolvimento de aplicações de IA.

Por fim, Green e Lamby (2025) evidenciam diferenças significativas entre países. Os países do Norte da Europa e o Reino Unido apresentam as maiores proporções de

Avaliação do impacto da Inteligência Artificial no emprego Europeu

trabalhadores com competências em IA, cerca de 0.45% da força laboral, enquanto os países do Sul da Europa registam as proporções mais baixas, abaixo dos 0.27%. Os empregos com maior intensidade em competências de IA incluem matemáticos, atuários, estatísticos, engenheiros eletrotécnicos, gestores e profissionais das tecnologias de informação, bem como analistas de *software*.

Por seu turno, Guarascio et al. (2024), analisam de forma detalhada como a IA está a afetar os mercados de trabalho nas regiões europeias, concluindo que os seus impactos são profundamente desiguais e dependem das características estruturais e institucionais de cada território. Os autores sustentam que não existe uma resposta única ou universal sobre os efeitos da IA no emprego, sendo o seu impacto moldado pelo contexto económico, social e político local. A base empírica do estudo assenta numa metodologia quantitativa e comparativa, utilizando dados ao nível regional (NUTS-2) UE, no do período entre 2011 e 2018.

A exposição regional à IA é medida com base na metodologia desenvolvida por Felten et al. (2021), que liga avanços em subcampos da IA (como visão computacional, reconhecimento de fala e processamento de linguagem natural) às tarefas ocupacionais listadas no O*NET, uma base de dados norte-americana de descrições de empregos. Essa exposição ocupacional à IA é então cruzada com a composição de emprego em cada região europeia, permitindo estimar o grau em que as economias regionais estão expostas às tecnologias de IA.

Para além da exposição à IA, Guarascio et al. (2024), construíram um índice de “prontidão regional”, que avalia a capacidade das regiões para adotar e beneficiar da IA. Este índice combina variáveis como o peso do emprego em setores de serviços intensivos em conhecimento, a percentagem de população com ensino superior, os gastos em investigação e desenvolvimento, a densidade de robôs industriais, a produtividade laboral e o grau de urbanização. Utilizando uma análise de *clusters*, as regiões foram agrupadas em quatro grandes perfis: os centros de serviços de alta tecnologia capital; o núcleo industrial avançado; a região periférica do Sul; e a região periférica Oriental.

Os resultados mostram que as regiões com maior “prontidão” tecnológica — geralmente capitais e centros de serviços avançados como Berlim, Viena ou Paris — tendem a ter alta exposição à IA, mas também beneficiam mais com essa exposição. Nestas regiões, a

Avaliação do impacto da Inteligência Artificial no emprego Europeu

IA aparece como uma tecnologia complementar, que aumenta a produtividade e pode gerar novos empregos, especialmente em setores altamente qualificados.

O núcleo industrial avançado, composto por regiões alemãs, italianas e espanholas com forte base manufatureira e bons níveis de qualificação, também está relativamente bem posicionado. Embora a exposição direta à IA seja moderada, estas regiões têm potencial para integrar IA em processos industriais, tirando partido da complementaridade entre robótica e IA. Apesar do risco de substituição de tarefas, os dados sugerem uma relação positiva entre exposição à IA e crescimento do emprego, sobretudo impulsionado pela competitividade industrial.

Em contraste, a periferia do Sul (com regiões do sul de Itália, Andaluzia e Grécia) e a periferia oriental (com várias regiões da Europa Central e de Leste) enfrentam maiores dificuldades. Estas regiões têm baixos níveis de qualificação, fraco investimento em investigação e desenvolvimento, menor densidade tecnológica e maior peso de setores tradicionais ou intensivos em mão de obra. Como tal, apresentam uma baixa exposição à IA e mostram poucos sinais de modernização tecnológica.

Noutro âmbito, Damioli et al. (2024), abordaram a perspetiva da criação de emprego através da IA, lacuna óbvia na literatura, sobre um possível efeito de criação de emprego do lado da oferta, entre os desenvolvedores de tecnologias de IA.

Para tal, utilizaram um modelo econométrico dinâmico de procura de trabalho derivado de uma função de utilidade *Cobb-Douglas*, complementada com um fator de inovação tecnológica. Para medir a inovação, o estudo recorre ao número de famílias de patentes de IA e não IA (*PatAI* e *PatNon-AI*), como forma de captar o progresso tecnológico alcançado pelas empresas através do desenvolvimento de tecnologias inovadoras e comercializáveis. O tamanho das famílias de patentes (i.e., o número de jurisdições onde a invenção é protegida) é utilizado como *proxy* da qualidade da inovação. Para lidar com questões de endogeneidade e simultaneidade, é aplicado o método de estimação GMM-SYS (*Generalized Method of Moments – System*), com variáveis instrumentais baseadas em desfasamento temporal, incluindo *dummies* para os setores, país e ano.

A base de dados utilizada resulta da fusão da PATSTAT (*European Patent Office*) com a ORBIS (*Bureau van Dijk*), permitindo construir um painel de 4.184 empresas ativas em patentes de IA e robótica entre 2000 e 2016, totalizando 28.840 observações.

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Os resultados do modelo GMM-SYS revelam um impacto positivo e estatisticamente significativo das famílias de patentes de IA no emprego. A elasticidade estimada da procura de trabalho relativamente às patentes de IA ronda os 2,3%. As patentes não relacionadas com a IA, também apresentam um impacto positivo (elasticidade de 2,2%). Quando a qualidade da patente é considerada (através do tamanho da família), apenas o tamanho das patentes de IA apresenta um efeito positivo significativo, enquanto o efeito das patentes não IA não é estatisticamente significativo.

Num estudo realizado por Green e Lamby (2025) são destacados países como a Suíça, Irlanda, Reino Unido e Áustria como países que apresentam a maior proporção de trabalhadores nascidos no estrangeiro na força de trabalho em IA. Guarascio et al. (2024), corroboraram esta ideia, destacando a capital da Áustria e do Reino Unido como centros de serviços de alta tecnologia e capital. Já no que concerne a concentração de trabalhadores capacitados na área de IA, quer sejam nativos do país ou não Green e Lamby (2025), destacam pela negativa alguns países do sul da Europa, sobretudo a Grécia, Itália, Espanha e Portugal.

No que se refere ao investimento em IA, Trabelsi (2024), destaca, neste âmbito, dois países: a Alemanha e a França, com cerca 7 mil milhões de dólares e 6,6 mil milhões de dólares investido, respetivamente, em território francês. No caso da França são evidenciadas previsões de aumento da produtividade em 20% devido à IA.

De uma forma geral, a análise do impacto da IA no emprego europeu revela um panorama marcado por fortes assimetrias regionais e institucionais, que condicionam não apenas a difusão da tecnologia, mas também os seus efeitos económicos e sociais (Guarascio et al., 2024). Na ótica de Guarascio et al. (2024), a UE é caracterizada por uma significativa heterogeneidade estrutural e territorial, o que se traduz em diferentes níveis de "prontidão" para a adoção da IA. Esta variação é influenciada por múltiplos fatores, como a acumulação de capacidade tecnológica e, níveis de investimento em investigação e desenvolvimento.

Neste contexto, as regiões onde predominam serviços de alta tecnologia e os centros urbanos— como Viena, Bruxelas, Berlim, Madrid, Île-de-France, Helsínquia e Praga — reúnem as condições mais propícias para a integração bem-sucedida da IA nas suas estruturas produtivas. Nestes territórios, espera-se que a IA funcione como um

Avaliação do impacto da Inteligência Artificial no emprego Europeu

complemento às atividades económicas já altamente qualificadas, potenciando a produtividade e, simultaneamente, criando oportunidades de trabalho (Guarascio et al., 2024) . Em contraste, as periferias do Sul e do Leste da Europa — incluindo as ilhas gregas, o sul de Itália, Andaluzia, Chéquia, Polónia, Hungria, Roménia e Bulgária — enfrentam fragilidades estruturais marcadas, como baixos níveis de investigação e desenvolvimento, ecossistemas de inovação menos desenvolvidos e uma maior dependência de setores intensivos em mão de obra. Nestes casos, o impacto da IA no mercado de trabalho será provavelmente limitado e poderá, inclusive, acentuar as disparidades económicas já existentes, de acordo com o mesmo autor.

Segundo Arntz (2016), a automatização potencial afeta, em média, cerca de 9% dos empregos nos países da OECD, segundo estimativas baseadas numa análise centrada nas tarefas realizadas dentro de cada ocupação. Em paralelo, uma maior exposição à IA tem vindo a ser associada à redução das horas médias de trabalho, especialmente em profissões com baixo uso de tecnologia computacional.

Importa sublinhar que a IA continua numa fase incipiente de difusão, o que torna prematura qualquer avaliação conclusiva sobre os seus efeitos no emprego. Tal realidade reforça a necessidade de aprofundar a investigação empírica, nomeadamente através da recolha de dados a nível empresarial. Acresce que grande parte da literatura disponível privilegia a análise quantitativa do número de postos de trabalho, descurando aspetos igualmente relevantes como a qualidade do emprego, as condições de trabalho e a evolução das relações laborais, entre outro tipo de indicadores.

Em suma, os dados sugerem que o impacto da IA no emprego europeu será moldado por profundas desigualdades territoriais, institucionais e tecnológicas, reforçando a importância de políticas públicas diferenciadas que promovam a capacitação regional, a qualificação da força de trabalho e o reforço dos ecossistemas de inovação para mitigar os riscos de polarização económica e social na era digital.

1.4 Desafios éticos e regulamentação da IA

O crescente interesse gerado em torno da IA e a sua presença cada vez mais intensa no nosso quotidiano têm suscitado diversas questões e preocupações na discussão pública.

Avaliação do impacto da Inteligência Artificial no emprego Europeu

As organizações, perante o desenvolvimento sem precedentes da IA e com os desafios ético-sociais que lhe estão associados, têm emitido declarações a afirmar o seu compromisso com os princípios éticos desta tecnologia. Tanto os países ocidentais como os asiáticos, têm começado a elaborar declarações de princípios nesta matéria (de Laat, 2021).

Em conformidade com o Regulamento Geral sobre a Proteção de Dados (RGPD) da UE, os indivíduos têm o direito de contestar e solicitar uma revisão de uma qualquer decisão feita de forma automática que afete significativamente os seus direitos e interesses legítimos (Rodrigues, 2020).

Rodrigues (2020) alerta para a falta de transparência algorítmica nos processos de recrutamento laboral, evidenciando a forma como os algoritmos são utilizados para selecionar candidatos com base em critérios opacos e inacessíveis. Esta falta de transparência no processo impede que os candidatos compreendam os motivos das decisões de seleção, levantando dúvidas relativas à equidade e à imparcialidade do processo. Em particular, há o risco de os algoritmos perpetuarem discriminações existentes, uma vez que podem refletir padrões históricos enviesados. No entanto, o acesso aberto a qualquer algoritmo não significa que o problema seja resolvido, pois colide com questões de proteção de dados, o que levanta preocupações quanto ao cumprimento do RGPD (Rodrigues, 2020). Como mencionado anteriormente, embora a utilização da IA apresente potencial para melhorar os processos laborais em diversas áreas, persiste o risco de violação dos direitos humanos (Stahl et al., 2022). A maioria dos atuais sistemas de IA requer grandes conjuntos de dados para melhorar o modelo de resposta, sendo que estes conjuntos de dados frequentemente incluem informações pessoais sensíveis.

Assim, deve-se garantir que, à medida que a IA continua a evoluir, é essencial orientar o seu desenvolvimento com base em princípios éticos, assegurando transparência, responsabilidade e conformidade regulatória (Devineni, 2024).

Com o objetivo de assegurar a integridade, a fiabilidade e a transparência dos sistemas de IA a UE desenvolveu o AI ACT (Ato sobre a IA), tendo o mesmo sido adotado pelas instituições da União Europeia e entrou em vigor a 1 de agosto de 2024 (Presno Linera & Meuwese, 2025). Por se tratar de um regulamento, é vinculativo na sua totalidade e

Avaliação do impacto da Inteligência Artificial no emprego Europeu

aplicável diretamente em todos os Estados-Membros da UE, não necessitando de transposição para a legislação nacional.

A principal função do AI Act é criar um quadro harmonizado para o desenvolvimento e utilização de sistemas de IA fiáveis e centrados no ser humano, promovendo ao mesmo tempo a inovação tecnológica e a proteção dos direitos fundamentais (Presno Linera & Meuwese, 2025).

O AI Act estabelece uma ambição dupla: por um lado, pretende reforçar a inovação e o desenvolvimento tecnológico, garantindo que os Estados-Membros da UE possam competir num mercado global de IA; por outro, procura proteger os direitos fundamentais, prevenindo potenciais riscos associados à IA, tais como decisões automatizadas opacas, discriminação baseada em género ou outras características, intrusão na vida privada e utilização de sistemas de IA para fins ilícitos (Presno Linera & Meuwese, 2025).

2 Metodologia

A DEA é uma metodologia não paramétrica amplamente utilizada para medir a eficiência relativa de unidades que tomam decisões, como empresas, escolas, hospitais ou municípios. Estas unidades utilizam múltiplos recursos (*inputs*) para gerar vários resultados (*outputs*) (Charnes et al., 1985).

A DEA teve as suas raízes nos estudos de (Farrell, 1957) sobre métodos para avaliação da produtividade, nos quais ele destacava a importância de desenvolver indicadores de eficiência global. Esta metodologia baseia-se em técnicas de programação linear para construir uma fronteira de eficiência. Essa fronteira representa o desempenho ótimo observado para um conjunto de unidades semelhantes. Cada *Decision-Making Unit* (DMU) é comparada com as melhores práticas do grupo, sendo considerada eficiente se se encontrar sobre a fronteira, e ineficiente se estiver abaixo dela.

Uma das principais vantagens do modelo DEA é a sua capacidade de lidar com múltiplos *inputs* e *outputs* sem necessidade de especificar uma forma funcional prévia (ao contrário, por exemplo, dos modelos econométricos tradicionais). Isso torna-o particularmente adequado para contextos em que a produção ou desempenho é avaliado com base em múltiplas dimensões.

Existem vários modelos de DEA, que procuram identificar quais das “n” DMUs compõem a fronteira eficiente (ou superfície envolvente) em termos da eficiência de Pareto-Koopmans. Uma DMU é considerada eficiente se, em comparação com as outras, produzir mais, para quantidades fixas de recursos (orientação a *outputs*) e/ou utilizar menos recursos para gerar uma quantidade fixa de produtos (orientação a *inputs*). A DEA estabelece uma fronteira empírica eficiente, conhecida como "superfície envolvente" de máxima eficiência (Ali & Seiford, 1993). Isso possibilita a identificação de unidades de referência (*benchmarks*) cujos níveis de eficiência servem como modelo para as demais unidades dentro da fronteira de eficiência.

De entre os vários modelos DEA destacam-se três abordagens principais: o modelo CCR (Charnes, Cooper e Rhodes), o modelo BCC (Banker, Charnes e Cooper) e o modelo ADD (Aditivo). O modelo CCR e o modelo BCC são modelos que podem ser orientados a *input* ou *output*, enquanto ao modelo aditivo, é não orientado.

Avaliação do impacto da Inteligência Artificial no emprego Europeu

O modelo CCR, apresentado originalmente por Charnes, Cooper e Rhodes (Charnes et al., 1978) baseia-se na transformação de múltiplos *inputs* e *outputs* em valores virtuais para cada unidade de decisão (DMU). A eficiência de cada DMU é mensurada por meio da razão entre o *output* virtual e o *input* virtual, determinada por um conjunto de multiplicadores que compõem as variáveis de um modelo de programação linear fracionária. Este modelo assume retornos constantes à escala implicando que qualquer alteração nos *inputs* resultará numa alteração proporcional nos *outputs*.

Proposto por Banker, Charnes e Cooper (Banker et al. 1984), o modelo BCC, quando aplicado assume uma relação entre *inputs* e *outputs* que pode variar (retornos variáveis à escala). O axioma da proporcionalidade entre *inputs* e *outputs* é substituído pelo axioma da convexidade. Em cenários em que a eficiência operacional pode variar este modelo é fundamental para a compreensão do fenómeno. A eficiência operacional refere-se à capacidade da DMU otimizar a utilização dos seus recursos, os *inputs*, de modo a maximizar a produção de bens ou serviços, os *outputs*. Ou seja, trata-se de alcançar o melhor resultado possível com o menor custo possível.

Relativamente ao modelo ADD, este minimiza simultaneamente os excessos de *inputs* e os défices de *outputs*, fornecendo assim uma visão da eficiência de forma equilibrada.

Mais recentemente, têm sido desenvolvidas versões avançadas desta metodologia, com a VBDEA, que integra técnicas de apoio multicritério à decisão e permite incorporar preferências dos decisores na análise. Este modelo transforma os *inputs* e *outputs* em escalas de valor e aplica a regra do arrependimento mínimo (*min-max regret*), tornando a análise mais robusta em contextos com dados negativos ou de difícil interpretação direta. O modelo DEA também pode ser aplicado de forma dinâmica, utilizando abordagens como o *Window* DEA que permite analisar a evolução da eficiência ao longo do tempo (Charnes et al., 1985). Nesta abordagem dinâmica cada unidade é tratada como uma nova entidade em cada período, o que facilita a comparação de desempenhos em janelas temporais móveis.

Aquando da sua aplicação, a metodologia DEA segue as seguintes etapas, presentes na Figura 1.




Figura 1 – Etapas da Metodologia DEA

Fonte: Elaboração Própria

Desde o aparecimento da DEA que a sua utilização por parte dos investigadores tem aumentado, não só por ser uma ferramenta de análise de dados que ajuda a identificar e quantificar a eficiência relativa de unidades de tomada de decisão, mas também porque identifica as fontes específicas de ineficiência para cada DMU. Ao fornecer *insights* para a melhoria contínua e para a tomada de decisões estratégicas, a DEA constitui uma ferramenta analítica de elevado valor. É por estas razões que esta metodologia foi selecionada para integrar o trabalho que será desenvolvido.

De uma forma sumária, a metodologia em questão tem as suas vantagens e limitações. Do lado das vantagens, a DEA permite a avaliação da eficiência utilizando simultaneamente múltiplos *inputs* e *outputs*, não requerendo a especificação de uma função de produção, isto é, a descrição da relação entre *inputs* e *outputs*. Possui ainda a vantagem de poder ser aplicada em diferentes setores de atividade.

Do ponto de vista das limitações, esta metodologia apresenta algumas restrições importantes. Em primeiro lugar, demonstra elevada sensibilidade a *outliers*, ou seja, a valores fora do comum. O que pode distorcer os resultados. Adicionalmente, identificam-se como principais limitações a falta de significância estatística inerente ao método, a exigência de um elevado nível de complexidade computacional, e a dificuldade na interpretação dos resultados obtidos.

O método VBDEA, que vai ser utilizado neste trabalho, permite ultrapassar problemas comuns inerentes ao modelo ADD, incluindo problemas de escala, a natureza pessimista da sua medida de eficiência e a falta de interpretação intuitiva. Este método desenvolvido por Gouveia et al. (2008) é uma variante do modelo ADD com projeções orientadas (Ali et al., 1995) que incorpora as preferências do decisor utilizando conceitos da *Multi-Attribute Utility/Value Theory* (MAUT/MAVT) com informação imprecisa.

2.1 O Método *Value-Based DEA*

O método VBDEA, proposto por (Gouveia et al., 2008), surge como uma evolução do modelo DEA aditivo tradicional, introduzindo projeções orientadas e superando algumas das suas limitações principais. Entre estas limitações estão o problema da escala, a dificuldade em lidar com valores negativos nos indicadores de desempenho e a ausência de uma interpretação clara da medida de eficiência. Para ultrapassar estas questões, o VBDEA transforma os desempenhos de cada *input* e *output* (critério) em funções de valor parciais, normalizadas no intervalo $[0,1]$.

Estas funções de valor, associadas a cada critério, são construídas com base nas preferências do decisor (caso exista) para cada uma das DMUs, atribuindo o valor 0 ao pior desempenho do critério e o valor 1 ao melhor, com o objetivo de maximizar todos os critérios. A seguir, estas funções são combinadas através de uma função de valor global, de natureza aditiva, fundamentada na MAVT.

Neste contexto, cada unidade de análise do conjunto $\{DMU_1, DMU_2, \dots, DMU_n\}$ é avaliada considerando m critérios que se pretendem minimizar (representados por x_{ij} , onde $i = 1, \dots, m$) e p critérios a maximizar (representados por y_{rj} com $r = 1, \dots, p$). A totalidade dos $q = m + p$ critérios é convertida em funções de valor $v_c(DMU_j)$ definidas de forma a refletir a *performance* relativa de cada DMU em cada critério, num intervalo de 0 (desempenho mais fraco) a 1 (desempenho mais forte).

Depois desta conversão, calcula-se uma função de valor global para cada DMU através da expressão: $V(DMU_j) = \sum_{c=1}^q w_c v_c(DMU_j)$, onde os pesos w_c (com $w_c \geq 0$, $\forall c = 1, \dots, q$ e $\sum_{c=1}^q w_c = 1$) representam a importância relativa de cada critério.

Estes pesos são definidos com base no princípio do arrependimento min-max (Bell, 1982), que procura minimizar a diferença de valor entre cada alternativa e a melhor alternativa possível. No contexto deste método, as DMUs tomam o lugar de alternativas. A formulação matemática do VBDEA é trazida em duas fases. A primeira fase, inclui o conceito de supereficiência de (Andersen & Petersen, 1993) e avalia uma DMU específica (a k -ésima) recorrendo a (1):

$$\begin{aligned} & \min_{d_k, w} d_k \\ & s. t. \sum_{c=1}^q w_c v_c(DMU_j) - \sum_{c=1}^q w_c v_c(DMU_k) \leq d_k, j = 1, \dots, n; j \neq k \\ & \sum_{c=1}^q w_c = 1 \\ & w_c \geq 0, \forall c = 1, \dots, q \end{aligned} \quad (1)$$

Neste problema linear, o objetivo é determinar o valor mínimo d_k^* que representa a maior desvantagem da DMU_k avaliada face às restantes, considerando a melhor combinação possível de pesos, que constitui o conjunto de variáveis do problema de programação linear. Esta abordagem permite medir o desempenho de cada DMU_k relativamente às outras, excluindo-se do conjunto de comparação, e identificar a sua distância em termos de valor agregado à melhor DMU do conjunto. Segundo os estudos desenvolvidos por Gouveia et al. (2008, 2013), a segunda fase do método VBDEA é resolvida para as DMUs que na primeira fase apresentam $d_k^* \geq 0$ e faz uso dos vetores de pesos ótimos obtidos na primeira fase para projetar a DMU_k analisada sobre a fronteira eficiente. Assim, quando $d_k^* \geq 0$, é então possível avançar para a formulação e resolução de um novo problema de programação linear (2).

$$\begin{aligned} & \min_{\lambda, s} z_k = - \sum_{c=1}^q w_c^* s_c \\ & s. t. \sum_{j=1, j \neq k}^n \lambda_j v_c(DMU_j) - s_c = v_c(DMU_k), c = 1, \dots, q \\ & \sum_{j=1, j \neq k}^n \lambda_j = 1 \\ & \lambda_j, s_c \geq 0, j = 1, \dots, k-1, k+1, \dots, n; c = 1, \dots, q \end{aligned} \quad (2)$$

O conjunto de DMUs eficientes, que pode conter uma ou mais unidades, permite a formação de uma combinação convexa por meio dos coeficientes $\lambda_j > 0$ ($j = 1, \dots, k - 1, k + 1, \dots, n$). Essa combinação constitui o chamado “conjunto de referência” da DMU_k em análise e define um ponto sobre a fronteira eficiente que domina a DMU_k , considerando as diferenças de valor s_c (*slack*) observadas em cada fator c .

A classificação das DMUs baseia-se no seguinte:

- Se $d_k^* < 0$ então a DMU é classificada como supereficiente
- Se $d_k^* > 0$ então a DMU é classificada como ineficiente;
- Se $d_k^* = 0$ então a DMU é classificada como fracamente eficiente.

2.2 Window Analysis Value-Based DEA

A análise DEA com janelas baseia-se no conceito de médias móveis (Charnes et al., 1994), permitindo observar a evolução do desempenho de uma unidade ao longo do tempo. Cada DMU em cada janela é tratada como uma entidade distinta, o que facilita a comparação de eficiências entre diferentes períodos. A largura da janela, que corresponde ao número de períodos considerados, pode ser ajustada, oferecendo uma análise mais focada ou abrangente conforme a necessidade. Para garantir resultados fiáveis, é importante escolher uma largura de janela tal que se possa assumir que as alterações tecnológicas dentro de cada janela são mínimas (Asmild et al., 2004) evitando assim comparações injustas ao longo do tempo.

A expressão que determina o número total de janelas possíveis, tendo em conta o número de períodos e a largura da janela é a seguinte: $\mu = \tau - \beta + 1$.

Por sua vez, a expressão que indica o número DMUs avaliadas, considerado o número total de DMUs, a largura da janela e o número de janelas:

$$\text{Número de DMUs distintas} = n \times \beta \times \mu$$

Onde:

- μ = número de janelas,
- T = número total de períodos,

Avaliação do impacto da Inteligência Artificial no emprego Europeu

- β = largura de cada janela,
- n = número de DMUs.

Suponha-se que existem n DMUs ($DMU_1^t, DMU_2^t, \dots, DMU_n^t$), avaliadas ao longo de T períodos ($t = 1, \dots, T$), perfazendo $n \times T$ observações. Cada DMU em cada período t utiliza m inputs, representados por uma matriz ($m \times n$), $X^t = [x_{ij}^t]$, e gera s outputs, representados por uma matriz ($s \times n$), $Y^t = [y_{rj}^t]$. Para cada DMU_k^t , os vetores linha correspondentes são $x_k^{t'}$ e $y_k^{t'}$ (transpostos).

Na metodologia *Window* DEA, o primeiro período de cada janela é descartado e um novo período é acrescentado. Se uma janela começar no período τ ($1 \leq \tau \leq T - \beta + 1$), com uma largura β , haverá $n \times \beta$ observações. As matrizes de inputs e outputs da janela serão: $X_{\tau\beta} = (x_{\tau}^1, x_{\tau}^2, \dots, x_{\tau}^n, x_{\tau+1}^1, x_{\tau+1}^2, \dots, x_{\tau+1}^n, \dots, x_{\tau+\beta-1}^1, x_{\tau+\beta-1}^2, \dots, x_{\tau+\beta-1}^n)$ e $Y_{\tau\beta} = (y_{\tau}^1, y_{\tau}^2, \dots, y_{\tau}^n, y_{\tau+1}^1, y_{\tau+1}^2, \dots, y_{\tau+1}^n, \dots, y_{\tau+\beta-1}^1, y_{\tau+\beta-1}^2, \dots, y_{\tau+\beta-1}^n)$, compostas pelas observações dos períodos entre τ e $\tau + \beta - 1$.

No VBDEA, todos os fatores são convertidos em funções de valor. Assim, $v_c^{\tau}(DMU_j)$ representa o valor da DMU_j segundo o critério c , no período τ . O método *Window* VBDEA (WVBDEA) apresenta a primeira fase especificada para cada período t ($t = 1, \dots, T$), em cada janela Ω ($\Omega = 1, \dots, n \times \beta$), e para cada subperíodo da janela ρ ($\rho = \tau, \dots, \tau + \beta - 1$), conforme formulação (3):

$$\begin{aligned} \min_{d_k, w} d_k^{t\Omega}, \\ s. t. \sum_{\rho=\tau}^{\tau+\beta-1} \sum_{c=1}^q w_c^{\rho} v_c^{\rho} (DMU_j^t) - \sum_{\rho=\tau}^{\tau+\beta-1} \sum_{c=1}^q w_c^{\rho} v_c^{\rho} (DMU_k^t) \leq d_k^{t\Omega}, j = 1, \dots, n; j \neq k, \\ \sum_{\rho=\tau}^{\tau+\beta-1} \sum_{c=1}^q w_c^{\rho} = 1, \\ w_c^{\rho} \geq 0, \forall c = 1, \dots, q, \rho = \tau, \dots, \tau + \beta - 1 \end{aligned} \quad (3)$$

Onde w_c^{ρ} representa o peso atribuído ao fator c no subperíodo ρ , ajustado de modo a minimizar a diferença de valor face à melhor DMU. O valor ótimo $d_k^{t\Omega*}$ reflete essa diferença, enquanto a soma dos pesos assegura a convexidade da superfície envolvente. Na abordagem WVBDEA, o problema linear (2) é adaptado para acomodar a dimensão temporal, otimizando as folgas (*slacks*) ao longo de vários períodos dentro de uma janela de análise. Esta segunda fase recorre à formulação (4) com os pesos ótimos $w_c^{\rho*}$, determinados na formulação (3), para identificar melhorias para as DMUs ineficientes.

$$\begin{aligned} \min_{\lambda, s} z_k &= - \sum_{\rho=\tau}^{\tau+\beta-1} \sum_{c=1}^q w_c^{\rho*} s_c^{\rho} \\ \text{s. t. } \sum_{\substack{j=1 \\ j \neq k}}^n \lambda_j^{\rho} v_c^{\rho}(DMU_j) - s_c^{\rho} &= v_c^{\rho}(DMU_k), c = 1, \dots, q; \rho = \tau, \dots, \tau + \beta - 1 \\ \sum_{\substack{j=1 \\ j \neq k}}^n \lambda_j^{\rho} &= 1 \\ \lambda_j^{\rho}, s_c^{\rho} &\geq 0, j = 1, \dots, k-1, k+1, \dots, n; c = 1, \dots, q, \rho = \tau, \dots, \tau + \beta - 1 \end{aligned} \quad (4)$$

A utilização de janelas temporais revela-se particularmente útil por oferecer uma perspetiva mais flexível e ajustável à natureza dinâmica dos fenómenos sociais e económicos. Na ótica de (Henriques et al., 2025), através da divisão dos dados em janelas temporais sucessivas, é possível observar tendências de desempenho ao longo do tempo, tratando cada unidade de decisão (DMU) em cada janela como uma entidade distinta. Tal estratégia possibilita comparações mais rigorosas entre períodos, permitindo a deteção de padrões e a avaliação do impacto de mudanças contextuais.

Além disso, a flexibilidade na definição da largura das janelas temporais permite adaptar a análise a diferentes objetivos, desde avaliações focadas num momento específico até estudos mais abrangentes de longo prazo. Ao mesmo tempo, esta abordagem contribui para a fiabilidade dos resultados, ao assumir que, dentro de cada janela, as alterações tecnológicas são mínimas, reduzindo assim a probabilidade de comparações enviesadas (Henriques et al., 2025).

2.3 Hierarchical Clustering

O *Hierarchical Clustering* é uma abordagem amplamente utilizada em análise de dados, devido à sua capacidade de revelar estruturas latentes em diferentes níveis de detalhe. Ao contrário dos métodos de agrupamento tradicionais, que produzem apenas uma divisão fixa do conjunto de dados, o agrupamento hierárquico permite representar várias divisões encadeadas — desde o nível mais detalhado, em que cada observação forma o seu próprio grupo, até ao mais geral, onde todas as observações pertencem ao mesmo agrupamento (Gama et al., 2017). Esta representação hierárquica é normalmente expressa através de um dendrograma, uma árvore enraizada onde cada folha representa uma observação individual, e os nós internos correspondem a fusões ou divisões sucessivas entre grupos

de observações. Como é salientado na literatura, o dendrograma oferece uma visualização intuitiva da estrutura de similaridade entre os elementos (Gama et al., 2017).

O método pode ser realizado através de duas abordagens principais: aglomerativa, que constrói a hierarquia de baixo para cima, fundindo iterativamente os pares de *clusters* mais semelhantes, e divisória, que procede no sentido inverso, partindo de um único *cluster* que inclui todos os elementos e dividindo-o sucessivamente até se obterem *clusters* individuais. Estas técnicas, embora populares, apresentam limitações importantes. Tal como sublinhado por Vichi et al. (2022), os algoritmos tradicionais baseiam-se em abordagens que não permitem a correção de decisões anteriores. Por serem aproximações empíricas, não otimizam uma função objetivo explícita e estão sujeitos a erros de agrupamento irrecuperáveis. Além disso, a sua implementação requer, em muitos casos, o armazenamento de matrizes de diferentes com complexidade quadrática, o que se torna proibitivo para conjuntos de dados de grande dimensão.

No plano teórico, o *Hierarchical Clustering* permaneceu durante muito tempo pouco formalizado em comparação com métodos de partição como o *k-means*. Como salienta Infante (2002), esta discrepância deve-se, em parte, à ausência de uma função objetivo clara que permitisse avaliar e comparar hierarquias de forma rigorosa. A sua contribuição pioneira consistiu em formular o problema como uma tarefa de otimização combinatória, propondo uma função de custo baseada nas similaridades entre os elementos de dados. Segundo este autor, uma boa hierarquia deve separar os elementos mais dissimilares nos níveis superiores da árvore, refletindo de forma fidedigna a estrutura do grafo de similaridade subjacente.

3 Dados

Os dados a utilizar na elaboração deste estudo foram recolhidos de diversas fontes, nomeadamente a partir das bases de dados OECD, do Eurostat e do *Our World in Data* (OWID). Estes dados, fundamentalmente de natureza estatística e demográfica, contemplam os seguintes aspetos de avaliação: o investimento privado anual em IA, a mobilidade de competências em IA entre países, a concentração geográfica de profissionais de IA por país, as tendências de contratação ao longo do tempo e ainda a aferição de especialista ICT empregados, de modo a perceber qual o impacto presente e futuro da IA no mercado de trabalho da UE.

No que diz respeito às fontes utilizadas, a OECD disponibiliza uma ampla gama de dados e relatórios oficiais sobre diversos temas da UE, com particular enfoque em áreas como o trabalho, a tecnologia, a inovação, entre outros. O Eurostat, enquanto serviço estatístico da UE, fornece dados harmonizados que permitem comparações entre os diversos países/regiões pertencentes à UE.

Relativamente à informação retirada da plataforma OWID, esta foi utilizada como fonte secundária, agregando e organizando dados provenientes de várias organizações internacionais.

Deste modo, é possível garantir que os dados são oficiais e comparáveis entre os diversos membros da UE.

No que concerne à conformidade com o RGPD, tanto a OECD, o Eurostat como a OWID garantem a proteção e privacidade dos dados. Estas entidades, ao recolherem maioritariamente dados agregados, garantem o seu anonimato da informação, protegendo adequadamente quaisquer dados pessoais identificáveis. Deste modo, cumprem não apenas com as disposições do RGPD, mas também com os princípios de integridade dos dados.

Para a obtenção dos dados, após verificação da conformidade com o RGPD, foram utilizados filtros e parâmetros específicos de modo a permitir selecionar somente os dados relevantes, tais como períodos temporais, regiões geográficas, setores económicos, entre outros.

Conforme descrito nas secções anteriores, compreender o desenvolvimento da IA nos diferentes países requer uma abordagem multidimensional que englobe: (1) a

Avaliação do impacto da Inteligência Artificial no emprego Europeu

quantificação do número de especialistas em TIC, que constituem a base técnica para o avanço da IA; (2) a análise dos níveis de investimento, tanto público como privado, que cada país direciona para a investigação e implementação de soluções de IA; e (3) a avaliação do volume e impacto da produção científica, que reflete não só a capacidade de inovação como também o potencial de transferência de conhecimento para a sociedade. Importa também identificar as competências tecnológicas mais procuradas no atual mercado de trabalho, cruzando as exigências emergentes nos novos perfis profissionais com as capacidades efetivamente disponíveis no sector, de modo a identificar possíveis desajustes entre a formação académica e as necessidades reais da indústria. Esta análise integrada permite uma visão abrangente do ecossistema de IA, fundamentando políticas públicas e estratégias empresariais mais eficazes.

Assim, os indicadores recolhidos para análise do objeto de estudo são os apresentados na Tabela 1.

Tabela 1 - Indicadores

Indicador	Descrição do Indicador	Fonte
<i>AI Research Productivity</i>	Refere-se ao número de publicações científicas relacionadas com IA produzidas por cada país. Mede a capacidade de inovação, a colaboração académica e o impacto da investigação em IA a nível global.	OECD
<i>AI Talent Migration Trends</i>	Analisa a migração de talentos em IA, fornecendo <i>insights</i> sobre o talento de IA ganho ou perdido entre países. Inclui fluxos líquidos de talentos normalizados para o país de interesse.	OECD
<i>Private AI investment</i>	Refere-se ao investimento privado em IA, incluindo capital de risco. Exclui financiamento não patrimonial e empresas de capital aberto, como as de <i>Big Tech</i> .	OWID
<i>ICT Workforce Availability</i>	Define especialistas em ICT como trabalhadores com capacidades para desenvolver, operar e manter sistemas de ICT. A recolha de dados é feita	EUROSTAT

Avaliação do impacto da Inteligência Artificial no emprego Europeu

	através de inquéritos realizados pelos institutos nacionais de estatística da UE.	
<i>AI Workforce Concentration</i>	Calcula a concentração de talentos em IA em diferentes países, com base nas contagens de membros do <i>LinkedIn</i> com competências ou cargos de IA.	OECD
<i>AI Hiring Trends</i>	Mostra as tendências de procura e oferta de talentos em IA em diferentes países e setores ao longo do tempo, com base nos dados do <i>LinkedIn</i> e no <i>Adzuna</i> .	OECD
<i>Contributions to Open AI Projects</i>	Mede a participação de diferentes países em projetos públicos de IA e o impacto desses projetos.	OECD

Fonte: Elaboração Própria

Posteriormente, foi realizada uma análise de correlação para todos os indicadores (ver Figura 37 no Apêndice 1).

A descrição dos indicadores referidos é apresentada nos termos seguintes:

1. ***AI Research Productivity***: Utilizam dados sobre publicações em IA do *OpenAlex* e do *Scopus* para fornecer informações detalhadas sobre as atividades de investigação em diferentes países. É um recurso ou condição prévia para que a IA tenha impacto. Mais investigação tende a gerar mais aplicações e efeitos sobre o emprego.
2. ***AI Talent Migration Trends***: A análise inclui tendências de migração de talentos em IA, o que pode informar políticas industriais, do mercado de trabalho e educacionais. Os dados fornecem *insights* aos países sobre o talento de IA ganho ou perdido devido às tendências de migração. A migração de talentos em IA é considerada para todos os profissionais com competências em IA que, num determinado momento, ocupam empregos na área no país A, que é o país em análise. O país B representa a origem dos talentos que entram e o destino dos que saem. Assim, a migração líquida de talentos em IA entre os países A e B — do ponto de vista do país A — é calculada da seguinte forma:

Avaliação do impacto da Inteligência Artificial no emprego Europeu

$$\text{Net AI Talent Migration}_{a,b,t} = \frac{\text{Net AI Talent flows}_{a,b,t}}{\text{Member count}_{a,t}}$$

Os fluxos líquidos são definidos como o total de chegadas menos partidas num determinado período. A associação ao *LinkedIn* varia consideravelmente entre os países, o que dificulta a interpretação dos movimentos absolutos de membros de um país para outro. Para comparar os fluxos migratórios entre países de forma justa, os fluxos migratórios são normalizados para o país de interesse. Por exemplo, se o país A for o país de interesse, todos os fluxos líquidos absolutos de entrada e saída do país A, independentemente dos países de origem e destino, são normalizados com base na associação ao *LinkedIn* no país A no final de cada ano e multiplicados por 10.000. Portanto, essa métrica indica a migração relativa de talentos de todos os países de e para o país A.

3. **AI Workforce Concentration:** As contagens de talentos de IA são usadas para calcular as métricas de concentração de talentos. Por exemplo, a concentração de talentos de IA no nível do país é calculada usando as contagens de talentos de IA em relação às contagens de membros do *LinkedIn* naquele país. Como tal, as métricas de concentração de talentos de IA podem ser influenciadas pela cobertura do *LinkedIn* de um país e devem ser usadas com cautela.

Como também abrange membros do *LinkedIn* com cargos de IA – em oposição a apenas membros do *LinkedIn* com competências em IA nos seus perfis – o talento de IA é considerado uma medida mais abrangente do que as competências de IA. Representa um resultado desejado da aplicação de recursos em IA, mais concentração de talento em IA sugere maior impacto no emprego.

4. **AI Hiring Trends:** Utilizam dados do *LinkedIn* e do *Adzuna* para mostrar as tendências na procura e oferta de talentos em IA em diferentes países e setores ao longo do tempo. Estes dados fornecem informações importantes sobre os países e as indústrias na vanguarda da adoção de IA e as competências mais procuradas. O índice de taxa de contratação de IA do *LinkedIn* é dado pelo número de membros do *LinkedIn* que têm competências em IA, no seu perfil, e que adicionaram um novo emprego com ligação a IA, dividido pelo número total de membros do *LinkedIn* no país. É um resultado direto da aplicação da IA na

Avaliação do impacto da Inteligência Artificial no emprego Europeu

economia, maior contratação indica maior impacto (positivo ou transformador) no mercado de trabalho.

5. ***Contributions to Open AI Projects:*** A OECD.AI faz parceria com o *GitHub* para identificar projetos públicos de IA – ou “repositórios” – seguindo a metodologia desenvolvida por Gonzalez et al. (2020).

Para calcular as contribuições de cada país para os projetos de IA de forma fracionada, cada contribuição é dividida igualmente entre todos os que participaram no projeto. Ou seja, se um projeto de IA recebeu várias contribuições de diferentes pessoas, o valor de cada contribuição é dividido pelo número total de contribuições no projeto.

A soma de todas as contribuições de um país para diferentes projetos de IA é feita somando as suas partes fracionadas em cada projeto.

Em termos relativos, a participação de um país nas contribuições totais para os projetos de IA é calculada comparando o número de contribuições desse país com o número total de contribuições feitas por todos os países. Assim, obtém-se a proporção de contribuições feitas por aquele país em relação ao total global. É um resultado produtivo da capacidade instalada e dos investimentos em IA, especialmente ligado à qualidade e à maturidade do ecossistema digital de um país.

6. ***Private AI Investment:*** O conjunto de dados cobre apenas investimentos no mercado privado, como capital de risco. Exclui financiamento não patrimonial, como dívida e doações, e empresas de capital aberto, incluindo grandes empresas de *Big Tech*. Neste indicador as empresas são classificadas como relacionadas com a IA com base em palavras-chave e *tags* do setor, incluindo potencialmente empresas que não são tradicionalmente vistas como focadas em IA, enquanto perdem outras devido a diferenças de definição. Portanto, é um recurso que alimenta o desenvolvimento e a adoção de IA.

7. ***ICT Workforce Availability:*** O Eurostat define especialistas em ICT como "trabalhadores que têm a capacidade de desenvolver, operar e manter sistemas de ICT e para quem as ICT são a parte principal do seu trabalho". Os dados sobre

Avaliação do impacto da Inteligência Artificial no emprego Europeu

estes profissionais são principalmente recolhidos através de inquéritos aos trabalhadores realizados pelos institutos nacionais de estatística dos Estados-Membros da UE. Estes inquéritos recolhem informações detalhadas sobre a ocupação, setor de atividade, competências e características demográficas dos trabalhadores, o que permite identificar e quantificar os especialistas em ICT. A força de trabalho em ICT é uma capacidade pré-existente que permite aplicar soluções baseadas em IA.

3.1 Preparação dos dados

Numa primeira fase, após a obtenção dos dados em bruto, procedeu-se à normalização dos mesmos e à sua transformação através de funções de valor, de modo a instanciar os valores dos desempenhos dos critérios utilizados no modelo VBDEA. Os resultados foram obtidos recorrendo ao OpenSolver 2.9.0, disponível em <https://opensolver.org/>. Para o efeito, foi desenvolvida uma aplicação personalizada em Excel com *Visual Basic for Applications* (VBA), a qual utiliza o OpenSolver como motor para a modelação e resolução dos problemas da DEA.

As funções de valor atribuídas a cada critério foram fundamentadas na literatura de análise multicritério (Keeney & Raiffa, 1976; Belton & Stewart, 2002), bem como em estudos empíricos europeus sobre emprego (Eurofound, 2017; OECD, 2019). Critérios como a taxa de emprego jovem e a disponibilidade de competências digitais apresentam retornos marginais decrescentes, justificando funções côncavas, enquanto o desemprego de longa duração tende a ter efeito crescente na utilidade quando os níveis são mais elevados, justificando funções convexas.

No modelo VBDEA, após a transformação dos desempenhos de cada critério através de funções de valor parciais, todos os critérios são considerados a maximizar. Assim, os indicadores (critérios) foram modificados de acordo com a informação constante da Tabela 2.

Tabela 2 - Funções de valor dos critérios

Indicador	Símbolo	Função de Valor V(c)	Explicação
<i>AI Research Productivity</i>	C_1	$V(C_1) = \log(1 + C_1)$	Rendimentos decrescentes: mais investigação contribui para a criação

Avaliação do impacto da Inteligência Artificial no emprego Europeu

			de postos de trabalho, mas a uma taxa decrescente.
<i>AI Talent Migration Trends</i>	C_2	$V(C_2) = C_2^2$ se $C_2 > 0$, caso contrário $V(C_2) = 0$	Favorece os países que atraem talento, ignorando a perda de talento.
<i>Private AI Investments</i>	C_3	$V(C_3) = \sqrt{C_3}$	Impacto marginal decrescente: grandes investimentos ajudam, mas de forma não linear.
<i>ICT Workforce Availability</i>	C_4	$V(C_4) = 0.5 \times C_4$	Peso reduzido devido à fraca correlação com a contratação em IA.
<i>AI Workforce Concentration</i>	C_5	$V(C_5) = C_5^2$	Rendimentos crescentes: uma força de trabalho forte em IA promove uma economia orientada pela IA.
<i>AI Hiring Trends</i>	C_6	$V(C_6) = 2 C_6$	Prioridade máxima: indicador direto da eficiência do mercado de trabalho em IA.
<i>Contributions to Open AI Projects</i>	C_7	$V(C_7) = \log(1 + C_7)$	Partilha de conhecimento tem benefícios a longo prazo, mas menor impacto imediato no emprego.

Fonte: Elaboração Própria

Os dados foram inicialmente filtrados de forma a assegurar a sua relevância e conformidade com os objetivos do presente estudo. Posteriormente, aplicaram-se filtros temporais, restringindo a análise a um período de quatro anos, compreendido entre 2019 e 2023. A delimitação temporal teve por base a disponibilidade de informação na fonte de dados utilizada.

Seguidamente, foi realizada uma verificação para identificar a possível existência de *missing values* ou *outliers*. Ao constatar a falta de dados em alguns casos, optou-se por excluir da análise os países com *missing values*, como Bulgária, Croácia, Chéquia,

Chipre, Malta, Roménia e Eslováquia, pois em um ou mais indicadores não possuíam dados disponíveis, ficando uma amostra de 20 países.

3.2 Dados gerados no modelo DEA

Para aplicação do modelo DEA foram consideradas janelas com três anos: 2019 a 2021, 2020 a 2022 e 2021 a 2023. Esta abordagem permite ultrapassar as limitações dos modelos DEA tradicionais, que assumem uma perspetiva estática, ao incorporar a dimensão temporal na análise de eficiência (Henriques et al., 2025).

Paralelamente, foi também realizada uma análise por ano, de modo a aferir a evolução dos resultados com periodicidade anual.

Após a execução do modelo os resultados aparecem divididos em três categorias:

1. *Windows score*
2. Pesos
3. Folgas

Refere-se que quanto mais negativos os *scores* de eficiência, mais supereficientes são as DMUs, demonstrando um desempenho superior em relação às demais unidades eficientes. Estes resultados indicam que as DMUs assim classificadas utilizam menos recursos ou geram mais resultados do que o necessário para serem classificadas como eficientes.

O *Windows score* permite aferir a eficiência das DMUs no conjunto dos sete indicadores em análise em cada janela.

Os dados relativos aos pesos são obtidos através do modelo DEA, de modo a maximizar a eficiência de cada DMU. Através dos pesos é possível verificar qual o indicador que mais contribui para a maximização do *score* de eficiência cada DMU.

Por seu turno, as folgas são calculadas para as DMUs ineficientes, ou seja, para aquelas com *scores* de eficiência positivos, e representam os ajustes necessários que essas unidades devem operar nos critérios para se tornarem eficientes.

3.3 Análise dos Dados

Para esta análise, foi adotada a metodologia que combina o método WVBDEA com a análise *Hierarchical Clustering*, permitindo uma avaliação dinâmica do impacto da IA nos países pertencentes à UE. A amostra incluiu 20 Unidades de Decisão (DMUs), correspondentes a 20 países da UE, ao longo de um período de 5 anos (2019 a 2023).

Os dados foram depois organizados em 3 intervalos temporais, cada um abrangendo três anos — intervalo 1 (2019-2021), intervalo 2 (2020-2022), e intervalo 3 (2021-2023) — permitindo acompanhar a evolução dos níveis de eficiência ao longo do tempo e identificar tendências, conferindo assim, uma perspetiva mais flexível e ajustável à natureza dinâmica dos fenómenos sociais e económicos.

3.3.1 Scores médios de eficiência

A Tabela 3 apresenta a estatística descritiva dos *scores* médios de eficiência obtidos nas três janelas temporais. A tabela evidencia que na presente amostra, a média dos *scores* é estável entre (0.0770) em 2019-2021 e (0.0797) em 2021-2023, indicando que a eficiência agregada não melhorou significativamente, mantendo níveis de ineficiência. A mediana aumentou de (0.0865) em 2019-2021 para (0.1235) em 2021-2023, mostrando distribuição assimétrica à direita (mais países com *scores* altos/ineficientes) e sugerindo que a Europa está a perder eficiência coletiva em IA. A dispersão aumentou, revelando maior desigualdade na capacidade de transformar recursos em impacto no emprego ligado à IA.

Importa notar que, o mínimo (melhor desempenho) revela que os *top performers* estão a melhorar e o máximo (pior desempenho) sugere que os países menos eficientes estão a recuperar, mas ainda muito lentamente.

Tabela 3 - Estatística descritiva dos scores de eficiência do WVBDEA

Estatística	2019-2021	2020-2022	2021-2023
Média	0.0770	0.0816	0.0797
Mediana	0.0865	0.1097	0.1233
Desvio Padrão	0.10268	0.1271	0.1274
Mínimo	-0.1381	-0.1737	-0.2465

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Máximo	0.3428	0.3387	0.2956
DMUs	20	20	20

A Tabela 4, expõe os *scores* médios de eficiência obtidos por cada DMU, por períodos de janela temporal. Em traços gerais verifica-se que os países com os *scores* médios mais elevados (*top performers*) foram: a Alemanha nas três janelas, 2019-2021 (-0.0673), 2020-2022 (-0.0995) e 2021-2023 (-0.0809), com desempenho consistentemente excelente, a Finlândia nas três janelas, 2019-2021 (-0.0183), 2020-2022 (-0.0347) e 2021-2023 (-0.0072), perdendo ligeiramente na última janela, o Luxemburgo nas janelas 2019-2020 (-0.0485), 2020-2022 (-0.1737) e na janela seguinte, 2021-2023 (-0.2465), revelando uma melhoria acentuada, e a Suécia também nas três janelas, 2019-2021 (-0.1381), 2020-2022 (-0.1737) e 2021-2023 (-0.1610), destacando-se como o país mais eficiente ao longo do período. Os piores desempenhos estão na Letónia, mas a melhorar, de janela para janela, (0.3428, 0.3387 e 0.2956), a Hungria, com ineficiência crescente até 2022 e com ligeira melhoria em 2023, a Estónia e Portugal ambos apresentam *scores* persistentemente positivos. No que toca a melhoria de desempenho ao longo do tempo, podemos apontar a Grécia, que melhora consistentemente de janela para janela (0.0972, 0.1348 e 0.1601), ainda que permanecendo ineficiente, a tendência indica progresso, e a Irlanda que também melhora nos três períodos (0.0714, 0.0854, 0.1378), acompanhando o desenvolvimento do seu ecossistema digital. Os que pioram o desempenho são a Lituânia de (0.1145) para (0.1367) seguindo para (0.1733) e os Países Baixos, em deterioração contínua (0.0421, 0.0291 e 0.0183) com valores relativamente baixos, mas a tendência de perda de eficiência é preocupante.

No estudo de Ajuzieogu (2025) as conclusões a retirar são semelhantes, pois é dado destaque a países como a Alemanha, França, Itália, Bélgica, Suécia, Finlândia e Irlanda que se evidenciam dos demais como países com maior impacto de IA no seu país. Por outro lado, destaca países como Portugal, Grécia, Lituânia, Letónia, Estónia, Hungria e Eslovénia como países que apresentam um impacto inferior.

Tabela 4 - Scores médios de eficiência

País	DMU	2019-2021	2020-2022	2021-2023
------	-----	-----------	-----------	-----------

Avaliação do impacto da Inteligência Artificial no emprego Europeu

AUT	1	0.1080	0.1123	0.1513
BEL	2	0.1260	0.1424	0.1284
DNK	3	0.0823	0.1071	0.0880
EST	4	0.1575	0.1880	0.1744
FIN	5	-0.0183	-0.0347	-0.0072
FRA	6	0.0495	0.0402	0.0519
DEU	7	-0.0672	-0.0944	-0.0809
GRC	8	0.0972	0.1348	0.1601
HUN	9	0.1894	0.2212	0.1718
IRL	10	0.0714	0.0854	0.1378
ITA	11	0.0145	0.0224	0.0280
LVA	12	0.3428	0.3387	0.2956
LTU	13	0.1145	0.1367	0.1733
LUX	14	-0.0485	-0.1737	-0.2465
NLD	15	0.0421	0.0291	0.0183
POL	16	0.1222	0.1569	0.1518
PRT	17	0.1467	0.1696	0.1609
SVN	18	0.0582	0.1307	0.1186
ESP	19	0.0908	0.0940	0.0789
SWE	20	-0.1381	-0.1737	-0.1610

3.3.2 Pesos médios dos indicadores

Através do método WVBDEA, é possível determinar os pesos atribuídos por cada DMU a cada fator, presentes nos Apêndices 2 e 3. A Figura 2 apresenta os pesos médios medianos atribuídos ao indicador “*AI Research Productivity*”. Verifica-se que os pesos médios atribuídos a este fator diminuem ligeiramente ao longo do tempo, sugerindo que, coletivamente, os países passaram a valorizar menos a produção científica como principal fator de eficiência. Por seu turno, os pesos medianos apresentaram-se consistentemente maiores que os médios, nas três janelas, revelando uma distribuição assimétrica com presença de pesos zero ou baixos em vários países. Isso indica que alguns países não usaram o critério (peso zero), enquanto outros o valorizaram significativamente, elevando a mediana.

No que toca à variância, cujos valores estão presentes na Tabela 18 do Apêndice 4, verifica-se que a mesma é relativamente estável revelando a existência de alta dispersão nos pesos atribuídos entre os países.

Ao analisar os *scores* obtidos por janela temporal, na Tabela 4 do Apêndice 2, verifica-se que países como a Estónia, a Lituânia, a Letónia, o Luxemburgo e a Eslovénia obtiveram valor 0 para este fator. O que expressa que este fator foi desprezado na avaliação para a obtenção dos *scores* de eficiências dos países enumerados. Em sentido inverso, importa destacar a Itália que para este fator apresenta os valores mais elevados no conjunto das janelas temporais, (0.3491), (0.3763) e (0.3194), respetivamente. Refere-se ainda que a Suécia, os Países Baixos, e a Bélgica sucedem à Itália como sendo os países que relevam a importância deste fator para a obtenção dos *scores* de eficiência.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 2 - Pesos "AI Research Productivity"

A Figura 3 expõe os pesos médios e medianos associados ao indicador “*AI Talent Migration Trends*”. Os pesos médios, (0.2049 na 1ª janela) e medianos (0.1898) são relativamente altos, o que mostra que entre os países que atraem talento em IA, este critério é valorizado de forma significativa no modelo. Contudo os pesos médios decrescem ao longo das três janelas (0.2049, 0.1557, 0.1399) o que indica uma redução na migração líquida de talentos em IA entre os países da UE no período analisado. Este fenómeno pode ser consequência dos efeitos da pandemia (2020–2022) e desaceleração económica subsequente ou ainda da saturação em mercados líderes (e.g., Luxemburgo, França). No que concerne aos pesos medianos, estes são mais baixos que os pesos médios em todas as janelas, o que confirma existirem poucos países a concentrar os maiores fluxos migratórios, pois a maioria tem impacto marginal ou zero. Os países com maior peso (e.g.: França, Itália e Luxemburgo), que puxam a média para cima, enquanto outros (e.g., Alemanha, Hungria e Lituânia) têm peso nulo ou próximo de zero em alguns períodos.

No que diz respeito à variância, disponível para consulta na Tabela 19 do Apêndice 4, a variância mais elevada é na janela 2020–2022 (0.0295) indicando que a diferença entre países em termos de atratividade de talento aumentou. Isto pode refletir os impactos assimétricos de eventos como a COVID-19, que alterou fluxos de mobilidade laboral, bem como a implementação de estratégias eficazes de alguns países (como Irlanda, Luxemburgo ou Estónia) que captaram talento, enquanto outros estagnaram ou perderam

Avaliação do impacto da Inteligência Artificial no emprego Europeu

atratividade. A redução da variância em 2021–2023 para (0.0122) sugere convergência entre os países ou maior homogeneização da *performance* neste critério.

Ao verificar os países que mais se destacam, de acordo com a Tabela 5 do Apêndice 2, importa referir o Luxemburgo, ao ser o país que neste fator teve a maior contribuição para obtenção do *score* de eficiência, refletindo um *boom* na migração líquida de talentos em IA, possivelmente ligado a políticas de atração. A Estónia e a Irlanda também ponderaram consideravelmente este critério, sendo conjuntamente líderes de atração em talentos, mas que apesar disso não conseguiram classificar-se como países eficientes. No sentido oposto a Alemanha, que desprezou este critério em todas as janelas (peso nulo), está nos *top performers* do grupo de países avaliados. Já a Grécia, a Lituânia, a Hungria e Portugal atribuíram pesos nulos ou mínimos a este critério, em alguns períodos, sugerindo baixa atratividade ou fuga de cérebros. Países como França e Dinamarca têm desempenho instável neste critério, sugerindo sensibilidade a fatores externos. Quanto aos *outliers*, presentes verifica-se a presença da França na primeira janela temporal, a presença do Luxemburgo na segunda janela temporal e por último, a assiduidade igualmente da França e Luxemburgo a par da Itália na última janela temporal.




Figura 3 - Pesos "AI Talent Migration Trends"

A Figura 4 evidencia, os pesos médios e medianos associados ao indicador “*Private AI Investments*”. Denota-se que os pesos médios tiveram uma evolução crescente de 2019-2021 para 2020-2022 com os seguintes resultados (0.1028) e (0.1401), o que sugere que este critério ganhou mais relevância na composição da eficiência dos países nestes períodos, mas depois recua em 2021-2023 para (0.2235), denunciando uma redução nos

Avaliação do impacto da Inteligência Artificial no emprego Europeu

investimentos privados em IA, decorrente de crises macroeconómicas, saturação em setores que receberam investimentos massivos durante a pandemia, ou a guerra na Ucrânia. No que diz respeito aos valores medianos, disponível para consulta na Tabela 20 do Apêndice 4, a mesma tendência é sempre crescente, com os seguintes valores (0.0666), (0.0711) e (0.0110), com valores bastante abaixo da média, em especial no período 2020–2022, em que a média é quase o dobro da mediana, refletindo a dominância de *outliers* como Suécia (0.6523) e Alemanha (0.5071). No que concerne à variância verificada, a mesma apresenta um valor mais elevado no período 2020-2022 (0.0339), o que mostra que neste período houve grande dispersão, reduzindo depois em 2021-2023 (0.0145), mais uniformização na contribuição do critério para a eficiência, também por via da função de valor que tende a nivelar o impacto entre países.

Apesar da função valor suavizar o impacto de investimentos muito altos, há países como a Suécia, a França e a Alemanha, países com políticas pró-inovação, que valorizam consideravelmente este critério (ver Tabela 6 do Apêndice 2). A Finlândia, os Países Baixos e a Espanha são países com desempenho mais volátil, possível consequência de políticas temporárias de estímulo à IA. Importa ainda destacar que a Bélgica, a Dinamarca e a Estónia ignoraram por completo este indicador.




Figura 4 - Pesos "Private AI Investments"

A Figura 5 relacionada com o indicador “*ICT Workforce Availability*”, exibe os pesos médios e os pesos medianos. Ao analisar os mesmos verifica-se que no caso dos pesos médios, houve uma diminuição progressiva ao longo do tempo (0.2392, 0.2175, 0.1837),

Avaliação do impacto da Inteligência Artificial no emprego Europeu

o que sugere que o critério foi perdendo importância à medida que se avançou no tempo. Já nos pesos medianos são sempre consistentemente superiores aos médios, indicando uma distribuição assimétrica negativa (cauda à esquerda), com alguns países (e.g., França, Grécia e Itália) a arrastar a média para baixo devido à atribuição de pesos nulos neste critério. No que concerne à variância, presente na tabela 21 do Apêndice 4, esta mantém-se relativamente constante com um ligeiro aumento no período de 2019-2021 (0.0282) para 2020-2022 (0.0299), período de maior desigualdade entre países, com alguns (e.g., Suécia com 0.5636) tendo pesos muito altos, enquanto outros têm pesos nulos (e.g., França e Grécia com 0.0000), de acordo com a Tabela 7 no Apêndice 2. Este fenómeno pode estar ligado a efeitos da pandemia, pois países com infraestrutura digital resiliente (e.g., Suécia e Estónia) mantiveram altos níveis, enquanto outros sofreram com o desemprego ou migração de talentos e depois na recuperação pós pandemia em países que tinham pesos nulos.

Assim, temos países como Irlanda, Suécia e Estónia que beneficiam deste critério consistentemente, sugerindo que suas estruturas de força de trabalho tradicional em ICT favorecem a transição para IA. Outros países (e.g. França, Grécia, Itália) não o usam, e dão maior importância a outros critérios.

O que demonstra que a concentração de força de trabalho em IA foi um *output* chave na sua tentativa de justificar eficiência. Este comportamento está alinhado com a escolha da função de valor, que reduz propositadamente o peso do critério, deixando que apenas em situações onde ele é altamente relevante para a eficiência, seja selecionado com peso significativo.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 5 - Pesos "ICT Workforce Availability"

A Figura 6 é representativa do indicador “*AI Workforce Concentration*” e faz notar os pesos médios e medianos. Iniciando a análise pelos pesos médios, verifica-se uma a média dos pesos desceu, em particular da primeira para a última janela (0.1382, 0.0895), o que apesar da função de valor ser quadrática, favorecendo valores altos, o critério foi perdendo destaque comparativamente a outros fatores. Já nos pesos medianos temos que são quase nulos nas três janelas, ou seja, este critério só foi realmente importante para um subconjunto muito pequeno de países, como a Finlândia e o Luxemburgo, enquanto 11 dos 20 países atribuíram peso nulo a este critério (ver Tabela 8 no Apêndice 2). No que concerne à variância, presente na Tabela 22 do Apêndice 4, esta é muito elevada, em especial nas duas primeiras janelas, corroborando o facto de alguns países atribuírem pesos muito elevados, mas a maioria ignora ou atribui pesos residuais a este critério.

Quanto aos *outliers*, os mesmos são visíveis a partir do segundo período temporal, com a presença da Alemanha, Luxemburgo e da Finlândia. Já a janela 2021-2023, conta com a Alemanha e o Luxemburgo.

Assim, temos países como a Finlândia e o Luxemburgo com pesos altos neste critério, o que demonstra que uma força de trabalho concentrada em IA tem sido o determinante de eficiência.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 6 - Pesos "AI Workforce Concentration"

A Figura 7 é elucidativa do indicador “*AI Hiring Trends*”, e de entre outras dados estatísticos, contém os pesos médios e os medianos. Ao analisar os mesmos, e encetando a análise pelos pesos médios temos valores elevados e crescentes da primeira janela temporal, 2019-2021, (0.3231), para a última janela, 2021-2023, (0.4131) o que indica uma valorização crescente do critério consistente com a prioridade atribuída à função de valor. Quanto aos pesos medianos, estes são superiores aos dos pesos médios, sendo na última janela de (0.4729), o que significa que metade dos países atribuem mais de 47% do peso total a este critério. Relativamente à variância, que consta no Apêndice 4 (Tabela 23), registou um aumento gradual em todas as janelas temporais, pois iniciou a (0.0151), de seguida passou para (0.0218) e terminou entre 2021-2023 em (0.0232). O aumento da variância consistentemente ao longo do tempo, revela que apesar da média crescente, a disparidade entre os países também aumenta.

No que concerne aos *outliers*, importa somente destacar a Estónia que surge na primeira janela temporal, 2019-2021.

Verificando o detalhe dos países no que concerne ao presente fator, a maioria apresenta pesos superiores a 0.3 em todas as janelas, com muitos casos acima de 0.4. Alemanha, Finlândia e Eslovénia no decurso das janelas temporais presentes em análise apresentam maior relevância neste fator, o que confirma a forte influência deste critério com o tempo,

Avaliação do impacto da Inteligência Artificial no emprego Europeu

provavelmente devido à intensificação da procura por profissionais em IA no espaço europeu.



Figura 7 - Pesos "AI Hiring Trends"

A Figura 8 expõe os pesos médios e medianos associados ao indicador “*Contributions to Open IA Projects*”. Nos pesos médios atribuídos ao presente fator são relativamente baixos ao longo das três janelas, mas verificam-se oscilações nos diversos períodos temporais, sugerindo que apenas alguns países atribuem importância significativa a este critério em janelas específicas, puxando a média para cima. A Alemanha atribui peso 1 (máximo) a este critério enquanto 12 dos 20 países têm peso nulo (ver tabela 10 no Apêndice 2). Relativamente aos pesos medianos a primeira janela temporal, 2019-2021, regista um valor 0 e nas restantes um valor muito baixo o que reforça a observação de que este critério não é muito escolhido como determinante de eficiência na generalidade dos países. Já a variância, disponível para visualização no Apêndice 4 (Tabela 24), apresenta o valor mais alto na primeira janela (0.0537) 2019-2021 (consequência do *outlier* Alemanha), reduzindo nas restantes. A Estónia e a Letónia mostram estabilidade neste critério, mas a Finlândia e o Luxemburgo desvalorizam este critério com o passar do tempo, o que pode sugerir que este critério perdeu competitividade relativa ou foi substituído por outros mais importantes na eficiência do país. Este critério é marginal para a maioria dos países e a sua função de valor logarítmica e explicação associada (benefício de longo prazo, menor impacto imediato no emprego) estão alinhadas com o seu comportamento empírico.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 8 - Pesos "Contributions to Open AI Projects"

3.3.3 Hierarchical Clustering

Para esta secção foi utilizado o *Hierarchical Clustering* é um método de agrupamento que organiza os dados numa estrutura hierárquica, sendo frequentemente representado por um dendrograma. Este diagrama em forma de árvore mostra visualmente como os elementos se vão agrupar com base na sua semelhança. A estrutura permite observar os diferentes níveis de agregação e facilita a identificação de grupos com características comuns. Este tipo de análise ajuda a interpretar relações de proximidade entre elementos de forma intuitiva. A sua construção baseia-se em medidas de distância e em métodos de ligação como o *single*, *complete* ou *average linkage*. Para determinar o número ótimo de *clusters*, a representar no dendrograma, foi utilizado o método do cotovelo, cuja representação é apresentada na Figura 9, revelando que o corte ideal corresponde a três *clusters*.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 9 - Método do Cotovelo

De acordo com a Figura 10 é possível observar três *clusters*. No primeiro *cluster* estão integrados a Áustria, Bélgica, Dinamarca, Estónia, Grécia, Hungria, Irlanda, Itália, Lituânia, Polónia, Portugal e Eslovénia. O segundo *cluster* é formado Letónia, Luxemburgo, Países Baixos e Espanha. Quanto ao terceiro *cluster* é constituído pela Finlândia, França, Alemanha e Suécia. A sua elaboração baseou-se nos *scores* obtidos através do modelo DEA, previamente aplicado.




Figura 10 - Dendrograma

Relativamente à Figura 11, a mesma apresenta a trajetória média dos três *cluster* determinados pelo método do *Hierarchical Clustering*. Observa-se que os países

Avaliação do impacto da Inteligência Artificial no emprego Europeu

pertencentes ao *cluster* 3 apresentam melhores resultados de eficiência face aos demais. Pois iniciam com um *score* na primeira janela, 2019-2021 de (-0.044), segue a janela temporal, entre 2020-2022 com um *score* de (-0.066), e termina no período de 2021-2023 com o *score* a fixar-se (-0.049). É o grupo globalmente mais eficiente, que mantém o melhor desempenho médio, o que sugere uma maior coerência entre os fatores em análise e eventuais estratégias mais eficazes na transição para uma economia de IA.

Quanto ao *cluster* 2 verifica-se uma tendência de aproximação à eficiência. Ou seja, entre 2019-2021 tem um *score* de (0.107), que passa para (0.072) e termina na janela temporal de 2021-2023 com (0.037), ainda assim é considerado um *cluster* ineficiente. Embora a tendência sugira que os países pertencentes ao *cluster* têm vindo a adotar políticas de IA, embora ainda insuficientes.

Quanto ao *cluster* 1, verifica-se uma tendência de crescimento de *score*, pois o mesmo entre 2019-2021 apresenta o valor de (0.107), o mesmo que o *cluster* 2, que posteriormente passa para (0.134), o que desde logo denota ser ineficiente, e termina no período temporal de 2021-2023 com uma ligeira subida para (0.137). Este é o *cluster* menos eficiente, com *scores* somente positivos, o que indica ineficiência relativa, revelando uma clara tendência de estagnação ou deterioração, sem recuperação nos últimos períodos. Os países deste *cluster* poderão ter problemas comuns de execução de políticas de IA.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 11 - Trajetória Média por Cluster

Aferindo as trajetórias por figura, como é o caso da Figura 12, os países pertencentes ao *cluster* 1, apresentam *scores* muito idênticos ao longo das várias janelas temporais, sendo que a tendência indica uma distância crescente da eficiência com o passar da janelas. Analisando a Hungria e a Itália, países que se distanciam dos restantes, verifica-se que no caso da Hungria obtém o pior *score* de eficiência no período de 2020-2022, com o valor a fixar-se em (0.221), e que no ponto de partida da análise, ou seja, no período de 2019-2021, apresentava igualmente o resultado mais fraco, cifrado em (0.190). Relativamente à Itália, é o país com *scores* mais perto da eficiência, no entanto apresenta ainda *scores* positivos, e com tendência crescente, (0.015), (0.022) e (0.028), respetivamente.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 12 - Trajetória Cluster 1

No que concerne à Figura 13, relativa às trajetórias dos países do *cluster 2*, verifica-se que o comportamento das 4 linhas, pertencentes à Letónia, Espanha, Países Baixos e Luxemburgo, seguem tendência voltadas para eficiência semelhante ao longo dos vários períodos, no entanto, com *scores* diferentes. Relativamente à Espanha e aos Países Baixos, países com *scores* mais aproximados ao longo do período, verifica-se um aproximar dos *scores* para valores negativos, ou seja, para a eficiência. Ambos os países, iniciam com um valor de (0.091) e (0.042), na primeira janela temporal e terminam no período de 2021-2023, com um valor de (0.079) e (0.018). O que indica uma ligeira melhoria dos *scores*. Relativamente a Letónia, país mais distante dentro do *cluster* da fronteira de eficiência, obtém o resultado mais perto dessa fronteira no período de 2021-2023, com o valor a fixar-se em (0.296), tendo iniciado aproximadamente a (0.340). Quanto ao país com melhor *score*, o Luxemburgo, verifica-se que desde a primeira janela temporal até à última teve um desempenho cada vez mais eficiente, tendo iniciado com um *score* de (-0.049) na primeira janela, no segundo período com (-0.174) e (-0.247) na última janela temporal, 2021-2023.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 13 - Trajetória Cluster 2

Relativamente ao *cluster 3*, presente na Figura 14, verifica-se a existência de eficiência na maioria dos países, exceção feita à França, que nas três janelas temporais aquela que mais se aproxima da eficiência é o período entre 2020-2022, com um valor de (0.040) e com o pior resultado a ser obtido na janela seguinte, 2021-2023, com (0.052). Relativamente aos restantes países, Finlândia, Alemanha e Suécia, em todos os períodos são eficientes. Com destaque para o período de 2020-2022, onde atingem o seu máximo de eficiência, (-0.035), (-0.094) e (-0.174), respetivamente. Sendo que após esse período os resultados pioram, embora ainda sejam considerados países eficientes. Para este grupo de países o período pandémico, que é coincidente com a janela temporal em que apresentam maior eficiência, teve impacto positivo no seu desempenho.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 14 - Trajetória Cluster 3

De uma forma mais pormenorizada é possível consultar no Apêndice 5 as métricas que compõem os *clusters* nas várias janelas temporais.

De acordo com a Figura 15, é possível verificar a distribuição geográfica por *cluster*, reforçando a ideia de que não há uma divisão geográfica clara entre países eficientes e ineficientes, mas sim diferenças estratégicas e estruturais.

Por exemplo, o *cluster* 1 e 2, inclui países de várias divisões geográficas europeias, o que sugere que eficiência não depende da região, mas da forma como os recursos e políticas são articulados; o *cluster* 3, inclui países com elevada capacidade económica, e com a economia desenvolvida no seu país.




Figura 15 - Distribuição geográfica por cluster

3.3.4 Análise dos pesos por clusters

De forma a avaliar o desempenho dos três *clusters* nos diferentes indicadores, foi realizada uma análise em formato de *boxplot* que será apresentada a seguida.

Relativamente ao indicador “*AI Research Productivity*”, recordando o mesmo indica rendimentos marginais decrescentes: quanto mais investigação se produz, menor o ganho adicional em termos de emprego em IA, verifica-se de acordo com a Figura 16 e com as métricas presentes no Apêndice 6 na Tabela 27, que no *cluster* 1, apesar das medianas baixas e próximas de zero entre (0.1674) e (0.2019), as médias apresentam-se relativamente elevadas, entre (0.1428) e (0.1579). Esta função é fundamental para não premiar cegamente altos volumes de investigação, mas sim o uso eficiente e produtivo dessa investigação em termos de emprego. A variância situa-se entre (0.0140) e (0.0152), refletindo uma dispersão significativa dos dados, i.e., indica instabilidade na relação num grupo heterogêneo e assimétrico de países.

O *cluster* 2, os valores centrais mantêm-se muito baixos, com medianas próximas de zero e médias entre (0.1185) e (0.1258), sem registo de *outliers*, evidenciam menor variação e menor influência do fator no *score* de eficiência. Nenhum país se destacou particularmente neste indicador, pelo que o modelo lhe atribuiu um peso relativo inferior, concentrando-se provavelmente noutros fatores. A variância, entre (0.0190) e (0.0214),

Avaliação do impacto da Inteligência Artificial no emprego Europeu

demonstra maior uniformidade entre os países deste grupo. Já o *cluster* 3 apresenta medianas muito similares, entre (0.2232) e (0.2435), enquanto as médias embora com valores próximos, oscilam mais comparando os dois primeiros períodos (0.2204) e (0.2257), com o último período temporal (0.1857), acompanhadas por uma variância irregular que varia entre (0.0045) e (0.0085). A presença da Alemanha como *outliers* no último período justifica a assimetria da distribuição com valores extremos a influir os resultados.




Figura 16 - Pesos por cluster "AI Research Productivity"

No que concerne ao indicador “*AI Talent Migration Trends*”, que apresenta melhores valores para os países que atraem talentos, nos *boxplots* na Figura 17 pode concluir-se a par da Tabela 28 no Apêndice 6, que no *cluster* 1, as medianas variam entre valores perto de 0, de (0.0730 a 0.1697), com médias que oscilam entre (0.0730 e 0.1697), sugerindo que o fator X_2 tem um impacto significativo na eficiência destes países. A queda da mediana no período 2020-2022 pode refletir o impacto da pandemia na mobilidade internacional. O mínimo varia entre (0.0000 e 0.0641), e o máximo oscila entre (0.3064) e (0.4111). A variância situa-se entre (0.0043 e 0.0156), indicando uma dispersão ainda que moderada dos dados, sublinhada pela presença de Itália como *outlier* nos dois últimos períodos temporais.

O *cluster* 2, as medianas situam-se entre (0.1779 e 0.2818), com médias entre (0.2177 e 0.3139), ligeiramente mais altas que no *cluster* 1, sugerem que a migração de talentos tem

Avaliação do impacto da Inteligência Artificial no emprego Europeu

um papel mais determinante na eficiência. O mínimo varia de (0.1253 a 0.2646), e o máximo é ligeiramente superior ao do *cluster* 1, oscilando entre (0.3716 e 0.4275). A variância apresenta-se, com valores entre (0.0588 e 0.0640), indicando variações na dispersão dos dados conforme o período, corroborada pela presença constante do Luxemburgo como *outlier*. O *cluster* 3 apresenta valores médios e medianos perto de 0, com medianas entre (0.0000 e 0.2178) e médias entre (0.0989 e 0.2313). O mínimo mantém-se constante a 0, enquanto o máximo varia entre (0.3954) e (0.4897). A variância não apresenta muitas oscilações, entre (0.0358) e (0.0406), demonstrando menor dispersão em relação aos outros *clusters*, ou seja, os países têm comportamentos semelhantes na atração de talentos. De notar, ainda, a presença de *outliers*, na janela temporal de 2021-2023, por parte da França.




Figura 17 - Pesos por cluster "AI Talent Migration Trends"

No que respeita ao indicador “*Private AI Investments*” de acordo com a Figura 18 e com as métricas presentes no Apêndice 6 na Tabela 29, é possível aferir que no *cluster* 1, os valores medianos são 0 nos dois primeiros períodos, enquanto que no último período, 2021-2023, o valor passa para (0.0511), indicando que, embora o *cluster* tenha começado com baixa relevância de X_3 , o último período mostra uma viragem, relativamente aos pesos médios, os valores obtidos são relativamente constantes, pois variam entre (0.0572) e (0.0662), já a variância vai de (0.0036) a (0.0083). Com estes resultados percebe-se que

Avaliação do impacto da Inteligência Artificial no emprego Europeu

o presente fator não teve muita contribuição para a obtenção de eficiência dos países em questão.

No *cluster 2*, as medianas tendem aumentar entre (0.0734) e (0.1332), o mesmo acontece com a média dos pesos (0.0748) para (0.1228) e por fim, no último período (0.1205), do segundo para o terceiro período existe uma queda, embora pouco significativa, assim a tendência de importância deste fator dentro do *cluster* com o passar dos anos tem vindo a ter maior relevância. O mínimo inicia em zero e sobe para (0.0240) no último período. A variância oscila entre (0.0049) e (0.0199), indicando que a dispersão dos dados ao longo do tempo. No *cluster 3*, as medianas variam entre (0.1929) e (0.3907), e as médias apresentam oscilações entre (0.2407) e (0.3952). A variância diminui de (0.0596) para (0.0276), sugerindo uma maior concentração dos valores.




Figura 18 - Pesos por cluster "Private AI investments"

No âmbito do indicador “*ICT Workforce Availability*” os resultados obtidos através de *boxplot*, presentes na Figura 19 e de várias métricas estatísticas que podem ser aferidas no Apêndice 6 na Tabela 30 indicam que no *cluster 1*, as variam, entre (0.1917) e (0.2833), enquanto as médias oscilam levemente entre (0.0582) e (0.0619). O mínimo é sempre zero e o máximo diminui de (0.1770) para (0.2833). A variância mostra uma tendência de queda, de (0.0302) para (0.0168), indicando menor dispersão ao longo do tempo. Este *cluster* apresenta somente *outliers* no último período, com a presença da Estónia, Grécia, Hungria, Irlanda e Itália. No *cluster 2*, as medianas apresentam uma tendência de descida, começando em (0.3631), e terminado em (0.2359). As médias

Avaliação do impacto da Inteligência Artificial no emprego Europeu

acompanham esta tendência, com o valor a iniciar em (0.3487) e a finalizar em (0.2034). O mínimo inicia (0.2003) e nos restantes períodos fixa-se a 0. A variância aumenta substancialmente do primeiro para o segundo período, passando de (0.0163) para (0.0300), e diminui para (0.0253) na última janela temporal. Por fim, no *cluster 3*, as medianas apresentam variações entre (0.0881) e (0.2241), enquanto as médias variam, embora ligeiramente entre (0.1850) e (0.1995). A variância apresenta igualmente variações ao longo dos vários períodos de (0.0313) e (0.0706), sugerindo uma dispersão dos dados.




Figura 19 - Pesos por cluster "ICT Workforce Availability"

Outro indicador em análise é referente ao “*AI Workforce Concentration*”, em que foram aplicadas as mesmas métricas que aos indicadores anteriores. Assim, de acordo com a Figura 20 e a Tabela 31 do Apêndice 6, no *cluster 1*, verifica-se que as medianas no primeiro e terceiro período são 0, ao passo que na janela de 2020-2022, existe uma ligeira subida para (0.006). As médias acompanham estes baixos resultados, variando entre (0.0292) e (0.0799), o que sugere que este fator não teve muita relevância para obtenção de eficiência por parte dos países pertencentes ao presente *cluster*. O mínimo mantém-se em zero em todos os períodos, enquanto o máximo diminui de (0.3516) para (0.1193). A variância reduz-se de forma significativa de (0.0198) para (0.0020), indicando menor dispersão dos dados no último período. Há a assinalar a presença de Grécia, Hungria e Lituânia como *outliers* no período de 2019-2021, em 2021-2023, surge novamente a

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Grécia e a Hungria como *outliers* presentes. No que respeita ao *cluster* 2, as medianas descem ao longo dos períodos, de (0.0928) para (0.0590), assim como as médias, que variam entre (0.2278) e (0.1282). O mínimo fixa-se a 0 e o máximo segue a tendência de decréscimo, iniciando a (0.7256) e terminando a (0.3948), perante estes resultados conclui-se que o presente fator tem vindo a ter uma menor relevância para a obtenção de eficiência por parte dos países em causa. A variância acompanha as tendências anteriores de queda de (0.1177), no primeiro período para (0.0346) no último período em análise, o que revela uma menor dispersão dos dados com o passar das janelas temporais. Relativamente ao *cluster* 3, as medianas oscilam entre (0.2061) e (0.2407), com médias próximas, variando entre (0.2238) e (0.2961). O mínimo permanece em zero e o máximo mantém-se relativamente estável, perto de (0.4455) a (0.7724). A variância oscila, entre (0.0335) e (0.0667), o que sugere uma distribuição irregular na perspetiva dos vários períodos temporais.




Figura 20 - Pesos por cluster "AI Workforce Concentration"

Quanto ao indicador “*AI Hiring Trends*”, verifica-se de acordo com a Figura 21 e com as métricas presentes no Apêndice 6 na Tabela 32, que no *cluster* 1, observa-se um aumento progressivo nas medianas, de (0.3818) para (0.4767), refletindo uma tendência crescente na variável analisada. As médias acompanham essa evolução, subindo de (0.3405) para (0.4733), o que sugere uma importância crescente que é dada pelos países que compõem o *cluster* para a obtenção de eficiência. O mínimo cresce de 0 para (0.2478), enquanto o máximo aumenta de (0.4345) para (0.6928). A variância oscila entre (0.0138) para

Avaliação do impacto da Inteligência Artificial no emprego Europeu

(0.0163), indicando maior dispersão nos dados, com a existência de *outliers*, nomeadamente Áustria, Bélgica e Estónia no período entre 2019-2021, Estónia e Lituânia em 2020-2022 e novamente a Estónia a par da Irlanda e Eslovénia na última janela temporal, 2021-2023. Já no *cluster 2*, as medianas apresentam igualmente um comportamento crescente: iniciam em (0.2607), crescem para (0.3106) no segundo período e terminam em (0.4101), em 2021-2023. As médias seguem a mesma tendência, entre (0.2662) e (0.3654). O mínimo varia, tendo um pico de (0.2130) no segundo período e o valor mais baixo em 2019-2021, com (0.1236). A variância é relativamente constante entre (0.0207) e (0.0215), o que sugere alguma dispersão dos dados. Com a visualização do *cluster 3*, denota-se que os valores centrais apresentam uma tendência decrescente, com medianas entre (0.2489) e (0.3895) e médias entre (0.2803) e (0.3281). O mínimo varia entre (0.1250) e (0.1626), e o máximo oscila entre (0.4083) e (0.6070). A variância é reduzida, próxima de (0.0185) a (0.0419), demonstrando baixa dispersão. Os *outliers* identificados são a França, no período de 2019-2021.




Figura 21 - Pesos por cluster "AI Hiring Trends"

Por fim, no indicador “*Contributions to Open AI Projects*” podemos aferir que de acordo com a Figura 22 e a Tabela 33 do Apêndice 6, que no *Cluster 1*, a mediana mantém-se em zero nos em dois períodos, 2019-2021 e 2021-2023 e fixa o valor de (0.0374) no período de 2020-2022. A média não varia muito entre (0.0705) para (0.0877), acompanhada por um comportamento idêntico do máximo, que vai de (0.2607) para (0.2803). A variância apresenta valores baixos, entre (0.0097) para (0.0141), indicando

Avaliação do impacto da Inteligência Artificial no emprego Europeu

uma dispersão reduzida dos dados. O *cluster* 2, indica um pico na mediana de (0.0521) no primeiro período, no seguinte o valor desce até 0, que posteriormente aumenta para 0.0290, ainda assim com valores próximos de 0. Os pesos dos valores médios apresentam igualmente oscilações entre (0.0538) e (0.0898). O máximo e a variância apresentam igualmente variações, o máximo oscila entre (0.2150) e (0.2550), relativamente à variância, a mesma vai de (0.0115) a (0.0145). No que concerne ao *outliers*, importa destacar a presença da Letónia na segunda janela temporal, 2020-2022. Já no *cluster* 3, a mediana apresenta um comportamento idêntico ao *cluster* anterior, ou seja, evolui de (0.1122) para 0 e termina a (0.1937), enquanto a média oscila de (0.0743) para (0.3061). O máximo varia, de 1, no primeiro período a (0.2971), ao passo que a variância mantém-se alternada entre (0.0220) e (0.2251). Foram ainda detetados *outliers*, no período de 2020-2022, com a presença da Alemanha.




Figura 22 - Países por cluster "Contributions to Open AI Projects"

3.3.5 Folgas dos indicadores para a fronteira de eficiência

Por meio da aplicação do método WVBDEA para avaliar o impacto IA no emprego europeu, foi possível analisar dinamicamente o desempenho relativo dos países, permitindo que cada um atribuisse livremente os pesos aos diferentes critérios de avaliação. Com base nos resultados obtidos, identificaram-se padrões de convergência entre os indicadores, que, posteriormente, foram utilizados numa análise de agrupamento

Avaliação do impacto da Inteligência Artificial no emprego Europeu

hierárquico, *Hierarchical Clustering*, permitindo a formação de clusters de países com características semelhantes.

Um dos elementos centrais desta análise foi o estudo das projeções para a fronteira eficiente, ou seja, a identificação dos ajustamentos necessários que cada país (DMU), considerado ineficiente, deverá realizar para atingir o nível de eficiência do alvo escolhido na fronteira. Neste contexto, uma folga igual a 0 s_c^p significa que, relativamente a esse indicador/critério específico, nesse período, o país já se encontra em conformidade com o desempenho de referência, não sendo necessário qualquer ajustamento adicional. Por outro lado, valores de folga compreendidos entre 0 e 1 indicam, na escala de valor, a melhoria exigida nos diversos critérios de avaliação para que o país possa ser considerado eficiente, nesse período. Estas projeções apontam para o desempenho desejado que cada DMU poderia alcançar (DMU virtual), caso ajustasse devidamente os seus fatores, de forma a atingir o nível de desempenho ótimo definido pelas DMUs escolhidas como referência (alvo) na fronteira eficiente.

Com o intuito de proporcionar uma leitura mais clara e comparativa do impacto da IA no emprego europeu em relação às melhorias propostas para os países ineficientes, serão analisados, sobretudo, os valores medianos e médios por janela temporal através de *boxplots* por indicador. Posteriormente, serão também considerados os valores medianos por indicador, mas desta vez organizados por cluster.

De acordo com a Figura 23, que faz referência ao indicador “*AI Research Productivity*” e com a Tabela 48 do Apêndice 9, verifica-se que a ineficiência média aumentou, especialmente na 3ª janela (2021-2023), com alta dispersão entre países. A mediana mais baixa que a média sugere que a maioria dos países tem folgas pequenas, mas alguns *outliers*, nomeadamente a Letónia, na 1ª e 2ª janela, e a Hungria na 2ª janela.

Enquanto a Finlândia e a França estão em melhoria contínua neste critério, pois passam de (0.3030) e (0.0864), respetivamente, no período 2029-2021 para 0 nos dois seguintes, a Áustria e Portugal pioram de forma acentuada, com um aumento muito acentuado (>0.5) no valor do ajustamento na última janela (2021-2023), revelando um possível desalinhamento entre investimento e resultados. De notar ainda que a Letónia é o país que necessita de maior ajustamento neste indicador, pois as folgas são elevadas (>0.5) em

Avaliação do impacto da Inteligência Artificial no emprego Europeu

todas as janelas (ver Tabela 34 do Apêndice 7). Assim, este caso, sugere a necessidade de políticas de incentivo à investigação de longo prazo.




Figura 23 - Folgas "AI Research Productivity"

No que concerne à Figura 24 e à Tabela 49 do Apêndice 9, resultante do indicador, “*AI Talent Migration Trends*” a análise das folgas ao longo das três janelas temporais revela que a média das folgas atingiu seu máximo (0.2072), com variância mais elevada (0.0566), indicando na 2ª janela (2020-2022), podendo esta ter sido devida ao impacto significativo da pandemia na migração de talentos, mostrando uma maior dispersão entre países (alguns foram muito afetados, outros pouco). Houve uma recuperação evidente na janela seguinte (2021-2023), com uma redução da média (0.1167) e da variância (0.0380), sugerindo adaptação aos novos padrões de mobilidade pós-pandemia a possível implementação de políticas de atração de talentos. A assimetria à direita, com a mediana sempre inferior à média, indica que poucos países concentram folgas elevadas, enquanto a maioria apresenta valores baixos. De realçar que o Luxemburgo, não sendo eficiente no ano 2019 (ver Tabela 5 do Apêndice 2), resolveu completamente a ineficiência nos anos seguintes, passando de uma necessidade de ajustamento na 1ª janela de (0.5692), para 0 nas janelas seguintes (ver Tabela 35 do Apêndice 7). Já a Irlanda e Portugal emergiram neste critério. O único país com necessidades crescentes, ao longo das três janelas, de melhoria neste critério é a Estónia, provavelmente porque concorre com os países nórdicos por talentos. A Lituânia, por exemplo, mostrou uma melhoria impressionante neste critério, passando de (0.5789) para (0.0249).

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 24 - Folgas "AI Talent Migration Trends"

Quanto à Figura 25 e à Tabela 50 do Apêndice 9, que dizem respeito ao indicador “*Private AI Investments*” pode aferir-se uma tendência de agravamento progressivo das necessidades de ajustamento por parte de vários países, sugerindo uma maior distância relativamente à fronteira eficiente, em cada período. Os resultados demonstram uma redução progressiva da ineficiência, dado que a média diminui de (0.2392) na janela de 2019-2021, para (0.2294) na janela de 2020-2022, passando para (0.1438) na janela 2021-2023. Sendo a mediana bastante próxima da média, a distribuição é relativamente simétrica, exceto na janela 2019-2021, onde os *outliers* puxam a média para cima (Suécia e Finlândia). A redução da variância para praticamente metade (0.051 na 1ª janela e 0.016 na última janela), indica que, para o fator em análise, os países estão a convergir na eficiência relativa. No entanto, países como a Irlanda e a Finlândia surgem como *outliers*, sinalizando situações específicas de menor desempenho. A Finlândia faz uma correção exemplar das ineficiências neste critério da 1ª para a segunda janela, passando de (0.5989) para 0 de necessidade de melhoria. Na Tabela 36 do Apêndice 7, a Finlândia de 2019 para 2020 passa do estado de ineficiente para o estado de eficiente, corroborando a necessidade de ajustamento em alguns critérios. A Irlanda faz um movimento inverso nas mesmas janelas, passando de (0.4586) para (0.7875), piorando consideravelmente e agravando a necessidade de ajustamento. É evidente que os países nórdicos fizeram investimentos corporativos em IA e devem manter os fluxos de investimento, outros há que diversificar as fontes de financiamento, como o caso Portugal que retrocedeu com necessidades maiores de ajustamento.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 25 - Folgas "Private AI Investments"

Relativamente ao indicador “*ICT Workforce Availability*” representado na Figura 26 e na Tabela 51 do Apêndice 9, é possível constatar a existência de uma tendência clara de aumento gradual das necessidades de ajustamento por parte dos países analisados de 2019-2020 para 2020-2021 traduzindo um possível impacto da pandemia no que toca à disponibilidade de mão de obra qualificada em IA/ICT, que já era escassa nos países do Leste Europeu, como se pode verificar na Tabela 37 do Apêndice 7 tanto na Letónia, como na Lituânia, em 2019 e 2020. A transição acelerada para um trabalho remoto poderá ter criado desequilíbrios regionais. Nesta mesma janela de 2020–2022, a variância é mais alta (0.0191) indicando uma maior desigualdade entre países e a mediana (0.1797) fica muito próxima da média (0.1832), mostrando uma distribuição quase simétrica durante o pico pandémico. A média diminui na janela seguinte, com a adaptação a novos modelos de trabalho, destacaram-se a Áustria, a Suécia e o Luxemburgo, que minimizam ou anulam por completo a ineficiência neste critério. No entanto, a Grécia, apesar de já apresentar deterioração no pico pandémico, não consegue uma boa recuperação, sendo o país que em 2022 surge com a necessidade de maior ajustamento (0.6771 - Tabela 44 do Apêndice 8).

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 26 - Folgas "ICT Workforce Availability"

No que respeita ao indicador “*AI Workforce Concentration*” a Figura 27 e a Tabela 52 do Apêndice 9, evidenciam um aumento das necessidades de ajustamento ao longo os anos, com a mediana consistentemente próxima ou superior à média. A variância quase que triplicou da 1ª para a última janela (0.0128 para 0.0391), indicando uma maior dispersão entre países, o que sugere a existência de dois grupos distintos de países com concentração estável de força de trabalho (folgas baixas) e com países com problemas estruturais (folgas altas). A ineficiência não apenas persiste, mas agrava-se no período pós pandémico (2021-2023), com uma variância particularmente alta. De acordo com a Tabela 38 no Apêndice 7, verifica-se que na janela temporal de 2019–2021, os resultados já são bastante críticos, nomeadamente no Leste Europeu e países Bálticos (folgas >0.3), verificando-se na janela seguinte que a ineficiência neste critério se agrava com sete países mantendo folgas acima de 0.3, comparativamente à janela anterior. A Estónia (0.4239), a Bélgica (0.3183) e a Dinamarca (0.3281), emergem como novos casos críticos. Na última janela a Letónia agrava mais ainda a sua situação, destacando-se como sendo o país que mais necessita de ajustamento, pois a folga atinge (0.6273) neste período, mas a Bélgica, a Polónia, Portugal e Espanha também ultrapassam 0.4 em termos de necessidade de alteração neste critério. São países que têm que implementar com urgência programas de retenção de talentos e replicar políticas de atração de multinacionais dos países *benchmark* (Alemanha e Suécia). Contrariamente a este fenómeno, a Hungria mostra uma melhoria acentuada passando de (0.3432) para (0.0240) da 2ª para a 3ª janela e a França que vai melhorando gradualmente desde o primeiro período até ao último.




Figura 27 - Folgas "AI Workforce Concentration"

Quanto à Figura 28 e à Tabela 53 do Apêndice 9, que evidenciam os resultados do indicador “AI Hiring Trends” revelam uma trajetória claramente positiva no sentido da eficiência, com uma redução significativa das necessidades de ajustamento ao longo do tempo.

No período temporal de 2019–2021, os valores mais elevados para a média, sugerindo maior variabilidade dos dados. A mediana relativamente estável das duas primeiras janelas e diminui na 3ª janela é (0.1159), alinhando-se com a tendência da média. A diferença entre a média e a mediana na janela 2019-2021 (0.1908 vs. 0.1215). A variância diminui consideravelmente da 1ª para a 2ª janela (0.021 para 0.01), refletindo menos dispersão nos dados. Na 3ª janela há um ligeiro aumento (0.012), possivelmente devido a casos como Eslovénia, Grécia ou Hungria, que apresentam valores altos. Estes resultados indicam que a maioria dos países reduz folgas ao longo do tempo, indicando melhoria neste critério. No entanto, há países em que a necessidade de ajustamento aumenta, ou permanece alta, nomeadamente a Hungria e a Grécia, ou a Eslovénia em que a folga neste critério dispara na última janela, possivelmente devido a fatores externos.

Avaliação do impacto da Inteligência Artificial no emprego Europeu



Figura 28 - Folgas "AI Hiring Trends"

Por fim, as folgas do último indicador “*Contributions to Open AI Projects*”, representadas na Figura 29 e na Tabela 54, do Apêndice 9, mostram um aumento de níveis de ineficiência ao longo do tempo, embora com uma ligeira oscilação nos valores médios e medianos da janela 2020-2022. Portanto, em termos agregados podemos afirmar que a eficiência na contribuição para projetos Open AI piorou em 2020-2023, na medida em que quer a média, quer a mediana aumentaram neste período. O aumento generalizado destas medidas estatísticas no período 2020-2023 evidencia o aumento das ineficiências em vários países (Áustria, Bélgica, Letónia, Polónia, Portugal e Espanha), o que pode refletir mudanças na dinâmica da contribuição para Open AI (cortes no investimento ou na participação em projetos). Contudo, existem casos de melhoria, como a Finlândia ou a Grécia (mas mínima).




Figura 29 - Folgas "Contributions to Open AI Projects"

3.3.6 Folgas dos indicadores para a fronteira de eficiência por *clusters*

Dando continuidade à secção anterior, a análise foi realizada através da alocação dos países aos respetivos *clusters*, definidos com recurso à técnica de *Hierarchical Clustering*. A interpretação dos resultados será feita com base em *boxplots*, sendo sustentada pelos dados apresentados no Apêndice 10 – “Estatística descritiva das folgas dos *clusters* por indicador”.

Com o objetivo de avaliar as folgas dos três *clusters* nos diferentes indicadores, foi realizada uma análise em formato de *boxplot* que será apresentada a seguida.

Assim, foi inicialmente analisado as folgas do indicador “*AI Research Productivity*”, pelo que de acordo com a Figura 30 e a Tabela 55, presente no Apêndice 10, o *cluster 1* revela uma trajetória de alternância ao longo das três janelas temporais. A mediana, que era de (0.0425) em 2019–2021, reduz-se para (0.0930) na janela seguinte e termina com (0.3392), acompanhada por uma igual alternância da média, que passa de (0.0930) para (0.1132) e (0.2827), e da variância, que oscila entre (0.0152) e (0.0424). É de referir a presença da Hungria e Eslovénia como *outliers* na segunda janela temporal, 2020-2022. O *cluster 2* apresenta um desempenho globalmente estável. As medianas não distam muito de (0.1000) ao longo da análise. Já as médias, apresentam uma tendência crescente ao iniciar a (0.1786) e a terminar em (0.2369), relativamente à variância, a mesma varia entre (0.0519) e (0.0912), o que reflete heterogeneidade interna. Como *outliers*, há a assinalar a presença da Letónia na janela de 2020-2022. Por sua vez, o *cluster 3* apresenta uma mediana de (0.0432), uma média de (0.0973), um máximo de (0.3030) e uma variância de (0.0204), no primeiro período temporal, ao passo que nos restantes todos os valores são 0, ou seja, os países pertencentes ao presente *cluster* não necessitam de melhoramento neste fator para a obtenção da sua eficiência.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 30 - Folgas por cluster "AI Research Productivity"

Relativamente ao indicador “AI Talent Migration Trends”, a Figura 31 e a Tabela 56 do Apêndice 10, mostram que no caso do *cluster 1* o mesmo apresenta medianas com valores crescente de (0.0145) a (0.0452), ao passo que os valores das folgas médias oscilam entre (0.1266) e (0.3168), sugerindo pequenas variações no desempenho global. A variância irregular, entre (0.0349) e (0.0613), e a Estónia surge como *outlier* na primeira e última janela temporal. Já o *cluster 2* demonstra uma necessidade de melhoria dos países do *cluster* com o passar dos períodos, pois o valor mediano inicia a (0.1616) e termina a (0.0438). As médias são ainda mais altas que o valor das medianas, variando entre (0.0700) e (0.2372) ao longo das três janelas. A variância é relativamente reduzida, oscilando entre (0.0104) e (0.0537), o que confirma a homogeneidade interna e a consistência do desempenho deste grupo de países, existindo ainda a Letónia como *outlier* nos dois últimos períodos temporais. Por fim, o *cluster 3* apresenta valores ligeiramente reduzidos face aos anteriores. As medianas variam entre (0.0007) e (0.0246), enquanto as médias de (0.0156) e (0.0307). A variância é praticamente nula em todas as janelas com o pico de (0.0013), o que mostra estabilidade no grupo, apesar da presença a França como *outlier* nos dois primeiros períodos.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 31 - Folgas por cluster "AI Talent Migration Trends"

No que concerne ao indicador “*Private AI Investments*”, presente na Figura 32 e na Tabela 57 do Apêndice 10, verifica-se que no *cluster 1* a mediana tem uma tendência crescente, pois na primeira janela é de (0.1475) e na última é de (0.2132), já as folgas médias apresentam um comportamento oscilante entre subidas e descida na comparação das janelas temporais, os valores oscilam entre (0.1673) e (0.2600). A variância presente, embora que baixa, atinge o pico entre 2020-2022, com o valor de (0.0461). O *cluster 2* evidencia uma tendência decrescente de valores, o que denota que com o passar dos anos os países estão perto de atingir os seus valores ótimos de eficiência. A mediana começa com (0.2934) e termina com (0.0498), no período em análise, já as médias assumem comportamento igual, com (0.3023) e a terminar com (0.1049). Quanto à variância, a mesma é marcada pela irregularidade, com o pico em 2019-2021 (0.0490) e o mínimo em 2020-2022 (0.0159). O *cluster 3* destaca-se por apresentar valores mais elevados e mais irregulares. A mediana desde de (0.3621) em 2019–2021 para (0.0570) em 2020–2022 e depois sobe para (0.0584) em 2021–2023. A média atinge o pico de (0.3918) na primeira janela, 2019-2021, com uma variância máxima de (0.1569), em igual período. A Suécia destaca-se como *outlier* entre 2020-2022.

Avaliação do impacto da Inteligência Artificial no emprego Europeu




Figura 32 - Folgas por cluster "Private AI Investments"

Relativamente ao indicador “ICT Workforce Availability” de acordo com a Figura 33 e Tabela 58 do Apêndice 10, constata-se que o *cluster 1* apresenta uma evolução alternada. Nas três janelas, as medianas oscilam os seus valores entre (0.1022) e (0.1958), ao passo que as médias assumem igual comportamento, com o valor máximo e (0.2443), na segunda janela temporal e o mínimo de (0.1164), na primeira janela temporal. O que denota que os países em causa apresentam mais condições para melhorar a sua eficiência neste indicador no período pandémico, 2020-2022. A variância é igualmente maior no período referido anteriormente, com o valor a fixar-se em (0.0176). A Grécia surge como *outlier* no último período temporal, 2021-2023. O *cluster 2* regista um padrão similar ao anterior. Com medianas a oscilarem entre (0.0850) e (0.1484), assim como as médias que vão desde (0.1167) a (0.1937), a conclusão a retirar é igual à anterior, em que os países, agora deste *cluster*, têm espaço para melhorar no período pandémico. Na variância importa destacar o elevado valor tido entre 2019-2021, (0.0368), face ao menor, obtido na janela temporal seguinte com (0.0092). Há ainda a registar a presença da Letónia como *outlier* na primeira janela temporal. Já o *cluster 3* apresenta, novamente um padrão ambíguo, não seguindo uma tendência. Entre 2019–2021, a mediana era (0.0458) e a média (0.0810), no período de 2020–2022, sobem para (0.0690) e (0.1111), respetivamente, com a variância a atingir o seu máximo, com o valor de (0.0082). Na última janela temporal 2021–2023, os valores caem para (0.0551), média de (0.0627). À luz dos últimos resultados face à janela anterior verificou-se um melhoramento, ou seja,

Avaliação do impacto da Inteligência Artificial no emprego Europeu

os países aproveitaram mais este fator para cálculo da sua eficiência. A França destaca-se como *outlier* na última janela temporal, 2021-2023.




Figura 33 - Folgas por cluster "ICT Workforce Availability"

Quanto ao indicador “*AI Workforce Concentration*” representado na Figura 34 e na Tabela 59 do Apêndice 10, verifica-se que o *cluster 1* apresenta uma evolução algo desigual. Pois existem oscilações de valores medianos entre (0.1983) e (0.3232), ao passo que nos valores médios, a mesma situação é verificada, entre (0.1737) e (0.3009), sendo que, os valores mais elevados situam-se entre o período de 2020-2022, período coincidente pandémico, em que perante os valores os países em questão têm ainda mais espaço para melhorar a sua eficiência face aos restantes períodos. Relativamente à variância, a mesma é perto de 0, exceção feita entre 2021-2023, com o valor a fixar-se em (0.0243). Os países *outliers* a registarem são a Grécia e a Eslovénia, na segunda janela temporal, 2020-2022. O *cluster 2* em todo igual ao anterior. Com as medianas a oscilarem entre (0.1311) e (0.2455) e com as médias entre (0.1720) e (0.2796), no entanto a distinção feita relativamente ao anterior é que os países deste *cluster* têm mais oportunidades de ajustamento do seu *score* no período entre 2021-2023. Em igual período é quando se regista a maior variância (0.0910). Importa destacar a Letónia como *outlier* entre 2019-2021. Quanto ao *cluster 3*, apresenta um novamente igual aos vários *clusters* deste fator. Em 2019–2021, a mediana é de (0.0400) e a média de (0.0772), na janela seguinte, 2020–2022, existe um decréscimo, com a mediana a fixar-se a (0.0324) e uma média de

Avaliação do impacto da Inteligência Artificial no emprego Europeu

(0.0575). A diferença face aos *clusters* anteriores, é que a mediana em 2021–2023, fixa-se a 0, enquanto que a média é de (0.0394), sendo registada a maior variância com (0.0062). A França surge como *outlier* no último período.




Figura 34 - Folgas por cluster "AI Workforce Concentration"

No que respeita ao indicador “*AI Hiring Trends*”, a Figura 35 e a Tabela 60 do Apêndice 10, demonstram que no *cluster* 1, verifica-se uma redução nas necessidades de ajustamento ao longo do tempo. Em 2019–2021, a mediana é (0.2713), com uma média de (0.2608) e uma variância de (0.0191), revelando um afastamento considerável da fronteira eficiente. Nas janelas seguintes, os valores descem significativamente: em 2020–2022, a mediana é (0.1700) e a média reduz-se para (0.1623), entre 2021–2023, os valores mantêm-se baixos, com mediana de (0.1459) e média de (0.1785). O *cluster* 2 novamente um comportamento de redução de necessidades de ajustamento com o passar das janelas temporais. Em 2019-2021 com mediana de (0.0981), média de (0.1345). Na janela temporal seguinte, a mediana baixa para (0.0137), bem como a média, que passa para (0.1286), por fim, entre 2021-2023, a mediana é de (0.0091), e a média cifra-se em (0.0500). A variância apresenta igualmente uma tendência decrescente ao longo das várias janelas, com valores entre (0.0083) e (0.0032). Há a notar a presença da Letónia como *outlier*, entre 2019-2021.

Por outro lado, o *cluster* 3 é o que regista os melhores valores, ou seja, valores 0. Entre 2019–2021, a mediana é de (0.0453) e a média de (0.0371), com uma variância quase nula de (0.0006). Em 2020–2022, a mediana é de 0 e a média para (0.0201), com a

Avaliação do impacto da Inteligência Artificial no emprego Europeu

variância de (0.0016). No período seguinte, 2021-2023, a mediana volta a ser 0 e média a situar-se em (0.0221). Como *outlier* surge a França, nos períodos de 2020-2022 e 2021-2023. Assim, com os resultados obtidos, sobretudo nos últimos dois períodos quase que aproveitam ao máximo este fator para contribuição do cálculo da sua eficiência.




Figura 35 - Folgas por cluster "AI Hiring Trends"

Por fim, no indicador “Contributions to Open AI Projects”. Verifica-se que de acordo com a Figura 36 e a Tabela 61 do Apêndice 10, que o *cluster* 1 apresenta medianas com tendência crescente, o que sugere uma maior necessidade de ajustamento por parte dos países pertencentes ao *cluster* com o passar das janelas temporais. Entre 2019–2021, a mediana é de (0.1481) e a média de (0.1642), com variância de (0.0239). No período de seguinte, 2020–2022, há um ligeiro aumento da mediana para (0.1984), bem como da média para (0.1716) e uma diminuição da variância para (0.0101). Na última janela temporal, 2021–2023, os valores sobem novamente, atingindo o seu pico, pois a mediana situa-se com (0.3030), a média com (0.3216) e a variância com o valor de (0.0507). O *cluster* 2 apresenta valores medianos mais consistentes e elevados, (0.2958), (0.1511) e (0.2821), mas com médias abaixo dos seus valores, (0.2859), (0.2326) e (0.2828). Já a variância apresenta estabilidade com valores entre (0.0516) e (0.0765). Relativamente ao *cluster* 3, o seu comportamento é em todo idêntico ao anterior *cluster*. Entre 2019–2021, a mediana é de (0.0908) e média de (0.1184). Contudo, nas duas janelas seguintes, há um diminuição das medianas, face à primeira janela temporal, para (0.0028) e (0.0110) e da média para (0.0245) e (0.0276), respetivamente. Relativamente ao comportamento da

Avaliação do impacto da Inteligência Artificial no emprego Europeu

variância, o mesmo é oscilante entre (0.0017) e (0.0198). A França é o único *outlier* identificado, ao surgir na janela temporal, 2020-2022.




Figura 36 - Folgas por cluster "Contributions to Open AI Projects"

4 Discussão dos Resultados

A avaliação do impacto da IA no emprego europeu entre 2019 e 2023, com base no método VBDEA e complementada pelo *Hierarchical Clustering*, para definição de *clusters*, revelou a complexidade, diversidade e transformação das dinâmicas empresarias no contexto europeu durante um período fortemente influenciado por alterações pandémicas, económicas e contexto geopolítico. Esta análise foi desenvolvida a partir de sete indicadores, em diversas categorias: produção científica, mobilidade de talento, dinâmica do mercado de trabalho, investimento, e envolvimento colaborativo.

Entre 2019 e 2023, registaram-se transformações profundas no panorama digital, económico e geopolítico da UE, fortemente marcadas por três grandes fatores: a pandemia de COVID-19, a guerra na Ucrânia e a intensificação da corrida tecnológica global. A crise pandémica (2020–2022) teve um impacto estrutural no mercado de trabalho europeu, acelerando a digitalização de setores inteiros, promovendo o teletrabalho e expondo desigualdades nas competências digitais. Esta realidade está refletida no Relatório 2030 UE - Era Digital, onde a Comissão Europeia: Direção-Geral das Redes de Comunicação, Conteúdos e Tecnologias (2023), reconhece que a pandemia “expôs a dependência crítica de tecnologias digitais e acelerou a sua adoção em todos os setores”, mas também acentuou o fosso digital entre cidadãos e empresas, tornando urgente a qualificação massiva da força de trabalho europeia.

Em 2022, esta conjuntura agravou-se com uma nova aceleração das tendências associadas à transformação digital. A rápida evolução tecnológica – com destaque para os avanços da inteligência artificial generativa – somou-se a preocupações sociais e ambientais ligadas às alterações climáticas, ao aumento da procura por conectividade de alta velocidade e à intensificação dos riscos para os valores democráticos da UE. Estes elementos encontram eco no mesmo relatório, que alerta para os riscos geopolíticos crescentes e salienta que o reforço da “soberania digital” europeia é essencial num mundo onde “a corrida pela liderança tecnológica se intensifica” e onde a UE precisa de garantir a sua autonomia estratégica em áreas como IA e cibersegurança. A geopolítica ganhou uma centralidade renovada, tanto pela invasão russa da Ucrânia como pela crescente fragmentação económica e rivalidades estratégicas no plano global, refletindo-se em

Avaliação do impacto da Inteligência Artificial no emprego Europeu

aumentos do custo de vida, ciberataques frequentes e perturbações nas cadeias de abastecimento. Tal como identificado pela Comissão Europeia: Direção-Geral das Redes de Comunicação, Conteúdos e Tecnologias (2023), estes desenvolvimentos reforçam a necessidade de infraestruturas digitais seguras, resilientes e sustentáveis, bem como a proteção da integridade democrática europeia.

Neste cenário volátil, as tecnologias digitais tornaram-se fulcrais na disputa pela liderança económica mundial, com a velocidade e a escala da inovação a influenciar diretamente a competitividade e a soberania digital da UE. Assim, as oscilações verificadas em diversos indicadores que tentam medir o impacto da inteligência artificial no emprego europeu devem ser compreendidas à luz desta confluência de fatores disruptivos – sanitários, tecnológicos e geopolíticos – que moldaram de forma profunda e desigual a transição digital e laboral no espaço europeu.

Ao analisar os *scores* de eficiência em convergência com os *cluster*, a ideia de oscilações dos *scores* é confirmada. Pois, a divisão dos países em *clusters*, com base na similaridade de evolução temporal dos seus *scores* de eficiência, permitiu identificar perfis diferenciados que refletem, de forma direta, o comportamento dos sete indicadores analisados. A utilização para interpretação dos resultados por via da média e da mediana permitiu maior confiança na leitura e interpretação das tendências de cada *cluster*, evitando enviesamento na leitura causada por valores extremos e garantindo, assim, uma análise comparável entre os países de cada *cluster*. Em relação aos pesos e folgas, estes foram interpretados como indicações de prioridades políticas. Pesos elevados refletem critérios determinantes para a eficiência relativa, sugerindo áreas que tiveram intervenção prioritária. Por sua vez, as folgas revelaram os domínios em que cada país apresenta maiores distâncias face à fronteira eficiente, apontando para necessidades concretas de melhoria. Por exemplo, os valores elevados das folgas observados em indicadores relacionados com o desemprego jovem confirmam a relevância de políticas dirigidas à integração dos jovens no mercado de trabalho, em linha com as orientações da Estratégia Europeia para o Emprego e da agenda Europe 2020.

Relativamente aos países pertencentes ao *cluster* 1 (Áustria, Bélgica, Dinamarca, Eslovénia, Estónia, Grécia, Hungria, Irlanda, Itália, Lituânia, Polónia e Portugal), de acordo com Guarascio et al. (2025), A Estónia, Grécia, Hungria, Itália, Eslovénia,

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Lituânia e Portugal enquadram-se como inovadores moderados. Já a Polónia é considerada um inovador emergente. Por outro lado, países como a Áustria e a Irlanda integram o grupo dos inovadores fortes, enquanto a Bélgica e a Dinamarca se destacam como líderes de inovação. Nessa medida, os efeitos da IA no emprego tendem a ser menos pronunciados nestes países, em comparação com os restantes países da UE incluídos na análise.

Ao observar os *scores* de eficiência obtidos por este grupo de países, constata-se uma tendência generalizada de degradação da eficiência ao longo das janelas temporais, para a maioria das DMUs.

No caso da Grécia, país amplamente conhecido pelas dificuldades económicas que enfrenta há vários anos, observou-se um agravamento contínuo da sua *performance* ao longo das janelas temporais, sendo o país que desde o ponto de partida em 2019-2021 mais se distanciou da fronteira de eficiência dentro deste *cluster*. Esta tendência encontra ligação na literatura, que aponta para dificuldades significativas na adoção e captação de IA. Guarascio et al. (2025) confirmam esta realidade ao associar a Grécia nos níveis mais baixos de exposição à IA entre os países da UE.

Outro exemplo relevante é o da Hungria, que apesar de apresentar níveis elevados de ineficiência nas duas primeiras janelas de análise, registou uma ligeira melhora no seu *score*. O estudo de Guarascio et al. (2025) posiciona este país no penúltimo lugar em termos de exposição à IA, apenas à frente da Grécia. Numa possível resposta a esta conjuntura, a Hungria lançou em setembro de 2020 a sua Estratégia Nacional de IA, comprometendo-se com a criação de pelo menos 15 projetos de cooperação internacional em investigação, incluindo dois no domínio da defesa e cinco relacionados com patentes internacionais em IA (Jorge Ricart et al., 2022).

Relativamente à Polónia, Guarascio et al. (2025) identificam igualmente um baixo nível de exposição à IA. No entanto, o financiamento por parte da Comissão Europeia que terá impulsionado o número de agentes de IA no país em cerca de 60%. Este reforço parece refletir-se nos resultados obtidos no fator “*Private AI Investments*”, uma vez que os pesos atribuídos a este indicador foram superiores aos dos restantes países do cluster, influenciando positivamente a sua eficiência.

Avaliação do impacto da Inteligência Artificial no emprego Europeu

No caso da Eslovénia, observa-se uma ligeira inversão da tendência de ineficiência entre 2020 e 2022, embora sem alcançar a fronteira de eficiência. Esta evolução pode estar relacionada com o lançamento do Programa Nacional de IA em maio de 2021, que prevê um investimento público de 110 milhões de euros até 2025 (Jorge Ricart et al., 2022). Tal iniciativa poderá contribuir para o aumento do interesse de investidores privados, o que se confirma pela introdução do fator “*Private AI Investments*” no cálculo da eficiência apenas a partir da janela de 2021-2023.

Portugal, à semelhança da Estónia, é referenciado na literatura por Guarascio et al. (2025) como um dos países onde o impacto da IA no emprego é reduzido e estatisticamente pouco significativo. Reis et al. (2020) destacam, contudo, a forte atividade da comunidade académica portuguesa em investigação na área da IA. Esta realidade é corroborada pelo indicador “*AI Research Productivity*”, que surge como um dos principais fatores para o cálculo da eficiência no caso português. Adicionalmente, o país tem procurado atrair talento internacional através de mecanismos como vistos simplificados para *start-ups* e serviços de via rápida para profissionais de IA (Jorge Ricart et al., 2022). Esta intenção é refletida no indicador “*AI Talent Concentration by Country*”, que teve peso relevante apenas na primeira janela temporal (2019-2021), sendo posteriormente desconsiderado. A Estónia, para além do reduzido impacto da IA no emprego (Guarascio et al., 2025), enfrenta desafios no que respeita à retenção de talento qualificado. De acordo com (Socol & Iuga, 2024), profissionais com competências em IA tendem a migrar para países com economias mais desenvolvidas, o que se reflete no peso crescente do fator “*AI Talent Migration Trends*” nas várias janelas temporais. A mesma tendência é observada, ainda que de forma menos acentuada, em Itália, onde se verifica igualmente uma fuga de talento Socol e Iuga, (2024). No entanto, o impacto desta realidade é atenuado pela robustez económica italiana. Itália distingue-se também pelo investimento na formação em IA e competências digitais desde o ensino básico (Jorge Ricart et al., 2022). Estes elementos contribuem para o bom posicionamento da Itália neste *cluster*, sendo o país mais próximo da fronteira de eficiência.

No que respeita à Dinamarca, Áustria, Bélgica e Irlanda, é possível agrupá-los numa análise conjunta, dado que possuem economias relativamente semelhantes. Todos estes países são classificados por Guarascio et al. (2025) como altamente expostos à IA, o que

Avaliação do impacto da Inteligência Artificial no emprego Europeu

se traduz numa melhoria consistente dos seus *scores* de eficiência, especialmente na última janela temporal. Em particular, a Dinamarca é elogiada por Foffano et al. (2023) pela sua forte produção académica em IA, tal como refletido no indicador “*AI Research Productivity*”. Adicionalmente, Pantelimon et al. (2024) salientam que a Dinamarca apresenta uma das maiores taxas de adoção de IA pelas empresas (15,2% em 2023). Neste sentido, juntamente com a Itália, a Dinamarca é um dos países mais próximos da eficiência no último período em análise. Por fim, a literatura destaca a Irlanda como um dos países com maior qualificação da sua força de trabalho em competências digitais e IA (Pantelimon et al., 2024), o que encontra paralelo no peso atribuído ao fator “*ICT Workforce Availability*” ao longo das três janelas temporais.

Relativamente aos países pertencentes ao *cluster* 2 (Letónia, Espanha, Luxemburgo e Países Baixos), de acordo com Guarascio et al. (2025), estes podem ser classificados como países com perfis heterogéneos em termos de inovação, desde emergentes a moderados ou líderes, embora apresentem trajetórias semelhantes no que respeita à adoção e exposição à IA.

Começando pela Letónia, trata-se do país que apresenta o pior resultado em termos de eficiência dentro deste *cluster*. A sua inclusão neste grupo justifica-se pela semelhança da sua trajetória temporal com os restantes países do *cluster*, ainda que os seus níveis de eficiência sejam significativamente inferiores. Este fraco desempenho é amplamente corroborado pela literatura: Jorge Ricart et al. (2022) referem que, no que diz respeito ao impacto da IA no emprego, a Letónia apresenta uma das exposições mais baixas da UE, sendo esta estatisticamente insignificante. Embora o país tenha publicado uma estratégia nacional de IA em fevereiro de 2020, é apontado como um dos Estados-Membros com menos iniciativas políticas relevantes nesta área. Adicionalmente, Barslund (2022) destaca que a Letónia se posiciona entre os países com piores resultados nos indicadores do Painel Digital da Comissão Europeia relativos às competências digitais, quer ao nível básico, quer acima do nível básico, o que pode comprometer a sua capacidade de adaptação às exigências da economia digital impulsionada pela IA.

No caso de Espanha e dos Países Baixos, ambos os países permanecem ineficientes nos *scores* obtidos ao longo das janelas temporais, embora com desempenhos relativamente superiores à Letónia e próximos da fronteira de eficiência. No que respeita à Espanha, a

Avaliação do impacto da Inteligência Artificial no emprego Europeu

literatura Espina-Romero et al. (2023) identifica o país como estando entre os líderes em termos de investimento em IA, juntamente com a Alemanha e a França. Ainda que o autor não especifique que tipo de investimento se trata, se público ou privado, os pesos atribuídos ao indicador “*Private AI Investments*” no presente estudo sugerem um contributo misto. Quanto aos Países Baixos, considerado um país ineficiente, a literatura apresenta uma caracterização bastante semelhante à feita para Espanha. De acordo com Foffano et al. (2020), o país realizou um investimento de 18 milhões de euros na aquisição de um supercomputador de última geração, com o objetivo de reforçar as suas capacidades em IA, e de aproximadamente 200 milhões de euros na área da cibersegurança. Apesar destas iniciativas, de cariz público, ao aferir o indicador “*Private AI Investments*”, o mesmo só passou a ser considerado no cálculo da eficiência a partir da segunda janela temporal, 2020–2022, possivelmente, impulsionado pelo investimento governativo. De acordo ainda com o mesmo autor, os Países Baixos integram o Top 5 europeu em número de profissionais em IA, o que se reflete no peso atribuído ao indicador “*AI Workforce Concentration*”, efetivamente utilizado no cálculo da sua eficiência.

Por fim, o Luxemburgo destaca-se como o único país eficiente dentro deste *cluster*. Este desempenho é sustentado pela literatura, que reconhece as medidas progressistas adotadas pelo governo, nomeadamente a integração da IA no sistema educativo (Jorge Ricart et al., 2022). O mesmo autor sublinha a importância atribuída à literacia digital e ao conhecimento básico de IA por parte da população, bem como a elevada proporção de especialistas em ICT na força de trabalho. Estes aspetos são confirmados pelo peso relevante atribuído aos indicadores “*ICT Workforce Availability*” e “*AI Workforce Concentration*” no cálculo da eficiência do país. De acordo com Guarascio et al. (2025), o Luxemburgo apresenta uma elevada exposição à IA, o que está intrinsecamente ligado à solidez da sua economia, considerada uma das mais desenvolvidas e digitalmente avançadas da UE.

Relativamente aos países pertencentes ao *cluster* 3 (França, Finlândia, Alemanha e Suécia), de acordo com Guarascio et al. (2025), estes países podem ser classificados como economias altamente desenvolvidas, com um elevado grau de maturidade em termos de adoção e desenvolvimento de IA, daí serem apelidados de “*Innovation Leaders*”. Este *cluster* distingue-se dos anteriores não apenas pelos seus níveis de eficiência mais

Avaliação do impacto da Inteligência Artificial no emprego Europeu

elevados, mas também pelo forte investimento em investigação, políticas públicas estruturadas e elevada concentração de talento especializado.

Iniciando a análise pela França, país que ainda não atingiu a fronteira de eficiência, mas cuja proximidade em relação à mesma é evidente. A literatura destaca a França como uma das nações europeias com maior produção científica em IA. Segundo Reis et al. (2020), a França ocupa a sexta posição no *ranking* europeu de publicações académicas na área, facto que é confirmado pelos pesos atribuídos ao indicador “*AI Research Productivity*” nas três janelas temporais analisadas. Adicionalmente, Bianchini (2023) salienta a posição de destaque do país no investimento em IA, refletido no peso relevante do indicador “*Private AI Investments*”. Neste âmbito, Jorge Ricart et al. (2022) referem que a Estratégia Nacional de IA francesa ambiciona multiplicar por dez o número de *startups* de *deeptech* até 2026, com um financiamento total de 40 milhões de euros, dos quais 25 milhões provêm de fundos públicos, destinados a facilitar a transição da investigação académica para o tecido empresarial. Ainda segundo Foffano et al. (2023), a França tem vindo a promover ativamente a literacia em IA junto dos seus cidadãos, começando desde cedo no sistema de ensino. Estes fatores sugerem que a França está no caminho certo para, num futuro próximo, atingir a fronteira de eficiência no contexto da IA aplicada ao emprego.

No que diz respeito à Alemanha, trata-se de um país com elevados níveis de investimento e produção científica em IA. Reis et al. (2020) posicionam a Alemanha como o quinto país europeu com mais publicações na área, o que se reflete nos pesos atribuídos ao indicador “*AI Research Productivity*” ao longo das janelas temporais. Maham (2022) acrescenta que a Alemanha é um destino atrativo para estudantes de doutoramento em IA, com mais de metade (53%) dos doutorandos a concentrarem-se neste país. Contudo, tal atratividade não se traduziu na consideração do indicador “*AI Talent Migration Trends*” no cálculo da eficiência, já que a Alemanha optou por desprezar esse fator, o que pode indicar uma subvalorização do seu impacto no contexto da eficiência medida neste estudo.

A Finlândia destaca-se pela sua abordagem precoce e adaptativa à IA. Em 2017, publicou a sua estratégia nacional “*Finland’s Age of Artificial Intelligence*”, antecipando-se à maioria dos países da UE. De acordo com Jorge Ricart et al. (2022), este programa tem

Avaliação do impacto da Inteligência Artificial no emprego Europeu

sido atualizado regularmente para acompanhar as exigências emergentes, que não estavam previstas na sua primeira versão. O governo finlandês alocou 200 milhões de euros ao “*AI Business Programme*” ao longo de quatro anos, e o Centro Finlandês para a IA recebeu 8,3 milhões de euros entre 2019 e 2022. Ainda assim, o impacto destes investimentos no presente estudo apenas se manifesta a partir da segunda janela temporal, 2020–2022, momento em que o indicador “*Private AI Investments*” começou a ser considerado para o cálculo da eficiência, tendo sido desvalorizado na janela anterior.

No que se refere à Suécia, trata-se de um país que se posiciona como referência em termos de produção académica sobre IA. Reis et al. (2020) destacam o seu contributo neste domínio, sendo o país que atribuiu maior peso ao indicador “*AI Research Productivity*” na segunda janela temporal, 2020–2022. De acordo com Foffano et al. (2023), a Suécia continua a investir significativamente em investigação académica, enquanto Jorge Ricart et al. (2022) referem a existência de programas de apoio dedicados a novas empresas de IA, que reforçam a inovação no setor. Barslund (2022), sublinha ainda, que a Suécia apresenta a maior intensidade de competências digitais da UE, cerca de 20% acima da média europeia. No entanto, o país apenas passou a considerar o indicador “*AI Workforce Concentration*” na terceira janela temporal entre 2021–2023, o que limita o impacto desse fator nos scores de eficiência obtidos. Ainda assim, tendo em conta o conjunto de iniciativas e políticas adotadas, é evidente que a Suécia segue uma estratégia bem estruturada e direcionada para a integração da IA na sua economia e sociedade.

Assim, este *cluster* destaca-se pela solidez das suas políticas públicas, elevados níveis de investimento e dinamismo científico, refletindo o posicionamento destes países na vanguarda da adoção da IA a nível europeu. A sua performance global no presente estudo revela uma clara aproximação à fronteira de eficiência, com margens de melhoria específicas em fatores que, se devidamente considerados, poderão contribuir para uma consolidação ainda maior da sua liderança em IA.

Importa ainda referir que, ao longo das três janelas temporais consideradas (2019–2021, 2020–2022 e 2021–2023), a janela intermédia coincide com o período de maior impacto da crise pandémica da COVID-19, o que se refletiu de forma distinta entre os países analisados. Verifica-se que as economias mais voláteis ou estruturalmente frágeis — nomeadamente a Grécia, a Hungria, a Eslovénia, entre outras — registaram uma

Avaliação do impacto da Inteligência Artificial no emprego Europeu

deterioração mais acentuada dos seus *scores* de eficiência neste intervalo, ao contrário de países com economias mais robustas e bem estruturadas, como por exemplo, a Alemanha, o Luxemburgo ou a Suécia, que demonstraram uma maior resiliência face às perturbações causadas pela pandemia. Esta assimetria evidencia a importância da solidez económica e institucional na mitigação dos efeitos adversos de choques externos, nomeadamente no que respeita à adoção e integração de tecnologias emergentes como a IA.

Estes resultados corroboram a análise realizada por Guarascio et al. (2025) que concluem que o impacto da IA é altamente dependente do contexto, as capacidades de inovação de um país influenciam significativamente o modo como estas tecnologias podem ser aproveitadas para impulsionar o crescimento económico e do emprego. Reis et al. (2020), salientam ainda que tecnologias de IA, estão a influenciar sociedades e sistemas políticos de forma diferente, o que torna útil compreender quais são os problemas comuns entre estados semelhantes na UE e como esses sistemas políticos podem colaborar entre si, procurando sinergias e encontrando oportunidades de avanço tecnológico.

Em síntese, os dados analisados apontam para trajetórias assimétricas no que respeita à integração da IA no mercado de trabalho europeu, refletindo disparidades sobretudo ao nível do investimento, muito por conta da especificidade económica de cada país, em competências digitais e de opções governativas, o que corrobora a linha de pensamento da comunidade científica.

CONCLUSÃO

O presente estudo teve como principal objetivo analisar o impacto da IA no emprego europeu, no período compreendido entre 2019 e 2023, recorrendo a uma abordagem metodológica inovadora que combinou o método VBDEA com o *Hierarchical Clustering*. Este trabalho procurou, assim, responder à questão central da investigação previamente definida na secção introdutória, com o intuito de aprofundar o entendimento sobre as transformações no mercado de trabalho europeu num contexto de rápida evolução tecnológica e incerteza socioeconómica. A estrutura da análise assentou na seleção de sete indicadores, escolhidos de forma a permitir uma avaliação abrangente das principais dimensões relacionadas com o impacto da IA no emprego, — como o número de publicações científicas, a migração de talentos, o investimento privado, a caracterização de especialistas em ICT, a concentração de talentos, a tendência de procura/oferta de talentos e a participação em projetos públicos, — em consonância com a literatura existente, que destaca a importância de uma abordagem multidimensional para compreender os efeitos da IA no contexto laboral.

Os países que apresentaram melhor desempenho ao longo do período em análise, de acordo com a avaliação dos *scores* de eficiência revelou padrões de progresso, com destaque para o Luxemburgo, a Suécia e a Alemanha, que, em momentos distintos, evidenciaram *scores* de eficiência superiores. Em sentido oposto, a Grécia, a Hungria e a Estónia apresentaram *scores* constantemente mais desfavoráveis, refletindo maiores necessidades de ajustamento para atingir a fronteira de eficiência.

De um modo geral, verificou-se que no período coincidente com a crise pandémica, ou seja, no ano de 2020, existiu um agravamento dos *scores* de eficiência na grande maioria dos países, o que indica a elevada volatilidade das estratégias adotadas com base em fatores externos.

No que diz respeito à análise por *clusters*, que agrupa os países com trajetórias semelhantes ao longo do tempo, observa-se um desempenho superior do *cluster* 3, seguido do *cluster* 2 e, por fim, do *cluster* 1. O *cluster* 3 integra economias consideradas robustas, fator que facilita a adoção e implementação de políticas orientadas para a IA. No entanto, destaca-se que, apesar de fazer parte deste grupo, a França não apresenta um desempenho eficiente. Relativamente ao *cluster* 2, este inclui o país com melhor

Avaliação do impacto da Inteligência Artificial no emprego Europeu

performance do estudo, o Luxemburgo, cuja sólida base económica, política e governativa contribuíram para essa posição. Os restantes países deste grupo, Letónia, Países Baixos e Espanha, apesar de apresentarem estruturas económicas e dimensões distintas, revelam ineficiências em todos os períodos analisados. Por último, o *cluster* 1 é constituído pelos restantes países em análise, maioritariamente economias mais frágeis que foram particularmente afetadas pela pandemia. Esta vulnerabilidade refletiu-se na deterioração dos seus *scores* no período de 2019–2021 para 2020–2022. Ainda assim, verifica-se uma recuperação generalizada no período seguinte, de 2021–2023, com a maioria dos países a registarem uma melhoria nos respetivos *scores*.

A utilização do VBDEA permitiu assim avaliar a eficiência relativa dos países de forma flexível, ao incorporar diferentes ponderações sobre os indicadores e possibilitar que cada país fosse analisado da forma mais favorável. Esta atribuição endógena de pesos revelou-se particularmente útil para captar as especificidades sobretudo governativas e económicas, permitindo ajustar a análise às diferentes realidades nacionais sem impor uma estrutura de avaliação uniforme que poderia distorcer os resultados.

Por outro lado, a aplicação da análise por *Hierarchical Clustering* possibilitou identificar padrões de evolução partilhados entre grupos de países, segmentando a amostra em trajetórias similares de eficiência. Esta abordagem evidenciou que, apesar das políticas europeias orientadas para uma transição digital coesa, subsistem diferenças estruturais relevantes entre os países, como demonstrado pelas distintas velocidades de convergência e pela composição heterogénea dos *clusters*. Deste modo, a análise por *clusters* complementou a abordagem de eficiência ao permitir perceber, não apenas quais os países mais ou menos preparados para enfrentar os desafios da IA, mas também de que forma se aproximam, ou divergem, de padrões comuns de transformação do emprego.

A combinação destes métodos trouxe ainda um contributo adicional: a possibilidade de analisar não apenas a situação estática de cada país, mas também a dinâmica de ajustamento necessária para alcançar a fronteira de eficiência no que respeita à adaptação ao impacto da IA no mercado de trabalho.

Em síntese, a conjugação do VBDEA com a análise de *Hierarchical Clustering* revelou-se uma metodologia capaz de oferecer uma avaliação mais rica, multidimensional e dinâmica do impacto da inteligência artificial no emprego no contexto europeu,

Avaliação do impacto da Inteligência Artificial no emprego Europeu

superando as abordagens tradicionais que tendem a tratar a UE como um bloco homogéneo. Esta inovação metodológica responde, assim, a lacunas identificadas na literatura, ao propor uma ferramenta analítica que respeita a diversidade das trajetórias nacionais e permite identificar com maior rigor as necessidades específicas de ajustamento dos países.

De forma global, o presente estudo representa um contributo significativo para o aprofundamento da análise dos efeitos da IA sobre o emprego na UE, propondo uma abordagem metodológica inovadora que combina a aplicação do método VBDEA com *Hierarchical Clustering*. Através desta integração, foi possível analisar, de forma mais rigorosa e dinâmica, o impacto tido em cada país entre o período de 2019 a 2023.

Neste sentido, o estudo realizado contribui de forma significativa para o aprofundamento do conhecimento sobre as dinâmicas laborais na UE, alinhando-se com os objetivos propostos no ODS 8, que promove o trabalho digno, a inclusão produtiva e o crescimento económico sustentável, reforçando assim a importância de metodologias integradas e flexíveis na investigação, especialmente num cenário global marcado por rápidas mudanças tecnológicas e crescente incerteza.

Para além da caracterização detalhada do desempenho relativo dos países face aos desafios impostos pela IA, os resultados desta investigação oferecem uma base crítica e estruturada para futuros trabalhos que pretendam aprofundar ou expandir este campo de estudo, reconhecendo a complexidade crescente das interações entre tecnologia e emprego, bem como a necessidade de abordagens mais dinâmicas, adaptativas e centradas na sustentabilidade social e económica.

Contudo, importa reconhecer algumas limitações deste estudo. Em primeiro lugar, a análise abrangeu apenas vinte dos vinte e sete Estados-Membros da UE, tendo sido excluídos a Bulgária, a Croácia, a Chéquia, Chipre, Malta, a Roménia e a Eslováquia. A exclusão destes países deveu-se à indisponibilidade de forma parcial ou total de dados para os indicadores utilizados no estudo. Adicionalmente, importa sublinhar que, do ponto de vista científico, existe ainda uma escassez de estudos que combinem, de forma integrada, os diversos tipos de indicadores utilizados nesta análise, desde métricas de desempenho económico e de qualificação profissional até indicadores relacionados com a adoção tecnológica e a exposição ocupacional à IA. Esta limitação reflete não só a

Avaliação do impacto da Inteligência Artificial no emprego Europeu

complexidade multidimensional do fenómeno, mas também a natureza emergente do tema, o que dificulta a comparação direta com trabalhos anteriores e reforça a necessidade de investigação contínua e aprofundada nesta área.

Mesmo com as limitações reconhecidas, o presente estudo destaca-se pelo seu contributo metodológico e analítico, ao aplicar uma abordagem integrada que alia técnicas de avaliação de eficiência e análise de convergência de *clusters*. Esta proposta contribui para um melhor entendimento dos impactos diferenciados da IA no mercado de trabalho europeu, em linha com os objetivos do ODS 8, ao apoiar a formulação de políticas que promovam inclusão produtiva e transições justas.

Este estudo abre diversas oportunidades para investigações futuras que poderão aprofundar o conhecimento sobre o impacto da IA no emprego europeu e contribuir para o desenvolvimento metodológico nesta área.

Desde logo, a escolha dos indicadores utilizados, embora sustentada pela literatura mais recente e coerente com as principais dimensões associadas à IA e à empregabilidade, poderá ser alargada em estudos subsequentes. A inclusão de variáveis complementares, como indicadores de capacidade de reconversão profissional, resistência a choques tecnológicos, ou métricas de inovação organizacional, permitiria captar de forma mais abrangente a complexidade do fenómeno e acompanhar a sua evolução num contexto em rápida mutação.

Além disso, uma outra via de aprofundamento reside na extensão do horizonte temporal da análise, pois o período de análise foi entre 2019-2023, intervalo temporal particularmente relevante por abranger eventos com forte impacto na estrutura e dinâmica do mercado de trabalho europeu, como a pandemia de COVID-19 e a intensificação da transição digital em diversos setores. No entanto, a inclusão de dados relativos a anos posteriores permitiria captar tendências estruturais mais consolidadas, avaliar os efeitos acumulados das políticas públicas de adaptação à IA e observar com maior clareza os padrões de ajustamento das economias europeias face à evolução tecnológica.

REFERÊNCIAS BIBLIOGRÁFICAS

- Agbaji, D. A., Lund, B. D., & Reddy Mannuru, N. (2023). Perceptions of the Fourth Industrial Revolution and AI's Impact on Society. *ArXiv Preprint ArXiv:2308.02030*. <https://api.semanticscholar.org/CorpusID:260611317>
- Ajuzieogu, U. (2025). *Cross-Country Analysis of AI Adoption and Economic Growth: Causal Identification Strategies*. <https://doi.org/10.13140/RG.2.2.21040.67844>.
- Ali, A. I., Lerne, C. S., & Seiford, L. M. (1995). Components of efficiency evaluation in data envelopment analysis. In *European Journal of Operational Research* (Vol. 80).
- Ali, A. I., & Seiford, L. M. (1993). Computational Accuracy and Infinitesimals In Data Envelopment Analysis. *INFOR: Information Systems and Operational Research*, 31(4), 290–297. <https://doi.org/10.1080/03155986.1993.11732232>
- Andersen, P., & Petersen, N. C. (1993). A Procedure for Ranking Efficient Units in Data Envelopment Analysis. <https://doi.org/10.1287/Mnsc.39.10.1261>, 39(10), 1261–1264. <https://doi.org/10.1287/MNSC.39.10.1261>
- Arntz, M. , T. G. and U. Z. (2016). *The Risk of Automation for Jobs in OECD Countries* (OECD Social, Employment and Migration Working Papers, Vol. 189). <https://doi.org/10.1787/5jlz9h56dvq7-en>
- Asmild, M., Paradi, J. C., Aggarwall, V., & Schaffnit, C. (2004). Combining DEA window analysis with the Malmquist index approach in a study of the Canadian banking industry. *Journal of Productivity Analysis*, 21(1), 67–89. <https://doi.org/10.1023/B:PROD.0000012453.91326.EC/METRICS>
- Badet, J. (2021). AI, Automation and New Jobs. *Open Journal of Business and Management*, 09(05), 2452–2463. <https://doi.org/10.4236/ojbm.2021.95132>
- Banker, R. D. , C. A. , & C. W. W. (1984). Some Models for Estimating Technical and Scale Inefficiencies in Data Envelopment Analysis. *Management Science*.
- Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., Garcia, S., Gil-Lopez, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts,

Avaliação do impacto da Inteligência Artificial no emprego Europeu

- taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Barslund, M. (2022). *Social Situation Monitor The dynamics of ICT skills in EU Member States*. <https://doi.org/10.2767/866469>
- BELL, D. E. (1982). REGRET IN DECISION MAKING UNDER UNCERTAINTY. *OPER RES*, 30(N 5), 961–981. <https://doi.org/10.1287/OPRE.30.5.961;CTYPE:STRING:JOURNAL>
- Belton, V., & Stewart, T. J. (2002). Multiple criteria decision analysis: An integrated approach. Springer Science & Business Media.
- Bianchini, N. , & A. L. (2023). Artificial Intelligence Europe must start dreaming. *Digital and Technologies*.
- Bianchini Niccolò, A. L. (2023). Artificial intelligence: Europe needs to start dreaming again. *Digital and Technologies*.
- Bogoslov, I. A., Corman, S., & Lungu, A. E. (2024). Perspectives on Artificial Intelligence Adoption for European Union Elderly in the Context of Digital Skills Development. *Sustainability (Switzerland)* , 16(11). <https://doi.org/10.3390/su16114579>
- Călinescu, G. (2023). The Impact of Artificial Intelligence on Employment in the European Economy. In *Geopolitical perspectives and technological challenges for sustainable growth in the 21st century* (pp. 536–543). Sciendo. <https://doi.org/10.2478/9788367405546-049>
- Charnes, A., Cooper, W., & Rhodes, E. (1978). Measuring the efficiency of decision making units. In *Company European Journal of Operational Research* (Vol. 2).
- Charnes, A., Cooper, W. W., Golany, B., Seiford, L., & Stutz, J. (1985). Foundations of data envelopment analysis for Pareto-Koopmans efficient empirical production functions. *Journal of Econometrics*, 30(1–2), 91–107. [https://doi.org/10.1016/0304-4076\(85\)90133-2](https://doi.org/10.1016/0304-4076(85)90133-2)
- Charnes, A., Cooper, W. W., Lewin, A. Y., & Seiford, L. M. (1994). Extensions to DEA Models. *Data Envelopment Analysis: Theory, Methodology, and Applications*, 49–61. https://doi.org/10.1007/978-94-011-0637-5_3

Avaliação do impacto da Inteligência Artificial no emprego Europeu

- Collins, C., Dennehy, D., Conboy, K., & Mikalef, P. (2021). Artificial intelligence in information systems research: A systematic literature review and research agenda. *International Journal of Information Management*, 60. <https://doi.org/10.1016/j.ijinfomgt.2021.102383>
- Cramarenco, R. E., Burcă-Voicu, M. I., & Dabija, D. C. (2023). The impact of artificial intelligence (AI) on employees' skills and well-being in global labor markets: A systematic review. In *Oeconomia Copernicana* (Vol. 14, Issue 3, pp. 731–767). Institute of Economic Research. <https://doi.org/10.24136/oc.2023.022>
- Dahlin, E. (2024). Who Says Artificial Intelligence Is Stealing Our Jobs? *Socius*, 10. <https://doi.org/10.1177/23780231241259672>
- Damioli, G., Van Roy, V., Vértesy, D., & Vivarelli, M. (2024). Drivers of employment dynamics of AI innovators. *Technological Forecasting and Social Change*, 201. <https://doi.org/10.1016/j.techfore.2024.123249>
- de Laat, P. B. (2021). Companies Committed to Responsible AI: From Principles towards Implementation and Regulation? *Philosophy and Technology*, 34(4), 1135–1193. <https://doi.org/10.1007/s13347-021-00474-3>
- Devineni, S. K. (2024). AI in Data Privacy and Security. *International Journal of Artificial Intelligence & Machine Learning (IJAIML)*, 3(1), 35–49. <https://doi.org/10.17605/OSF.IO/WCN8A>
- Dol, M., & Geetha, A. (2021). A Learning Transition from Machine Learning to Deep Learning: A Survey. *Proceedings of the 2021 International Conference on Emerging Techniques in Computational Intelligence, ICETCI 2021*, 89–94. <https://doi.org/10.1109/ICETCI51973.2021.9574066>
- Espina-Romero, L., Noroño Sánchez, J. G., Gutiérrez Hurtado, H., Dworaczek Conde, H., Solier Castro, Y., Cervera Cajo, L. E., & Rio Corredoira, J. (2023). Which Industrial Sectors Are Affected by Artificial Intelligence? A Bibliometric Analysis of Trends and Perspectives. In *Sustainability (Switzerland)* (Vol. 15, Issue 16). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/su151612176>

Avaliação do impacto da Inteligência Artificial no emprego Europeu

- Eurofound (2017). Occupational change and wage inequality: European Jobs Monitor 2017, Publications Office of the European Union, Luxembourg.
- European Commission: Directorate-General for Communications Networks, Content and Technology, 2030 Digital Decade – Report on the state of the Digital Decade 2023, Publications Office of the European Union, 2023, <https://data.europa.eu/doi/10.2759/318547>
- Farrell, M. J. (1957). The Measurement of Productive Efficiency. *Journal of the Royal Statistical Society. Series A (General)*, 120(3), 253. <https://doi.org/10.2307/2343100>
- Felten, E., Raj, M., & Seamans, R. (2021). Occupational, industry, and geographic exposure to artificial intelligence: A novel dataset and its potential uses. *Strategic Management Journal*, 42(12), 2195–2217. <https://doi.org/10.1002/SMJ.3286;REQUESTEDJOURNAL:JOURNAL:10970266;WGROU:STRING:PUBLICATION>
- Ferneda, E. (2006). *Neural networks and its application in information retrieval systems*.
- Foffano, F., Scantamburlo, T., & Cortés, A. (2023). Investing in AI for social good: an analysis of European national strategies. *AI and Society*, 38(2), 479–500. <https://doi.org/10.1007/s00146-022-01445-8>
- Foffano, F., Scantamburlo, T., Cortés, A., & Bissolo, C. (2020). *European Strategy on AI: Are we truly fostering social good?* <http://arxiv.org/abs/2011.12863>
- Frank, M. R., Autor, D., Bessen, J. E., Brynjolfsson, E., Cebrian, M., Deming, D. J., Feldman, M., Groh, M., Lobo, J., Moro, E., Wang, D., Youn, H., & Rahwan, I. (2019). Toward understanding the impact of artificial intelligence on labor. In *Proceedings of the National Academy of Sciences of the United States of America* (Vol. 116, Issue 14, pp. 6531–6539). National Academy of Sciences. <https://doi.org/10.1073/pnas.1900949116>
- Gama, F., Segarra, S., & Ribeiro, A. (2017). Hierarchical Overlapping Clustering of Network Data Using Cut Metrics. *Institute of Electrical and Electronics Engineers Inc.* <http://arxiv.org/abs/1611.01393>

Avaliação do impacto da Inteligência Artificial no emprego Europeu

- Gouveia, M. C., Dias, L. C., & Antunes, C. H. (2008). Additive DEA based on MCDA with imprecise information. *Journal of the Operational Research Society*, 59(1), 54–63. <https://doi.org/10.1057/palgrave.jors.2602317>
- Gouveia, M., Henriques, C., & Moutinho², V. (2025). *Analyzing Quality of Life Convergence in Europe: A Novel Approach Integrating Window Value-Based DEA and Club Convergence Method*.
- Green, A., & Lamby, L. (2025). The Characteristics of the Artificial Intelligence Workforce across OECD Countries. *The Indian Journal of Labour Economics*. <https://doi.org/10.1007/s41027-024-00549-7>
- Guarascio, D., Reljic, J., & Stöllinger, R. (2024). Diverging paths: AI exposure and employment across European regions. *Structural Change and Economic Dynamics*. <https://doi.org/10.1016/j.strueco.2024.12.010>
- Guarascio, D., Reljic, J., & Strong, S. (2025). *AI and employment in Europe*. <https://ssrn.com/abstract=4977989>
- Henriques, C., Viseu, C., & Sousa, S. (2025). Evaluating eco-innovation efficiency and club convergence trends across the European Union: A window slack-based measure approach. *Sustainable Futures*, 9, 100673. <https://doi.org/10.1016/J.SFTR.2025.100673>
- Iman, M., Arabnia, H. R., & Rasheed, K. (2023). A Review of Deep Transfer Learning and Recent Advancements. In *Technologies* (Vol. 11, Issue 2). MDPI. <https://doi.org/10.3390/technologies11020040>
- Infante, L. (2002). Hierarchical clustering. *Revista Mexicana de Astronomia y Astrofisica: Serie de Conferencias*, 14, 63–67. <https://doi.org/10.1145/3321386>
- Jarrahi, M. H., Lutz, C., Boyd, K., Oesterlund, C., & Willis, M. (2023). Artificial intelligence in the work context. *Journal of the Association for Information Science and Technology*, 74(3), 303–310. <https://doi.org/10.1002/asi.24730>
- Jorge Ricart, R. Esther., Rossetti, Fiammetta., Tangi, Luca., & Van Roy, Vincent. (2022). *AI watch, national strategies on artificial intelligence : a European perspective*. Publications Office of the European Union.
- Kariri, E., Louati, H., Louati, A., & Masmoudi, F. (2023). Exploring the Advancements and Future Research Directions of Artificial Neural Networks:

Avaliação do impacto da Inteligência Artificial no emprego Europeu

- A Text Mining Approach. *Applied Sciences (Switzerland)*, 13(5).
<https://doi.org/10.3390/app13053186>
- Keeney, R. L., & Raiffa, H. (1976). Decisions with multiple objectives: Preferences and value tradeoffs. John Wiley & Sons.
- Maham, P. , H. S. , D. W. , H. L. , & S. A. (2022). *AI Talent Flows in Germany Think Tank at the Intersection of Technology and Society 2 Data Brief January 2023 AI Talent Flows in Germany*.
- Marino, D., Gil Lafuente, J., & Tebala, D. (2023). Innovations and development of artificial intelligence in Europe: some empirical evidences. *European Journal of Management and Business Economics*, 32(5), 620–636.
<https://doi.org/10.1108/EJMBE-03-2023-0085>
- Mathew, A., Amudha, P., & Sivakumari, S. (2021). Deep learning techniques: an overview. *Advances in Intelligent Systems and Computing*, 1141, 599–608.
https://doi.org/10.1007/978-981-15-3383-9_54
- Meng, T., Jing, X., Yan, Z., & Pedrycz, W. (2020). A survey on machine learning for data fusion. *Information Fusion*, 57, 115–129.
<https://doi.org/10.1016/j.inffus.2019.12.001>
- Mihai, F., Aleca, O. E., & Gheorghe, M. (2023). Digital Transformation Based on AI Technologies in European Union Organizations. *Electronics (Switzerland)*, 12(11). <https://doi.org/10.3390/electronics12112386>
- Munnisunker, S., Nel, L., & Diederichs, D. (2022). The Impact of Artificial Intelligence on Agricultural Labour in Europe. *Journal of Agricultural Informatics*, 13(1). <https://doi.org/10.17700/jai.2022.13.1.638>
- Ng, D. T. K., Leung, J. K. L., Chu, S. K. W., & Qiao, M. S. (2021). Conceptualizing AI literacy: An exploratory review. *Computers and Education: Artificial Intelligence*, 2, 100041. <https://doi.org/10.1016/J.CAEAI.2021.100041>
- OECD. (2019). OECD Employment Outlook 2019: The future of work. OECD Publishing. <https://doi.org/10.1787/9ee00155-en>
- Pantelimon, F.-V., Posedaru, B.-S., Toader, L.-A., Dulgheru, M.-N., & Georgescu, T.-M. (2024). The Dynamics of the ICT Workforce and the Effects on the Use of Artificial Intelligence Technologies in the European Union. *Proceedings of*

Avaliação do impacto da Inteligência Artificial no emprego Europeu

- the International Conference on Business Excellence*, 18(1), 3490–3502.
<https://doi.org/10.2478/picbe-2024-0283>
- Presno Linera, M. Á., & Meuwese, A. (2025). Regulating AI from Europe: a joint analysis of the AI Act and the Framework Convention on AI. *The Theory and Practice of Legislation*, 1–20. <https://doi.org/10.1080/20508840.2025.2492524>
- Reis, J., Santo, P., & Melão, N. (2020). Artificial intelligence research and its contributions to the European Union’s political governance: comparative study between member states. *Social Sciences*, 9(11), 1–17.
<https://doi.org/10.3390/socsci9110207>
- Rodrigues, R. (2020). Legal and human rights issues of AI: Gaps, challenges and vulnerabilities. *Journal of Responsible Technology*, 4, 100005.
<https://doi.org/10.1016/j.jrt.2020.100005>
- SAMOILI, S., LOPEZ, C. M., GOMEZ, G. E., DE, P. G., MARTINEZ-PLUMED, F., & DELIPETREV, B. (2020). AI WATCH. Defining Artificial Intelligence. *Joint Research Centre (European Commission)*, 1–90.
<https://doi.org/10.2760/382730>
- Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. In *SN Computer Science* (Vol. 2, Issue 6). Springer. <https://doi.org/10.1007/s42979-021-00815-1>
- Savage, N. (2020). The race to the top among the world’s leaders in artificial intelligence. *Nature Index*.
- Sheikh, H., Prins, C., & Schrijvers, E. (2023). *Artificial Intelligence: Definition and Background*. In: *Mission AI*. [https://doi.org/https://doi.org/10.1007/978-3-031-21448-6_2](https://doi.org/10.1007/978-3-031-21448-6_2)
- Socol, A., & Iuga, I. C. (2024). Addressing brain drain and strengthening governance for advancing government readiness in artificial intelligence (AI). *Kybernetes*, 53(13), 47–71. <https://doi.org/10.1108/K-03-2024-0629>
- Soori, M., Arezoo, B., & Dastres, R. (2023). Artificial intelligence, machine learning and deep learning in advanced robotics, a review. In *Cognitive Robotics* (Vol. 3, pp. 54–70). KeAi Communications Co.
<https://doi.org/10.1016/j.cogr.2023.04.001>

Avaliação do impacto da Inteligência Artificial no emprego Europeu

- Stahl, B. C., Rodrigues, R., Santiago, N., & Macnish, K. (2022). A European Agency for Artificial Intelligence: Protecting fundamental rights and ethical values. *Computer Law and Security Review*, 45. <https://doi.org/10.1016/j.clsr.2022.105661>
- Talaei Khoei, T., Ould Slimane, H., & Kaabouch, N. (2023). Deep learning: systematic review, models, challenges, and research directions. In *Neural Computing and Applications* (Vol. 35, Issue 31, pp. 23103–23124). Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1007/s00521-023-08957-4>
- Taye, M. M. (2023). Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. In *Computers* (Vol. 12, Issue 5). MDPI. <https://doi.org/10.3390/computers12050091>
- Tiwari, T., Tiwari, T., & Tiwari, S. (2018). How Artificial Intelligence, Machine Learning and Deep Learning are Radically Different? *International Journal of Advanced Research in Computer Science and Software Engineering*, 8(2), 1. <https://doi.org/10.23956/ijarcsse.v8i2.569>
- Trabelsi, M. A. (2024). The impact of artificial intelligence on economic development. *Journal of Electronic Business & Digital Economics*, 3(2), 142–155. <https://doi.org/10.1108/jebde-10-2023-0022>
- Ulnicane, I. (2022). Artificial intelligence in the European Union: Policy, ethics and regulation. In *The Routledge Handbook of European Integrations* (pp. 254–269). Taylor and Francis. <https://doi.org/10.4324/9780429262081-19>
- van Noordt, C., Medaglia, R., & Tangi, L. (2023). Policy initiatives for Artificial Intelligence-enabled government: An analysis of national strategies in Europe. *Public Policy and Administration*. <https://doi.org/10.1177/09520767231198411>
- van Noordt, C., & Misuraca, G. (2022). Exploratory Insights on Artificial Intelligence for Government in Europe. *Social Science Computer Review*, 40(2), 426–444. <https://doi.org/10.1177/0894439320980449>

Avaliação do impacto da Inteligência Artificial no emprego Europeu

- Vichi, M., Cavicchia, C., & Groenen, P. J. F. (2022). Hierarchical Means Clustering. *Journal of Classification*, 39(3), 553–577. <https://doi.org/10.1007/s00357-022-09419-7>
- Zirar, A., Ali, S. I., & Islam, N. (2023). Worker and workplace Artificial Intelligence (AI) coexistence: Emerging themes and research agenda. *Technovation*, 124. <https://doi.org/10.1016/j.technovation.2023.102747>

APÊNDICES

Apêndice 1 – Heatmap da Correlação




Figura 37 - Heatmap correlação

Legenda dos Indicadores:

- [A] - *AI Research Productivity*;
- [B] - *AI Talent Migration Trends*;
- [C] - *AI Workforce Concentration*;
- [D] - *AI Hiring Trends*;
- [E] - *Contributions to Open AI Projects*;
- [F] - *Private AI Investments*;
- [G] - *ICT Workforce Availability*;

Apêndice 2 – Pesos por janela temporal

Tabela 4 - Pesos por janela – “AI Reserch Productivity”

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.2502	0.1959	0.2286
BEL	2	0.2502	0.2595	0.2435
DNK	3	0.2302	0.2013	0.2360
EST	4	0.0000	0.0000	0.0000
FIN	5	0.1237	0.1009	0.2114
FRA	6	0.2710	0.2604	0.2412
DEU	7	0.2263	0.2223	0.0553
GRC	8	0.1874	0.1679	0.1895
HUN	9	0.1861	0.1291	0.1705
IRL	10	0.0000	0.0000	0.0000
ITA	11	0.3491	0.3763	0.3194
LVA	12	0.0000	0.0000	0.0000
LTU	13	0.0000	0.0000	0.0000
LUX	14	0.0000	0.0000	0.0000
NLD	15	0.2450	0.2579	0.2931
POL	16	0.2164	0.1670	0.2140

Avaliação do impacto da Inteligência Artificial no emprego Europeu

PRT	17	0.2256	0.2170	0.2360
SVN	18	0.0000	0.0000	0.0000
ESP	19	0.2582	0.2161	0.1958
SWE	20	0.2607	0.3191	0.2350

Tabela 5 - Pesos por janela "AI Talent Migration Trends"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.1821	0.1416	0.1493
BEL	2	0.1821	0.1328	0.1265
DNK	3	0.1131	0.0568	0.0950
EST	4	0.2574	0.0540	0.0641
FIN	5	0.1926	0.0000	0.0000
FRA	6	0.4897	0.3993	0.3954
DEU	7	0.0000	0.0000	0.0000
GRC	8	0.1054	0.2640	0.1689
HUN	9	0.1193	0.0000	0.1117
IRL	10	0.0240	0.0208	0.0678
ITA	11	0.3197	0.4111	0.3064
LVA	12	0.2938	0.1493	0.1253

Avaliação do impacto da Inteligência Artificial no emprego Europeu

LTU	13	0.1870	0.0000	0.0932
LUX	14	0.4275	0.6638	0.3716
NLD	15	0.2646	0.1293	0.1954
POL	16	0.2456	0.2047	0.1608
PRT	17	0.1572	0.0892	0.0950
SVN	18	0.0240	0.0160	0.0932
ESP	19	0.2698	0.2065	0.1784
SWE	20	0.2431	0.1751	0.0000

Tabela 6 - Pesos por janela "Private AI Investments"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.0000	0.0000	0.1219
BEL	2	0.0000	0.0000	0.0000
DNK	3	0.0000	0.0000	0.0000
EST	4	0.0000	0.0000	0.0000
FIN	5	0.0000	0.1471	0.0406
FRA	6	0.2339	0.2744	0.2770
DEU	7	0.1518	0.5071	0.4282
GRC	8	0.0000	0.1861	0.1151

Avaliação do impacto da Inteligência Artificial no emprego Europeu

HUN	9	0.1332	0.1358	0.1133
IRL	10	0.0000	0.0000	0.0000
ITA	11	0.1468	0.0000	0.0000
LVA	12	0.1524	0.2777	0.1916
LTU	13	0.2211	0.2060	0.1261
LUX	14	0.0000	0.0000	0.1411
NLD	15	0.0000	0.0064	0.0240
POL	16	0.1468	0.2027	0.1021
PRT	17	0.1468	0.0000	0.0000
SVN	18	0.0000	0.0000	0.1086
ESP	19	0.1468	0.2070	0.1253
SWE	20	0.5769	0.6523	0.3419

Tabela 7 - Pesos por janela "ICT Workforce Availability"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.2919	0.2341	0.1914
BEL	2	0.2919	0.3032	0.1952
DNK	3	0.2833	0.2836	0.1919
EST	4	0.4550	0.4427	0.3915

Avaliação do impacto da Inteligência Artificial no emprego Europeu

FIN	5	0.3499	0.1762	0.3155
FRA	6	0.0000	0.0000	0.0000
DEU	7	0.1009	0.0000	0.0000
GRC	8	0.0000	0.0000	0.0000
HUN	9	0.1869	0.1178	0.0000
IRL	10	0.3898	0.3254	0.3856
ITA	11	0.0000	0.0000	0.0000
LVA	12	0.4419	0.4021	0.3418
LTU	13	0.0000	0.3828	0.1869
LUX	14	0.4683	0.0000	0.0000
NLD	15	0.2842	0.3112	0.3178
POL	16	0.0000	0.0000	0.2029
PRT	17	0.2833	0.2840	0.1919
SVN	18	0.4085	0.2443	0.1869
ESP	19	0.2003	0.2794	0.1540
SWE	20	0.3474	0.5636	0.4208

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Tabela 8 - Pesos por janela "AI Workforce Concentration"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.0000	0.0132	0.0000
BEL	2	0.0000	0.0000	0.0000
DNK	3	0.0000	0.0000	0.0000
EST	4	0.0217	0.1422	0.0335
FIN	5	0.4504	0.4121	0.2653
FRA	6	0.0000	0.0000	0.0000
DEU	7	0.4446	0.7724	0.4455
GRC	8	0.2941	0.2229	0.1193
HUN	9	0.2910	0.1761	0.1185
IRL	10	0.0000	0.1376	0.0335
ITA	11	0.0000	0.0000	0.0000
LVA	12	0.0000	0.0000	0.0000
LTU	13	0.3516	0.0879	0.0000
LUX	14	0.7256	0.5638	0.3948
NLD	15	0.1856	0.1296	0.1180
POL	16	0.0000	0.0000	0.0456

Avaliação do impacto da Inteligência Artificial no emprego Europeu

PRT	17	0.0000	0.0000	0.0000
SVN	18	0.0000	0.0000	0.0000
ESP	19	0.0000	0.0000	0.0000
SWE	20	0.0000	0.0000	0.2162

Tabela 9 - Pesos por janela "AI Hiring Trends"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.2758	0.4711	0.4539
BEL	2	0.2758	0.3045	0.4348
DNK	3	0.3734	0.4453	0.4771
EST	4	0.0000	0.1951	0.2478
FIN	5	0.4083	0.3927	0.2913
FRA	6	0.1250	0.1978	0.1057
DEU	7	0.4056	0.6070	0.5179
GRC	8	0.4131	0.4592	0.5416
HUN	9	0.3842	0.5244	0.5812
IRL	10	0.3748	0.4058	0.2783
ITA	11	0.3888	0.3496	0.4763
LVA	12	0.1651	0.2750	0.3487

Avaliação do impacto da Inteligência Artificial no emprego Europeu

LTU	13	0.3946	0.6679	0.5440
LUX	14	0.4196	0.5543	0.4773
NLD	15	0.1236	0.2130	0.1641
POL	16	0.3912	0.4072	0.4742
PRT	17	0.3794	0.4033	0.4771
SVN	18	0.4345	0.6127	0.6928
ESP	19	0.3563	0.3463	0.4716
SWE	20	0.3734	0.1626	0.2064

Tabela 10 - Pesos por janela "Contributions to Open AI Projects"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.0000	0.0000	0.0000
BEL	2	0.0000	0.0000	0.0000
DNK	3	0.0000	0.0196	0.0000
EST	4	0.2803	0.2607	0.2744
FIN	5	0.2244	0.0000	0.0000
FRA	6	0.0000	0.0000	0.0478
DEU	7	1.0000	0.2971	0.3396
GRC	8	0.0000	0.0000	0.0000

Avaliação do impacto da Inteligência Artificial no emprego Europeu

HUN	9	0.0000	0.1152	0.0579
IRL	10	0.2114	0.2161	0.2797
ITA	11	0.0000	0.0000	0.0000
LVA	12	0.2550	0.2150	0.2342
LTU	13	0.1425	0.1597	0.2055
LUX	14	0.1042	0.0000	0.0000
NLD	15	0.0000	0.0000	0.0000
POL	16	0.0000	0.0552	0.0000
PRT	17	0.0000	0.0196	0.0000
SVN	18	0.2114	0.2066	0.2121
ESP	19	0.0000	0.0000	0.0579
SWE	20	0.0000	0.0000	0.3961

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Apêndice 3 – Pesos por anos

Tabela 11 - Pesos por ano “AI Reserch Productivity”

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.2302	0.1705	0.2427	0.2408	0.2431
BEL	2	0.2302	0.2256	0.2573	0.2817	0.2431
DNK	3	0.2302	0.2108	0.2315	0.2065	0.2431
EST	4	0.0000	0.0000	0.0000	0.0000	0.0000
FIN	5	0.0000	0.1361	0.1346	0.1367	0.2458
FRA	6	0.3648	0.2360	0.2476	0.2416	0.2549
DEU	7	0.0000	0.2297	0.2225	0.0000	0.0553
GRC	8	0.2607	0.1548	0.1737	0.1969	0.1494
HUN	9	0.1923	0.2302	0.1399	0.1513	0.1833
IRL	10	0.0000	0.0000	0.0000	0.0000	0.0000
ITA	11	0.2164	0.4291	0.3223	0.3879	0.3172
LVA	12	0.0000	0.0000	0.0000	0.0000	0.0000
LTU	13	0.0000	0.0000	0.0000	0.0000	0.0000
LUX	14	0.0000	0.0000	0.0000	0.0000	0.0000
NLD	15	0.2902	0.2276	0.2795	0.2935	0.2172
POL	16	0.2164	0.1578	0.1960	0.2142	0.2442
PRT	17	0.2164	0.2108	0.2243	0.2408	0.2431
SVN	18	0.0000	0.0000	0.0000	0.0000	0.0000
ESP	19	0.3114	0.2338	0.1811	0.2202	0.2477
SWE	20	0.2302	0.3052	0.0000	0.0000	0.2350

Tabela 12 - Pesos por ano “AI Talent Migration Trends”

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.1131	0.1131	0.2248	0.1297	0.1177
BEL	2	0.1131	0.0973	0.1932	0.1595	0.1177
DNK	3	0.1131	0.0787	0.1041	0.0469	0.1177

Avaliação do impacto da Inteligência Artificial no emprego Europeu

EST	4	0.2597	0.1656	0.1315	0.0400	0.0611
FIN	5	0.1926	0.0000	0.0000	0.0000	0.0000
FRA	6	0.5782	0.3546	0.4444	0.4255	0.3818
DEU	7	0.0000	0.0000	0.0000	0.0000	0.0000
GRC	8	0.2569	0.0509	0.0525	0.2526	0.0000
HUN	9	0.2242	0.1131	0.0735	0.0971	0.0000
IRL	10	0.0240	0.0240	0.0240	0.0477	0.0611
ITA	11	0.2456	0.0000	0.3779	0.3833	0.3064
LVA	12	0.3473	0.2947	0.1874	0.0683	0.0701
LTU	13	0.1870	0.1870	0.0932	0.0932	0.0000
LUX	14	0.0080	0.6638	0.1911	1.0000	0.0068
NLD	15	0.3203	0.1427	0.2059	0.2198	0.0000
POL	16	0.2456	0.1723	0.1797	0.2801	0.1440
PRT	17	0.2456	0.0787	0.0814	0.1297	0.1177
SVN	18	0.0000	0.0200	0.0240	0.0000	0.0932
ESP	19	0.3939	0.1258	0.1894	0.2913	0.1677
SWE	20	0.1131	0.2741	0.0000	0.0000	0.0000

Tabela 13 - Pesos por ano "Private AI Investments"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.0000	0.0000	0.1219	0.0000	0.0000
BEL	2	0.0000	0.0000	0.0000	0.0000	0.0000
DNK	3	0.0000	0.0000	0.0000	0.0000	0.0000
EST	4	0.0000	0.0000	0.0000	0.0000	0.0000
FIN	5	0.0000	0.0000	0.0000	0.0938	0.0000
FRA	6	0.0000	0.2140	0.2728	0.3090	0.2576
DEU	7	0.0000	0.0000	0.4010	0.0000	0.3125
GRC	8	0.0000	0.0000	0.0000	0.1573	0.1018
HUN	9	0.1975	0.2060	0.0836	0.1231	0.0000
IRL	10	0.0000	0.0000	0.0000	0.0000	0.0000
ITA	11	0.1468	0.0000	0.0000	0.0000	0.0000
LVA	12	0.2832	0.1496	0.1916	0.0000	0.0000
LTU	13	0.2559	0.2559	0.1729	0.1612	0.0559

Avaliação do impacto da Inteligência Artificial no emprego Europeu

LUX	14	0.0000	0.0000	0.1411	0.0000	0.0000
NLD	15	0.0000	0.0000	0.0000	0.0249	0.0046
POL	16	0.1468	0.1772	0.1488	0.1526	0.0000
PRT	17	0.1468	0.0000	0.0000	0.0000	0.0000
SVN	18	0.0000	0.0000	0.0000	0.0559	0.1612
ESP	19	0.0000	0.0000	0.1547	0.1735	0.0000
SWE	20	0.0000	0.0000	0.6232	0.0434	0.0000

Tabela 14 - Pesos por ano "ICT Workforce Availability"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.2833	0.2060	0.2979	0.2391	0.1914
BEL	2	0.2833	0.2814	0.2624	0.2730	0.1914
DNK	3	0.2833	0.2845	0.2514	0.2394	0.1914
EST	4	0.4582	0.4604	0.4177	0.4097	0.4163
FIN	5	0.3998	0.2793	0.1384	0.2707	0.3987
FRA	6	0.0000	0.0000	0.0000	0.0000	0.0000
DEU	7	0.0000	0.1009	0.0000	0.0000	0.0000
GRC	8	0.0000	0.0000	0.0000	0.0000	0.0000
HUN	9	0.0000	0.2833	0.1041	0.0000	0.0000
IRL	10	0.3898	0.2894	0.3606	0.4178	0.4163
ITA	11	0.0000	0.0000	0.0000	0.0000	0.0000
LVA	12	0.0000	0.4256	0.4302	0.3720	0.3418
LTU	13	0.0000	0.0000	0.0000	0.3828	0.1869
LUX	14	0.4683	0.0000	0.0000	0.0000	0.0000
NLD	15	0.3090	0.2558	0.3137	0.3463	0.2854
POL	16	0.0000	0.0000	0.0000	0.0000	0.2029
PRT	17	0.0000	0.2845	0.2519	0.2391	0.1914
SVN	18	0.4459	0.2736	0.2912	0.2849	0.0000
ESP	19	0.0000	0.2399	0.0000	0.0000	0.1540
SWE	20	0.2833	0.3394	0.3768	0.7802	0.3424

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Tabela 15 - Pesos por ano "AI Workforce Concentration"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.0000	0.0132	0.0000	0.0000	0.0000
BEL	2	0.0000	0.0000	0.0000	0.0000	0.0000
DNK	3	0.0000	0.0000	0.0000	0.0000	0.0000
EST	4	0.0000	0.0000	0.0217	0.0879	0.0335
FIN	5	0.1832	0.1678	0.5509	0.4282	0.3556
FRA	6	0.0000	0.0000	0.0000	0.0000	0.0000
DEU	7	0.0000	0.2638	0.6254	0.5156	0.6322
GRC	8	0.0750	0.3372	0.2699	0.0826	0.1476
HUN	9	0.0000	0.0879	0.2612	0.1272	0.1915
IRL	10	0.0000	0.0000	0.0000	0.1376	0.0335
ITA	11	0.0000	0.0000	0.0000	0.0000	0.0000
LVA	12	0.0000	0.0000	0.0000	0.0000	0.0000
LTU	13	0.0000	0.0000	0.2197	0.0000	0.0000
LUX	14	0.0000	0.0000	0.4906	0.0000	0.6073
NLD	15	0.0000	0.1444	0.1147	0.1333	0.2110
POL	16	0.0000	0.0000	0.0456	0.0000	0.0000
PRT	17	0.0000	0.0000	0.0000	0.0000	0.0000
SVN	18	0.0000	0.0000	0.0000	0.0000	0.0000
ESP	19	0.0000	0.0000	0.0000	0.0000	0.0000
SWE	20	0.0000	0.0000	0.0000	0.0000	0.2162

Tabela 16 - Pesos por ano "AI Hiring Trends"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.3734	0.5604	0.2933	0.3904	0.4477
BEL	2	0.3734	0.3957	0.2871	0.2858	0.4477
DNK	3	0.3734	0.4162	0.4130	0.4975	0.4477
EST	4	0.0000	0.1936	0.2616	0.2025	0.2068
FIN	5	0.0000	0.4168	0.4006	0.1413	0.0000
FRA	6	0.0570	0.1954	0.1057	0.0000	0.1057
DEU	7	0.0000	0.5063	0.0000	0.5179	0.0000
GRC	8	0.4074	0.4825	0.5214	0.3520	0.6012

Avaliação do impacto da Inteligência Artificial no emprego Europeu

HUN	9	0.3860	0.4822	0.4647	0.5498	0.6253
IRL	10	0.3748	0.4908	0.4077	0.1952	0.2068
ITA	11	0.3912	0.5709	0.4257	0.2288	0.3764
LVA	12	0.1651	0.2105	0.3470	0.3184	0.3296
LTU	13	0.3908	0.6954	0.5155	0.4832	0.5251
LUX	14	0.4196	0.6725	0.5024	0.0000	0.3859
NLD	15	0.0806	0.2294	0.1867	0.0920	0.2818
POL	16	0.3912	0.4652	0.4603	0.3531	0.4089
PRT	17	0.3912	0.4162	0.4424	0.3904	0.4477
SVN	18	0.5541	0.4962	0.7274	0.4690	0.5534
ESP	19	0.2947	0.4005	0.4554	0.3150	0.4307
SWE	20	0.3734	0.1626	0.0000	0.0000	0.2064

Tabela 17 - Pesos por ano "Contributions to Open AI Projects"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.0000	0.0000	0.0000	0.0000	0.0000
BEL	2	0.0000	0.0000	0.0000	0.0000	0.0000
DNK	3	0.0000	0.0196	0.0000	0.0196	0.0000
EST	4	0.2821	0.2772	0.2692	0.2600	0.2823
FIN	5	0.2244	0.0000	0.0000	0.0000	0.0000
FRA	6	0.0000	0.0000	0.0000	0.0478	0.0000
DEU	7	1.0000	0.3930	0.3633	0.2255	0.0000
GRC	8	0.0000	0.0000	0.0000	0.0000	0.0000
HUN	9	0.0000	0.1152	0.0579	0.0000	0.0000
IRL	10	0.2114	0.2078	0.2237	0.2706	0.2823
ITA	11	0.0000	0.0000	0.0000	0.0000	0.0000
LVA	12	0.2044	0.2376	0.2306	0.2414	0.2585
LTU	13	0.1663	0.1663	0.1340	0.1982	0.2321
LUX	14	0.1042	0.0000	0.0000	0.0000	0.0000
NLD	15	0.0000	0.0000	0.0000	0.0000	0.0000
POL	16	0.0000	0.0552	0.0000	0.0000	0.0000
PRT	17	0.0000	0.0196	0.0000	0.0000	0.0000
SVN	18	0.0000	0.2102	0.2114	0.2182	0.1921

Avaliação do impacto da Inteligência Artificial no emprego Europeu

ESP	19	0.0000	0.0000	0.0579	0.0000	0.0000
SWE	20	0.0000	0.0000	0.0000	0.3961	0.0000

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Apêndice 4 – Estatística descritiva dos pesos por indicador

Tabela 18 - Estatística descritiva "AI Reserch Productivity"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.0	0.2210	0.1640	0.2502	0.3491	0.0139	
2020-2022	0.0	0.0	0.1819	0.1545	0.2312	0.3763	0.0143	
2021-2023	0.0	0.0	0.2036	0.1535	0.2360	0.3194	0.0132	

Tabela 19 - Estatística descritiva "AI Talent Migration Trends"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.1178	0.1898	0.2049	0.2659	0.4897	0.0159	FRA
2020-2022	0.0	0.0196	0.1310	0.1557	0.2052	0.6638	0.0295	LUX
2021-2023	0.0	0.0869	0.1185	0.1399	0.1713	0.3954	0.0122	FRA, ITA, LUX

Tabela 20 - Estatística descritiva - "Private AI Investments"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.0	0.0666	0.1028	0.1480	0.5769	0.0197	SWE
2020-2022	0.0	0.0	0.0711	0.1401	0.2062	0.6523	0.0339	SWE
2021-2023	0.0	0.0	0.1109	0.1128	0.1298	0.4282	0.0145	DEU, SWE

Tabela 21 - Estatística descritiva "ICT Workforce Availability"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.0757	0.2838	0.2392	0.3599	0.4683	0.0282	
2020-2022	0.0	0.0000	0.2619	0.2175	0.3147	0.5636	0.0299	
2021-2023	0.0	0.0000	0.1917	0.1837	0.3161	0.4208	0.0213	

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Tabela 22 - Estatística descritiva "AI Workforce Concentration"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.0	0.0000	0.1382	0.2917	0.7256	0.0460	
2020-2022	0.0	0.0	0.0066	0.1329	0.1507	0.7724	0.0461	DEU, FIN, LUX
2021-2023	0.0	0.0	0.0168	0.0895	0.1187	0.4455	0.0188	DEU, LUX

Tabela 23 - Estatística descritiva "AI Hiring Trends"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.2758	0.3771	0.3231	0.3973	0.4345	0.0151	EST
2020-2022	0.1626	0.2971	0.4045	0.3997	0.4845	0.6679	0.0218	
2021-2023	0.1057	0.2881	0.4729	0.4131	0.4874	0.6928	0.0232	

Tabela 24 - Estatística descritiva "Contributions to Open AI Projects"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.0	0.0000	0.1215	0.2114	1.0000	0.0537	DEU
2020-2022	0.0	0.0	0.0098	0.0782	0.1714	0.2971	0.0112	
2021-2023	0.0	0.0	0.0239	0.1053	0.2176	0.3961	0.0187	

Apêndice 5 – Estatística descritiva *clusters*

Tabela 25 - Estatísticas por cluster

<i>Cluster</i>	<i>Média</i>	<i>Desvio Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>
1	0.0297	0.0280	-0.0175	0.0664
2	-0.0702	0.0864	-0.1980	-0.0118
3	-0.0057	0.0153	-0.0228	0.0111

Tabela 26 - Estatísticas descritivas por janela temporal e cluster

	2019-2021				2020-2022				2021-2023			
Cluster	Média	Desvio Padrão	Mínimo	Máximo	Média	Desvio Padrão	Mínimo	Máximo	Média	Desvio Padrão	Mínimo	Máximo
1	0.1073	0.0471	0.0145	0.1894	0.1340	0.0508	0.0224	0.2212	0.1370	0.0428	0.0280	0.1744
2	0.1068	0.1676	-0.0485	0.3428	0.0720	0.2112	-0.1737	0.3387	0.0366	0.2231	-0.2465	0.2956
3	-0.0435	0.0791	-0.1381	0.0495	-0.0656	0.0907	-0.1737	0.0402	-0.0493	0.0922	-0.1610	0.0519

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Apêndice 6 – Estatística descritiva dos pesos dos *clusters* por indicador

Tabela 27 - Métricas dos pesos por clusters "AI Research Productivity"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0	0.0	0.2019	0.1579	0.2352	0.3491	0.0152	
	2020-2022	0.0	0.0	0.1674	0.1428	0.2052	0.3763	0.0148	
	2021-2023	0.0	0.0	0.2018	0.1531	0.2360	0.3194	0.0140	
CLUSTER 2	2019-2021	0.0	0.0	0.1225	0.1258	0.2483	0.2582	0.0211	
	2020-2022	0.0	0.0	0.1081	0.1185	0.2266	0.2579	0.0190	
	2021-2023	0.0	0.0	0.0979	0.1222	0.2202	0.2931	0.0214	
CLUSTER 3	2019-2021	0.1237	0.2006	0.2435	0.2204	0.2633	0.2710	0.0045	
	2020-2022	0.1009	0.1919	0.2413	0.2257	0.2751	0.3191	0.0085	
	2021-2023	0.0553	0.1724	0.2232	0.1857	0.2366	0.2412	0.0077	DEU

Tabela 28 - Métricas dos pesos por clusters "AI Talent Migration Trends"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0240	0.1111	0.1697	0.1597	0.2016	0.3197	0.0079	
	2020-2022	0.0000	0.0196	0.0730	0.1159	0.1574	0.4111	0.0156	ITA
	2021-2023	0.0641	0.0932	0.1033	0.1277	0.1522	0.3064	0.0043	ITA
CLUSTER 2	2019-2021	0.2646	0.2685	0.2818	0.3139	0.3272	0.4275	0.0058	LUX
	2020-2022	0.1293	0.1443	0.1779	0.2872	0.3208	0.6638	0.0640	LUX
	2021-2023	0.1253	0.1651	0.1869	0.2177	0.2395	0.3716	0.0114	LUX
CLUSTER 3	2019-2021	0.0	0.1444	0.2178	0.2313	0.3047	0.4897	0.0406	
	2020-2022	0.0	0.0	0.0875	0.1436	0.2311	0.3993	0.0358	
	2021-2023	0.0	0.0	0.0	0.0989	0.0989	0.3954	0.0390	FRA

Tabela 29 - Métricas dos pesos por clusters "Private AI Investments"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0	0.0	0.0	0.0662	0.1468	0.2211	0.0071	
	2020-2022	0.0	0.0	0.0	0.0609	0.1484	0.2060	0.0083	
	2021-2023	0.0	0.0	0.0511	0.0572	0.1137	0.1261	0.0036	
CLUSTER 2	2019-2021	0.0	0.0	0.0734	0.0748	0.1482	0.1524	0.0074	
	2020-2022	0.0	0.0048	0.1067	0.1228	0.2246	0.2777	0.0199	
	2021-2023	0.0240	0.1000	0.1332	0.1205	0.1537	0.1916	0.0049	
CLUSTER 3	2019-2021	0.0000	0.1138	0.1929	0.2407	0.3197	0.5769	0.0596	
	2020-2022	0.1471	0.2425	0.3907	0.3952	0.5434	0.6523	0.0515	
	2021-2023	0.0406	0.2179	0.3094	0.2719	0.3635	0.4282	0.0276	

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Tabela 30 - Métricas dos pesos por clusters "ICT Workforce Availability"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0	0.0	0.2833	0.2159	0.3164	0.4550	0.0302	
	2020-2022	0.0	0.0883	0.2639	0.2182	0.3087	0.4427	0.0235	
	2021-2023	0.0	0.1402	0.1917	0.1770	0.1972	0.3915	0.0168	EST, GRC, HUN, IRL, ITA
CLUSTER 2	2019-2021	0.2003	0.2632	0.3631	0.3487	0.4485	0.4683	0.0163	
	2020-2022	0.0	0.2096	0.2953	0.2482	0.3339	0.4021	0.0300	LUX
	2021-2023	0.0	0.1155	0.2359	0.2034	0.3238	0.3418	0.0253	
CLUSTER 3	2019-2021	0.0	0.0757	0.2241	0.1995	0.3480	0.3499	0.0313	
	2020-2022	0.0	0.0	0.0881	0.1850	0.2731	0.5636	0.0706	
	2021-2023	0.0	0.0	0.1578	0.1841	0.3419	0.4208	0.0470	

Tabela 31 - Métricas dos pesos por clusters "AI Workforce Concentration"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0	0.0	0.0000	0.0799	0.0890	0.3516	0.0198	GRC, HUN, LTU
	2020-2022	0.0	0.0	0.0066	0.0650	0.1388	0.2229	0.0070	
	2021-2023	0.0	0.0	0.0000	0.0292	0.0365	0.1193	0.0020	GRC, HUN
CLUSTER 2	2019-2021	0.0	0.0	0.0928	0.2278	0.3206	0.7256	0.1177	
	2020-2022	0.0	0.0	0.0648	0.1734	0.2381	0.5638	0.0714	
	2021-2023	0.0	0.0	0.0590	0.1282	0.1872	0.3948	0.0346	
CLUSTER 3	2019-2021	0.0	0.0	0.2223	0.2238	0.4460	0.4504	0.0667	
	2020-2022	0.0	0.0	0.2061	0.2961	0.5022	0.7724	0.1385	
	2021-2023	0.0	0.1621	0.2407	0.2317	0.3103	0.4455	0.0335	

Tabela 32 - Métricas dos pesos por clusters "AI Hiring Trends"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0	0.3490	0.3818	0.3405	0.3921	0.4345	0.0138	AUT, BEL, EST
	2020-2022	0.1951	0.3899	0.4262	0.4372	0.4845	0.6679	0.0163	EST, LTU
	2021-2023	0.2478	0.4491	0.4767	0.4733	0.5422	0.6928	0.0145	EST, IRL, SVN
CLUSTER 2	2019-2021	0.1236	0.1547	0.2607	0.2662	0.3721	0.4196	0.0207	
	2020-2022	0.2130	0.2595	0.3106	0.3472	0.3983	0.5543	0.0220	
	2021-2023	0.1641	0.3025	0.4101	0.3654	0.4730	0.4773	0.0215	
CLUSTER 3	2019-2021	0.1250	0.3113	0.3895	0.3281	0.4063	0.4083	0.0185	FRA
	2020-2022	0.1626	0.1890	0.2952	0.3400	0.4463	0.6070	0.0419	
	2021-2023	0.1057	0.1812	0.2489	0.2803	0.3480	0.5179	0.0308	

Tabela 33 - Métricas dos pesos por clusters "Contributions to Open AI Projects"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0	0.0	0.0	0.0705	0.1597	0.2803	0.0116	
	2020-2022	0.0	0.0	0.0374	0.0877	0.1714	0.2607	0.0097	
	2021-2023	0.0	0.0	0.0	0.0858	0.2071	0.2797	0.0141	

Avaliação do impacto da Inteligência Artificial no emprego Europeu

CLUSTER 2	2019-2021	0.0	0.0	0.0521	0.0898	0.1419	0.2550	0.0145	
	2020-2022	0.0	0.0	0.0000	0.0538	0.0538	0.2150	0.0115	LVA
	2021-2023	0.0	0.0	0.0290	0.0730	0.1020	0.2342	0.0122	
CLUSTER 3	2019-2021	0.0	0.0	0.1122	0.3061	0.4183	1.0	0.2251	
	2020-2022	0.0	0.0	0.0	0.0743	0.0743	0.2971	0.0220	DEU
	2021-2023	0.0	0.0	0.1937	0.1959	0.3528	0.3961	0.0403	

Apêndice 7 – Folgas por janela temporal

Tabela 34 - Folgas por janela "AI Reserch Productivity"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.0000	0.0918	0.5532
BEL	2	0.3578	0.0942	0.4314
DNK	3	0.0000	0.0000	0.3672
EST	4	0.0000	0.0758	0.0844
FIN	5	0.3030	0.0000	0.0000
FRA	6	0.0864	0.0000	0.0000
DEU	7	0.0000	0.0000	0.0000
GRC	8	0.1640	0.0697	0.1792
HUN	9	0.0182	0.3771	0.0000
IRL	10	0.1495	0.1177	0.3144
ITA	11	0.0000	0.1241	0.0000
LVA	12	0.5028	0.6634	0.6686
LTU	13	0.0697	0.0000	0.3640
LUX	14	0.0000	0.0000	0.0000
NLD	15	0.0414	0.0920	0.0680
POL	16	0.2906	0.1350	0.4672
PRT	17	0.0000	0.0000	0.5505
SVN	18	0.0668	0.2726	0.0808
ESP	19	0.1701	0.1079	0.2108
SWE	20	0.0000	0.0000	0.0000

Tabela 35 - Folgas por janela "AI Talent Migration Trends"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.3609	0.5765	0.0285
BEL	2	0.0356	0.2370	0.1309
DNK	3	0.0071	0.3706	0.1943
EST	4	0.5374	0.8246	0.8306
FIN	5	0.0103	0.0000	0.0736
FRA	6	0.0719	0.0609	0.0491
DEU	7	0.0000	0.0000	0.0000

Avaliação do impacto da Inteligência Artificial no emprego Europeu

GRC	8	0.0113	0.0923	0.1181
HUN	9	0.1702	0.0667	0.0270
IRL	10	0.0038	0.3647	0.2837
ITA	11	0.0087	0.0427	0.0208
LVA	12	0.2207	0.2213	0.3689
LTU	13	0.3567	0.5789	0.0249
LUX	14	0.5692	0.0000	0.0000
NLD	15	0.1026	0.0180	0.0377
POL	16	0.0176	0.2504	0.0500
PRT	17	0.0087	0.3540	0.0404
SVN	18	0.0010	0.0426	0.0049
ESP	19	0.0564	0.0406	0.0499
SWE	20	0.0039	0.0014	0.0000

Tabela 36 - Folgas por janela "Private AI Investments"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.1445	0.4201	0.3169
BEL	2	0.2454	0.0784	0.2786
DNK	3	0.2581	0.1061	0.2128
EST	4	0.1339	0.0000	0.0000
FIN	5	0.5989	0.0000	0.1169
FRA	6	0.1252	0.1139	0.1420
DEU	7	0.0000	0.0000	0.0000
GRC	8	0.1147	0.3651	0.1125
HUN	9	0.0773	0.3322	0.0409
IRL	10	0.4586	0.7875	0.3002
ITA	11	0.0257	0.1888	0.0909
LVA	12	0.5594	0.3033	0.3200
LTU	13	0.1505	0.1905	0.2137
LUX	14	0.1845	0.0000	0.0000
NLD	15	0.4024	0.1245	0.0160
POL	16	0.1694	0.1294	0.2641
PRT	17	0.0674	0.1259	0.3499

Avaliação do impacto da Inteligência Artificial no emprego Europeu

SVN	18	0.1616	0.3960	0.0175
ESP	19	0.0631	0.1868	0.0835
SWE	20	0.8429	0.7397	0.0000

Tabela 37 - Folgas por janela "ICT Workforce Availability"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.1966	0.3757	0.0373
BEL	2	0.0000	0.1688	0.0848
DNK	3	0.0000	0.0299	0.0177
EST	4	0.0320	0.1778	0.1470
FIN	5	0.0000	0.0000	0.0153
FRA	6	0.1130	0.1917	0.2051
DEU	7	0.0000	0.0000	0.0000
GRC	8	0.3358	0.5336	0.4218
HUN	9	0.1448	0.2211	0.1279
IRL	10	0.1515	0.1794	0.1050
ITA	11	0.0246	0.1642	0.0164
LVA	12	0.4328	0.1940	0.2488
LTU	13	0.2912	0.3315	0.1223
LUX	14	0.0353	0.0000	0.0000
NLD	15	0.0304	0.0682	0.0186
POL	16	0.1487	0.2114	0.1590
PRT	17	0.0712	0.1801	0.0694
SVN	18	0.0000	0.3582	0.0993
ESP	19	0.0952	0.1936	0.0727
SWE	20	0.0703	0.0843	0.0000

Tabela 38 - Folgas por janela "AI Workforce Concentration"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.2321	0.2796	0.3805
BEL	2	0.2364	0.3183	0.4568
DNK	3	0.1837	0.3281	0.3030

Avaliação do impacto da Inteligência Artificial no emprego Europeu

EST	4	0.2447	0.4239	0.3423
FIN	5	0.0000	0.0000	0.0000
FRA	6	0.2287	0.1651	0.1577
DEU	7	0.0000	0.0000	0.0000
GRC	8	0.1583	0.1114	0.2926
HUN	9	0.1626	0.3432	0.0240
IRL	10	0.1091	0.2748	0.2730
ITA	11	0.0464	0.3677	0.1188
LVA	12	0.4883	0.4258	0.6273
LTU	13	0.2422	0.3313	0.2608
LUX	14	0.1150	0.0000	0.0000
NLD	15	0.1281	0.1005	0.0561
POL	16	0.2366	0.3152	0.4358
PRT	17	0.2130	0.3709	0.4452
SVN	18	0.0190	0.1464	0.0000
ESP	19	0.1704	0.1617	0.4349
SWE	20	0.0800	0.0647	0.0000

Tabela 39 - Folgas por janela "AI Hiring Trends"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.1138	0.1038	0.0207
BEL	2	0.3249	0.2048	0.1291
DNK	3	0.2190	0.1740	0.1278
EST	4	0.5107	0.1615	0.1605
FIN	5	0.0577	0.0000	0.0000
FRA	6	0.0513	0.0802	0.0884
DEU	7	0.0000	0.0000	0.0000
GRC	8	0.2339	0.1660	0.2294
HUN	9	0.3590	0.2203	0.2958
IRL	10	0.1272	0.0689	0.1313
ITA	11	0.0842	0.1064	0.1868
LVA	12	0.2688	0.3560	0.1248
LTU	13	0.0879	0.2604	0.2583

Avaliação do impacto da Inteligência Artificial no emprego Europeu

LUX	14	0.0802	0.0000	0.0000
NLD	15	0.0732	0.0182	0.0121
POL	16	0.3922	0.1956	0.0949
PRT	17	0.3680	0.2256	0.1070
SVN	18	0.3087	0.0602	0.4008
ESP	19	0.1159	0.1400	0.0630
SWE	20	0.0393	0.0000	0.0000

Tabela 40 - Folgas por janela "Contributions to Open AI Projects"

País	DMU	2019-2021	2020-2022	2021-2023
AUT	1	0.2706	0.2025	0.7572
BEL	2	0.3488	0.2649	0.5158
DNK	3	0.1704	0.3061	0.2963
EST	4	0.0117	0.0847	0.0670
FIN	5	0.2918	0.0000	0.0221
FRA	6	0.1741	0.0923	0.0884
DEU	7	0.0000	0.0000	0.0000
GRC	8	0.2927	0.0602	0.2414
HUN	9	0.1258	0.3122	0.0963
IRL	10	0.0028	0.0533	0.3097
ITA	11	0.0205	0.2130	0.0715
LVA	12	0.3432	0.6284	0.5671
LTU	13	0.0099	0.0180	0.4397
LUX	14	0.0021	0.0000	0.0000
NLD	15	0.2485	0.2044	0.2241
POL	16	0.4510	0.1944	0.4922
PRT	17	0.2393	0.2228	0.5096
SVN	18	0.0267	0.1275	0.0621
ESP	19	0.5499	0.0978	0.3401
SWE	20	0.0075	0.0056	0.0000

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Apêndice 8 – Folgas por anos

Tabela 41 - Folgas por anos "AI Reserch Productivity"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.0000	0.0000	0.5746	0.3303	0.5161
BEL	2	0.0000	0.0000	0.3863	0.2710	0.0000
DNK	3	0.0000	0.0000	0.3672	0.0000	0.0000
EST	4	0.0000	0.0119	0.0262	0.1893	0.0375
FIN	5	0.3030	0.0000	0.0000	0.0000	0.0000
FRA	6	0.0589	0.0000	0.1139	0.0000	0.0000
DEU	7	0.0000	0.0000	0.0000	0.0000	0.0000
GRC	8	0.2807	0.0300	0.0000	0.1268	0.1792
HUN	9	0.0000	0.1366	0.7760	0.1003	0.0000
IRL	10	0.0627	0.1520	0.2910	0.0018	0.5358
ITA	11	0.0000	0.0000	0.0000	0.1241	0.0000
LVA	12	0.5082	0.9844	0.6619	0.5008	0.0400
LTU	13	0.0697	0.0000	0.0572	0.9007	0.1340
LUX	14	0.0000	0.0000	0.0000	0.0000	0.0000
NLD	15	0.0513	0.0316	0.0998	0.0285	0.0000
POL	16	0.2615	0.2274	0.0000	0.4641	0.4703
PRT	17	0.0000	0.0000	0.0000	0.5501	0.5509
SVN	18	0.0000	0.1022	0.1617	0.2420	0.1013
ESP	19	0.0000	0.0959	0.2079	0.2419	0.2310
SWE	20	0.0000	0.0000	0.0000	0.0000	0.0000

Tabela 42 - Folgas por anos "AI Talent Migration Trends"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.3789	0.0000	0.3126	0.0458	0.0216
BEL	2	0.0067	0.1781	0.1705	0.0290	0.2781
DNK	3	0.0073	0.1924	0.2334	0.3703	0.2853
EST	4	0.6021	0.7298	0.6828	0.7677	0.9322
FIN	5	0.0103	0.0000	0.0000	0.0736	0.0000
FRA	6	0.0799	0.0804	0.0341	0.0866	0.0296
DEU	7	0.0000	0.0000	0.0000	0.0000	0.0000

Avaliação do impacto da Inteligência Artificial no emprego Europeu

GRC	8	0.0148	0.0482	0.0701	0.1551	0.0331
HUN	9	0.0031	0.0078	0.1920	0.0665	0.0641
IRL	10	0.0051	0.0030	0.0335	0.7261	0.0310
ITA	11	0.0013	0.0000	0.0185	0.0413	0.0233
LVA	12	0.0060	0.0342	0.2267	0.3391	0.9998
LTU	13	0.0001	0.4765	0.5857	0.3120	0.0058
LUX	14	0.5692	0.0000	0.0000	0.0000	0.0000
NLD	15	0.1693	0.0848	0.0135	0.0005	0.0575
POL	16	0.0204	0.0779	0.1165	0.1836	0.0613
PRT	17	0.0090	0.1690	0.1267	0.2099	0.0625
SVN	18	0.0000	0.0019	0.0600	0.0046	0.0066
ESP	19	0.1131	0.0177	0.0479	0.0431	0.0622
SWE	20	0.0068	0.0012	0.0000	0.0000	0.0000

Tabela 43 - Folgas por ano "Private AI Investments"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.1702	0.0918	0.1580	0.5510	0.3865
BEL	2	0.2135	0.1232	0.2573	0.2167	0.1420
DNK	3	0.2676	0.1776	0.2094	0.1785	0.1230
EST	4	0.1523	0.1460	0.1034	0.0000	0.0000
FIN	5	0.5989	0.0000	0.0000	0.1169	0.0000
FRA	6	0.1252	0.0000	0.1139	0.0000	0.1700
DEU	7	0.0000	0.0000	0.0000	0.0000	0.0000
GRC	8	0.1926	0.0909	0.0715	0.5427	0.1026
HUN	9	0.0222	0.3041	0.1965	0.0281	0.0623
IRL	10	0.1587	0.4296	0.6521	0.0000	0.2191
ITA	11	0.0000	0.0000	0.0221	0.2282	0.0847
LVA	12	0.9954	0.4305	0.3549	0.3063	0.0144
LTU	13	0.0000	0.1337	0.1855	0.2929	0.0189
LUX	14	0.1845	0.0000	0.0000	0.0000	0.0000
NLD	15	0.3360	0.2425	0.2170	0.0000	0.0000
POL	16	0.2120	0.1193	0.1338	0.2457	0.3458
PRT	17	0.0429	0.1084	0.0912	0.2234	0.3909

Avaliação do impacto da Inteligência Artificial no emprego Europeu

SVN	18	0.0000	0.1072	0.1579	0.4964	0.0233
ESP	19	0.0419	0.0130	0.0811	0.1807	0.2219
SWE	20	0.7997	0.8129	0.0000	0.0000	0.0000

Tabela 44 - Folgas por ano "ICT Workforce Availability"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.2067	0.0000	0.1884	0.2236	0.0000
BEL	2	0.0000	0.0883	0.0000	0.4181	0.0848
DNK	3	0.0000	0.0537	0.0062	0.0000	0.0177
EST	4	0.0734	0.1177	0.1550	0.0828	0.1312
FIN	5	0.0000	0.0000	0.0000	0.0153	0.0000
FRA	6	0.1181	0.1388	0.1738	0.2071	0.1982
DEU	7	0.0000	0.0000	0.0000	0.0000	0.0000
GRC	8	0.3527	0.3495	0.3648	0.6771	0.3735
HUN	9	0.0892	0.2120	0.2052	0.1118	0.1288
IRL	10	0.0000	0.0494	0.2537	0.1050	0.0000
ITA	11	0.0246	0.0000	0.0000	0.0903	0.0000
LVA	12	0.7313	0.1791	0.2239	0.1866	0.4925
LTU	13	0.1317	0.3749	0.3030	0.1829	0.0000
LUX	14	0.0353	0.0000	0.0000	0.0000	0.0000
NLD	15	0.0000	0.0682	0.0304	0.0000	0.0186
POL	16	0.1997	0.1315	0.1766	0.2303	0.1045
PRT	17	0.1018	0.1059	0.0998	0.1514	0.0746
SVN	18	0.0000	0.1940	0.0000	0.2843	0.1523
ESP	19	0.1009	0.0000	0.0556	0.2192	0.0896
SWE	20	0.0725	0.0761	0.0000	0.0000	0.0000

Tabela 45 - Folgas por ano "AI Workforce Concentration"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.3589	0.0635	0.3720	0.2837	0.2914
BEL	2	0.1868	0.2475	0.3883	0.3811	0.4256
DNK	3	0.2140	0.2836	0.3249	0.1631	0.3622

Avaliação do impacto da Inteligência Artificial no emprego Europeu

EST	4	0.3330	0.3812	0.3190	0.3555	0.2694
FIN	5	0.0000	0.0000	0.0000	0.0000	0.0000
FRA	6	0.2771	0.1746	0.1891	0.1689	0.1231
DEU	7	0.0000	0.0000	0.0000	0.0000	0.0000
GRC	8	0.1583	0.0000	0.0000	0.2020	0.0000
HUN	9	0.0294	0.1801	0.2791	0.0126	0.0000
IRL	10	0.0787	0.0867	0.2092	0.3877	0.1276
ITA	11	0.0371	0.0000	0.0539	0.3920	0.1370
LVA	12	0.4574	0.4856	0.4617	0.5518	0.7066
LTU	13	0.0573	0.3248	0.2363	0.4099	0.0000
LUX	14	0.1150	0.0000	0.0000	0.0000	0.0000
NLD	15	0.1699	0.1545	0.0917	0.0038	0.0000
POL	16	0.3067	0.2783	0.2448	0.4179	0.4924
PRT	17	0.2221	0.2272	0.2525	0.5304	0.5924
SVN	18	0.0000	0.0632	0.0421	0.2667	0.0000
ESP	19	0.1515	0.0085	0.2051	0.4858	0.5455
SWE	20	0.1011	0.0618	0.0000	0.0000	0.0000

Tabela 46 - Folgas por ano "AI Hiring Trends"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.0095	0.0859	0.1266	0.0613	0.0130
BEL	2	0.3274	0.2368	0.2584	0.1118	0.1464
DNK	3	0.0399	0.1890	0.2941	0.1501	0.1281
EST	4	0.5137	0.3377	0.2792	0.1553	0.1608
FIN	5	0.0577	0.0000	0.0000	0.0000	0.0000
FRA	6	0.0000	0.0693	0.0703	0.0915	0.0937
DEU	7	0.0000	0.0000	0.0000	0.0000	0.0000
GRC	8	0.0000	0.1133	0.1770	0.3373	0.2218
HUN	9	0.2421	0.4607	0.2692	0.3665	0.1616
IRL	10	0.2455	0.0000	0.0088	0.1290	0.1335
ITA	11	0.0161	0.0000	0.1507	0.1350	0.1675
LVA	12	0.2067	0.1807	0.2921	0.3210	0.1624
LTU	13	0.0124	0.0000	0.1717	0.3669	0.3186

Avaliação do impacto da Inteligência Artificial no emprego Europeu

LUX	14	0.0802	0.0000	0.0000	0.0000	0.0000
NLD	15	0.0000	0.0182	0.0732	0.0132	0.0110
POL	16	0.0000	0.0977	0.2272	0.1877	0.1089
PRT	17	0.3310	0.2375	0.2721	0.2098	0.0599
SVN	18	0.0000	0.2229	0.1207	0.2708	0.3707
ESP	19	0.1640	0.1341	0.1191	0.0864	0.0507
SWE	20	0.0454	0.0332	0.0000	0.0000	0.0000

Tabela 47 - Folgas por ano "Contributions to Open AI Projects"

País	DMU	2019	2020	2021	2022	2023
AUT	1	0.2892	0.2386	0.4532	0.4414	0.7179
BEL	2	0.2366	0.2906	0.5047	0.3751	0.3068
DNK	3	0.1711	0.2391	0.3479	0.1788	0.2676
EST	4	0.0026	0.0126	0.0119	0.1615	0.0315
FIN	5	0.2918	0.0000	0.0000	0.0221	0.0000
FRA	6	0.1784	0.1317	0.1032	0.0958	0.1215
DEU	7	0.0000	0.0000	0.0000	0.0000	0.0000
GRC	8	0.4666	0.2511	0.1222	0.1386	0.3614
HUN	9	0.1006	0.1081	0.3473	0.0694	0.1051
IRL	10	0.0000	0.0000	0.1101	0.1039	0.5005
ITA	11	0.0174	0.0000	0.0188	0.4121	0.0715
LVA	12	0.1571	0.9001	0.6044	0.4216	0.0025
LTU	13	0.0010	0.0061	0.0145	0.4153	0.0783
LUX	14	0.0021	0.0000	0.0000	0.0000	0.0000
NLD	15	0.3084	0.2403	0.2247	0.1659	0.2357
POL	16	0.5279	0.2832	0.2642	0.4457	0.6342
PRT	17	0.2393	0.1525	0.2027	0.5193	0.7243
SVN	18	0.0000	0.1033	0.0415	0.0930	0.0846
ESP	19	0.0000	0.0000	0.3502	0.2697	0.4282
SWE	20	0.0000	0.0065	0.0000	0.0000	0.0000

Apêndice 9 – Estatística descritiva das folgas por indicador

Tabela 48 - Estatística descritiva "AI Research Productivity"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.0	0.0541	0.1110	0.1655	0.5028	0.0215	LVA
2020-2022	0.0	0.0	0.0838	0.1111	0.1193	0.6634	0.0266	HUN, LVA
2021-2023	0.0	0.0	0.1318	0.2170	0.3833	0.6686	0.0516	

Tabela 49 - Estatística descritiva "AI Talent Migration Trends"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.0083	0.0266	0.1277	0.1828	0.5692	0.0338	EST, LUX
2020-2022	0.0	0.0349	0.0795	0.2072	0.3567	0.8246	0.0566	
2021-2023	0.0	0.0239	0.0448	0.1167	0.1213	0.8306	0.0380	EST, IRL, LVA

Tabela 50 - Estatística descritiva "Private AI Investments"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.1054	0.1561	0.2392	0.2942	0.8429	0.049	FIN, SWE
2020-2022	0.0	0.0991	0.1581	0.2294	0.3405	0.7875	0.051	IRL, SWE
2021-2023	0.0	0.0171	0.1147	0.1438	0.2678	0.3499	0.016	

Tabela 51 - Estatística descritiva "ICT Workforce Availability"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.0184	0.0707	0.1087	0.1494	0.4328	0.0152	LVA
2020-2022	0.0	0.0803	0.1797	0.1832	0.2139	0.5336	0.0191	GRC
2021-2023	0.0	0.0174	0.0787	0.0984	0.1326	0.4218	0.0109	GRC

Tabela 52 - Estatística descritiva "AI Workforce Concentration"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.1018	0.1665	0.1647	0.2332	0.4883	0.0128	LVA
2020-2022	0.0	0.1086	0.2772	0.2264	0.3343	0.4258	0.0210	
2021-2023	0.0	0.0180	0.2669	0.2304	0.3941	0.6273	0.0391	

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Tabela 53 - Estatística descritiva "AI Hiring Trends"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.0784	0.1215	0.1908	0.3128	0.5107	0.0212	
2020-2022	0.0	0.0497	0.1232	0.1271	0.1979	0.3560	0.0101	
2021-2023	0.0	0.0186	0.1159	0.1215	0.1671	0.4008	0.0122	SVN

Tabela 54 - Estatística descritiva "Contributions to Open AI Projects"

Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
2019-2021	0.0	0.0113	0.1723	0.1794	0.2920	0.5499	0.0285	
2020-2022	0.0	0.0445	0.1126	0.1544	0.2155	0.6284	0.0233	LVA
2021-2023	0.0	0.0657	0.2327	0.2550	0.4528	0.7572	0.0523	

Apêndice 10 – Estatística descritiva das folgas dos *clusters* por indicador

Tabela 55 - Métricas das folgas por cluster "AI Research Productivity"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0	0.0	0.0425	0.0930	0.1531	0.3578	0.0152	
	2020-2022	0.0	0.0523	0.0930	0.1132	0.1268	0.3771	0.0125	HUN, SVN
	2021-2023	0.0	0.0835	0.3392	0.2827	0.4403	0.5532	0.0424	
CLUSTER 2	2019-2021	0.0	0.0311	0.1058	0.1786	0.2533	0.5028	0.0519	
	2020-2022	0.0	0.0690	0.1000	0.2158	0.2468	0.6634	0.0912	LVA
	2021-2023	0.0	0.0510	0.1394	0.2369	0.3252	0.6686	0.0905	
CLUSTER 3	2019-2021	0.0	0.0	0.0432	0.0973	0.1405	0.3030	0.0204	
	2020-2022	0.0	0.0	0.0	0.0	0.0	0.0	0.0	
	2021-2023	0.0	0.0	0.0	0.0	0.0	0.0	0.0	

Tabela 56 - Métricas das folgas por cluster "AI Talent Migration Trends"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0010	0.0083	0.0145	0.1266	0.2168	0.5374	0.0349	EST
	2020-2022	0.0426	0.0859	0.3022	0.3168	0.4221	0.8246	0.0613	
	2021-2023	0.0049	0.0265	0.0452	0.1462	0.1467	0.8306	0.0535	EST
CLUSTER 2	2019-2021	0.0564	0.0911	0.1616	0.2372	0.3078	0.5692	0.0537	
	2020-2022	0.0	0.0135	0.0293	0.0700	0.0858	0.2213	0.0104	LVA
	2021-2023	0.0	0.0283	0.0438	0.1141	0.1296	0.3689	0.0292	LVA
CLUSTER 3	2019-2021	0.0	0.0029	0.0071	0.0215	0.0257	0.0719	0.0011	FRA
	2020-2022	0.0	0.0	0.0007	0.0156	0.0162	0.0609	0.0009	FRA
	2021-2023	0.0	0.0	0.0246	0.0307	0.0552	0.0736	0.0013	

Tabela 57 - Métricas das folgas por cluster "Private AI Investments"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0257	0.1054	0.1475	0.1673	0.1884	0.4586	0.0129	IRL
	2020-2022	0.0	0.1209	0.1896	0.2600	0.3729	0.7875	0.0461	IRL
	2021-2023	0.0	0.0784	0.2132	0.1832	0.2840	0.3499	0.0156	
CLUSTER 2	2019-2021	0.0631	0.1541	0.2934	0.3023	0.4416	0.5594	0.0490	
	2020-2022	0.0	0.0934	0.1556	0.1536	0.2159	0.3033	0.0159	
	2021-2023	0.0	0.0120	0.0498	0.1049	0.1427	0.3200	0.0218	
CLUSTER 3	2019-2021	0.0	0.0939	0.3621	0.3918	0.6599	0.8429	0.1569	
	2020-2022	0.0	0.0	0.0570	0.2134	0.2704	0.7397	0.1259	SWE
	2021-2023	0.0	0.0	0.0584	0.0647	0.1231	0.1420	0.0056	

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Tabela 58 - Métricas das folgas por cluster "ICT Workforce Availability"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	0.0	0.0184	0.1080	0.1164	0.1628	0.3358	0.0133		0.0
	0.0299	0.1756	0.1958	0.2443	0.3382	0.5336	0.0176		0.0299
	0.0164	0.0613	0.1022	0.1173	0.1326	0.4218	0.0114	GRC	0.0164
CLUSTER 2	0.0304	0.0341	0.0653	0.1484	0.1796	0.4328	0.0368	LVA	0.0304
	0.0	0.0511	0.1309	0.1139	0.1937	0.1940	0.0092		0.0
	0.0	0.0139	0.0456	0.0850	0.1167	0.2488	0.0128		0.0
CLUSTER 3	0.0	0.0	0.0351	0.0458	0.0810	0.1130	0.0031		0.0
	0.0	0.0	0.0421	0.0690	0.1111	0.1917	0.0082		0.0
	0.0	0.0	0.0076	0.0551	0.0627	0.2051	0.0100	FRA	0.0

Tabela 59 - Métricas das folgas por cluster "AI Workforce Concentration"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0190	0.1460	0.1983	0.1737	0.2365	0.2447	0.0061	
	2020-2022	0.1114	0.2784	0.3232	0.3009	0.3493	0.4239	0.0081	GRC, SVN
	2021-2023	0.0	0.2253	0.2978	0.2777	0.3943	0.4568	0.0243	
CLUSTER 2	2019-2021	0.115	0.1249	0.1492	0.2255	0.2499	0.4883	0.0312	LVA
	2020-2022	0.0	0.0754	0.1311	0.1720	0.2277	0.4258	0.0330	
	2021-2023	0.0	0.0421	0.2455	0.2796	0.4830	0.6273	0.0910	
CLUSTER 3	2019-2021	0.0	0.0	0.0400	0.0772	0.1172	0.2287	0.0116	
	2020-2022	0.0	0.0	0.0324	0.0575	0.0898	0.1651	0.0060	
	2021-2023	0.0	0.0	0.0	0.0394	0.0394	0.1577	0.0062	FRA

Tabela 60 - Métricas das folgas por cluster "AI Hiring Trends"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0842	0.1238	0.2713	0.2608	0.3613	0.5107	0.0191	
	2020-2022	0.0602	0.1058	0.1700	0.1623	0.2087	0.2604	0.0041	
	2021-2023	0.0207	0.1226	0.1459	0.1785	0.2366	0.4008	0.0106	
CLUSTER 2	2019-2021	0.0732	0.0784	0.0981	0.1345	0.1542	0.2688	0.0083	LVA
	2020-2022	0.0	0.0137	0.0791	0.1286	0.1940	0.3560	0.0268	
	2021-2023	0.0	0.0091	0.0376	0.0500	0.0785	0.1248	0.0032	
CLUSTER 3	2019-2021	0.0	0.0294	0.0453	0.0371	0.0529	0.0577	0.0006	
	2020-2022	0.0	0.0	0.0	0.0201	0.0201	0.0802	0.0016	FRA
	2021-2023	0.0	0.0	0.0	0.0221	0.0221	0.0884	0.0019	FRA

Avaliação do impacto da Inteligência Artificial no emprego Europeu

Tabela 61 - Métricas das folgas por cluster "Contributions to Open AI Projects"

	Period	Min	Q1	Median	Mean	Q3	Max	Variance	Outliers
CLUSTER 1	2019-2021	0.0028	0.0183	0.1481	0.1642	0.2761	0.4510	0.0239	
	2020-2022	0.0180	0.0786	0.1984	0.1716	0.2334	0.3122	0.0101	
	2021-2023	0.0621	0.0901	0.3030	0.3216	0.4966	0.7572	0.0507	
CLUSTER 2	2019-2021	0.0021	0.1869	0.2958	0.2859	0.3949	0.5499	0.0516	
	2020-2022	0.0	0.0733	0.1511	0.2326	0.3104	0.6284	0.0765	
	2021-2023	0.0	0.1680	0.2821	0.2828	0.3968	0.5671	0.0558	
CLUSTER 3	2019-2021	0.0	0.0056	0.0908	0.1184	0.2036	0.2918	0.0198	
	2020-2022	0.0	0.0	0.0028	0.0245	0.0272	0.0923	0.0020	FRA
	2021-2023	0.0	0.0	0.0110	0.0276	0.0386	0.0884	0.0017	