



ESCOLA  
SUPERIOR  
DE SAÚDE  
DE LISBOA



POLITÉCNICO  
DE LISBOA

POLYTECHNIC  
UNIVERSITY  
OF LISBON



UAlg **ESS**  
UNIVERSIDADE DO ALGARVE  
ESCOLA SUPERIOR DE SAÚDE

**INSTITUTO POLITÉCNICO DE LISBOA**  
**ESCOLA SUPERIOR DE SAÚDE DE LISBOA**

TECNOLOGIA INVISÍVEL E IMPACTOS VISÍVEIS: DESAFIOS E  
IMPLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL E AUTOMAÇÃO  
NO NOVO LABORATÓRIO DE PATOLOGIA CLÍNICA DO  
HOSPITAL DE LISBOA ORIENTAL.

Marta Sofia Alves Leitão do Carmo

Professor Doutor André Filipe Coelho – Escola Superior de Saúde de Lisboa

Professor Doutor Paulo Jorge Esguedelhado Monteiro – Escola Superior de  
Saúde de Lisboa

Mestrado em Gestão e Avaliação de Tecnologias em Saúde

Lisboa, 2025

**INSTITUTO POLITÉCNICO DE LISBOA**  
**ESCOLA SUPERIOR DE SAÚDE DE LISBOA**

**TECNOLOGIA INVISÍVEL E IMPACTOS VISÍVEIS: DESAFIOS E  
IMPLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL E AUTOMAÇÃO  
NO NOVO LABORATÓRIO DE PATOLOGIA CLÍNICA DO  
HOSPITAL DE LISBOA ORIENTAL**

**MARTA SOFIA ALVES LEITÃO DO CARMO**

**Orientadores:**

Doutor André Filipe Coelho – Escola Superior de Saúde de Lisboa

Doutor Paulo Jorge Esguedelhado Monteiro - Escola Superior de Saúde de Lisboa

**Júri:**

Presidente - Doutor Rui Miguel Plácido Raposo – Escola Superior de Saúde da  
Universidade do Algarve

Arguente - Doutora Daniela Ferreira Santos - Instituto de Engenharia de Sistemas e  
Computadores, Tecnologia e Ciência

**Mestrado em Gestão e Avaliação de Tecnologias em Saúde**

(esta versão incluiu as críticas e sugestões feitas pelo júri)

Lisboa, 2025

A Escola Superior de Saúde Lisboa, Instituto Politécnico de Lisboa e a Escola Superior de Saúde da Universidade do Algarve têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito aos autores e que tal não viole nenhuma restrição imposta por artigos publicados que estejam incluídos neste trabalho.



## **AGRADECIMENTOS**

A realização desta dissertação de mestrado contou com importantes apoios e incentivos sem os quais não se teria tornado uma realidade e aos quais estarei eternamente grata.

Em primeiro lugar, agradeço aos meus orientadores, Professor Doutor André Coelho, Professor Doutor Paulo Monteiro e à consultora Professora Doutora Cátia Pesquita, pela disponibilidade, paciência e tempo dedicados a esta tese. A vossa orientação, conhecimento e apoio foram fundamentais para transformar ideias dispersas num trabalho estruturado e consistente.

Ao Dr. Carlos Flores e à minha coordenadora, Dra. Ana Canas, deixo o meu sincero agradecimento por me facilitarem a realização desta investigação, mesmo nos momentos mais burocráticos (e complexos).

Às minhas colegas de trabalho Anabela, Filipa, Joana e Lina, o meu muito obrigada pelo incentivo, pela paciência e por compreenderem as minhas ausências, físicas e mentais, sempre que estava mergulhada no mundo da tese.

Aos meus filhos, Lourenço e Alice, por toda a paciência e carinho, mesmo quando estive mais ausente para me dedicar a este projeto. Vocês são a minha maior motivação.

Ao meu marido, Rafael, pelo incentivo constante a investir na minha formação e pela cumplicidade nesta “loucura” de estarmos ambos a estudar ao mesmo tempo.

Aos meus pais, ao meu irmão e à minha sogra, que foram o meu braço direito, permitindo-me frequentar este mestrado e apoiando-me em tudo o que foi preciso.

A todos vocês, o meu sincero obrigado. Esta conquista é minha, mas também é um pouco vossa.

## RESUMO

A integração crescente da Inteligência Artificial (IA) e da automação nos laboratórios de Patologia Clínica está a transformar a eficiência, a precisão do diagnóstico e os processos organizacionais na área da patologia clínica. Esta dissertação mapeia e analisa as perceções e atitudes dos profissionais da Unidade Local de Saúde São José relativamente à adoção destas tecnologias no novo Laboratório de Patologia Clínica do Hospital de Lisboa Oriental.

Com uma abordagem mista, foram recolhidos dados quantitativos de um questionário (n=118) e qualitativos de entrevistas semiestruturadas (n=9). A análise estatística e a segmentação por *clusters* identificaram três perfis atitudinais: reticentes (23%), entusiastas (23%) e ambivalentes (54%). A análise temática confirmou benefícios percecionados, como poupança de tempo, redução de erros e otimização do fluxo de trabalho, e evidenciou desafios como interoperabilidade, limitações infraestruturais e questões éticas.

Os resultados revelam elevada predisposição para formação, com uma média de 4,38 numa escala de *Likert* de 1 (discordo totalmente) a 5 (concordo totalmente), evidenciando uma atitude marcadamente positiva entre os profissionais. As perspetivas de liderança reforçam a inevitabilidade estratégica da IA e a sua importância na modernização hospitalar e na equidade de acesso a diagnósticos avançados.

Conclui-se que a adoção da IA em contexto laboratorial exige um equilíbrio entre a robustez tecnológica e a implementação de políticas de formação, comunicação e ética que reforcem a confiança dos profissionais, assegurando uma integração sustentada nos processos clínicos.

**Palavras-chave:** *Inteligência Artificial; Patologia Clínica; Automação Laboratorial; Saúde Digital; Atitude dos Profissionais de Saúde.*

## **ABSTRACT**

The growing integration of Artificial Intelligence (AI) and automation in clinical pathology laboratories is transforming efficiency, diagnostic accuracy, and organizational processes in the field of clinical pathology. This dissertation identifies and analyzes the perceptions and attitudes of professionals at ULS S. José regarding the adoption of these technologies for the new Clinical Pathology Laboratory of the future Hospital de Lisboa Oriental.

Using a mixed-methods approach, quantitative data were collected from a questionnaire (n=118) and qualitative data from semi-structured interviews (n=9). Statistical analysis and *cluster* segmentation identified three attitudinal profiles: reluctant (23%), enthusiastic (23%), and ambivalent (54%). Thematic analysis confirmed perceived benefits such as time savings, error reduction, and workflow optimization, while highlighting challenges such as interoperability, infrastructural limitations, and ethical concerns.

The results reveal a strong willingness to undergo training, with a mean score of 4.38 on a *Likert* scale from 1 (“strongly disagree”) to 5 (“strongly agree”), demonstrating a clearly positive attitude among professionals. Leadership perspectives reinforce the strategic inevitability of AI and its importance in hospital modernization and in ensuring equitable access to advanced diagnostics.

It is concluded that the adoption of AI in laboratory contexts requires a balance between technological robustness and the implementation of training, communication, and ethical policies that strengthen professionals’ trust, thereby ensuring a sustainable integration into clinical processes.

**Keywords:** *Artificial Intelligence; Pathology, Clinical; Laboratory Automation; Digital Health; Attitude of Health Personnel*



## ÍNDICE GERAL

Agradecimentos .....	v
Resumo .....	vi
Abstract .....	vii
Índice Geral .....	ix
Índice de Tabelas .....	xii
Índice de Figuras .....	xiii
Lista de Abreviaturas e Acrónimos .....	xiv

INTRODUÇÃO .....	1
------------------	---

CAPÍTULO 1 — ENQUADRAMENTO TEÓRICO E REGULATÓRIO .....	4
--	---

1.1 Inteligência Artificial: Definição e Delimitação Conceptual .....	4
---	---

1.2 Breve Contexto Histórico da Inteligência Artificial .....	6
---	---

1.3 Estado da Arte e Tendências Atuais da Inteligência Artificial na Saúde .....	7
--	---

1.4 Aplicabilidade da Inteligência Artificial nos Laboratórios Clínicos .....	8
---	---

1.4.1 Inteligência Artificial Aplicada à Patologia Clínica .....	9
--	---

1.5 Quadro Ético e Regulatório da Inteligência Artificial em Saúde: Perspetiva Portuguesa e Europeia .....	11
--	----

1.5.1 Princípios Éticos Fundamentais .....	11
--	----

1.5.2 Quadro Regulatório Europeu .....	12
--	----

1.5.3 Enquadramento Legal e Institucional em Portugal .....	12
---	----

1.5.4 Desafios Éticos Emergentes .....	13
--	----

1.6 Inteligência Artificial Explicável e Interoperabilidade Semântica em Saúde .....	14
--	----

CAPÍTULO 2 — METODOLOGIA .....	18
--------------------------------	----

2.1 Pergunta de investigação e desenho de estudo .....	18
--	----

2.2 Objetivo Geral .....	18
--------------------------	----

2.2.1 Objetivos Específicos .....	18
-----------------------------------	----

2.3 Tipo de Estudo .....	19
--------------------------	----

2.4 População e Amostra .....	19
-------------------------------	----

2.5 Elaboração e Validação dos Instrumentos de Recolha de Dados .....	20
---	----

2.5.1 Operacionalização das Variáveis do Estudo .....	21
---	----

2.6 Recolha de Dados .....	24
----------------------------	----

2.7 Tratamento de Dados e Análise Estatística .....	25
---	----

2.7.1 Análise Univariada .....	25
--------------------------------	----

2.7.2 Análise Fatorial Exploratória .....	26
---	----

2.7.3 Construção de Fatores e Avaliação de Fiabilidade .....	26
--	----

2.7.4	Análise de <i>Clusters</i> .....	27
2.7.5	Análise Bivariada ( <i>Crosstabs</i> ) .....	27
2.7.6	Entrevistas Semiestruturadas .....	27
2.8	Considerações Éticas .....	27
CAPÍTULO 3 — RESULTADOS .....		29
3.1	Caracterização da Amostra .....	29
3.2	Descrição das Variáveis Sociodemográficas e Profissionais .....	29
3.3	Conhecimento e Experiência com Tecnologias Emergentes .....	31
3.3.1	Contacto Prévio, Formação e Utilização Atual .....	31
3.3.2	Áreas de Conhecimento Declarado .....	31
3.4	Percepções sobre Benefícios da Inteligência Artificial e Automação .....	32
3.4.1	Precisão, Padronização e Redução de Erros .....	32
3.4.2	Eficiência e Otimização de Recursos .....	32
3.4.3	Impacto Direto no Trabalho dos Profissionais .....	33
3.5	Desafios Técnicos .....	33
3.5.1	Limitações Estruturais e Organizacionais .....	33
3.5.2	Competências e Confiança Tecnológica .....	34
3.6	Desafios Éticos .....	34
3.6.1	Riscos para a Prática Profissional e Privacidade .....	34
3.6.2	Participação e Envolvimento nas Decisões .....	35
3.7	Aceitação e Confiança na Tecnologia .....	35
3.7.1	Conforto e Confiança na Utilização da Inteligência Artificial .....	36
3.7.2	Percepções sobre o Impacto da Automação e da IA .....	36
3.7.3	Motivação e Predisposição para Formação .....	37
3.7.4	Obstáculos e Áreas de Maior Impacto .....	37
3.8	Análise Fatorial e Segmentação por <i>Clusters</i> .....	38
3.9	Análise Bivariada: Contacto Prévio com IA e Pertença ao Cluster .....	39
3.10	Análise das Entrevistas .....	40
3.10.1	Caracterização da Amostra Qualitativa .....	40
3.10.2	Eixos Temáticos .....	40
3.10.3	Integração com <i>Clusters</i> Quantitativos .....	42
CAPÍTULO 4 — DISCUSSÃO .....		44
CAPÍTULO 5 — CONCLUSÃO .....		49
REFERÊNCIAS BIBLIOGRÁFICAS .....		51
ANEXOS .....		xvii
Anexo 1 – Aprovação CTC, ESTeSL .....		xvii

Anexo 2 – Aprovação Conselho de Ética, ESTeSL .....	xviii
Anexo 3 – Aprovação Conselho de Administração, ULS S. José .....	xix
APÊNDICES .....	xx
Apêndice A – Resultados do Pré-teste do Questionário .....	xx
Apêndice B – Inquérito por Questionário .....	xi
Apêndice C – Análise Fatorial e de <i>Clusters</i> .....	xxxvi
Apêndice D – Análise detalhada por questão .....	lxiv
Apêndice E – Guião de Entrevistas .....	lxxxvi
Apêndice F– Análise Individual por Entrevistado (MAXQDA) .....	lxxxviii
Apêndice G – Plano de Ação para Implementação da IA no Laboratório de Patologia Clínica .....	xcii

## ÍNDICE DE TABELAS

Tabela 1 — Aplicações da Inteligência Artificial em Patologia Clínica .....	11
Tabela 2 — Síntese dos princípios éticos da UE e enquadramento legal aplicável à IA em saúde .....	14
Tabela 3 — Operacionalização das variáveis do estudo .....	21
Tabela 4 — Operacionalização do guião das entrevistas .....	24
Tabela 5 — Caracterização da amostra .....	30
Tabela 6 — Contacto prévio, participação em formação e utilização atual de IA em laboratório .....	31
Tabela 7 — Distribuição das respostas sobre precisão, redução de erros e padronização dos processos .....	32
Tabela 8 — Distribuição das respostas sobre eficiência e otimização de recursos ....	33
Tabela 9 — Distribuição das respostas sobre limitações estruturais e organizacionais .....	34
Tabela 10 — Distribuição das respostas sobre competências e confiança tecnológica .....	34
Tabela 11 — Distribuição das respostas sobre riscos profissionais e éticos .....	35
Tabela 12 — Distribuição das respostas sobre participação nas decisões .....	35
Tabela 13 — Distribuição das respostas sobre conforto e confiança na utilização da IA .....	36
Tabela 14 — Perceções globais sobre o impacto da IA e automação .....	36
Tabela 15 — Motivação e predisposição .....	37
Tabela 16 — Fatores e Clusters identificados .....	39
Tabela 17 — Associação entre contacto prévio com IA e pertença ao Cluster .....	40
Tabela 18 — Frequência dos eixos temáticos nas entrevistas (n=9) .....	41

## ÍNDICE DE FIGURAS

Figura 1 - "Volume Anual de Publicações de Inteligência Artificial na Saúde".....	8
Figura 2 - Áreas de conhecimento tecnológico declaradas pelos profissionais .....	31
Figura 3 - Distribuição dos eixos temáticos identificados nas entrevistas (n=9) .....	41

*Nota: As tabelas apresentadas nos Apêndices mantêm a numeração sequencial utilizada no corpo do texto. Por esse motivo, não constam do Índice de Tabelas nem Figuras principal, estando organizadas exclusivamente na secção dos Apêndices.*

## LISTA DE ABREVIATURAS E ACRÓNIMOS

**AFE** – Análise Fatorial Exploratória

**AI Act** – *Artificial Intelligence Act*

**CNPD** – Comissão Nacional de Proteção de Dados

**DL** – *Deep Learning*

**DGS** – Direção-Geral da Saúde

**EC** – *European Commission* (Comissão Europeia)

**EHDS** - *European Health Data Space*

**ERS** – Entidade Reguladora da Saúde

**GPU** – *Graphics Processing Unit* (Unidade de Processamento Gráfico)

**HCC** – Hospital Curry Cabral

**HDE** – Hospital D. Estefânia

**HIS** – *Hospital Information System* (Sistema de Informação Hospitalar)

**HLO** – Hospital de Lisboa Oriental

**HSAC** – Hospital Santo António dos Capuchos

**HSJ** – Hospital de São José

**HSM** – Hospital de Santa Marta

**IA** – Inteligência Artificial (AI - *Artificial Intelligence*)

**LIME** - *Local Interpretable Model-agnostic Explanations*

**LIS** – *Laboratory Information System* (Sistema de Informação Laboratorial)

**LOINC** - *Logical Observation Identifiers Names and Codes*

**MAC** – Maternidade Alfredo da Costa

**ML** – *Machine Learning*

**MLP** – *Multilayer Perceptron* (Perceptron Multicamada)

**NLP** – *Natural Language Processing* (Processamento de Linguagem Natural)

**OGMS** – *Ontology for General Medical Science*

**OMS** – Organização Mundial da Saúde (WHO – *World Health Organization*)

**PNDS** – Plano Nacional de Saúde Digital

**RGPD** – Regulamento Geral sobre a Proteção de Dados

**SHAP** - *SHapley Additive exPlanations*

**SNS** - Serviço Nacional de Saúde

**SPC** – Serviço de Patologia Clínica

**SNOMED CT** - *Systematized Nomenclature of Medicine – Clinical Terms*

**TAM** – *Technology Acceptance Model*

**TSDT** – Técnicos Superiores de Diagnóstico e Terapêutica

**ULS** – Unidade Local de Saúde

**XAI** – *Explainable Artificial Intelligence* (Inteligência Artificial Explicável)

**$\chi^2$**  – Qui-quadrado (Chi-squared test)



## INTRODUÇÃO

A adoção crescente de tecnologias baseadas em Inteligência Artificial (IA) e automação no setor da saúde representa uma mudança estrutural profunda, com repercussões significativas na prática clínica e laboratorial. Ferramentas como *machine learning* (ML) e *deep learning* (DL) têm demonstrado elevada eficácia na análise de grandes volumes de dados, acelerando a tomada de decisão e aumentando a precisão do diagnóstico. Tal como sublinhado por Pinsky et al. (2024), estas tecnologias “têm o potencial de transformar a monitorização em tempo real e a tomada de decisão crítica, especialmente em ambientes laboratoriais”.

Com base nos contributos de Russell & Norvig (2021) e Jiang et al. (2017), e para efeitos desta investigação, a IA será delimitada como o conjunto de técnicas computacionais capazes de realizar inferência automatizada a partir de dados laboratoriais e clínicos, com foco particular em modelos de aprendizagem automática aplicados à automação de fluxos laboratoriais, interpretação de resultados e apoio à decisão diagnóstica, tendo como premissas basilares a segurança, equidade, explicabilidade e eficiência clínica.

Nos laboratórios de patologia clínica, estas inovações são particularmente úteis na automação de processos repetitivos, na gestão e no processamento de amostras, bem como no controlo de qualidade. Paralelamente, a integração da IA em plataformas de apoio à decisão clínica tem viabilizado diagnósticos mais personalizados e alinhados com os princípios da medicina de precisão (Grassini & Salsedo, 2023; Maccaro et al., 2023).

Apesar deste potencial, a sua implementação enfrenta obstáculos que vão além da componente técnica. Questões como a explicabilidade dos algoritmos, a proteção de dados de saúde e o risco de enviesamento merecem atenção especial.

Neste contexto, assume particular relevância o *Artificial Intelligence Act* (AI Act) da União Europeia, que classifica a IA aplicada à saúde como tecnologia de alto risco e estabelece critérios rigorosos de supervisão humana, transparência e segurança de dados (Cansado, 2024; European Commission, 2021). Estas exigências são especialmente críticas em laboratórios de patologia clínica, onde decisões automatizadas podem impactar diretamente o diagnóstico e tratamento dos doentes. Também a nível organizacional, destaca-se a importância de capacitar os profissionais de saúde e de os envolver ativamente na introdução destas soluções, mitigando resistências e promovendo uma adoção sustentada (Gerlich, 2023; Ahmad & Aziz, 2021; WHO, 2021).

A compreensão da evolução técnica e ética da IA na saúde, bem como do respetivo enquadramento legal, é essencial para contextualizar a presente investigação. Dado o cenário real da Unidade Local de Saúde São José (ULS S. José), onde sistemas de automação laboratorial e algoritmos de validação assistida já se encontram implementados, torna-se pertinente analisar empiricamente as perceções dos profissionais de saúde, os impactos práticos e as inquietações éticas associadas a estas novas tecnologias. A presente dissertação toma como objeto de investigação a ULS S. José, entidade que integrará a futura estrutura do Hospital de Lisboa Oriental (HLO). Este centro hospitalar reúne seis unidades de referência com relevância clínica e histórica: Hospital de São José (HSJ), Hospital de Santa Marta (HSM), Hospital de Santo António dos Capuchos (HSAC), Hospital D. Estefânia (HDE), Maternidade Alfredo da Costa (MAC) e Hospital Curry Cabral (HCC). Estes polos constituem um dos principais eixos de prestação de cuidados de saúde da região de Lisboa, abrangendo áreas como, urgência, cuidados intensivos, cirurgia, hospital de dia, maternidade e pediatria.

No seu funcionamento, o Serviço de Patologia Clínica (SPC) desempenha um papel transversal, sendo essencial na deteção, monitorização e tratamento de patologias. O diagnóstico laboratorial representa uma peça central na cadeia de cuidados, garantindo qualidade e segurança da decisão clínica. A ULS S. José já apresenta um grau significativo de maturidade digital, com sistemas de automação laboratorial e algoritmos de validação assistida, integrados em plataformas *Laboratory Information System (LIS)* interoperáveis com registos clínicos eletrónicos.

A transição para o HLO implica, além da construção de uma nova infraestrutura moderna, uma reestruturação profunda da prática laboratorial. A consolidação de recursos humanos e tecnológicos, numa única unidade, visa aumentar a escala e a eficiência operacional, tornando inevitável a adoção de soluções avançadas de IA e automação (Topol, 2019; Li et al., 2024; Davenport & Kalakota, 2019). Este novo paradigma assenta na substituição progressiva de processos manuais por fluxos automatizados, com validação assistida e integração digital dos resultados (LeCun et al., 2015; Rajkomar et al., 2019). Como referem alguns autores, a IA é essencial para enfrentar a pressão crescente sobre os sistemas laboratoriais, reduzir erros humanos e permitir decisões mais rápidas e seguras, sobretudo em contextos de elevada complexidade (Buess et al., 2025; Shaik et al., 2023).

Este ecossistema, marcado pela diversidade clínica e pela sofisticação tecnológica, constitui um ambiente privilegiado para estudar a adoção de modelos de IA em contexto hospitalar. A coexistência de processos tradicionais com soluções inovadoras oferece

uma oportunidade concreta para analisar impactos, desafios e potencialidades da IA na prática laboratorial, com implicações diretas na melhoria dos cuidados prestados.

O objetivo central desta investigação é mapear e explorar analiticamente as perceções dos profissionais da ULS S. José sobre a introdução de sistemas de IA e automação no novo Laboratório de Patologia Clínica do HLO. Pretende-se analisar benefícios, limitações e implicações éticas, compreendendo tanto as oportunidades técnicas, como os receios organizacionais e humanos.

Este estudo propõe-se contribuir para a exploração da relação entre inovação tecnológica e responsabilidade ética em saúde. Após esta introdução, a dissertação organiza-se em cinco capítulos: o primeiro dedica-se ao enquadramento teórico e regulatório; o segundo apresenta a metodologia; o terceiro expõe os resultados empíricos; o quarto procede à sua discussão à luz da literatura; e o quinto reúne as conclusões e recomendações para uma implementação ética, inclusiva e sustentável da IA e automação no novo Laboratório de Patologia Clínica do HLO.

## **CAPÍTULO 1 – ENQUADRAMENTO TEÓRICO e REGULATÓRIO**

Este capítulo dedica-se à exploração da IA a partir da sua fundamentação conceptual, estabelecendo os principais princípios que sustentam esta tecnologia emergente. Numa primeira etapa, procede-se à análise crítica do estado da arte, evidenciando as áreas onde a IA tem vindo a demonstrar maior aplicabilidade, com especial destaque para o setor da saúde. Numa segunda etapa, é traçado um breve percurso evolutivo da IA, contextualizando as suas principais transformações e avanços ao longo das últimas décadas.

A abordagem proposta suporta-se na revisão da literatura científica relevante sobre o tema, abre o caminho para a apresentação dos objetivos do estudo e enquadra os restantes capítulos do presente trabalho.

### **1.1 Inteligência Artificial: definição e delimitação conceptual**

A IA pode ser definida como o domínio da ciência computacional que desenvolve sistemas com a capacidade de realizar tarefas que, tradicionalmente, requerem inteligência humana, tais como raciocínio, aprendizagem, reconhecimento de padrões e tomada de decisão (Russell & Norvig, 2021). No contexto da saúde, a IA manifesta-se como um conjunto de técnicas, incluindo *ML*, *DL*, *natural language processing (NLP)* e raciocínio baseado em conhecimento, aplicadas à análise e interpretação de grandes volumes de dados clínicos e biomédicos com o objetivo de apoiar decisões clínicas, personalizar tratamentos e otimizar processos assistenciais e administrativos (Jiang et al., 2017).

A aplicação da IA à saúde tem-se revelado particularmente promissora em diversas áreas clínicas, onde algoritmos de *DL demonstram* desempenho equivalente ao de especialistas humanos (Esteva et al., 2019). Do ponto de vista sistémico, a IA tem potencial para reconfigurar a prática clínica, não substituindo os profissionais de saúde, mas amplificando as suas capacidades cognitivas e libertando-os de tarefas repetitivas ou burocráticas, contribuindo assim para um modelo de cuidados mais humano e centrado no doente (Topol, 2019).

Contudo, a adoção da IA em saúde deve ser acompanhada por uma análise crítica e multidisciplinar dos seus impactos éticos, legais e sociais. A explicabilidade dos modelos, a transparência algorítmica, a robustez dos dados utilizados e a equidade no acesso às soluções tecnológicas são desafios centrais para a integração responsável da IA em contextos clínicos (Morley et al., 2020).

No contexto da saúde, a IA assume uma relevância crescente, sobretudo devido à sua capacidade de processar, correlacionar e extrair conhecimento útil a partir de grandes volumes de dados biomédicos heterogéneos.

A IA abrange uma diversidade de técnicas e abordagens, que podem ser agrupadas em subdomínios distintos:

- *Machine Learning*: sistema de algoritmos capazes de identificar padrões a partir de dados históricos e ajustar os seus parâmetros para melhorar o desempenho preditivo. Como salientam Rajkomar, Dean & Kohane (2019), o *ML* tem sido uma das ferramentas mais promissoras na transformação da medicina baseada em dados, sobretudo na estratificação de risco e no diagnóstico automatizado.
- *Deep Learning*: técnica avançada de *ML* baseada em redes neuronais artificiais profundas, particularmente eficaz na análise de dados não estruturados, como imagens, sinais e linguagem natural (Esteva et al., 2017).
- Aprendizagem supervisionada e não supervisionada: distinção metodológica essencial no desenvolvimento de modelos de IA, sendo a primeira orientada por variáveis-alvo conhecidas (ex: diagnósticos anteriores) e a segunda focada na identificação de estruturas ou agrupamentos latentes nos dados (Topol, 2019).
- Processamento de Linguagem Natural (PLN): permite a extração e interpretação de informação semântica a partir de textos clínicos, com potencial para automatizar relatórios médicos e melhorar a interoperabilidade entre sistemas de saúde (Chen & Asch, 2017).

É fundamental distinguir, do ponto de vista conceptual, entre sistemas baseados em regras explícitas, com lógica predeterminada (ex: motores de decisão clínicos tradicionais), e sistemas baseados em aprendizagem estatística, cuja lógica é indutiva e frequentemente opaca, característica frequentemente referida como *black-box IA* (Amann et al., 2020). Esta distinção é crítica em contextos clínicos, onde a explicabilidade (*explainability*) e a transparência algorítmica são requisitos fundamentais para garantir a confiança dos profissionais e a segurança do doente (London, 2019).

No domínio da saúde, a IA não é uma tecnologia isolada, mas sim um ecossistema computacional que depende da qualidade, representatividade e gestão dos dados. A sua implementação em ambientes clínicos exige uma infraestrutura tecnológica robusta, interoperável com sistemas existentes (ex: Laboratory Information System (*LIS*), *Hospital Information System (HIS)*), bem como modelos regulatórios claros que contemplem aspetos éticos, jurídicos e sociais (*European Commission*, 2019; *WHO*, 2020).

## 1.2 Breve Contexto Histórico da Inteligência Artificial

A trajetória da IA, enquanto campo científico, é marcada por ciclos de entusiasmo, avanços disruptivos e períodos de estagnação, os denominados “*AI winters*”<sup>1</sup>. A compreensão da sua evolução histórica é essencial para contextualizar o seu estado atual e as suas aplicações emergentes em domínios como a saúde.

O termo *Artificial Intelligence* foi estabelecido formalmente em 1956, durante a conferência de *Dartmouth* organizada por *John McCarthy*, *Marvin Minsky*, *Claude Shannon* e *Nathaniel Rochester*, que delinearam uma proposta ambiciosa: desenvolver máquinas capazes de simular todas as facetas da aprendizagem e inteligência humanas (Russell & Norvig, 2021).

Nas décadas de 1960 e 1970, os primeiros sistemas baseados em regras, conhecidos como sistemas especialistas, emergiram como uma das primeiras materializações práticas da IA. Ferramentas como o *MYCIN*, desenvolvido na Universidade de *Stanford* para diagnosticar infeções bacterianas, demonstraram o potencial da IA em contextos médicos, embora limitadas pela sua incapacidade de lidar com incerteza e ambiguidade (Shortliffe, 1976).

Durante os anos 1980, registou-se um novo impulso com a introdução de métodos de representação do conhecimento, mas também a emergência de limitações críticas, nomeadamente a escalabilidade e a dependência de conhecimento explícito, que levaram ao primeiro período de desinvestimento em IA - *AI winter*.

A viragem paradigmática ocorreu a partir dos anos 2000, com o ressurgimento do *Machine Learning* sustentado pelo crescimento exponencial do poder computacional, do armazenamento de dados e da disponibilidade de *datasets* massivos (*big data*). A introdução das redes neurais profundas, impulsionada por avanços em *hardware* gráfico (Graphics Processing Unit - GPUs), culminou na consolidação do *DL* cuja

---

<sup>1</sup> “*AI winters*” referem-se a períodos históricos de estagnação e desinvestimento no campo da Inteligência Artificial, marcados por uma quebra nas expectativas, financiamento e avanços técnicos, geralmente após fases de entusiasmo exagerado. Estes ciclos ocorreram sobretudo nas décadas de 1970 e final dos anos 1980, quando as promessas da IA não corresponderam às suas aplicações práticas. (Russell & Norvig, 2021; Hendler, 2008)

eficácia foi amplamente demonstrada em tarefas complexas como o reconhecimento de imagem e voz (LeCun, Bengio & Hinton, 2015).

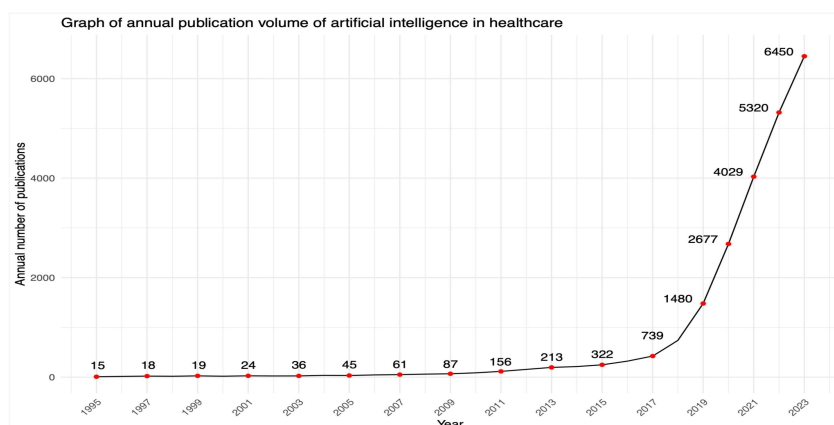
Na década de 2010, o campo da IA expandiu-se exponencialmente, com aplicações clínicas cada vez mais sofisticadas. Modelos preditivos passaram a ser aplicados em diagnóstico automatizado, triagem de utentes, análise de imagem médica e estratificação de risco, especialmente em áreas como oncologia, cardiologia e patologia clínica (Topol, 2019; Rajkomar et al., 2019).

Atualmente, a IA em saúde é moldada por dois vetores centrais: por um lado, o seu potencial transformador, e por outro, os desafios éticos, regulatórios e operacionais que acompanham a sua implementação. A OMS (2020) e a Comissão Europeia (2019) alertam para a necessidade de adotar princípios de *IA confiável (trustworthy AI)*, que inclua explicabilidade, robustez técnica, segurança de dados e justiça algorítmica.

### **1.3 Estado da Arte e Tendências Atuais da Inteligência Artificial na Saúde**

A IA consolidou-se como uma força transformadora na saúde, graças ao progresso em algoritmos de *ML*, ao aumento da capacidade computacional e à crescente disponibilidade de dados clínicos. Desde os primeiros sistemas baseados em regras até aos modelos modernos de aprendizagem profunda, a IA permite aplicações que abarcam desde o diagnóstico assistido até à otimização da gestão hospitalar (Topol, 2019; Davenport & Kalakota, 2019).

Os estudos bibliométricos indicam um crescimento robusto na produção científica sobre IA na saúde ao longo das últimas três décadas: entre 1990 e 2023, as publicações aumentaram exponencialmente, com destaque para os Estados Unidos e a China como principais centros de investigação (Agarwal et al., 2023; Shen et al., 2024). Este aumento reflete não só o interesse académico, mas também a adoção prática da IA em diversas especialidades clínicas, incluindo radiologia, patologia, gastroenterologia, cardiologia, oncologia e medicina laboratorial (Agaewal et al., 2023; Gómez-González et al., 2020; Topol, 2019)" conforme ilustrado na figura 1.



**Figura 1** - "Volume Anual de Publicações de Inteligência Artificial na Saúde: Uma Análise Bibliométrica de 30 Anos". (Adaptado de Xie, X., 2024)

#### 1.4 Aplicabilidade da Inteligência Artificial nos Laboratórios Clínicos

A aplicabilidade da Inteligência Artificial nos laboratórios clínicos decorre da convergência de três fatores: o acesso a grandes volumes de dados, o aumento da capacidade computacional e a sofisticação de algoritmos de *ML* e *DL* (Topol, 2019; Jiang et al., 2017). Uma das áreas mais exploradas é o apoio ao diagnóstico clínico, onde sistemas de visão computacional têm demonstrado desempenhos comparáveis ou superiores aos de especialistas humanos na interpretação de exames de imagem, como radiografias, ressonâncias magnéticas e tomografias (Esteva et al., 2017; Rajpurkar et al., 2018). Estes algoritmos não só permitem aumentar a precisão do diagnóstico como também reduzir o tempo de análise e a sobrecarga de trabalho dos profissionais.

Outra dimensão relevante é a predição e monitorização de risco, nomeadamente através de modelos que analisam dados eletrónicos de saúde para antecipar a evolução de doenças crónicas, prever readmissões hospitalares ou identificar padrões de risco cardiovascular (Rajkomar et al., 2019). Estas ferramentas contribuem para práticas médicas mais proativas e personalizadas, alinhadas com os princípios da medicina preditiva.

A IA tem igualmente impacto na descoberta de fármacos e no desenvolvimento de terapias personalizadas, ao acelerar a identificação de moléculas com potencial terapêutico e ao otimizar ensaios clínicos com base em dados genómicos e biomarcadores (Vamathevan et al., 2019).

No plano organizacional, destaca-se a aplicação da IA em gestão hospitalar e otimização de recursos, incluindo sistemas de triagem automatizada, previsão de procura de serviços e melhoria na alocação de camas e equipas médicas (Shickel et al., 2018). Estas soluções permitem aumentar a eficiência operacional e reduzir custos, enquanto melhoram a experiência do utente.

Apesar do elevado potencial, importa sublinhar que estas aplicações devem ser avaliadas criticamente quanto à sua validade externa, escalabilidade e impacto ético, de modo a garantir que a adoção da tecnologia se traduz em ganhos efetivos para os sistemas de saúde e para os utentes (WHO, 2021).

#### **1.4.1 Inteligência Artificial Aplicada à Patologia Clínica**

Para efeitos desta dissertação, entende-se por Inteligência Artificial, no contexto da patologia clínica, o conjunto de sistemas computacionais baseados em algoritmos de *machine learning*, *deep learning* e processamento de linguagem natural, aplicados a tarefas como validação automatizada de resultados, classificação morfológica de células sanguíneas e apoio à decisão clínica laboratorial. Por automação entende-se a utilização de sistemas robóticos e de *software* que executam de forma autónoma tarefas físicas e processuais do fluxo laboratorial, como a receção, triagem, processamento e distribuição de amostras, sem necessidade de intervenção humana direta em cada etapa.

No contexto específico do Serviço de Patologia Clínica da ULS S. José, estas tecnologias encontram-se já parcialmente implementadas. Na área da hematologia, o analisador *Sysmex XR*, com suporte do *middleware IPU*, integra capacidades de automação do fluxo analítico com algoritmos de validação assistida, permitindo a triagem automatizada de amostras e a geração de alertas morfológicos. O *SP-50* prepara automaticamente os esfregaços de sangue periférico, ajustando o ângulo de extensão da lâmina em função do hematócrito de cada amostra. Após coloração, as lâminas são processadas pelo *DI-60*, um digitalizador automático desenvolvido pela CellaVision que recorre a algoritmos de *deep learning* para pré-classificar morfológicamente as células sanguíneas (CellaVision, 2024). A validação final é realizada pelo Técnico Superior de Diagnóstico e Terapêutica (TSDT) em Análises Clínicas ou Médico Patologista, que revê, corrige e aprova a classificação sugerida pelo sistema, um modelo que se enquadra nos princípios da Inteligência Artificial Explicável (XAI), na medida em que a decisão algorítmica é auditável, transparente e sujeita a supervisão humana (Amann et al., 2020). Estas soluções constituem exemplos concretos da convergência entre automação laboratorial e IA aplicada à patologia clínica, e representam o referencial tecnológico que enquadra a presente investigação. Ambos os conceitos, IA e automação são operacionalizados neste estudo através das perceções dos profissionais relativamente à sua utilidade, impacto e aceitação, medidas pelos instrumentos descritos na secção 2.5.1.

A patologia clínica destaca-se como uma das áreas laboratoriais mais recetivas à aplicação de IA, em virtude da elevada complexidade dos dados gerados e da necessidade de padronização e escalabilidade dos processos (Topol, 2019). A literatura recente evidencia avanços expressivos nos domínios da hematologia, microbiologia clínica, imunologia e bioquímica clínica, com impacto direto na precisão do diagnóstico e na eficiência operacional (Xie, 2024; Mencacci et al., 2023). Na hematologia digital, algoritmos de *deep learning* têm demonstrado elevada capacidade na classificação automática de células sanguíneas, reduzindo erros de interpretação e acelerando o diagnóstico de condições hematológicas (Chatterjee et al., 2021). Na microbiologia clínica, modelos preditivos permitem antecipar perfis de resistência antimicrobiana com base em padrões históricos e dados genómicos, contribuindo para uma utilização mais racional dos antibióticos (Arango-Argoty et al., 2018). Outra frente em expansão é a interpretação automatizada de biomarcadores complexos, como perfis hormonais e imunológicos, que suportam a estratificação de risco e o seguimento personalizado de doentes crónicos. Destaca-se ainda o desenvolvimento de sistemas de validação automatizada de resultados laboratoriais, baseados em *machine learning* e adaptados a dados locais, permitindo ajustar critérios de validação à realidade específica de cada instituição (Chen & Asch, 2017).

Não obstante o potencial, diversos autores sublinham a necessidade de uma adoção crítica e responsável. Amann et al. (2020) referem que a falta de explicabilidade pode comprometer a confiança dos profissionais, enquanto London (2019) enfatiza os princípios da justiça e da auditabilidade como fundamentais em decisões clínicas mediadas por IA. Em consonância, a OMS (WHO, 2020) defende que os sistemas de IA em saúde devem ser seguros, robustos, explicáveis e sensíveis ao contexto local — dimensão particularmente relevante para a integração eficaz em realidades diversas, como a da ULS S. José.

Para sintetizar as principais contribuições da literatura e evidenciar a diversidade de aplicações reportadas, apresenta-se de seguida na Tabela 1, que organiza as áreas laboratoriais onde a IA tem sido aplicada, os benefícios identificados e as respetivas referências bibliográficas.

**Tabela 1 - Aplicações da Inteligência Artificial em Patologia Clínica**

<b>Área Laboratorial</b>	<b>Aplicação Principal</b>	<b>Benefícios Identificados</b>	<b>Referências</b>
Hematologia digital	Classificação automática de células sanguíneas	Redução de erros de interpretação; maior rapidez no diagnóstico	Chatterjee et al. (2021); Xie (2024); Mencacci et al. (2023)
Microbiologia clínica	Predição de perfis de resistência antimicrobiana	Apoio ao uso racional de antibióticos; prevenção da resistência	Arango-Argoty et al. (2018); Mencacci et al. (2023)
Imunologia e bioquímica	Interpretação de biomarcadores complexos (hormonais, imunológicos)	Estratificação de risco; seguimento personalizado de doentes crónicos	Topol (2019); Rajkomar et al. (2019); Xie (2024)
Validação laboratorial	Sistemas automatizados de validação de resultados adaptados a dados locais	Padronização; eficiência; integração em contextos institucionais específicos	Chen & Asch (2017); Topol (2019); Rajkomar et al. (2019)
Dimensão ética e regulatória	Necessidade de explicabilidade, justiça e auditabilidade	Confiança dos profissionais; segurança dos doentes	Amann et al. (2020); London (2019); WHO (2020)

### **1.5. Quadro Ético e Regulatório da Inteligência Artificial em Saúde: Perspetiva Portuguesa e Europeia**

A adoção crescente de tecnologias baseadas em IA no setor da saúde exige uma análise rigorosa dos princípios éticos e dos normativos legais que orientam o seu desenvolvimento e aplicação. Em contextos clínicos, onde a dignidade humana, a privacidade e a confiança são inegociáveis, torna-se imperativo assegurar que a inovação tecnológica ocorra em alinhamento com os direitos fundamentais, a segurança e a equidade no acesso aos cuidados (*World Health Organization (WHO)*, 2021; *European Commission*, 2021).

#### **1.5.1. Princípios Éticos Fundamentais**

A Comissão Europeia (2019) definiu sete requisitos essenciais para garantir uma IA de confiança (*trustworthy AI*), os quais são particularmente relevantes quando aplicados à saúde:

- i. **Supervisão Humana:** a tomada de decisão clínica assistida por IA deve manter o controlo humano significativo (*meaningful human oversight*), garantindo que os profissionais possam intervir e validar os resultados.
- ii. **Robustez Técnica e Segurança:** os sistemas devem ser fiáveis, resilientes a falhas e protegidos contra ciberataques.
- iii. **Privacidade e Governação de Dados:** a recolha e o tratamento de dados sensíveis devem obedecer ao Regulamento Geral sobre a Proteção de Dados (RGPD), assegurando confidencialidade, minimização de dados e fundamentação jurídica sólida.

- iv. **Transparência e Explicabilidade:** os processos e decisões automatizadas devem ser compreensíveis para os utilizadores, mitigando o risco de decisões opacas (*black box AI*).
- v. **Diversidade, Não Discriminação e Equidade:** os sistemas devem ser concebidos de forma a prevenir enviesamentos que possam afetar grupos vulneráveis.
- vi. **Bem-Estar Social e Ambiental:** a IA deve promover o bem coletivo e não comprometer os princípios de sustentabilidade.
- vii. **Responsabilização:** devem existir mecanismos claros de atribuição de responsabilidade em caso de erro ou falha clínica.

### **1.5.2 Quadro Regulatório Europeu**

A União Europeia estabeleceu um conjunto de instrumentos legais que enquadram a utilização ética e segura da IA em saúde:

- *AI Act* (2024): regula o desenvolvimento e aplicação de IA com base numa abordagem de risco. Classifica os sistemas usados na saúde como “de alto risco”, exigindo requisitos reforçados de documentação, testes de segurança, explicabilidade, supervisão humana e gestão de risco (*European Commission, 2021*).
- Regulamento Geral sobre a Proteção de Dados (RGPD – 2016/679): define o quadro legal para o tratamento de dados pessoais, com ênfase nos dados de saúde. Exige o consentimento informado, limitação de finalidades, minimização de dados e garantias reforçadas.
- O *European Health Data Space* (EHDS), ainda em fase de desenvolvimento, constitui uma estrutura pan-europeia que visa facilitar a partilha de dados de saúde de forma segura e ética, promovendo a interoperabilidade e o avanço da investigação clínica. Para além das oportunidades associadas à melhoria da qualidade dos cuidados e ao suporte à inovação, o EHDS levanta também desafios significativos em matéria de cibersegurança e de uso secundário de dados, nomeadamente quando utilizados por sistemas de Inteligência Artificial (*European Commission, 2025; van Drumpt et al., 2025*).

### **1.5.3 Enquadramento Legal e Institucional em Portugal**

Em território nacional, o desenvolvimento e aplicação da IA em saúde está subordinado a um conjunto de instrumentos legais e entidades reguladoras:

- Constituição da República Portuguesa: os artigos 26.º e 35.º consagram o direito à identidade pessoal, à integridade física e à proteção de dados pessoais.

- Lei de Bases da Saúde (Lei n.º 95/2019): estabelece a centralidade do utente e princípios como a equidade, segurança clínica e humanização dos cuidados, aplicáveis a qualquer tecnologia implementada no Serviço Nacional de Saúde (SNS).
- Comissão Nacional de Proteção de Dados (CNPd): garante a fiscalização do tratamento de dados sensíveis, incluindo os sistemas baseados em IA.
- Entidade Reguladora da Saúde (ERS): responsável pela supervisão da qualidade e segurança dos serviços de saúde, com potencial para regular riscos associados a soluções digitais.
- INFARMED e Direção-Geral da Saúde (DGS): intervêm na regulação de dispositivos médicos e sistemas clínicos que incorporem IA.

#### 1.5.4. Desafios Éticos Emergentes

Entre os principais debates éticos relacionados com a aplicação da IA em saúde destacam-se a opacidade algorítmica, a necessidade de explicabilidade e os riscos de enviesamento. Estes aspetos têm sido amplamente discutidos na literatura científica (Doshi-Velez & Kim, 2017; Floridi et al., 2018; WHO, 2021) e são considerados barreiras críticas à confiança, adoção e utilização responsável da tecnologia em contextos clínicos (Goodman & Flaxman, 2017; European Commission, 2021).

Um dos maiores desafios prende-se com a opacidade dos modelos de elevada complexidade, frequentemente designados por *black box*. Esta designação aplica-se sobretudo a algoritmos de *deep learning*, cuja lógica interna de funcionamento é de difícil interpretação até para especialistas. A ausência de clareza compromete a confiança dos profissionais de saúde, que necessitam compreender a base das recomendações clínicas para sustentar diagnósticos e decisões terapêuticas (Topol, 2019; Rajkomar et al., 2019).

Neste sentido, tem emergido o campo da *Explainable Artificial Intelligence (XAI)*, que procura tornar mais transparentes os processos de decisão. As abordagens mais relevantes incluem modelos intrinsecamente interpretáveis (como árvores de decisão e regressões lineares) e métodos de explicação pós-hoc aplicados a modelos complexos, entre os quais se destacam o LIME (*Local Interpretable Model-agnostic Explanations*) e o SHAP (*SHapley Additive exPlanations*) (Ribeiro et al., 2016; Lundberg & Lee, 2017). Estas ferramentas permitem identificar variáveis determinantes nas previsões, oferecendo aos clínicos maior clareza sobre os resultados gerados.

Outro eixo crítico refere-se ao enviesamento algorítmico (*algorithmic bias*), resultante de bases de dados não representativas ou de erros sistemáticos no processo de recolha

de informação. Este viés pode traduzir-se em desigualdades de desempenho entre diferentes grupos populacionais, reforçando disparidades já existentes no acesso e na qualidade dos cuidados de saúde (Mehrabi et al., 2021). Exemplos documentados incluem algoritmos treinados com dados maioritariamente caucasianos, que apresentaram menor precisão em diagnósticos em indivíduos de outras origens étnicas (Obermeyer et al., 2019).

Para mitigar estas limitações, a literatura recomenda estratégias de auditoria algorítmica, diversidade nos conjuntos de treino e mecanismos de supervisão humana, em consonância com os princípios definidos no *AI Act* da União Europeia e nas diretrizes da OMS (European Commission, 2021; WHO, 2021).

A síntese destes desafios encontra-se sistematizada na Tabela 2, que apresenta uma visão comparativa das principais questões éticas emergentes associadas à utilização da IA em saúde.

**Tabela 2 - Síntese dos princípios éticos da UE e enquadramento legal aplicável à IA em saúde**

Dimensão	Princípios Éticos (UE)	Exigências Legais (AI Act, RGPD, Portugal)	Referências
Supervisão Humana	Decisões devem ser auditadas por profissionais humanos	AI Act exige supervisão humana significativa nos sistemas de alto risco	<i>European Commission (2021); World Health Organization (2021)</i>
Transparência & Explicabilidade	Sistemas devem ser compreensíveis e rastreáveis	Obrigação de explicação adequada no AI Act; dever de informação ao titular no RGPD	Doshi-Velez & Kim (2017); Floridi et al. (2018); <i>European Commission (2021)</i>
Privacidade e Proteção de Dados	Proteção de dados sensíveis, minimização, controlo pelo titular	RGPD (2016/679) e Art. 35.º CRP garantem proteção de dados pessoais em contexto clínico	<i>European Union (2016); Assembleia da República (1976/2005)</i>
Justiça e Não Discriminação	Evitar enviesamentos algorítmicos e proteger grupos vulneráveis	AI Act obriga avaliação de risco e testes para mitigar viés algorítmico	Goodman & Flaxman (2017); <i>European Commission (2021)</i>
Robustez Técnica e Segurança	Sistemas devem ser tecnicamente resilientes e resistentes a falhas	AI Act exige provas de fiabilidade, testes contínuos e certificação técnica	LeCun et al. (2015); Rajkomar et al. (2019)
Responsabilização	Deve haver mecanismos de prestação de contas	A ausência de mecanismos jurídicos claros é um desafio; AI Act exige documentação e registo de decisões automatizadas	Floridi et al. (2018); <i>European Commission (2021)</i>
Benefício Social	A IA deve promover o bem comum e respeitar os direitos humanos	Constituição Portuguesa (Art. 1.º, 26.º) e Lei de Bases da Saúde exigem respeito pela dignidade e integridade do cidadão	Assembleia da República (1976/2005, 2019)

### 1.6 Inteligência Artificial Explicável e Interoperabilidade Semântica em Saúde

O aumento da complexidade algorítmica, particularmente com modelos de *DL*, torna imperativa a procura por mecanismos que assegurem a explicabilidade, transparência e confiança nos resultados produzidos por estas tecnologias. Neste contexto, a

Inteligência Artificial Explicável ou *Explainable Artificial Intelligence (XAI)*, emerge como um subcampo essencial para garantir a compreensão e validação dos sistemas de IA por parte dos profissionais de saúde e decisores (Samek et al., 2017; Ghassemi et al., 2021).

A explicabilidade refere-se à capacidade de um sistema de IA justificar os seus *outputs* de forma compreensível para utilizadores humanos. Tal propriedade é especialmente crítica em saúde, onde decisões clínicas automatizadas podem ter consequências diretas para o bem-estar do doente. Como alertam Amann et al. (2020), a ausência de explicações claras compromete a responsabilização médica, gera resistências organizacionais e fragiliza a confiança dos utilizadores. A *XAI* procura responder a este desafio através de abordagens como modelos intrinsecamente interpretáveis, métodos pós-hoc<sup>2</sup> de explicação (ex: Local Interpretable Model-agnostic Explanations (*LIME*), SHapley Additive exPlanations (*SHAP*) e visualizações interativas, que tornam transparentes os critérios de decisão dos algoritmos.

Paralelamente, a aplicabilidade clínica da IA requer interoperabilidade semântica, isto é, a capacidade de diferentes sistemas e aplicações compreenderem e processarem dados de forma consistente, preservando o seu significado clínico. A ausência de normas semânticas e estruturas comuns prejudica a integração entre os sistemas de IA, os Sistemas de Informação Hospitalar (*HIS*) e os Sistemas de Informação Laboratorial (*LIS*), dificultando a sua escalabilidade e a partilha de dados (Pesquita, 2021).

Neste domínio, os grafos<sup>3</sup> de conhecimento e as ontologias biomédicas têm vindo a ganhar relevo. Estas estruturas organizam conceitos médicos e laboratoriais de forma hierárquica e relacional, permitindo que os algoritmos compreendam o contexto clínico e mantenham coerência semântica entre fontes de dados heterogéneas (Cardoso et al., 2020; Pesquita et al., 2021). O uso de ontologias como a Systematized Nomenclature of Medicine – Clinical Terms (*SNOMED CT*), a Logical Observation Identifiers Names and Codes (*LOINC*) ou a Ontology for General Medical Science (*OGMS*) viabiliza a

---

<sup>2</sup> O termo *pós-hoc* significa literalmente “depois do facto” — ou seja, a explicação não é incorporada no processo de aprendizagem do modelo, mas é gerada a posteriori para interpretar as previsões.

<sup>3</sup> Um grafo é uma estrutura matemática usada para representar relações entre objetos. Ele é formado por dois elementos principais: Vértices (*nós* ou *nodes*) → representam os objetos ou entidades e Arestas (*edges* ou *links*) → representam as ligações ou relações entre os vértices.

automatização da análise sem perda de precisão semântica, contribuindo tanto para a explicabilidade como para a interoperabilidade entre sistemas.

Como destaca a Professora Doutora Cátia Pesquita, investigadora da Faculdade de Ciências da Universidade de Lisboa, “a combinação entre IA explicável e representação do conhecimento é crucial para a criação de sistemas clínicos transparentes, interoperáveis e auditáveis”, sendo este um vetor fundamental para a construção de soluções tecnológicas eticamente sustentáveis e cientificamente robustas (Pesquita et al., 2021).

O investimento em XAI e em infraestruturas semânticas torna-se, assim, não apenas uma exigência técnica, mas também uma condição ética para assegurar que a adoção da IA em saúde respeita os princípios de justiça, autonomia e responsabilidade. Tal como sublinha London (2019), “decisões médicas automatizadas que não podem ser explicadas violam os direitos fundamentais dos utentes à informação e à autodeterminação”.

Neste sentido, a evolução da IA na saúde dependerá, em grande parte, da sua capacidade de se tornar compreensível, auditável e interoperável, atributos que não devem ser encarados como barreiras, mas como requisitos fundamentais para a sua integração responsável nos sistemas de saúde modernos.

Para além dos desafios técnicos e regulatórios, a adoção de IA em saúde exige uma transformação organizacional profunda, que promova a literacia digital dos profissionais, a atualização dos protocolos de trabalho e o desenvolvimento de uma cultura institucional de confiança nos sistemas inteligentes. Como sublinha Floridi (2019), a ética da IA não pode ser uma camada externa aos sistemas, mas sim um princípio estruturante embutido desde o design até à implementação. Assim, a integração responsável da IA em saúde deve ser vista como uma mudança cultural e institucional, que exige diálogo interdisciplinar, formação contínua e supervisão ética permanente. Em suma, a harmonização entre progresso tecnológico e salvaguarda dos valores humanos será determinante para que a IA contribua positivamente para a transformação dos sistemas de saúde.

Em suma, a revisão da literatura evidencia que a aplicação da IA à saúde, e em particular à patologia clínica, apresenta avanços significativos tanto no apoio ao diagnóstico como na otimização de processos laboratoriais. No entanto, apesar dos benefícios associados à precisão, rapidez e escalabilidade, permanece clara a necessidade de uma integração responsável e contextualizada. Questões como a

explicabilidade dos modelos, a justiça algorítmica, a auditabilidade das decisões e a adaptação às especificidades institucionais continuam a constituir desafios centrais para a sua adoção sustentada. Assim, a investigação aponta não apenas para o potencial transformador da IA, mas também para a urgência de quadros éticos, regulatórios e organizacionais que assegurem a sua utilização de forma segura, robusta e orientada para os reais benefícios dos doentes e dos sistemas de saúde.

## **CAPÍTULO 2 – METODOLOGIA**

Dada a relevância dos avanços e desafios identificados no enquadramento teórico e regulatório, torna-se essencial compreender de que forma estes aspetos se refletem no contexto específico dos laboratórios de patologia clínica. O presente capítulo apresenta, assim, a metodologia adotada neste estudo, detalhando o desenho da investigação, os instrumentos de recolha de dados e os procedimentos de análise utilizados. Este enquadramento metodológico permitirá avaliar de forma estruturada a perceção dos profissionais e os desafios associados à integração da IA em ambiente laboratorial.

### **2.1 Pergunta de Investigação e Desenho do Estudo**

A problemática considerada como ponto de partida é: De que forma a introdução de IA e automação no novo laboratório de Patologia Clínica do HLO potencia oportunidades técnicas, suscita desafios éticos e impacta as perceções dos profissionais de saúde envolvidos?

Esta formulação integra de forma coerente três eixos fundamentais definidos nos objetivos do estudo: os aspetos técnicos, associados à eficiência, padronização e aceleração dos processos de diagnóstico; os desafios éticos, relacionados com as implicações e os riscos decorrentes da utilização de sistemas automatizados e de IA; e as dimensões humanas, centradas nas perceções, preocupações e racionalidades dos profissionais de saúde;

Tendo como ponto de partida esta pergunta exploratória, optou-se por um desenho metodológico baseado num estudo de caso com abordagem mista, considerado o mais adequado para captar de forma abrangente e contextualizada o impacto da transformação digital nos laboratórios hospitalares, considerando não apenas os ganhos tecnológicos, mas também os efeitos éticos e organizacionais emergentes.

### **2.2 Objetivo Geral**

Mapear e explorar analiticamente as oportunidades e desafios técnicos, assim como, eventuais implicações éticas decorrentes da introdução de IA e automação no novo laboratório de patologia clínica do HLO.

#### **2.2.1 Objetivos Específicos**

1. Mapear oportunidades proporcionadas pela IA na padronização e aceleração dos processos de diagnóstico.
2. Analisar os desafios técnicos decorrentes da implementação de IA e automação.

3. Explorar os desafios éticos associados à implementação de tecnologia que incorpora a IA, assim como, eventuais impactos na redução dos profissionais.
4. Identificar e mapear, as percepções e racionalidades por parte das pessoas envolvidas no processo.

### **2.3 Tipo de Estudo**

O presente trabalho assume a natureza de um estudo de caso exploratório com abordagem mista, combinando metodologias quantitativas e qualitativas. Esta opção metodológica visa proporcionar uma compreensão abrangente do fenómeno em análise, a introdução de sistemas de IA e automação no novo laboratório de Patologia Clínica da ULS S. José, permitindo captar simultaneamente tendências gerais e potenciar profundidade interpretativa. A abordagem mista justifica-se pela necessidade de articular dados quantitativos (como percepções sobre eficiência ou impacto técnico) com dimensões mais qualitativas e contextuais (como preocupações éticas ou racionalidades dos profissionais), em linha com a complexidade própria dos ambientes hospitalares. No contexto específico deste estudo, os sistemas de IA e automação em análise incluem, a título exemplificativo, o analisador *Sysmex XR* com suporte do *middleware IPU*, o preparador automático de esfregaços *SP-50* e o digitalizador *DI-60* da CellaVision, atualmente em utilização no Serviço de Patologia Clínica da ULS S. José, e cujas características foram descritas em detalhe na secção 1.4.1. Estes sistemas ilustram a convergência entre automação laboratorial e IA aplicada à patologia clínica que constitui o objeto empírico desta investigação.

### **2.4 População e Amostra**

A população deste estudo é composta exclusivamente por profissionais da ULS S. José com envolvimento direto nos processos laboratoriais e na gestão das tecnologias associadas ao SPC. Esta população inclui TSDT da área de Análises Clínicas, médicos patologistas clínicos e outros profissionais com funções relacionadas com a implementação, operação ou supervisão de sistemas laboratoriais automatizados (como administradores, técnicos superiores e diretores técnicos).

O universo de profissionais elegíveis para o estudo integra 152 TSDT em análises clínicas, dos quais 147 se encontravam no ativo no momento da recolha de dados. Foram definidos critérios de inclusão comuns a todos os grupos profissionais considerados: pelo menos um ano de atividade efetiva em funções num dos seis polos hospitalares da ULS S. José e exclusão de profissionais em situação de licença prolongada ou sem contacto direto com os processos laboratoriais.

A amostra foi obtida através de amostragem estratificada aleatória, garantindo representatividade entre os diferentes grupos profissionais identificados. A seleção aleatória dentro de cada estrato assegurou diversidade de experiências e perspectivas relativamente à adoção de tecnologias emergentes, com especial enfoque na IA e automação.

Para determinar o tamanho amostral mínimo necessário, foi aplicada a fórmula de cálculo para populações finitas, considerando um nível de confiança de 95% ( $z=1,96$ ), uma margem de erro de 5% e uma proporção estimada de 0,5 (critério conservador maximizando o tamanho da amostra). Com base numa população elegível de  $N=162$  profissionais, o tamanho amostral mínimo calculado foi de  $n=114$ . A amostra efetivamente obtida ( $n=118$ ) supera este limiar, garantindo a representatividade estatística da população em análise e sustentando a validade dos resultados.

## **2.5 Elaboração e Validação dos Instrumentos de Recolha de Dados**

O questionário utilizado na primeira fase do estudo foi elaborado com base na revisão da literatura científica nacional e internacional sobre IA na saúde, automação laboratorial e ética tecnológica, incorporando dimensões alinhadas com os objetivos específicos do presente trabalho.

Embora o *Technology Acceptance Model* (TAM), proposto por Davis (1989), constitua o modelo de referência mais amplamente utilizado no estudo da aceitação tecnológica assente nos construtos de utilidade percebida e facilidade de uso percebida, a presente investigação não o adotou como modelo estruturante. Esta opção justifica-se por três razões. Em primeiro lugar, o desenho do estudo é de natureza exploratória, não confirmatória, não se pretendendo testar hipóteses derivadas de um modelo teórico pré-definido, mas sim mapear e compreender a diversidade de perceções e atitudes num contexto específico e ainda pouco estudado. Em segundo lugar, o TAM foi originalmente desenvolvido para contextos de adoção voluntária de tecnologias de informação em ambiente organizacional geral (Davis, 1989; Venkatesh et al., 2003), sendo a sua aplicabilidade direta a contextos de saúde objeto de debate na literatura (Holden & Karsh, 2010) concluindo os autores que o modelo necessita de adaptações e modificações substanciais para captar adequadamente a complexidade da aceitação tecnológica em contextos clínicos. Em terceiro lugar, o fenómeno em análise, a introdução de IA e automação num laboratório hospitalar em fase de transição envolve dimensões que transcendem os construtos clássicos do TAM, nomeadamente desafios

éticos, questões de interoperabilidade, impactos laborais e dinâmicas de confiança institucional.

Neste sentido, o instrumento foi estruturado em blocos temáticos com base numa revisão sistemática da literatura científica sobre adoção tecnológica em saúde, incluindo: Conhecimento e Experiência com Tecnologias Emergentes, Perceções sobre Benefícios das Tecnologias no Laboratório, Desafios Técnicos, Desafios Éticos, Aceitação e Confiança na Tecnologia e Dados sociodemográficos. Esta estrutura captura, ainda que sem seguir formalmente o TAM, dimensões conceptualmente próximas dos seus construtos centrais, nomeadamente a utilidade percebida, a confiança na tecnologia e as barreiras à adoção, complementadas por dimensões éticas e organizacionais relevantes para o contexto laboratorial em estudo.

Para garantir a validade de conteúdo, o questionário foi submetido a uma revisão por um painel de especialistas, composto por docentes universitários com experiência nas áreas da saúde, ética biomédica e ciência de dados. Foram realizadas reformulações de itens com base nos pareceres recebidos, assegurando clareza, pertinência e alinhamento com a realidade institucional. Antes da aplicação definitiva, foi conduzido um pré-teste com um grupo reduzido de profissionais (n=6), que cumpriam os requisitos definidos para os critérios de inclusão, mas não foram integrados na amostra final, com o objetivo de aferir a compreensão das questões, a coerência lógica do instrumento e a estimativa do tempo de resposta. As sugestões recolhidas nesta fase foram incorporadas na versão final (Apêndice A), reforçando a fiabilidade e aplicabilidade prática do questionário no contexto específico da ULS S. José.

### 2.5.1 Operacionalização das Variáveis do Estudo

A operacionalização das variáveis constitui um passo essencial para assegurar a consistência metodológica entre o enquadramento teórico e os instrumentos de recolha de dados. A Tabela 3 apresenta a sistematização adotada, associando cada dimensão do estudo aos respetivos itens do questionário, ao tipo de variável e ao formato de resposta considerado.

**Tabela 3** - Operacionalização das variáveis do estudo

Variável	Descrição	Item(s) no questionário	Tipo de variável
Contacto prévio com IA	Experiência anterior com tecnologias de IA ou automação	1.1	Categórica (binária)
Formação em IA	Participação em formações ou eventos relacionados com IA	1.2	Categórica (binária)

Utilização de IA no laboratório	Presença de tecnologias de IA no local de trabalho	1.3	Categórica (binária)
Conhecimento declarado	Áreas de conhecimento reconhecidas pelos inquiridos	1.4	Categórica (múltipla escolha)
Perceção dos benefícios	Crença na utilidade e eficácia da IA e automação em contexto laboratorial	2.1 a 2.8	Ordinal (escala de <i>Likert</i> )
Barreiras à implementação	Obstáculos técnicos, organizacionais e estruturais	3.1 a 3.6	Ordinal (escala de <i>Likert</i> )
Riscos éticos e profissionais	Percepções sobre o impacto ético e laboral da IA	4.1 a 4.5	Ordinal (escala de <i>Likert</i> )
Confiança e motivação	Grau de aceitação, conforto e motivação para colaborar com IA	5.1 a 5.9	Ordinal (escala de <i>Likert</i> )
Importância da IA	Avaliação global sobre o papel futuro da IA na medicina laboratorial	5.12	Ordinal (escala de <i>Likert</i> )
Local	Polo onde o participante exerce funções	6.1	Categóricas e ordinais
Anos de trabalho	Tempo de experiência profissional em laboratório	6.2	Categóricas e ordinais
Idade	Faixa etária por participante	6.3	Categóricas e ordinais
Género	Identificação de género	6.4	Categóricas e ordinais
Formação	Nível académico	6.5	Categóricas e ordinais
Classe profissional	Categoria profissional (ex.: TSDT, médico, etc.)	6.6	Categóricas e ordinais

As variáveis foram operacionalizadas com base em estudos prévios sobre adoção tecnológica em saúde (Amann et al., 2020; WHO, 2021; Gerlich, 2023). A maioria das variáveis de perceção, incluindo barreiras, riscos éticos e profissionais, bem como confiança e motivação, foi medida através de escalas de *Likert* de cinco pontos (1 = "discordo totalmente"; 5 = "concordo totalmente"), adequadas para captar atitudes e graus diferenciados de concordância. Apenas a questão 2.8 ("Acredito que a Inteligência Artificial vai melhorar o meu trabalho") foi avaliada com recurso a uma escala de dez pontos (1 = "Discordo Totalmente"; 10 = "Concordo Totalmente"), de modo a aumentar a sensibilidade da medida e captar variações mais subtis ao nível da perceção individual. Esta opção metodológica visou enriquecer a análise, permitindo uma maior precisão na diferenciação entre os respondentes quanto ao impacto esperado da IA na sua prática profissional.

A estrutura do questionário reflete uma lógica progressiva de análise: parte do conhecimento e experiência prévia dos profissionais, o que constitui uma variável contextual fundamental para compreender as atitudes subseqüentes, avança para as percepções sobre benefícios e desafios técnicos e éticos, e culmina nas dimensões de aceitação, confiança e motivação. Esta sequência permite captar não apenas a posição dos profissionais face à tecnologia, mas também os fatores que a condicionam,

nomeadamente o grau de familiaridade tecnológica, a perceção de utilidade e os receios associados à implementação. A inclusão de variáveis sociodemográficas e profissionais, como a classe profissional, os anos de experiência, o polo hospitalar e o nível académico, permitiu analisar se as perceções variam em função do perfil dos respondentes, contribuindo para uma segmentação mais rigorosa dos resultados. Esta abordagem está alinhada com a literatura sobre adoção tecnológica em saúde, que identifica consistentemente o perfil sociodemográfico e a experiência prévia como preditores relevantes das atitudes face à inovação (Venkatesh et al., 2003; Gerlich, 2023).

O guião das entrevistas semiestruturadas, utilizado na segunda fase do estudo, foi elaborado com base na revisão da literatura científica sobre a adoção de tecnologias emergentes em saúde e nas orientações internacionais em ética da IA (Floridi et al., 2018; WHO, 2021; European Commission, 2021) e na análise preliminar das respostas ao questionário. A sua construção teve como objetivo explorar de forma aprofundada dimensões que, no questionário, foram tratadas de modo quantitativo, permitindo captar narrativas, interpretações e racionalidades dos profissionais.

O guião foi estruturado em quatro blocos temáticos principais:

1. Experiência prévia com IA e automação: contacto com tecnologias no contexto hospitalar e perceção da sua utilidade.
2. Benefícios e riscos percebidos: expectativas relativamente a ganhos de eficiência, bem como receios técnicos, organizacionais ou laborais.
3. Implicações éticas e organizacionais: reflexões sobre transparência, proteção de dados, supervisão humana e impacto na prática profissional.
4. Expectativas futuras: recomendações, condições para aceitação e visão sobre a integração sustentável da IA nos laboratórios clínicos.

O guião (Apêndice E) incluiu um conjunto de perguntas comuns a todos os entrevistados, assegurando a coerência das respostas, e perguntas específicas adaptadas às funções e responsabilidades de cada participante, de modo a captar nuances próprias de diferentes contextos profissionais.

Para garantir a validade de conteúdo, o guião foi submetido a apreciação por um painel de especialistas (académicos), assegurando a pertinência das questões e a sua adequação terminológica. Foi ainda conduzido um pré-teste com dois profissionais, não

incluídos na amostra final, que permitiu ajustar a ordem das questões e simplificar alguns enunciados.

A Tabela 4 apresenta a operacionalização dos blocos temáticos do guião, evidenciando a relação entre cada temática abordada, a finalidade exploratória e o tipo de questão utilizado. Esta sistematização reforça a consistência metodológica e evidencia o paralelismo entre os instrumentos quantitativos e qualitativos do estudo.

**Tabela 4** - Operacionalização do guião das entrevistas

Bloco temático	Âmbito de Análise	Tipo de questão
Experiência prévia com IA e automação	Explorar contacto real e perceção inicial de utilidade	Perguntas comuns (abertas, exploratórias)
Benefícios e riscos percebidos	Identificar ganhos esperados e obstáculos associados à adoção de IA	Perguntas comuns + específicas (abertas, exemplificativas)
Implicações éticas e organizacionais	Analisar preocupações relacionadas com ética, transparência e impacto na prática	Perguntas comuns + específicas (abertas, reflexivas)
Expectativas futuras	Recolher recomendações e visão sobre a integração da IA no futuro	Perguntas comuns (abertas, prospetivas)

## 2.6 Recolha de Dados

A recolha de dados foi realizada em duas fases complementares, alinhadas com a abordagem metodológica mista adotada no estudo.

Numa primeira fase, foi aplicado um questionário, criado na plataforma *Google Forms* (Apêndice B). O questionário foi enviado via e-mail institucional a todos os profissionais elegíveis das unidades hospitalares da ULS S. José, estando disponível entre 4 de maio e 16 de junho de 2025. A sua aplicação assegurou acessibilidade, anonimato e equidade de participação, tendo sido incluídas apenas respostas provenientes de profissionais em exercício efetivo de funções laboratoriais. O formulário integrou, na página inicial, o termo de consentimento informado, previamente aprovado pelas comissões de ética competentes.

Na segunda fase, foram realizadas entrevistas semiestruturadas (Apêndice E), permitindo uma exploração mais aprofundada e contextualizada dos dados. A seleção dos participantes foi realizada entre aqueles que, no final do questionário, voluntariamente disponibilizaram o seu e-mail institucional, seguindo posteriormente um critério de amostragem intencional, assegurando a inclusão de três representantes de cada *cluster* identificado na análise quantitativa. As entrevistas decorreram presencialmente ou por videoconferência, conforme a disponibilidade dos participantes, com duração média de 20 a 35 minutos. Todas foram conduzidas mediante consentimento informado, gravadas e transcritas integralmente para posterior análise temática.

Esta metodologia sequencial potenciou a triangulação de resultados e a riqueza interpretativa do estudo.

## **2.7 Tratamento de Dados e Análise Estatística**

O tratamento estatístico dos dados foi realizado com recurso ao software IBM *SPSS Statistics* v30. A análise seguiu uma abordagem descritiva, exploratória e multivariada, estruturada em várias etapas, complementada por análise qualitativa das entrevistas com apoio do software *MAXQDA*.

### **2.7.1 Análise Univariada**

Inicialmente, foram conduzidas análises univariadas, com o propósito de caracterizar a amostra e analisar a distribuição das variáveis recolhidas. Esta análise permitiu descrever o perfil sociodemográfico e profissional dos participantes (género, faixa etária, polo hospitalar, anos de experiência, formação académica e classe profissional), bem como as suas respostas às afirmações apresentadas em escalas de *Likert*. Foram calculadas frequências absolutas e frequências relativas. No caso das escalas de *Likert*, foram calculados *scores* médios, permitindo identificar tanto a tendência central como a distribuição das respostas, sem descurar eventuais assimetrias. Esta etapa revelou-se essencial para traçar um retrato inicial do campo empírico, fornecendo uma base sólida para as análises subsequentes.

A opção por tratar as escalas de *Likert* de cinco pontos como variáveis intervalares, em vez de estritamente ordinais, fundamenta-se num conjunto de argumentos metodológicos amplamente discutidos na literatura. Embora as escalas de *Likert* sejam, do ponto de vista formal, de natureza ordinal, vários autores defendem que, quando compostas por cinco ou mais categorias de resposta com intervalos percebidos como aproximadamente equidistantes, o seu tratamento como variáveis intervalares é estatisticamente admissível e produz resultados robustos (Norman, 2010; Sullivan & Artino, 2013). Esta abordagem é particularmente justificada quando o objetivo é calcular *scores* médios compostos, realizar análise fatorial ou avaliar consistência interna através do *alfa de Cronbach*, procedimentos que requerem a assunção de propriedades intervalares e que foram centrais na presente análise. No que respeita à avaliação da distribuição, a estrutura das distribuições observadas revelou-se compatível com o tratamento intervalar adotado, não tendo sido identificadas assimetrias extremas que inviabilizassem os procedimentos estatísticos subsequentes. Esta opção está em linha com a prática corrente em investigação em saúde e ciências sociais (Carifio & Perla, 2008).

### 2.7.2 Análise Fatorial Exploratória

Para validar a estrutura subjacente às escalas utilizadas e reduzir a dimensionalidade do questionário, foi realizada uma Análise Fatorial Exploratória (AFE) com rotação *Oblimin* (não ortogonal), considerando a possível correlação entre fatores. A adequação dos dados foi confirmada pelos testes:

- Teste de Esfericidade de Bartlett:  $p < 0,001$  (Tabela 27; Apêndice C)
- *Kaiser-Meyer-Olkin (KMO)*: 0,886 → Muito bom (Tabela 28; Apêndice C)

Com base nos *eigenvalues* (superiores a 1) e no gráfico *Scree Plot* (Figura 4; Apêndice C)), foram retidos três fatores, que em conjunto explicam 57,5% da variância total. Esta estrutura permitiu consolidar uma leitura das atitudes dos profissionais: aceitação/confiança, preocupações éticas/técnicas e motivação pessoal.

### 2.7.3 Construção de Fatores e Avaliação de Fiabilidade

Com base nas questões estruturadas em escala de *Likert* (1 = “Discordo totalmente” a 5 = “Concordo totalmente”), foram construídos *scores* compostos normalizados, agrupando itens conceptualmente relacionados para avaliar dimensões latentes, nomeadamente:

- Fator 1: Confiança, conforto e abertura à IA
- Fator 2: Perceção de ameaça, risco e preocupações éticas
- Fator 3: Motivação pessoal e disponibilidade para aprendizagem

A consistência interna destes fatores foi validada com recurso ao alfa de *Cronbach*, com resultados que atestam uma boa fiabilidade dos blocos:

- Fator 1:  $\alpha = 0,925$  (excelente) (George & Mallery, 2003) (Tabela 34; Apêndice C)
- Fator 2:  $\alpha = 0,678$  (questionável, expectável numa dimensão de natureza multidimensional em contexto exploratório) (George & Mallery, 2003) (Tabela 36; Apêndice C)
- Fator 3:  $\alpha = 0,775$  (bom) (George & Mallery, 2003) (Tabela 38; Apêndice C)

Os fatores identificados não correspondem de forma estrita às dimensões teóricas previamente delineadas no questionário e no guião de entrevista, mas apresentam uma relação de proximidade e sobreposição temática. As dimensões constituíram a estrutura teórica de base para a construção dos instrumentos, enquanto os fatores resultam da

agregação empírica de itens que evidenciaram elevada consistência interna. Neste sentido, os fatores podem ser entendidos como construções estatisticamente validadas que sintetizam determinadas dimensões analíticas, assegurando coerência entre a análise quantitativa e a exploração qualitativa das mesmas temáticas.

#### **2.7.4 Análise de *Clusters***

Com base nos *scores* fatoriais extraídos, procedeu-se à segmentação da amostra através de análise de *clusters*, com recurso a dois métodos complementares:

1. Análise hierárquica para determinar o número ótimo de *clusters* (tabela 41; Apêndice C);
2. *K-means clustering* (tabela 41; Apêndice C), que permitiu consolidar a segmentação de acordo com a tendência identificada no ponto 1 em três perfis atitudinais distintos.

#### **2.7.5 Análise Bivariada**

A etapa seguinte envolveu análise bivariada, recorrendo a tabulações cruzadas e à aplicação do teste do qui-quadrado de *Pearson*, tendo sido definido um limiar de significância estatística de 0,05. Esta abordagem permitiu explorar relações entre experiência prévia, pertença a *clusters* e características sociodemográficas.

#### **2.7.6 Entrevistas Semiestruturadas**

As entrevistas semiestruturadas (Apêndice E) foram gravadas com consentimento informado, transcritas integralmente e submetidas a análise temática. A codificação foi desenvolvida em várias etapas: numa primeira fase, foram definidos códigos iniciais de natureza dedutiva, com base na literatura e nos objetivos da investigação; numa segunda fase, emergiram códigos adicionais de carácter indutivo, a partir da leitura aprofundada das transcrições. Estes códigos foram posteriormente ajustados e organizados em temas mais abrangentes, permitindo identificar padrões de discurso, bem como convergências e divergências entre perfis. Todo o processo foi realizado no software MAXQDA, assegurando sistematização, rastreabilidade e rigor na análise, e contribuindo para a triangulação dos dados quantitativos e qualitativos.

#### **2.8 Considerações Éticas**

A presente investigação foi conduzida em conformidade com os princípios éticos consagrados na Declaração de Helsínquia (*World Medical Association*, 2013), bem como com o Regulamento Geral sobre a Proteção de Dados (RGPD – UE 2016/679). Tendo em conta a natureza sensível dos dados recolhidos e o envolvimento direto de

profissionais de saúde em contexto clínico real, o estudo foi submetido a avaliação ética e aprovado pelas Comissões de Ética da Escola Superior de Tecnologia da Saúde de Lisboa do Instituto Politécnico de Lisboa (ESTeSL-IPL) (*Anexos 1 e 2*) e da ULS S. José. (*Anexo 3*).

A aplicação do questionário *online* foi precedida da apresentação de um termo de consentimento informado, integrado na página inicial do formulário digital (*Google Forms*). Os participantes foram devidamente informados sobre os objetivos do estudo, a sua natureza voluntária, o carácter anónimo das respostas e a possibilidade de desistência em qualquer momento, sem qualquer consequência.

As respostas recolhidas foram totalmente anonimizadas, não tendo sido armazenados dados pessoais identificáveis. A participação nas entrevistas semiestruturadas decorreu exclusivamente entre os profissionais que, no final do questionário, manifestaram interesse explícito em colaborar e forneceram o respetivo contacto institucional. Antes de cada entrevista, foi obtido novo consentimento informado por escrito.

Todos os dados foram armazenados de forma segura, com acesso restrito ao investigador principal, respeitando as normas de confidencialidade e integridade digital. As práticas adotadas garantiram a proteção dos direitos fundamentais dos participantes, bem como a segurança, privacidade e confidencialidade em todas as fases da investigação.

## **CAPÍTULO 3 – RESULTADOS**

### **3.1 Caracterização da amostra**

Para efeitos da análise que se apresenta neste capítulo, importa recordar que os conceitos centrais desta investigação foram operacionalizados da seguinte forma: entende-se por Inteligência Artificial, no contexto da patologia clínica, o conjunto de sistemas computacionais baseados em algoritmos de *machine learning* e *deep learning*, aplicados a tarefas como validação automatizada de resultados, classificação morfológica de células sanguíneas e apoio à decisão clínica laboratorial; por automação entende-se a utilização de sistemas que executam de forma autónoma tarefas físicas e processuais do fluxo laboratorial, como a preparação, coloração e digitalização de amostras. Estes conceitos encontram expressão concreta no contexto do Serviço de Patologia Clínica da ULS S. José através dos equipamentos e fluxos descritos na secção 1.4.1, e são medidos ao longo deste capítulo através das perceções dos profissionais relativamente à sua utilidade, impacto e aceitação, nos termos definidos na secção 2.5.1.

Do universo inicial de 152 TSDT em análises clínicas, cinco foram excluídos por não cumprirem o critério de tempo mínimo de atividade (menos de um ano) ou baixa prolongada, e vinte por não desenvolverem funções laboratoriais em nenhum dos polos hospitalares da ULS S. José, resultando numa população efetivamente considerada de 127 TSDT em análises clínicas com contacto direto com os processos laboratoriais. No caso dos médicos patologistas clínicos (n=32) e dos profissionais com responsabilidades de gestão ou supervisão técnica (n=3), todos cumpriram os critérios de inclusão definidos, não tendo sido registadas exclusões nestes grupos. Do universo de 162 profissionais elegíveis, 118 participaram efetivamente no estudo, correspondendo a uma taxa de resposta de aproximadamente 73%. Esta dimensão amostral garante a representatividade da população em análise e sustenta a validade dos resultados obtidos.

### **3.2 Descrição das Variáveis Sociodemográficas e Profissionais**

A Tabela 5 apresenta a caracterização global da amostra, integrando as variáveis sociodemográficas e profissionais mais relevantes. Destaca-se o predomínio dos Técnicos Superiores de Diagnóstico e Terapêutica em análises clínicas (79,7%), seguidos de médicos patologistas clínicos (18,6%). Todos os participantes possuem formação superior, sendo a licenciatura o grau mais frequente (74,6%). A distribuição

por polos hospitalares revela um peso expressivo do Hospital de São José (55,9%), seguido pelo Hospital D. Estefânia (19,5%).

No que respeita à experiência profissional, quase metade dos participantes (48,3%) trabalha em patologia clínica há mais de 20 anos, refletindo um perfil consolidado. A idade concentra-se sobretudo entre os 30 e 59 anos (78,8%), o que evidencia uma população em plena maturidade profissional. Por fim, verifica-se uma predominância clara do género feminino (81,4%), em consonância com a tendência nacional das profissões de saúde e diagnóstico laboratorial (Tabela 5). As tabelas e figuras detalhadas, com a distribuição completa de cada variável do inquérito por questionário, encontram-se no Apêndice D.

**Tabela 5 - Caracterização da amostra (frequência absoluta e relativa)**

Variável	Categoria	n	%
Classe profissional	TSDT em análises clínicas	94	79,7
	Médico/Patologista clínico	22	18,6
	Outro	2	1,7
Formação académica	Licenciatura	88	74,6
	Mestrado	29	24,6
	Doutoramento	1	0,8
Polo hospitalar	HSJ	66	55,9
	HDE	23	19,5
	HCC	9	7,6
	MAC	9	7,6
	HSAC	6	5,1
	HSM	5	4,2
Experiência profissional	1–5 anos	17	14,4
	6–10 anos	15	12,7
	11–15 anos	19	16,1
	16–20 anos	10	8,5
	>20 anos	57	48,3
Idade	<30 anos	3	2,5
	30–39 anos	32	27,1
	40–49 anos	29	24,6
	50–59 anos	32	27,1
	>60 anos	22	18,6
Género	Feminino	96	81,4
	Masculino	17	14,4
	Prefiro não dizer	5	4,2

*HSJ – Hospital de São José; HDE - Hospital D. Estefânia; HCC – Hospital Curry Cabral; MAC – Maternidade Alfredo da Costa; HSAC – Hospital Sto. António dos Capuchos; HSM – Hospital de S. Marta*

### 3.3. Conhecimento e Experiência com Tecnologias Emergentes

#### 3.3.1 Contacto Prévio, Formação e Utilização Atual

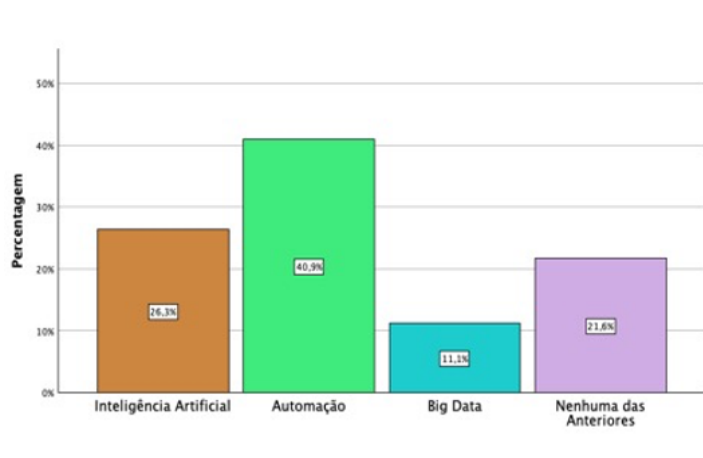
A análise destas três variáveis em conjunto evidencia uma aparente discrepância: embora 61,0% refiram já ter tido contacto com sistemas de IA ou automação no local de trabalho, apenas 36,4% indicam que a sua unidade dispõe efetivamente dessas tecnologias e 44,1% participaram em formações específicas. Esta diferença sugere que os inquiridos podem ter interpretado 'contacto' de forma ampla, incluindo experiências pontuais, exposições indiretas ou mesmo ações formativas. A inconsistência entre estas respostas constitui um resultado relevante em si, pois evidencia a ausência de uma compreensão homogénea sobre o que significa 'utilizar IA em contexto laboral'

**Tabela 6** – *Contacto prévio, participação em formação e utilização atual de IA em laboratório (frequência absoluta e relativa)*

Afirmação	SIM (n; %)	NÃO (n; %)	TOTAL
Contacto prévio com IA/automação	72 (61%)	46 (39,0%)	118 (100%)
Participação em formação	52 (44,1%)	66 (55,9%)	118 (100%)
Utilização de IA no laboratório	43 (36,4%)	75 (63,6%)	118 (100%)

#### 3.3.2 Áreas de Conhecimento Declarado

Quando questionados sobre áreas de conhecimento, a automação foi a mais referida (40,7%), seguida da inteligência artificial (31,4%). O *Big Data* surge com menor expressão (11,9%), enquanto 21,2% afirmaram não possuir conhecimentos em nenhuma das áreas apresentadas. Esta distribuição indica que o conhecimento declarado tende a concentrar-se nas tecnologias já aplicadas diretamente ao contexto laboratorial, ao passo que conceitos mais avançados, como o *Big Data*, permanecem menos disseminados.



**Figura 2** – *Áreas de conhecimento tecnológico declaradas pelos profissionais*

Em síntese, embora 61% dos participantes já tenham tido contacto com IA ou automação, apenas 44% referem ter recebido formação formal na área. A utilização efetiva nos laboratórios ainda é minoritária (36%), revelando uma implementação desigual. No que respeita ao conhecimento declarado, a automação surge como a área mais reconhecida (40,7%), enquanto cerca de um quinto dos profissionais admite não possuir contacto com nenhuma das dimensões tecnológicas propostas.

### 3.4 Perceções Sobre Benefícios da IA e Automação

Os profissionais inquiridos manifestaram, de forma consistente, uma perceção positiva quanto ao potencial da IA e da automação para melhorar a prática laboratorial. As médias situaram-se entre 3,7 e 4,0 numa escala de 1 a 5, indicando uma avaliação predominantemente positiva dos benefícios esperados.

#### 3.4.1 Precisão, Padronização e Redução de Erros

Os resultados evidenciam uma perceção globalmente favorável quanto ao potencial da IA na melhoria da qualidade laboratorial (Tabela 7). A redução de erros e o aumento da precisão no processamento de amostras são as dimensões mais valorizadas, enquanto a padronização de processos, embora também avaliada positivamente, revela maior dispersão de opiniões. Este padrão sugere que os profissionais percecionam os benefícios operacionais da IA de forma mais imediata do que os seus efeitos na uniformização de procedimentos, dimensão que implica mudanças mais profundas na prática laboratorial.

**Tabela 7** - Distribuição das respostas sobre precisão, redução de erros e padronização dos processos (frequência absoluta e relativa, escala Likert: 1 = Discordo Totalmente; 5 = Concordo Totalmente)

Afirmção	1 (n/%)	2 (n/%)	3 (n/%)	4 (n/%)	5 (n/%)	Média (M)
Precisão e eficiência no processamento	1 (0,8%)	3 (2,5%)	17 (14,4%)	71 (60,2%)	22 (18,6%)	3,94
Redução de erros no diagnóstico	0 (0%)	3 (2,5%)	19 (16,1%)	54 (45,8%)	42 (35,6%)	3,99
Padronização de processos	1 (0,8%)	3 (2,5%)	28 (23,7%)	61 (51,7%)	25 (21,2%)	3,77

#### 3.4.2 Eficiência e Otimização de Recursos

A eficiência e a otimização de recursos são percecionadas de forma amplamente positiva (Tabela 8). Os ganhos operacionais mais imediatos, poupança de tempo e gestão de amostras são as que recolhem maior consenso entre os profissionais, enquanto a otimização de recursos humanos e tecnológicos gera opiniões mais

divididas. Esta diferença é interpretável: benefícios tangíveis no dia-a-dia laboratorial são mais facilmente antecipados do que impactos estruturais na alocação de pessoas e equipamentos, que envolvem decisões de gestão mais complexas.

**Tabela 8** - Distribuição das respostas sobre eficiência e otimização de recursos (frequência absoluta e relativa, escala Likert: 1 = Discordo Totalmente; 5 = Concordo Totalmente)

Afirmação	1 (n/%)	2 (n/%)	3 (n/%)	4 (n/%)	5 (n/%)	Média (M)
Conveniência/poupança de tempo	1 (0,8%)	2 (1,7%)	18 (15,3%)	64 (54,2%)	30 (25,4%)	4,04
Gestão de amostras/fluxo de trabalho	1 (0,8%)	1 (0,8%)	18 (15,3%)	66 (55,9%)	32 (27,1%)	4,03
Otimização de recursos humanos e tecnológicos	1 (0,8%)	4 (3,4%)	30 (25,4%)	60 (50,8%)	23 (19,5%)	3,86
Redução do tempo de entrega de resultados	1 (0,8%)	2 (1,7%)	22 (18,6%)	62 (52,5%)	31 (26,3%)	3,97

### 3.4.3 Impacto Direto no Trabalho dos Profissionais

Quando convidados a avaliar se a IA poderia melhorar o seu próprio trabalho, os participantes atribuíram, em média, 6,75 pontos numa escala de 1 a 10. A distribuição das respostas mostra maior concentração nos níveis 7, 8 e 5, enquanto apenas uma pequena percentagem pontuou entre 1 e 3. Estes resultados indicam uma tendência globalmente positiva, com avaliações situadas predominantemente nos níveis intermédios a elevados da escala, ainda que sem uniformidade total entre os profissionais.

## 3.5 Desafios Técnicos

Os profissionais inquiridos identificam múltiplos obstáculos à adoção plena da IA e da automação em laboratórios clínicos.

### 3.5.1 Limitações Estruturais e Organizacionais

As barreiras estruturais e organizacionais são transversalmente reconhecidas como obstáculos relevantes à adoção da IA (Tabela 9). O investimento financeiro e a interoperabilidade entre sistemas surgem como as preocupações mais consensuais, reflectindo uma consciência clara de que a transformação digital implica custos e reestruturações técnicas significativas. A maior dispersão verificada na infraestrutura adequada indica que a realidade varia entre os diferentes polos hospitalares da ULS S. José, o que é coerente com a heterogeneidade organizacional da instituição.

**Tabela 9** - Distribuição das respostas sobre limitações estruturais e organizacionais (escala Likert: 1 = Discordo Totalmente; 5 = Concordo Totalmente)

Afirmção	1 (n/%)	2 (n/%)	3 (n/%)	4 (n/%)	5 (n/%)	Média (M)
Falta de infraestrutura adequada	1 (0,8%)	6 (5,1%)	32 (27,1%)	47 (39,8%)	32 (27,1%)	3,87
Manutenção contínua dos sistemas	1 (0,8%)	2 (1,7%)	14 (11,9%)	61 (51,7%)	40 (33,9%)	4,07
Interoperabilidade entre sistemas	0 (0%)	3 (2,5%)	12 (10,2%)	62 (52,5%)	41 (34,7%)	4,27
Investimentos financeiros significativos	0 (0%)	1 (0,8%)	12 (10,2%)	56 (47,5%)	49 (41,5%)	4,35

### 3.5.2 Competências e Confiança Tecnológica

Este bloco apresenta os resultados mais heterogêneos de toda a dimensão técnica (Tabela 10). A avaliação dividida sobre a capacidade da formação atual reflete realidades distintas entre profissionais: os que já tiveram contacto com sistemas automatizados tendem a sentir-se mais preparados, enquanto os sem experiência prévia identificam lacunas formativas. Notavelmente, a confiança na precisão da IA é superior à percepção de preparação da equipa, o que sugere que os profissionais acreditam na tecnologia mas não se sentem ainda habilitados para a operar com plena autonomia, argumento que reforça a necessidade de programas de literacia digital diferenciados.

**Tabela 10** - Distribuição das respostas sobre competências e confiança tecnológica (escala Likert: 1 = Discordo Totalmente; 5 = Concordo Totalmente)

Afirmção	1 (n/%)	2 (n/%)	3 (n/%)	4 (n/%)	5 (n/%)	Média (M)
Formação técnica da equipa atual não é suficiente	2 (1,7%)	8 (6,8%)	47 (39,8%)	44 (37,3%)	17 (14,4%)	3,40
Confiança de que a IA realiza tarefas laboratoriais com precisão	1 (0,8%)	7 (5,9%)	24 (20,3%)	59 (50,0%)	27 (22,9%)	3,68

### 3.6 Desafios Éticos

As percepções dos profissionais refletem preocupações significativas em torno das implicações éticas da adoção da IA e automação em laboratórios clínicos.

#### 3.6.1 Riscos para a Prática Profissional e a Privacidade

As preocupações éticas e profissionais revelam um padrão de risco percebido que é simultaneamente difuso e diferenciado (Tabela 11). Os riscos relacionados com o emprego e com a autonomia profissional na validação do diagnóstico concentram maior concordância, enquanto a privacidade dos dados gera as opiniões mais divididas, o que é interpretável num contexto em que os profissionais têm experiências muito distintas

com sistemas de informação hospitalar. Em conjunto, os resultados apontam para uma aceitação condicionada: os profissionais estão abertos à IA, mas exigem garantias sobre o seu papel e sobre a proteção dos dados antes de aderirem plenamente.

**Tabela 11** - Distribuição das respostas sobre riscos profissionais e éticos (escala Likert: 1 = Discordo Totalmente; 5 = Concordo Totalmente)

Afirmção	1 (n/%)	2 (n/%)	3 (n/%)	4 (n/%)	5 (n/%)	Média (M)
A automação pode impactar negativamente a segurança e privacidade dos dados	6 (5,1%)	22 (18,6%)	33 (28,0%)	41 (34,7%)	16 (13,6%)	3,07
A implementação de IA pode reduzir o número de postos de trabalho no laboratório	1 (0,8%)	11 (9,3%)	35 (29,7%)	41 (34,7%)	30 (25,4%)	3,71
A introdução de IA e automação pode gerar insegurança nos profissionais de saúde	4 (3,4%)	13 (11,0%)	32 (27,1%)	47 (39,8%)	22 (18,6%)	3,47
A utilização de IA pode comprometer o papel crítico dos profissionais na validação de diagnósticos	4 (3,4%)	11 (9,3%)	19 (16,1%)	49 (41,5%)	35 (29,7%)	3,64

### 3.6.2 Participação e Envolvimento nas Decisões

O envolvimento dos profissionais nas decisões sobre a implementação da IA é o ponto com maior consenso de todo o questionário (Tabela 12). Este resultado não é trivial: numa amostra que inclui perfis atitudinais tão distintos como Reticentes, Ambivalentes e Entusiastas, a convergência em torno desta afirmação indica que a participação é percebida como condição de legitimidade do processo, independentemente da posição face à tecnologia. Por outras palavras, mesmo quem desconfia da IA considera essencial ser ouvido antes da sua introdução, o que tem implicações diretas para o modelo de governança a adotar no HLO.

**Tabela 12** - Distribuição das respostas sobre participação nas decisões (escala Likert: 1 = Discordo Totalmente; 5 = Concordo Totalmente)

Afirmção	1 (n/%)	2 (n/%)	3 (n/%)	4 (n/%)	5 (n/%)	Média (M)
É essencial envolver os profissionais nas decisões sobre a implementação de IA	0 (0,0%)	3 (2,5%)	3 (2,5%)	39 (33,1%)	73 (61,9%)	4,62

### 3.7 Aceitação e Confiança na Tecnologia

Os resultados evidenciam uma aceitação globalmente positiva da IA e da automação em contexto laboratorial, embora marcada por algumas reservas quanto à ética, previsibilidade e proteção de dados.

### 3.7.1 Conforto e Confiança na Utilização da Inteligência Artificial

Os níveis de conforto e confiança na IA são moderados e internamente diferenciados (Tabela 13). O dado mais saliente é a protecção de dados pessoais, única variável abaixo do ponto médio da escala (M=2,99), o que contrasta com a confiança na capacidade de aprendizagem e evolução da tecnologia (M=3,62). Este padrão — confiar na tecnologia como sistema, mas desconfiar da sua gestão de dados — é consistente com a literatura sobre aceitação tecnológica em saúde e aponta para a necessidade de políticas de transparência e comunicação sobre o tratamento de dados antes da implementação.

**Tabela 13** - Distribuição das respostas sobre conforto e confiança na utilização da IA (escala Likert: 1 = Discordo Totalmente; 5 = Concordo Totalmente)

Afirmção	1 n (%)	2 n (%)	3 n (%)	4 n (%)	5 n (%)	Média (M)
Sinto-me confortável com o uso de IA no meu ambiente de trabalho	2 (1,7%)	8 (6,8%)	39 (33,1%)	52 (44,1%)	17 (14,4%)	3,47
Confio que a IA pode ser usada de forma ética	3 (2,5%)	11 (9,3%)	41 (34,7%)	42 (35,6%)	21 (17,8%)	3,54
Confio que a IA protege os meus dados pessoais	5 (4,2%)	18 (15,3%)	53 (44,9%)	30 (25,4%)	12 (10,2%)	2,99
Acredito que a IA é previsível no seu funcionamento	3 (2,5%)	15 (12,7%)	50 (42,4%)	40 (33,9%)	10 (8,5%)	3,29
Tenho confiança na capacidade da IA de aprender e melhorar	2 (1,7%)	8 (6,8%)	30 (25,4%)	56 (47,5%)	22 (18,6%)	3,62

### 3.7.2 Percepções sobre o Impacto da Automação e da Inteligência Artificial

Os resultados revelam uma percepção globalmente favorável quanto ao impacto da automação e da IA nos laboratórios. A automação é vista como uma evolução positiva por 83,1% dos profissionais (M=4,06), e 71,2% consideram a IA essencial para o futuro da medicina laboratorial (M=3,94). Ainda que 28,8% tenham mantido posição neutra relativamente ao impacto global, a tendência predominante é claramente positiva.

**Tabela 14** - Percepções globais sobre o impacto da IA e automação (escala Likert: 1 = Discordo Totalmente; 5 = Concordo Totalmente)

Afirmção	1 n (%)	2n (%)	3 n (%)	4 n (%)	5 n (%)	Média (M)
A automação no laboratório é uma evolução positiva para os profissionais de saúde	1 (0,8%)	8 (6,8%)	11 (9,3%)	58 (49,2%)	40 (33,9%)	4,06
Considero que o impacto da IA e automação será mais positivo do que negativo	2 (1,7%)	15 (12,7%)	34 (28,8%)	48 (40,7%)	19 (16,1%)	3,85
De uma forma geral, acho que a IA é essencial para o futuro da medicina laboratorial	3 (2,5%)	11 (9,3%)	19 (16,1%)	54 (45,8%)	30 (25,4%)	3,94

### 3.7.3 Motivação e Predisposição para Formação

A predisposição para formação e a motivação para participar na integração da IA são os resultados mais positivos de todo o questionário (Tabela 15). Este dado é estrategicamente relevante: mesmo entre profissionais com reservas éticas ou técnicas, a abertura à aprendizagem mantém-se elevada, o que indica que a resistência à IA não é estrutural mas circunstancial, dependente de formação adequada e de um processo de implementação que inclua os profissionais. É um ponto de desenvolvimento central para qualquer plano de adoção.

**Tabela 15** - Motivação e predisposição (escala Likert: 1 = Discordo Totalmente; 5 = Concordo Totalmente)

Afirmação	1 n (%)	2 n (%)	3 n (%)	4 n (%)	5 n (%)	Média (M)
Estou disposto(a) a receber formação para trabalhar com IA e automação	1 (0,8%)	2 (1,7%)	10 (8,5%)	55 (46,6%)	49 (41,5%)	4,38
Estou motivado(a) para contribuir para a integração destas tecnologias no laboratório	2 (1,7%)	4 (3,4%)	19 (16,1%)	59 (50,0%)	34 (28,8%)	4,09

### 3.7.4 Obstáculos e Áreas de maior Impacto

Quando convidados a identificar os principais obstáculos à adoção de tecnologias emergentes, os participantes destacaram sobretudo o custo elevado e a insuficiência de infraestrutura, seguidos pela falta de formação adequada. Foram também referidas preocupações éticas (privacidade, transparência algorítmica e substituição de funções humanas) e a resistência à mudança. Quanto às áreas com maior impacto esperado, a automatização de tarefas repetitivas surge como a mais assinalada, referindo-se, no contexto laboratorial, a processos como pipetagem, centrifugação, rotulagem e distribuição de amostras, atualmente executados de forma manual ou semi-automática. Seguem-se a gestão de amostras e a triagem inicial, que englobam a receção, identificação e priorização dos pedidos analíticos, a interpretação de resultados, que inclui a validação técnica e biopatológica dos resultados antes da sua emissão, e a organização de dados clínicos, relacionada com a integração e gestão da informação nos sistemas LIS e HIS. Estas são funções críticas para a rastreabilidade, a eficiência e a redução do erro humano no fluxo laboratorial.

De forma global, os resultados indicam que, embora persistam reservas quanto a questões éticas e organizacionais, a amostra valoriza fortemente os ganhos de eficiência e demonstra disposição ativa para a integração da IA e automação no futuro da medicina laboratorial (M=3,94).

### 3.8 Análise Fatorial e Segmentação por *Clusters*

A Análise Fatorial Exploratória permitiu identificar três fatores que explicam 57,5% da variância total (ver secção 2.7.2), aos quais correspondem três perfis atitudinais distintos:

1. Confiança e abertura à IA — integra percepções positivas sobre a utilidade, eficiência e predisposição para a adoção da tecnologia. Os itens com maior peso neste fator relacionam-se com a crença na capacidade da IA para melhorar o desempenho laboratorial, reduzir erros e otimizar o fluxo de trabalho ( $\alpha = 0,925$ ; excelente consistência interna) (George & Mallery, 2003).
2. Preocupações éticas, técnicas e profissionais — abrange receios relativos à privacidade de dados, ao impacto no emprego e ao papel humano no processo diagnóstico. Os itens dominantes referem-se ao risco de substituição de profissionais, à opacidade dos algoritmos e à insegurança face à proteção de dados pessoais ( $\alpha = 0,678$ ; questionável, expectável numa dimensão de natureza multidimensional em contexto exploratório) (George & Mallery, 2003).
3. Conforto e segurança pessoal com a IA — reflete a confiança subjetiva na tecnologia e o bem-estar associado ao seu uso quotidiano. Destacam-se itens relacionados com o conforto no uso de IA no ambiente de trabalho, a confiança na sua previsibilidade e na sua capacidade de aprendizagem e evolução ( $\alpha = 0,775$ ; bom) (George & Mallery, 2003).

A partir destes fatores, foi conduzida uma análise de *clusters* que permitiu identificar três perfis distintos entre os profissionais:

- *Cluster 1* – Reticentes (23%): perfil mais crítico e desconfiado, caracterizado por maiores preocupações éticas e técnicas, associado a menor conforto subjetivo no uso da tecnologia.
- *Cluster 2* – Entusiastas (23%): perfil mais confiante, com reduzida percepção de risco e elevado conforto na utilização da IA e da automação.
- *Cluster 3* – Ambivalentes (54%): grupo maioritário, com percepções mistas; demonstram abertura moderada à inovação, mas mantêm reservas em algumas dimensões.

A classificação em *clusters* permitiu, assim, distinguir grupos de profissionais com padrões de percepção diferenciados, oferecendo uma base sólida para a análise qualitativa subsequente.

**Tabela 16** - *Fatores e Clusters identificados*

<b>Fator identificado</b>	<b>Alfa de Cronbach</b>	<b>Perfil associado ao Cluster</b>	<b>Proporção aproximada da amostra</b>
Confiança e abertura à IA	0,925 (excelente)	Entusiastas	23%
Preocupações éticas, técnicas e profissionais	0,678 (aceitável)	Reticentes	23%
Conforto e segurança pessoal com a IA	0,775 (bom)	Ambivalentes	54%

### **3.9 Análise Bivariada entre Contacto Prévio com IA e Pertença ao Cluster**

Com o objetivo de compreender a relação entre a experiência prática dos profissionais e as suas atitudes perante a IA, foi testada a associação entre a variável “contacto prévio com IA” e a “pertença ao *cluster*” identificado na análise anterior.

O teste do qui-quadrado de independência revelou associação estatisticamente significativa ( $\chi^2(2) = 9,034$ ;  $p = 0,011$ ), rejeitando-se a hipótese nula de independência entre as variáveis. Este resultado indica que a experiência prática com IA influencia a probabilidade de pertença a um determinado *cluster*.

A análise detalhada mostra que os profissionais com contacto prévio com IA tendem a concentrar-se nos grupos mais favoráveis à tecnologia, em particular entre os entusiastas e, em menor grau, nos ambivalentes. Já entre os reticentes, observa-se maior proporção de indivíduos sem experiência prévia com estas ferramentas (ver tabela 17).

Este padrão sugere que o contacto direto com tecnologias de IA contribui para aumentar a familiaridade, a confiança e a percepção de utilidade, enquanto a ausência de experiência está mais associada a reservas ou preocupações éticas e técnicas. Assim, a experiência prática emerge como um fator diferenciador nas atitudes face à transformação digital em contexto laboratorial.

**Tabela 17 - Associação entre contacto prévio com IA e pertença ao Cluster**

<b>Cluster</b>	<b>Com contacto prévio com IA</b>	<b>Sem contacto prévio com IA</b>	<b>Interpretação principal</b>
Reticentes (23%)	10 (37%)	17 (63,0%)	Mais críticos, associam-se a ausência de experiência
Entusiastas (23%)	20 (74,1%)	7 (25,9%)	Confiança elevada, associada ao contacto prévio
Ambivalentes (54%)	42 (65,6%)	22 (34,4%)	Atitudes mistas, mas influenciadas pela experiência

De forma global, os resultados evidenciam um equilíbrio entre perceções positivas e preocupações éticas, técnicas e profissionais, refletindo a complexidade da integração da IA em contexto laboratorial. A identificação de três perfis distintos de profissionais e a associação significativa entre experiência prévia e atitudes face à tecnologia constituem pistas relevantes para compreender os fatores que potenciam ou limitam a adoção destas soluções.

### **3.10 Análise das Entrevistas**

A segunda fase da investigação incluiu entrevistas semiestruturadas (n=9) com profissionais da ULS S. José, selecionados entre os respondentes ao questionário que manifestaram interesse em participar.

#### **3.10.1 Caracterização da Amostra Qualitativa**

A amostra das entrevistas foi composta maioritariamente por profissionais do HSJ (66,7%), incluindo ainda participantes do HDE (11,1%), HSM (11,1%) e MAC (11,1%). Em termos de género, registou-se uma predominância masculina (55,6% homens, 44,4% mulheres). No que respeita à idade, destacaram-se os profissionais 30–39 anos (55,6%), seguidos dos grupos >60 anos (22,2%), 50–59 anos (11,1%) e >50 anos não especificado (11,1%). Esta diversidade permitiu captar perspetivas de diferentes trajetórias profissionais e níveis de experiência.

#### **3.10.2 Eixos Temáticos**

A análise temática, realizada com apoio do software MAXQDA, evidenciou seis grandes eixos transversais, conforme apresentado na tabela 18. Para além da identificação qualitativa, foi realizada a codificação das respostas, contabilizando o número de entrevistados que abordaram cada eixo. Esta análise de frequência permitiu identificar os temas mais recorrentes.

**Tabela 18** – Frequência dos eixos temáticos nas entrevistas (n=9; % calculada sobre o total de entrevistados)

Eixo Temático	Nº de entrevistados (n) e %	Exemplos de citações
Contacto prévio e experiência com IA	4 – 44,4%	“Desde que foi implementado, o processo tornou-se mais rápido e mais seguro” (I); “Nunca usei, por isso não sei se confio. Dá-me alguma insegurança” (C)
Perceção de benefícios	5 – 55,6%	“Se a máquina consegue evitar que eu repita um erro, é bem-vinda” (F); “A IA ajuda na triagem, poupa-nos tempo” (D)
Barreiras técnicas e organizacionais	3 – 33,3%	“O sistema atual não está preparado para trabalhar com estas novas plataformas. Teria de ser tudo integrado de raiz” (H); “Claro que custa dinheiro, mas se for bem implementado, compensa” (B)
Questões éticas e papel profissional	6 – 66,7%	“Se for tudo automático, o nosso trabalho perde valor” (H); “Tenho medo de onde vão parar os nossos dados. Não confio totalmente” (E); “Temos que ser maduros. Saber supervisionar, porque a inteligência artificial ainda não tem esse dom que nós temos” (I)
Motivação e predisposição para formação	4 – 44,4%	“Se explicarem bem e houver tempo, posso aprender” (A); “Acho que os procedimentos emocionais são preponderantes” (G)
Visão estratégica e liderança institucional	3 – 33,3%	“Se o novo hospital não for IA, já nasce velho” (I); “Um comboio que já arrancou” (F)

Nota: Os valores (n) referem-se ao número de entrevistados que abordaram explicitamente cada eixo. Como cada entrevistado podia mencionar mais do que um tema, a soma ultrapassa o total de 9 entrevistas.

Os temas foram distribuídos conforme a Figura 3, esta apresenta a distribuição relativa dos temas referidos pelos entrevistados. Observa-se que as questões éticas e o papel profissional foram os aspetos mais destacados (6 em 9 entrevistados), seguidos da perceção de benefícios (5 em 9). Em contrapartida, as barreiras técnicas e a visão estratégica foram menos salientadas, embora relevantes para a compreensão da diversidade de perceções.



**Figura 3** – Distribuição relativa dos eixos temáticos identificados nas entrevistas. Elaboração própria com base na análise temática realizada no MAXQDA e representação gráfica construída no Microsoft Excel.

### 3.10.3 Integração com *Clusters* Quantitativos

A análise qualitativa confirma e aprofunda os padrões previamente identificados nos *clusters* da análise quantitativa (Apêndice G – Caracterização dos *Clusters*).

#### **Cluster 1 – Reticentes (n=27; 23%)**

- Perfil sociodemográfico: Predominância de profissionais seniores, sobretudo entre os 40–49 anos (48,1%) e >60 anos (11,1%), maioritariamente femininos (77,8%), (14,8%) masculinos e prefiro não dizer com (7,4%), estando essencialmente concentrados no HSJ (55,6%) e HDE (18,5%).
- Atitudes: Elevada preocupação com perda de postos de trabalho (M=3,71), insegurança profissional (M=3,47) e desvalorização do papel humano na validação (M=3,64).
- Testemunhos:
  - “Nunca usei, por isso não sei se confio. Dá-me alguma insegurança.” (C)
  - “Se for tudo automático, o nosso trabalho perde valor.” (H).

#### **Cluster 2 – Entusiastas (n=27; 23%)**

- Perfil sociodemográfico: Maior proporção de profissionais com formação avançada (mestrado 33,7% e doutoramento 3,7%), novamente presença maioritária no HSJ, com 81,5% de profissionais do género feminino e 18,5% masculino.
- Atitudes: Elevada confiança na IA (M>4), perceção de ganhos em rapidez, eficiência e qualidade.
- Testemunhos:
  - “Desde que foi implementado, o processo tornou-se mais rápido e mais seguro.” (I)
  - “É impossível ser contra porque já se está nela. É o futuro.” (I)

#### **Cluster 3 – Ambivalentes (n=64; 54%)**

- Perfil sociodemográfico: Grupo mais heterogéneo, distribuído por vários polos hospitalares: HSJ (45,3%), HDE (23,4%), MAC (12,5%), HSM (7,8%), HCC (6,3%) e HSAC (4,7%), incluindo profissionais seniores e intermédios. Aqui a representatividade volta a ser maioritariamente feminina (82,8%), (12,5%) masculina e (4,7%) prefiro não dizer.

- Atitudes: Reconhecem benefícios (ex.: poupança de tempo M=4,04; eficiência do fluxo M=4,03), mas mantêm reservas sobre ética (dados pessoais M=2,99) e previsibilidade da IA (M=3,29).
- Testemunhos:
  - o “Temos que ser maduros. Saber supervisionar, porque a inteligência artificial ainda não tem esse dom que nós temos.” (I)
  - o “Acho que os procedimentos emocionais são preponderantes.” (A)

Em conjunto, os dados qualitativos e quantitativos revelam um quadro heterogêneo de percepções. Identificam-se convergências, como o reconhecimento dos benefícios práticos da IA, a predisposição para formação e a valorização da supervisão humana. Em contrapartida, emergem divergências em torno da confiança, com maior resistência entre os profissionais sem contacto prévio com IA e receios relacionados com a substituição do trabalho humano ou com riscos associados à proteção de dados.

Os retratos individuais de cada entrevistado e os retratos comparativos por *cluster*, gerados no MAXQDA, encontram-se apresentados no Apêndice F, constituindo material de suporte e evidência para a interpretação desenvolvida neste capítulo.

Estes resultados demonstram que a aceitação da inteligência artificial depende não apenas de fatores técnicos, mas também de dimensões éticas, emocionais e da experiência profissional acumulada.

## CAPÍTULO 4 - DISCUSSÃO

A análise dos resultados permitiu compreender em profundidade as percepções, atitudes e racionalidades dos profissionais da ULS S. José relativamente à introdução de sistemas de IA e automação no novo Laboratório de Patologia Clínica do HLO. A triangulação metodológica, que combinou análise quantitativa através da análise estatística dos questionários (*SPSS*), entrevistas semiestruturadas com análise qualitativa apoiada pelo *MAXQDA*, revelou uma realidade marcada por contrastes: entusiasmo e confiança convivem com receios éticos, técnicos e organizacionais.

Um dos achados centrais consiste na associação entre contacto prévio com tecnologias emergentes e atitudes mais favoráveis face à sua adoção. Os profissionais do *Cluster 2* (Entusiastas), com maior experiência em automação e algoritmos de validação, revelaram níveis mais elevados de confiança e perceção de utilidade, corroborando evidência empírica que demonstra que a familiaridade tecnológica constitui um preditor significativo de aceitação da IA em saúde (Rony et al., 2024). Em contrapartida, o *Cluster 1* (Reticentes) agregou profissionais com menor contacto prévio e maior antiguidade, manifestando percepções de vulnerabilidade e insegurança, particularmente no que respeita à desvalorização do papel humano.

Neste âmbito, destacou-se de forma recorrente o receio de perda de postos de trabalho, associado quer à automação, quer ao processo de fusão dos seis polos hospitalares que integrarão o HLO. O testemunho "Se for tudo automático, o nosso trabalho perde valor" (H) sintetiza esta preocupação. A literatura internacional confirma a pertinência deste achado: Jussupow et al. (2022) salientam que a introdução de algoritmos clínicos pode ser interpretada como ameaça à identidade profissional, potenciando sentimentos de perda de autonomia e de poder de decisão. De igual modo, Davenport e Kalakota (2019) referem que a automatização de tarefas clínicas suscita receios de redundância, sobretudo em contextos de reorganização institucional.

Estes resultados demonstram que a aceitação da inteligência artificial depende não apenas de fatores técnicos, mas também de dimensões éticas, emocionais e da experiência profissional acumulada. A conjugação entre reorganização estrutural e inovação tecnológica reforça a dimensão ética da discussão. Não se trata apenas de avaliar riscos algorítmicos ou falhas técnicas, mas de compreender o impacto humano de uma mudança sistémica que pode deixar parte dos profissionais sem função ou sem identidade profissional clara. Estudos recentes apontam que a introdução de inteligência artificial pode constituir uma ameaça à identidade profissional, levando a percepções de

perda de autonomia e poder de decisão, frequentemente interpretadas pelos profissionais como ameaça à sua prática e papel social (Jussupow et al., 2022). Esta reticência não deve, por isso, ser entendida como simples resistência cultural, mas antes como expressão de vulnerabilidade perante a transição tecnológica, que conjuga racionalização de recursos com a introdução de sistemas disruptivos. Do ponto de vista ético, a literatura enfatiza que a adoção de IA em saúde deve estar ancorada em princípios como a autonomia, a beneficência, a não-maleficência, a justiça e a transparência, de modo a assegurar que a eficiência técnica não compromete a dimensão humana do cuidado (Pham, 2025). Estes elementos reforçam que a reflexão ética é indispensável, não apenas para mitigar riscos técnicos, mas também para garantir a preservação de valores humanos e profissionais num contexto de inovação acelerada.

Os participantes nas entrevistas expressam preocupações com a proteção de dados ("Tenho medo de onde vão parar os nossos dados. Não confio totalmente" – E) evidenciam a relevância da explicabilidade algorítmica e da supervisão humana significativa, identificadas como condições necessárias à construção de confiança (London, 2019; Rajkomar et al., 2019).

Por outro lado, os Entusiastas demonstraram uma percepção estratégica e positiva da inevitabilidade da digitalização. Declarações como "Se o novo hospital não for IA, já nasce velho" (I) e "É impossível ser contra porque já se está nela. É o futuro" (I) expressam não apenas familiaridade técnica, mas também uma leitura institucional alargada, que reconhece na IA um requisito de modernização organizacional e democratização do acesso à informação. Este posicionamento converge com perspectivas de equidade e justiça distributiva salientadas por Rajkomar et al. (2019).

O *Cluster 3* (Ambivalentes), representando mais de metade da amostra, assumiu uma posição intermédia, reconhecendo benefícios claros como a rapidez e a redução de erros, mas mantendo reservas éticas e organizacionais. A literatura indica que, em fases iniciais de introdução de tecnologias emergentes, é expectável que predomine a ambivalência, traduzindo simultaneamente prudência e abertura à experimentação (Greenhalgh et al., 2017; Holden & Karsh, 2010). Este posicionamento sugere que a maioria dos profissionais poderá ser mobilizada através de estratégias de formação prática, *quick wins* e comunicação transparente, que demonstrem a fiabilidade da IA em contextos reais, reduzindo incertezas e promovendo confiança (Jussupow et al., 2022).

Do ponto de vista técnico e organizacional, os dados reforçam que as principais barreiras percebidas estão relacionadas com os custos de implementação e com a interoperabilidade dos sistemas, aspectos frequentemente identificados como desafios estruturais em processos de transformação digital (Morley et al., 2020; WHO, 2021). O reconhecimento de que tais custos podem ser compensados por ganhos de eficiência futura ("Claro que custa dinheiro, mas se for bem implementado, compensa" – B) demonstra uma percepção pragmática e a necessidade de avaliações de custo-benefício robustas.

A predisposição generalizada para formação constituiu um dos achados mais consistentes. Mesmo entre os Reticentes, emergiu a abertura a processos formativos ("Se explicarem bem e houver tempo, posso aprender" – A). Este resultado reforça que a resistência não é absoluta, mas modulável mediante estratégias adequadas de capacitação. A literatura confirma a eficácia de programas de literacia digital progressivos (Gerlich, 2023) e da tutoria entre pares como fator de redução de resistências (Holden & Karsh, 2010). A valorização de aspectos emocionais na aprendizagem ("Acho que os procedimentos emocionais são preponderantes" – A) indica que a formação deverá integrar não apenas competências técnicas, mas também dimensões culturais e relacionais.

O resultado mais consensual de todo o estudo, - a percepção de que os profissionais devem ser ativamente envolvidos nas decisões sobre a implementação da IA (M=4,62; >95% de concordância) — merece reflexão aprofundada. Este achado traduz uma reivindicação ética de agência profissional num processo de transformação que os afeta diretamente. A literatura sobre mudança organizacional em saúde é clara neste ponto — a ausência de envolvimento dos profissionais nas decisões tecnológicas é um dos principais preditores de resistência e insucesso na implementação (Greenhalgh et al., 2017; WHO, 2021). Este resultado deve, por isso, ser traduzido em mecanismos concretos de participação, como grupos de trabalho multidisciplinares, processos de consulta formal e canais de *feedback* contínuo durante a transição para o HLO.

A análise do conhecimento tecnológico declarado revela um padrão relevante: a automação é a área mais reconhecida (40,7%), seguida da IA (31,4%), enquanto conceitos mais avançados como o *Big Data* permanecem pouco disseminados (11,9%). Este gradiente reflete a proximidade funcional dos profissionais com as tecnologias, a automação laboratorial já é uma realidade do quotidiano, enquanto a IA e os dados massivos são ainda percebidos como mais distantes. Esta hierarquia de familiaridade deve orientar as estratégias de formação, partindo das tecnologias já

conhecidas para introduzir progressivamente conceitos mais complexos, reduzindo a distância percebida e aumentando a confiança na adoção (Gerlich, 2023).

Com base nos achados apresentados, foi elaborado um Plano de Ação estruturado em cinco eixos estratégicos, capacitação profissional, infraestrutura tecnológica, ética e governança, comunicação interna e monitorização contínua, detalhado no Apêndice G. Em particular, a elevada predisposição para formação ( $M=4,38$ ) e o valor atribuído ao envolvimento dos profissionais nas decisões ( $M=4,62$ ) fundamentam diretamente os eixos de capacitação e comunicação propostos.

Este estudo apresenta limitações que importa considerar. A natureza de estudo de caso, circunscrito à ULS S. José, restringe a possibilidade de generalização a outros contextos hospitalares. A recolha de dados por questionário online poderá ter introduzido viés de auto-seleção, favorecendo a participação de profissionais mais motivados ou com maior familiaridade tecnológica.

No questionário, obteve-se um total de 118 respostas, maioritariamente de profissionais do sexo feminino ( $n=96$ ), seguidos de masculino ( $n=17$ ) e 'prefiro não dizer' ( $n=5$ ). Contudo, apenas 11 participantes disponibilizaram voluntariamente o e-mail para contacto posterior, dos quais a maioria era do género masculino ( $n=7$ ), face a apenas ( $n=4$ ) do género feminino. Este desequilíbrio refletiu-se na realização das entrevistas qualitativas, limitando a diversidade de perspetivas recolhidas e introduzindo um potencial viés de género na análise qualitativa. A literatura sobre adoção tecnológica sugere que diferenças de género podem influenciar perceções de utilidade, confiança e risco (Venkatesh & Morris, 2000; Cooper, 2006), pelo que esta assimetria deve ser considerada na interpretação dos resultados qualitativos.

A ausência de uma análise longitudinal constitui igualmente uma limitação relevante, na medida em que impede avaliar a evolução das perceções após a implementação efetiva da IA. Complementarmente, o estudo centra-se exclusivamente nas perceções subjetivas dos profissionais, não sendo possível estabelecer uma articulação direta com indicadores objetivos de desempenho clínico, como taxas de erro laboratorial, tempos de resposta ou indicadores de qualidade analítica. Esta opção decorre do próprio desenho exploratório do estudo, que privilegia a compreensão das atitudes e racionalidades dos profissionais numa fase de pré-implementação. Reconhece-se, contudo, que a triangulação com dados objetivos de desempenho constituiria um contributo relevante para avaliar a concordância entre perceção e impacto real. Sugere-se que estudos futuros integrem esta dimensão, nomeadamente através de desenhos

longitudinais que permitam comparar percepções antes e após a implementação efetiva dos sistemas de IA, correlacionando-as com métricas de qualidade laboratorial mensuráveis.

Em síntese, os achados revelam que a aceitação da IA em contexto laboratorial depende de um equilíbrio entre inovação tecnológica e valorização do capital humano. O entusiasmo manifestado por alguns profissionais coexiste com receios éticos e técnicos, bem como com o medo da perda de postos de trabalho, amplificado pela reestruturação hospitalar. A aceitação da tecnologia dependerá, assim, da capacidade institucional de assegurar uma implementação acompanhada por formação adequada, mecanismos de supervisão ética e comunicação transparente. Apesar das limitações inerentes ao desenho de caso único, os resultados obtidos oferecem contributos relevantes para compreender os desafios da digitalização em saúde e sustentam as recomendações apresentadas na conclusão.

## **CAPÍTULO 5 – CONCLUSÃO**

O presente estudo permitiu mapear e explorar analiticamente as oportunidades, os desafios técnicos e as implicações éticas decorrentes da introdução da IA e da automação no novo Laboratório de Patologia Clínica do Hospital de Lisboa Oriental. Através de uma metodologia mista, que combinou análise estatística de questionários e entrevistas qualitativas, foi possível construir uma visão aprofundada sobre as percepções dos profissionais, revelando que a aceitação da tecnologia não se esgota nos seus benefícios técnicos, mas depende também de dimensões éticas, emocionais e organizacionais.

Os resultados mostraram que a IA é amplamente reconhecida pelo seu potencial para melhorar a padronização, acelerar processos e aumentar a eficiência do diagnóstico laboratorial. Contudo, persistem desafios técnicos significativos, relacionados sobretudo com os custos financeiros, a necessidade de infraestruturas mais robustas e a interoperabilidade entre sistemas. Em paralelo, emergiram preocupações éticas consistentes, centradas na proteção de dados, na opacidade algorítmica e no receio de desvalorização do papel humano, aspetos que demonstram que a resistência expressa por alguns profissionais não deve ser entendida como barreira cultural, mas como manifestação de vulnerabilidade perante a transição tecnológica.

A análise permitiu ainda identificar três perfis atitudinais distintos: Reticentes, Ambivalentes e Entusiastas, que refletem diferentes níveis de confiança, motivação para formação e percepções sobre os impactos da IA. Destaca-se que o grupo dos Ambivalentes constituiu a maioria da amostra, revelando uma posição intermédia marcada pela coexistência de expectativas positivas e reservas quanto às implicações da tecnologia. Este achado encontra respaldo na literatura, que aponta para a predominância de posturas ambivalentes em fases iniciais de adoção de tecnologias emergentes, sobretudo em contextos de elevada incerteza (Topol, 2019; Jussupow et al., 2022; Greenhalgh et al., 2017). Tal evidência reforça que a aceitação tecnológica não é homogénea e que a maioria dos profissionais necessita de informação, capacitação e confiança institucional para evoluir de uma postura hesitante para uma utilização confiante e sustentável.

Apesar de se tratar de um estudo de caso localizado na ULS S. José, e por isso não generalizável, a triangulação de dados demonstrou uma forte coerência entre os resultados estatísticos, os padrões atitudinais e os discursos qualitativos. Esta convergência valida a robustez da metodologia aplicada e confere solidez às recomendações estratégicas formuladas. Para além disso, o alinhamento com políticas

nacionais, como o Plano Nacional de Saúde Digital 2022–2026 e o Plano Nacional de Saúde 2021–2030, e internacionais, como o *AI Act* e as orientações da Organização Mundial de Saúde, posiciona esta investigação como contributo relevante para o debate público e institucional sobre a transformação digital da saúde.

Em linha com estas conclusões, o estudo sustenta ainda um conjunto de recomendações práticas traduzidas num plano de ação orientado para cinco eixos: capacitação profissional, reforço da infraestrutura tecnológica, criação de mecanismos de ética e governança, estratégias de comunicação interna e processos contínuos de monitorização. Estas recomendações procuram assegurar que a transição digital do HLO decorra de forma inclusiva e sustentável, respondendo de forma diferenciada às necessidades dos Reticentes, Ambivalentes e Entusiastas, e alinhando a inovação tecnológica com a valorização do capital humano. O Apêndice G apresenta o Plano de Ação completo, constituindo o principal contributo aplicado desta dissertação para a prática institucional. Este plano propõe-se a operacionalizar os cinco eixos estratégicos identificados, capacitação, infraestrutura, ética, comunicação e monitorização, e distingue-se por ser construído sobre evidência empírica recolhida no próprio contexto de implementação, respondendo de forma diferenciada aos três perfis atitudinais dos profissionais. A sua implementação sistemática poderá constituir um referencial para outras instituições de saúde que enfrentem desafios semelhantes na adoção de IA.

Em síntese, a investigação confirma que a integração da IA no novo Laboratório de Patologia Clínica do HLO representa tanto um desafio tecnológico como humano e institucional. O sucesso desta transformação dependerá menos da rapidez com que os algoritmos forem introduzidos e mais da capacidade da organização em valorizar o capital humano, cultivar confiança e assegurar que todos os profissionais se sintam preparados e envolvidos no processo. A IA poderá constituir o motor da mudança, mas será a inteligência coletiva e o compromisso dos profissionais que determinarão a sua verdadeira integração e impacto no futuro da saúde.

O futuro da patologia clínica dependerá menos da velocidade das máquinas e mais da capacidade das instituições de alinhar inovação tecnológica com ética, transparência e valorização do papel humano.

## REFERÊNCIAS BIBLIOGRÁFICAS

1. Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on explainable artificial intelligence (XAI). *IEEE Access*, 6, 52138–52160 .  
<https://doi.org/10.1109/ACCESS.2018.2870052>
2. Ahmad, N., & Aziz, S. (2021). Transformational leadership and innovation in healthcare organizations: A review. *Leadership in Health Services*, 34(4), 437–451.  
<https://doi.org/10.1108/LHS-02-2020-0009>
3. Amann, J., Blasimme, A., Vayena, E., Frey, D., & Madai, V. I. (2020). Explainability for artificial intelligence in healthcare: A multidisciplinary perspective. *BMC Medical Informatics and Decision Making*, 20(1), 310. <https://doi.org/10.1186/s12911-020-01332-6>
4. Arango-Argoty, G., Garner, E., Pruden, A., Heath, L. S., Vikesland, P., & Zhang, L. (2018). DeepARG: A deep learning approach for predicting antibiotic resistance genes from metagenomic data. *Microbiome*, 6(1), 23. <https://doi.org/10.1186/s40168-018-0401-z>
5. Beauchamp, T. L., & Childress, J. F. (2019). *Principles of biomedical ethics* (8th ed.). Oxford University Press.
6. Benjamins, S., Dhunoo, P., & Mesko, B. (2020). The state of artificial intelligence-based FDA-approved medical devices and algorithms: An online database. *npj Digital Medicine*, 3, 118.  
<https://doi.org/10.1038/s41746-020-00324-0>
7. Blease, C., Kaptchuk, T. J., Bernstein, M. H., Mandl, K. D., Halamka, J. D., & DesRoches, C. M. (2019). Artificial intelligence and the future of primary care: Exploratory qualitative study of UK general practitioners' views. *Journal of Medical Internet Research*, 21(3), e12802.  
<https://doi.org/10.2196/12802>
8. Bodenreider, O. (2004). The Unified Medical Language System (UMLS): Integrating biomedical terminology. *Nucleic Acids Research*, 32(Database issue), D267–D270.  
<https://doi.org/10.1093/nar/gkh061>
9. Buess, M., Keller, R., & Hoffmann, R. (2025). AI-enabled laboratories: Toward adaptive diagnostics. *Journal of Laboratory Automation*. Advance online publication.
10. Cardoso, J., Silva, M., & Oliveira, L. (2020). Knowledge graphs in healthcare: A survey. *Journal of Biomedical Informatics*, 110, 103539. <https://doi.org/10.1016/j.jbi.2020.103539>
11. Cattell, R. B. (1966). The scree test for the number of factors. *Multivariate Behavioral Research*, 1(2), 245–276. [https://doi.org/10.1207/s15327906mbr0102\\_10](https://doi.org/10.1207/s15327906mbr0102_10)
12. Carifio, J., & Perla, R. J. (2008). Resolving the 50-year debate around using and misusing Likert scales. *Medical Education*, 42(12), 1150–1152. <https://doi.org/10.1111/j.1365-2923.2008.03172.x>
13. CEN-GENELEC-ETSI. (2020). *White paper on artificial intelligence: Building trust in human-centric AI*. <https://www.cencenelec.eu>
14. CEN/ISO. (2021). *HL7 FHIR R4 standard*. <https://hl7.org/fhir>
15. Cansado, J. (2024). O AI Act e a saúde: Implicações práticas no SNS. *Revista de Direito e Tecnologia em Saúde*, 6(1), 45–62.
16. Chen, J. H., & Asch, S. M. (2017). Machine learning and prediction in medicine — Beyond the peak of inflated expectations. *The New England Journal of Medicine*, 376(26), 2507–2509.  
<https://doi.org/10.1056/NEJMp1702071>
17. Chen, M., Hao, Y., Cai, Y., Wang, Y., & Wang, K. (2020). Deep learning for medical image processing: Overview, challenges and the future. *Brain Informatics*, 7, 44.  
<https://doi.org/10.1186/s40708-020-00188-1>

18. Chatterjee, S., Dey, S., Munshi, S., & Sural, S. (2021). Hematology image analysis using deep learning: A review. *IEEE Reviews in Biomedical Engineering*, 14, 374–386. <https://doi.org/10.1109/RBME.2020.3001623>
19. Cooper, J. (2006). *The digital divide: The special case of gender*. *Journal of Computer Assisted Learning*, 22(5), 320–334. <https://doi.org/10.1111/j.1365-2729.2006.00185.x>
20. Davenport, T., & Kalakota, R. (2019). The potential for artificial intelligence in healthcare. *Future Healthcare Journal*, 6(2), 94–98. <https://doi.org/10.7861/futurehosp.6-2-94>
21. Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319–340. <https://doi.org/10.2307/249008>
22. Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of Experimental Psychology: General*, 144(1), 114–126. <https://doi.org/10.1037/xge0000033>
23. Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*. <https://doi.org/10.48550/arXiv.1702.08608>
24. Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>
25. Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., ... Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25, 24–29. <https://doi.org/10.1038/s41591-018-0316-z>
26. European Commission. (2019). *Ethics guidelines for trustworthy AI*. <https://digital-strategy.ec.europa.eu/en/library/ethics-guidelines-trustworthy-ai>
27. European Commission. (2021). *Proposal for a regulation laying down harmonised rules on artificial intelligence (AI Act)*. COM(2021) 206 final. <https://eur-lex.europa.eu>
28. European Parliament & Council. (2016). *Regulation (EU) 2016/679 (GDPR)*. <https://eur-lex.europa.eu>
29. European Parliament & Council. (2024). *Artificial Intelligence Act (final text)*. <https://eur-lex.europa.eu>
30. European Parliament & Council. (2024). *European Health Data Space (EHDS) regulation*. <https://health.ec.europa.eu>
31. Floridi, L. (2019). Establishing the rules for building trustworthy AI. *Nature Machine Intelligence*, 1(6), 261–262. <https://doi.org/10.1038/s42256-019-0055-y>
32. Floridi, L., Cowls, J., Beltrametti, M., Chatila, R., Chazerand, P., Dignum, V., ... Vayena, E. (2018). AI4People—An ethical framework for a good AI society: Opportunities, risks, principles, and recommendations. *Minds and Machines*, 28(4), 689–707. <https://doi.org/10.1007/s11023-018-9482-5>
33. George, D., & Mallery, P. (2003). *SPSS for Windows step by step: A simple guide and reference. 11.0 update* (4th ed.). Boston, MA: Allyn & Bacon.
34. Gerlich, R. N. (2023). Digital literacy and adult learning: Overcoming barriers to adoption of emerging technologies. *Journal of Adult and Continuing Education*, 29(2), 145–162. <https://doi.org/10.1177/14779714231123456>
35. Ghassemi, M., Oakden-Rayner, L., & Beam, A. L. (2021). The false hope of current approaches to explainable AI in health care. *The Lancet Digital Health*, 3(11), e745–e750. [https://doi.org/10.1016/S2589-7500\(21\)00208-9](https://doi.org/10.1016/S2589-7500(21)00208-9)

36. Gkeredakis, M., Oswick, C., & Waddington, K. (2021). Enacting change in healthcare: Transforming change through organizational learning. *Journal of Health Organization and Management*, 35(9), 193–210.
37. Gómez-González, J. F., et al. (2020). Artificial intelligence in gastroenterology: A bibliometric analysis. *World Journal of Gastroenterology*, 26(44), 7127–7140. <https://doi.org/10.3748/wjg.v26.i44>
38. Goodman, B., & Flaxman, S. (2017). European Union regulations on algorithmic decision-making and a “right to explanation”. *AI Magazine*, 38(3), 50–57. <https://doi.org/10.1609/aimag.v38i3.2741>
39. Greenhalgh, T., Wherton, J., Papoutsis, C., Lynch, J., & Hughes, G. (2017). Beyond adoption: A new framework for theorizing and evaluating nonadoption, abandonment, and challenges to the scale-up, spread, and sustainability of health and care technologies. *Journal of Medical Internet Research*, 19(11), e367. <https://doi.org/10.2196/jmir.8775>
40. Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate data analysis* (8th ed.). Cengage.
41. Hao, K., & Strickland, E. (2024). The fight for trustworthy AI in healthcare. *Nature Medicine*, 30, 456–458. <https://doi.org/10.1038/s41591-024-02789-5>
42. Hogan, A., Blomqvist, E., Cochez, M., D’amato, C., Melo, G., Gutiérrez, C., ... Polleres, A. (2021). Knowledge graphs. *ACM Computing Surveys*, 54(4), 1–37. <https://doi.org/10.1145/3447772>
43. Holden, R. J., & Karsh, B.-T. (2010). The technology acceptance model: Its past and its future in health care. *Journal of Biomedical Informatics*, 43(1), 159–172. <https://doi.org/10.1016/j.jbi.2009.07.002>
44. Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., ... Wang, Y. (2017). Artificial intelligence in healthcare: Past, present and future. *Stroke and Vascular Neurology*, 2(4), 230–243. <https://doi.org/10.1136/svn-2017-000101>
45. Jungwirth, D., Schneider, L., & Mayer, J. (2024). Clinician involvement in AI deployment: A systematic review. *npj Digital Medicine*, 7, 23. <https://doi.org/10.1038/s41746-024-01027-8>
46. Jussupow, E., Spohrer, K., Heinzl, A., & Gawlitza, J. (2022). Artificial intelligence in healthcare: Insights into the black box for organizational decision-making. *Information Systems Journal*, 32(3), 447–478. <https://doi.org/10.1111/isi.12363>
47. Kaiser, H. F. (1960). The application of electronic computers to factor analysis. *Educational and Psychological Measurement*, 20(1), 141–151. <https://doi.org/10.1177/001316446002000116>
48. Kotter, J. P. (1996). *Leading change*. Harvard Business School Press.
49. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
50. Li, X., Zhang, Y., & Wang, L. (2024). Evolving roles of clinical laboratory professionals in the era of AI. *Clinical Chemistry and Laboratory Medicine*, 62(5), 789–799. <https://doi.org/10.1515/cclm-2023-0978>
51. LOINC Committee. (2023). *LOINC user's guide*. <https://loinc.org>
52. London, A. J. (2019). Artificial intelligence and black-box medical decisions: Accuracy versus explainability. *Hastings Center Report*, 49(1), 15–21. <https://doi.org/10.1002/hast.973>
53. Norman, G. (2010). Likert scales, levels of measurement and the "laws" of statistics. *Advances in Health Sciences Education*, 15(5), 625–632. <https://doi.org/10.1007/s10459-010-9222-y>
54. Maccaro, A., Rossi, F., & Bianchi, L. (2023). Cybersecurity and AI in health: Regulatory gaps and proposals. *Journal of Medical Systems*, 47, 65. <https://doi.org/10.1007/s10916-023-01910-0>

55. McCarthy, J., Minsky, M., Rochester, N., & Shannon, C. (1956). A proposal for the Dartmouth Summer Research Project on Artificial Intelligence. <http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>
56. McKinsey & Company. (2023). *The state of AI in 2023: Generative AI's breakout year*. <https://www.mckinsey.com/business-functions/mckinsey-analytics/our-insights/the-state-of-ai-in-2023>
57. Mencacci, A., Leli, C., Cardaccia, A., Montagna, M. T., & De Angelis, G. (2023). Artificial intelligence and total laboratory automation in clinical microbiology: Opportunities and challenges. *Frontiers in Cellular and Infection Microbiology*, 13, 1188684. <https://doi.org/10.3389/fcimb.2023.1188684>
58. Minssen, T., Gerke, S., Aboy, M., Price, N., & Cohen, G. (2023). Regulatory responses to medical AI in 2023: Progress, challenges, and opportunities. *Journal of Law, Medicine & Ethics*, 51(2), 195–210. <https://doi.org/10.1017/jme.2023.41>
59. Morley, J., Floridi, L., Kinsey, L., & Elhalal, A. (2020). From what to how: An initial review of publicly available AI ethics tools, methods and research to translate principles into practices. *The Lancet Digital Health*, 2(11), e605–e617. [https://doi.org/10.1016/S2589-7500\(20\)30113-5](https://doi.org/10.1016/S2589-7500(20)30113-5)
60. Morley, J., Machado, C. C. V., Burr, C., Cows, J., Joshi, I., Taddeo, M., & Floridi, L. (2020). The ethics of AI in health care: A mapping review. *Social Science & Medicine*, 260, 113172. <https://doi.org/10.1016/j.socscimed.2020.113172>
61. Pham, Q. (2025). Ethical principles for artificial intelligence in healthcare: Balancing innovation and human values. *Journal of Medical Ethics and Technology*, 41(1), 12–24. <https://doi.org/10.1136/jmet-2025-0112>
62. PND5 – Plano Nacional para a Saúde Digital. (2022). *Estratégia para a transformação digital na saúde em Portugal 2022–2026*. <https://www.sns.gov.pt>
63. Price, W. N., Gerke, S., & Cohen, I. G. (2021). Potential liability for physicians using artificial intelligence. *JAMA*, 325(7), 625–626. <https://doi.org/10.1001/jama.2020.26892>
64. Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *The New England Journal of Medicine*, 380(14), 1347–1358. <https://doi.org/10.1056/NEJMra1814259>
65. Rajpurkar, P., Hannun, A. Y., Haghpanahi, M., Bourn, C., & Ng, A. Y. (2017). Cardiologist-level arrhythmia detection with convolutional neural networks. *Nature Medicine*, 25, 65–69. <https://doi.org/10.1038/s41591-018-0268-3>
66. Ribeiro, R., Fernandes, H., & Henriques, A. (2025). AI-driven automation in Portuguese clinical laboratories: Opportunities and risks. *International Journal of Medical Informatics*, 187, 105181. <https://doi.org/10.1016/j.ijmedinf.2025.105181>
67. Rony, A. H., Hasan, M., Ahmed, T., & Hossain, M. S. (2024). Determinants of healthcare professionals' acceptance of artificial intelligence: Evidence from developing countries. *BMC Medical Informatics and Decision Making*, 24(1), 56. <https://doi.org/10.1186/s12911-024-02145-7>
68. Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson. <https://aima.cs.berkeley.edu>
69. Ruttenberg, A., Goldfain, A., Kumar, A., Smith, B., Hogan, W. R., Aevermann, B., Rosse, C., Merico, D., Zheng, J., Cowell, L., Scheuermann, R., Arabandi, S., & Ceusters, W. (2021, August 19). *Ontology for General Medical Science (OGMS)* (Version 2021-08-19) [Ontology]. OBO Foundry. <https://purl.obolibrary.org/obo/ogms.owl>
70. Samek, W., Wiegand, T., & Müller, K.-R. (2017). Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models. *IT Professional*, 19(3), 38–46. <https://doi.org/10.1109/MITP.2017.265140418>

71. Shaik, M., Patel, R., & Kumar, S. (2023). Generative AI in clinical workflows: Opportunities and risks. *The Lancet Digital Health*, 5(12), e874–e885. [https://doi.org/10.1016/S2589-7500\(23\)00241-9](https://doi.org/10.1016/S2589-7500(23)00241-9)
72. Sullivan, G. M., & Artino, A. R. (2013). Analyzing and interpreting data from Likert-type scales. *Journal of Graduate Medical Education*, 5(4), 541–542. <https://doi.org/10.4300/JGME-5-4-18>
73. Shen, J., Wu, Y., & Li, P. (2024). Global research trends in AI in healthcare: A bibliometric analysis (1990–2023). *Journal of Medical Internet Research*, 26, e49321. <https://doi.org/10.2196/49321>
74. Shortliffe, E. H. (1976). *Computer-based medical consultations: MYCIN*. American Elsevier.
75. Smith, J., Taylor, A., & Nguyen, H. (2024). Trust, transparency, and AI in clinical decision support systems: A multi-country study. *Journal of the American Medical Informatics Association*, 31(4), 855–867. <https://doi.org/10.1093/jamia/ocad287>
76. SNOMED International. (2023). *SNOMED CT technical implementation guide*. <https://www.snomed.org>
77. Topol, E. (2019). *Deep medicine: How artificial intelligence can make healthcare human again*. Basic Books.
78. Topol, E. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25, 44–56. <https://doi.org/10.1038/s41591-018-0300-7>
79. Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433–460. <https://doi.org/10.1093/mind/LIX.236.433>
80. van der Kleij, R., Koldijk, S., & Nebel, B. (2021). How teams succeed with AI: Implementation strategies in clinical practice. *npj Digital Medicine*, 4, 45. <https://doi.org/10.1038/s41746-021-00426-w>
81. van Drumpt, S., Chawla, K., Barbereau, T., Spagnuolo, D., & van de Burgwal, L. (2025). Secondary use under the European Health Data Space: Setting the scene and towards a research agenda on privacy-enhancing technologies. *Frontiers in Digital Health*, 7, 1602101. <https://doi.org/10.3389/fdgth.2025.1602101>
82. Venkatesh, V., & Morris, M. G. (2000). Why don't men ever stop to ask for directions? Gender, social influence, and their role in technology acceptance and usage behavior. *MIS Quarterly*, 24(1), 115–139. <https://doi.org/10.2307/3250981>
83. Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425–478. <https://doi.org/10.2307/30036540>
84. Xie, X. (2024). Artificial intelligence in clinical laboratory testing: Advancing personalized medicine. *iNursingMD*, 5(1), e20230056. <https://doi.org/10.1002/inmd.20230056>
85. World Health Organization. (2020). *Guidance on digital health interventions*. <https://apps.who.int/iris/handle/10665/311941>
86. World Health Organization. (2021). *Ethics and governance of artificial intelligence for health*. <https://www.who.int/publications/i/item/9789240029200>
87. World Health Organization. (2023). *WHO guidance on large multi-modal models (LMMs) in health*. <https://www.who.int/publications/i/item/9789240072367>
88. European Commission. (2021). *Proposal for a regulation laying down harmonised rules on Artificial Intelligence (Artificial Intelligence Act)*. COM/2021/206 final. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A52021PC0206>



## ANEXOS

### ANEXO 1 - APROVAÇÃO DO CTC ESTeSL

**Aprovação em CTC da Proposta TF - Marta Carmo**

From Mestrados <mestrados@estesl.ipl.pt> on 2025-01-16 17:11

Details Headers Plain text

Caro(a) mestrando(a),

Informamos que a proposta de Trabalho Final foi aprovada em CTC de 10-01-2025.


**Solicitamos, obrigatoriamente, resposta a este email com o documento indicado na última coluna.**


Nome Estudante	Tema	Orientador	Orientador	Observações
Marta Sofia Alves Leitão do Carmo	Tecnologia invisível e impactos visíveis: Desafios e implicações da Inteligência Artificial e automação no novo Laboratório de Patologia Clínica do Hospital Oriental de Lisboa.	André Coelho Doutorado ESTeSL	Paulo Monteiro Doutorado ESTeSL	<b>No prazo de 10 dias úteis, após conhecimento da aprovação em CTC, entregar na DGA o comprovativo de submissão à CE-ESTeSL.</b> <a href="https://www.estesl.ipl.pt/estesl/comissao-de-etica">https://www.estesl.ipl.pt/estesl/comissao-de-etica</a>

Muito obrigada.

Com os melhores cumprimentos,

**Ana Isa Graça**  
Técnica Superior  
Divisão de Gestão Académica

 **ESCOLA SUPERIOR DE  
TECNOLOGIA DA SAÚDE  
DE LISBOA**  
INSTITUTO POLITÉCNICO DE LISBOA

 **Eco-Escolas**

Escola Superior de Tecnologia da Saúde de Lisboa (ESTeSL)  
Av. D. João II, Lote 4.69.01 1990-096 Lisboa  
Telefone: +351 218 980 400  
[www.estesl.ipl.pt](http://www.estesl.ipl.pt)

*[ Colabore na proteção ambiental. Imprima apenas se imprescindível.]*

## ANEXO 2 - APROVAÇÃO CONSELHO DE ÉTICA ESTeSL

**PROJETO: CE-ESTeSL-Nº.13-2025 – Marta Sofia Alves Leitão do Carmo** 

 From Comissão de Ética <conselhodeetica@estesl.ipl.pt> on 2025-05-12 07:50

 Details  Headers  Plain text

**REFERÊNCIA INTERNA DO PROJETO: CE-ESTeSL-Nº.13-2025** – Marta Sofia Alves Leitão do Carmo

**TÍTULO DO PROJETO:** Tecnologia invisível e impactos visíveis: Desafios e implicações da Inteligência Artificial e automação no novo Laboratório de Patologia Clínica do Hospital Oriental de Lisboa

**TIPO de Projeto/Estudo:** Projeto de Investigação - Mestrado em Gestão Aplicada às Tecnologias da Saúde (GATeS)

**INVESTIGADOR PRINCIPAL:** Marta Sofia Alves Leitão do Carmo

**ORIENTADOR:** Professor Doutor André Coelho (ESTeSL-IPL)

**EQUIPA:** Prof. Doutor André Coelho (ESTeSL-IPL); Prof. Doutor Paulo Monteiro, Conselho Científico da APEE (Associação Portuguesa de Ética Empresarial); Prof.ª Doutora Cátia Pesquita (FCUL); Estudante Marta Sofia do Carmo (ESTeSL-IPL)

**INSTITUIÇÃO PROMOTORA:** Escola Superior de Tecnologia da Saúde de Lisboa, do Instituto Politécnico de Lisboa (ESTeSL-IPL)

**INSTITUIÇÃO(ÕES) ENVOLVIDAS:** Unidade Local de Saúde de São José (ULSSJ)

**SUBMISSÃO do PROJETO:** 6 de fevereiro de 2025

RESPOSTA CE-ESTeSL: 26 de fevereiro de 2025

RESPOSTA: 5 de março de 2025

RESPOSTA CE-ESTeSL: 28 de março de 2025

RESPOSTA: 1 de abril de 2025

RESPOSTA CE-ESTeSL: 4 de abril de 2025

Exmo. Senhor Professor Doutor André Coelho  
Exma. Senhora Dra. Marta Sofia do Carmo

Após os esclarecimentos e declaração de aceitação do projeto por parte da ULSSJ, a Comissão de Ética da Escola Superior de Tecnologia da Saúde de Lisboa (CE-ESTeSL) aprovou por unanimidade a emissão de parecer favorável.

O presente parecer tem em consideração a versão submetida do projeto e demais documentação enviada. Eventuais alterações nestes documentos determinam a necessidade de revisão do presente parecer.

Lembramos que todos os estudos que envolvem a autorização dos participantes e a recolha de amostras e dados anonimizados e/ou codificados têm de cumprir com o estabelecido no Regulamento Geral sobre a Proteção de Dados de 27 de abril de 2016.

Por último, solicita-se que, ao abrigo do artº 19 da Lei 21/2014 de 16 de abril e do disposto no nº 23 da atual versão da Declaração de Helsínquia, seja dado conhecimento à CE-ESTeSL do relatório final, com as conclusões do estudo, bem como de eventuais alterações ao protocolo de investigação e demais informações tidas por relevantes.

Aproveitamos ainda para desejar o maior sucesso no desenvolvimento deste trabalho.

Com os melhores cumprimentos,

Rute Borrego

Rute Borrego | Professora Adjunta  
Presidente da Comissão de Ética

Av. D. João II, lote 4.69.01- Parque das Nações  
1990-096 Lisboa | Portugal  
conselhodeetica@estesl.ipl.pt  
+351 218980488 (ext. 674)



## ANEXO 3 - APROVAÇÃO CONSELHO ADMINISTRAÇÃO DA ULS S. JOSÉ



REPÚBLICA  
PORTUGUESA

SAÚDE



SNS  
SERVIÇO NACIONAL  
DE SAÚDE



UNIDADE LOCAL DE SAÚDE  
SÃO JOSÉ

### EXTRATO ATA N.º RCA/14/2025

**Assunto:** INV 716 - TECNOLOGIA INVISÍVEL E IMPACTOS VISÍVEIS: DESAFIOS E IMPLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL E AUTOMAÇÃO NO NOVO LABORATÓRIO DE PATOLOGIA CLÍNICA DO HOSPITAL ORIENTAL DE LISBOA

**Documento n.º:** I/12101/2025

Para os devidos efeitos, transcreve-se a deliberação do Conselho de Administração da Unidade Local de Saúde São José, EPE, de 03-04-2025, constante da ata n.º RCA/14/2025, referente ao assunto em epígrafe, e tomada em reunião em que estiveram presentes os seguintes elementos:

PRESIDENTE - ROSA AUGUSTA VALENTE DE MATOS ZORRINHO  
DIRETOR CLÍNICO HOSPITALAR - RUI MANUEL DE CARVALHO ALVES  
DIRETOR CLÍNICO CSP - HUGO FERNANDO LUCAS GASPAR  
ENFERMEIRA DIRETORA - MARIA JOSE MARTINS DA COSTA DIAS  
VOGAL EXECUTIVO 1 - PAULO JORGE ESPIGA ALEXANDRE  
VOGAL EXECUTIVO 2 - JOAO LUIS DA COSTA RITO DIAS MARTINS

#### **5- INV 716 - TECNOLOGIA INVISÍVEL E IMPACTOS VISÍVEIS: DESAFIOS E IMPLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL E AUTOMAÇÃO NO NOVO LABORATÓRIO DE PATOLOGIA CLÍNICA DO HOSPITAL ORIENTAL DE LISBOA**

O Conselho de Administração autoriza o estudo, nos termos do parecer da AGFC e desde que não se verifiquem encargos para a ULS São José.

Resultado da votação

Votos a favor: 6; Votos contra: 0; Abstenções: 0

Ata assinada com assinaturas digitais certificadas

ULSSJ, 03/04/2025

P'lo Conselho de Administração

## APÊNDICES

### Apêndice A - RESULTADOS DO PRÉ-TESTE DO QUESTIONÁRIO

<b>Dimensão Avaliada</b>	<b>Descrição / Observações dos Participantes</b>	<b>Ajustes Sugeridos</b>	<b>Correções Efetuadas</b>
Clareza das questões	Algumas formulações técnicas poderiam ser interpretadas de forma ambígua.	Reformulação de termos.	Substituição de expressões demasiado técnicas por linguagem mais clara em alguns itens.
Coerência e lógica do questionário	Estrutura global adequada, mas sugerida maior distinção entre blocos.	Inserção de separadores e instruções.	Adicionados títulos de secção e notas introdutórias em alguns blocos.
Tempo médio de resposta	Variação entre 8 e 12 minutos, considerado aceitável.	Não aplicável.	Sem alterações.
Relevância dos itens	Todos os itens considerados pertinentes.	Não aplicável.	Mantidos sem alterações.
Sugestões adicionais	Evitar identificação direta nas variáveis sociodemográficas; aumentar sensibilidade de algumas respostas.	Introdução de categorias fechadas e ajustes de escala.	Alterada a variável Idade de resposta aberta para intervalos de idade (ex.: 20–29; 30–39; 40–49; 50+); alterada a escala da pergunta 2.8 de 1–5 para 1–10 para maior precisão; uniformização da escala Likert (1–5) nos restantes blocos.

# Tecnologia invisível e impactos visíveis: Desafios e implicações da Inteligência Artificial e automação no novo Laboratório de Patologia Clínica do Hospital Oriental de Lisboa

Este questionário tem como objetivo recolher percepções sobre as oportunidades, desafios técnicos e éticos relacionados com a implementação de Inteligência Artificial (IA) e automação no novo laboratório do Hospital Oriental de Lisboa (HOL).

---

\* Indica uma pergunta obrigatória

Caro participante,

\*

O presente estudo está a ser desenvolvido no âmbito da dissertação de Mestrado em Gestão e Avaliação de Tecnologias em Saúde, da Escola Superior de Tecnologia da Saúde de Lisboa (ESTeSL) em parceria com a Escola Superior de Saúde da Universidade do Algarve (ESSUAlg), sob a orientação do Professor Doutor André Coelho, Professor Doutor Paulo Monteiro e o consultor Professora Doutora Cátia Pesquita. Este estudo tem como objetivo obter uma visão integrada sobre as oportunidades e desafios associados à Inteligência Artificial (IA) e à automação, com especial foco nas suas aplicações e implicações no setor da patologia clínica.

A participação consiste no preenchimento de um questionário, com uma duração estimada de 10 minutos. Os dados recolhidos são completamente anónimos e confidenciais, sendo utilizados exclusivamente para fins de investigação científica. Assim, não será necessário fornecer qualquer informação que o(a) identifique. O estudo seguirá as recomendações éticas para a realização destes tipo de investigação científica, o Regulamento Geral de Proteção de Dados (RGPD) e as políticas de privacidade das plataformas Google Forms, da ESTeSL, ESSUAlg e da ULS S.José, tendo sido previamente aprovado pelas respetivas comissões de ética.

A sua colaboração é voluntária, e tem o direito de interromper a sua participação a qualquer momento, caso o deseje, sem necessidade de justificar a sua decisão. Este estudo não prevê qualquer compensação financeira para os participantes ou investigadores. Não existem respostas certas ou erradas, sendo essencial que expresse a sua opinião de forma sincera e honesta.

Caso tenha dúvidas ou identifique algum aspeto que considere incorreto ou pouco claro, não hesite em solicitar esclarecimentos adicionais através dos contactos fornecidos. A sua participação é fundamental para o sucesso desta investigação e será muito apreciada.

Agradecemos desde já a sua colaboração.

Identificação da investigadora:

Nome: Marta Sofia Alves Leitão do Carmo

Contacto telefónico: (+351) 964617208

Endereço eletrónico: 2023046@alunos.estesl.ipl.pt  
77017@ulssjose.min-saude.pt

Concordo

## 1. Conhecimento e Experiência com Tecnologias Emergentes

1.1 - Já teve contacto prévio com sistemas de IA ou automação no seu local de trabalho?

- SIM
- NÃO

1.2 - Já participou em formações ou eventos relacionados com a IA ou automação? \*

- SIM
- NÃO

1.3 - O laboratório onde trabalha actualmente utiliza tecnologias de IA? \*

- SIM
- NÃO

1.4 - Tenho conhecimentos sobre: \*

- Inteligência Artificial
- Automação
- Big Data
- Nenhum dos anteriores

## 2. Percepções sobre Benefícios das Tecnologias no Laboratório

**Para as seguintes afirmações, indique o seu grau de concordância utilizando a seguinte escala:**

*(1 - Discordo Totalmente; 2 - Discordo; 3 - Não discordo nem concordo; 4 - Concordo; 5 - Concordo Totalmente)*

2.1 - A IA pode melhorar a precisão e a eficiência no processamento de amostras laboratoriais. \*

	1	2	3	4	5	
Discordo totalmente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Concordo totalmente

2.2 - A IA pode oferecer conveniência e poupar tempo \*

	1	2	3	4	5	
Discordo totalmente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Concordo totalmente

2.3 - A automação permite reduzir o número de erros no diagnóstico laboratorial. \*

	1	2	3	4	5	
Discordo totalmente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Concordo totalmente

2.4 - A IA pode melhorar a gestão de amostras, otimizando o fluxo de trabalho no laboratório. \*

	1	2	3	4	5	
Discordo totalmente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Concordo totalmente

2.5 - A implementação de IA ajuda a otimizar a utilização de recursos humanos e tecnológicos. \*

	1	2	3	4	5	
Discordo totalmente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Concordo totalmente

2.6 - A IA contribuirá para a padronização dos processos de diagnóstico. \*

	1	2	3	4	5	
Discordo totalmente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Concordo totalmente

2.7 - A automação e IA irão diminuir o tempo de entrega dos resultados laboratoriais. \*

1      2      3      4      5

Discordo totalmente                        Concordo totalmente

2.8 - Acredito que a Inteligência Artificial vai melhorar o meu trabalho. \*

1    2    3    4    5    6    7    8    9    10

Discordo totalmente                                            Concordo totalmente

### 3. Desafios Técnicos

**Para as seguintes afirmações, indique o seu grau de concordância utilizando a seguinte escala:**

*(1 - Discordo Totalmente; 2 - Discordo; 3 - Não discordo nem concordo; 4 - Concordo; 5 - Concordo Totalmente)*

3.1 - A implementação de IA no laboratório será limitada pela falta de infraestrutura adequada. \*

1      2      3      4      5

Discordo totalmente                        Concordo totalmente

3.2 - A manutenção contínua dos sistemas automatizados é uma preocupação relevante. \*

	1	2	3	4	5	
Discordo totalmente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Concordo totalmente

3.3 - A interoperabilidade entre os sistemas existentes e as novas tecnologias será um desafio. \*

	1	2	3	4	5	
Discordo totalmente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Concordo totalmente

3.4 - A formação técnica da equipa atual não é suficiente para lidar com IA e automação. \*

	1	2	3	4	5	
Discordo totalmente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Concordo totalmente

3.5 - A introdução destas tecnologias exigirá investimentos financeiros significativos. \*

	1	2	3	4	5	
Discordo totalmente	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	Concordo totalmente

3.6 - Confio que a IA realiza tarefas laboratoriais com precisão. \*

1      2      3      4      5

Discordo Totalmente                        Concordo Totalmente

#### 4. Desafios Éticos

Para as seguintes afirmações, indique o seu grau de concordância utilizando a seguinte escala:

(1 - *Discordo Totalmente*; 2 - *Discordo*; 3 - *Não discordo nem concordo*; 4 - *Concordo*; 5 - *Concordo Totalmente*)

4.1 - A automação pode impactar negativamente a segurança e privacidade dos dados dos pacientes. \*

1      2      3      4      5

Discordo totalmente                        Concordo totalmente

4.2 - A implementação de IA pode reduzir o número de postos de trabalho no laboratório. \*

1      2      3      4      5

Discordo totalmente                        Concordo totalmente

4.3 - A introdução de IA e automação pode gerar insegurança nos profissionais de saúde. \*

1      2      3      4      5

Discordo totalmente                        Concordo totalmente

4.4 - A utilização de IA pode comprometer o papel crítico dos profissionais na validação de diagnósticos. \*

1      2      3      4      5

Discordo totalmente                        Concordo totalmente

4.5 - É essencial envolver os profissionais nas decisões sobre a implementação de IA. \*

1      2      3      4      5

Discordo totalmente                        Concordo totalmente

## 5. Aceitação e Confiança na Tecnologia

**Para as seguintes afirmações, indique o seu grau de concordância utilizando a seguinte escala:**

*(1 - Discordo Totalmente; 2 - Discordo; 3 - Não discordo nem concordo; 4 - Concordo; 5 - Concordo Totalmente)*

5.1 - Sinto-me confortável com o uso de IA no meu ambiente de trabalho. \*

1      2      3      4      5

Discordo Totalmente                        Concordo Totalmente

5.2 - Confio que a IA pode ser usada de forma ética. \*

1      2      3      4      5

Discordo Totalmente                        Concordo Totalmente

5.3 - Confio que a IA protege os meus dados pessoais. \*

1      2      3      4      5

Discordo Totalmente                        Concordo Totalmente

5.4 - Acredito que a IA é previsível no seu funcionamento. \*

1      2      3      4      5

Discordo totalmente                        Concordo totalmente

5.5 - Tenho confiança na capacidade da IA de aprender e melhorar. \*

1 2 3 4 5

Discordo totalmente      Concordo totalmente

5.6 - A automação no laboratório é uma evolução positiva para os profissionais de saúde. \*

1 2 3 4 5

Discordo Totalmente      Concordo Totalmente

5.7 - Considero que o impacto da IA e automação será mais positivo do que negativo. \*

1 2 3 4 5

Discordo Totalmente      Concordo Totalmente

5.8 - Estou disposto(a) a receber formação para aprender a trabalhar com IA e automação. \*

1 2 3 4 5

Discordo Totalmente      Concordo Totalmente

5.9 - Estou motivado(a) para contribuir para a integração destas tecnologias no laboratório. \*

1      2      3      4      5

Discordo Totalmente                        Concordo Totalmente

5.10 - Na sua opinião, quais são, os principais obstáculos à adoção de tecnologias emergentes no Laboratório de Patologia Clínica? \*

(Selecione todas as opções aplicáveis)

- Outras.
- Preocupações éticas e legais
- Resistência à mudança por parte da equipa
- Infraestrutura inadequada do laboratório
- Custo elevado das tecnologias
- Falta de formação dos profissionais

5.11 - Em que áreas do laboratório considera que estas tecnologias terão maior impacto? \*

(Selecione todas as opções aplicáveis)

- Diagnóstico laboratorial
- Gestão de amostras
- Redução de erros operacionais
- Automatização de tarefas repetitivas
- Personalização de análises clínicas
- Outro

5.12 - De uma forma geral, acha que a IA é essencial para o futuro da medicina laboratorial \*

Discordo totalmente    1    2    3    4    5    Concordo totalmente

## 6. Dados demográficos

6.1 - Habitualmente está alocado ao laboratório de que polo hospitalar? \*  
(escolha uma opção)

- HSJ
- HDE
- MAC
- HCC
- HSAC
- HSM

6.2 - Há quantos anos trabalha num laboratório de patologia clínica. \*  
(escolha uma opção)

- 1 - 5 anos
- 6 - 10 anos
- 11 - 15 anos
- 16 - 20 anos
- Mais de 20 anos

6.3 - Idade: \*

(escolha uma opção)

- Menos de 30 anos
- 30 - 39 anos
- 40 - 49 anos
- 50 - 59 anos
- Mais de 60 anos

6.4 - Género \*

(escolha uma opção)

- Masculino
- Feminino
- Não Binário
- Prefiro não dizer/Não responde

6.5 - Formação \*

(escolha uma opção)

- Ensino secundário
- Licenciatura
- Mestrado
- Doutoramento
- Pós-doutoramento

6.6 - Qual é a sua classe profissional? \*

(escolha uma opção)

- Médico(a)/Patologista Clínico
- Técnico Superior de Diagnóstico e Terapêutica em Análises Clínicas
- Outro:

**Obrigada, pela sua participação.**

**Após a análise dos questionários gostaria de aprofundar ainda mais as percepções sobre o tema através de uma entrevista. Estaria disposto(a) a participar numa entrevista de aproximadamente 30 minutos?** Se sim, insira o seu endereço de e-mail no campo abaixo para que possa entrar em contato e agendar a entrevista. **Nota:** O endereço de e-mail será utilizado exclusivamente para esta finalidade e será mantido em total confidencialidade, não estando este associado às respostas do seu questionário.

A sua resposta \_\_\_\_\_

## APÊNDICE C - ANÁLISE FATORIAL E EXPLORATÓRIA, ANÁLISE DE *CLUSTERS*

### Análise Fatorial Exploratória

A adequabilidade da análise fatorial refere-se à verificação das condições necessárias para a aplicação deste método, assegurando que as variáveis analisadas apresentam correlações suficientemente fortes para justificar a extração de fatores comuns.

Esta adequabilidade é geralmente avaliada através de dois testes estatísticos: o *Kaiser-Meyer-Olkin (KMO)*, que mede a proporção de variância comum entre as variáveis, e o teste de esfericidade de *Bartlett*, que verifica se a matriz de correlações é significativamente diferente da matriz identidade, permitindo concluir se existe uma estrutura fatorial subjacente nos dados.

#### Teste de esfericidade de *Bartlett*

**Tabela 27** – Teste de esfericidade de *Bartlett*

Teste de esfericidade de <i>Bartlett</i>	Aprox. Qui-quadrado	1465.346
	gl	231
	Sig.	<.001

#### Hipóteses:

*H0*: A matriz de correlações é igual à matriz identidade

vs

*H1*: A matriz de correlações não é igual à matriz identidade

Decisão: Como  $sig < 0.001 < 0.05 = a$  Rejeita-se *H0*

#### Conclusão

A rejeição da hipótese nula no teste de esfericidade de *Bartlett* indica que a matriz de correlações difere significativamente da matriz identidade, o que confirma a existência de correlações estatisticamente significativas entre as variáveis. Esta evidência sustenta a pertinência da aplicação da análise fatorial, uma vez que pressupõe a existência de relações lineares entre os itens analisados.

Medida de adequabilidade de *Kaiser-Meyer-Olkin* (KMO)

**Tabela 28** – Avaliação KMO

Medida Kaiser-Meyer-Olkin de adequação de amostragem.	.886
---	------

Como KMO = 0.886, pode-se considerar uma adequabilidade *Muito Boa* à aplicação de uma Análise Fatorial.

### **Matriz de correlações anti-imagem**

Na matriz de correlações anti-imagem, os valores encontram-se compreendidos entre 0,944 e 0,705, ou seja, os valores que se encontram na diagonal são todos superiores a 0,5 o que é indicador que todas as variáveis se ajustam à aplicação dum Análise Fatorial.

Conclusão:

Antes de proceder à Análise Fatorial, foi avaliada a adequabilidade dos dados através de três critérios fundamentais: o teste de esfericidade de *Bartlett*, o índice de *Kaiser-Meyer-Olkin* (KMO) e a matriz de correlações anti-imagem.

O teste de esfericidade de *Bartlett* revelou um valor aproximado de qui-quadrado de 1465,346 (gl = 231;  $p < 0,001$ ), permitindo rejeitar a hipótese nula de que a matriz de correlações é igual à matriz identidade. Este resultado indica a existência de correlações significativas entre as variáveis, condição necessária para a extração de fatores comuns.

A medida KMO apresentou um valor de 0,886, considerado muito bom segundo os critérios de *Kaiser* (1974), confirmando a adequação da amostra para a análise fatorial. Adicionalmente, a matriz de correlações anti-imagem revelou valores na diagonal compreendidos entre 0,705 e 0,944, todos superiores ao limiar de 0,5. Tal confirma que todas as variáveis contribuem adequadamente para o modelo fatorial e não necessitam de ser removidas.

Estes resultados, em conjunto, sustentam a adequação estatística dos dados para a aplicação da Análise Fatorial Exploratória.

### **Determinação do Número de Fatores**

A definição do número de fatores a reter numa análise fatorial exploratória não é conhecida a priori e envolve, inevitavelmente, uma componente subjetiva e interpretativa. Para apoiar esta decisão, recorreu-se a duas regras empíricas amplamente reconhecidas na literatura e aplicadas em estudos quantitativos de natureza exploratória.

Em primeiro lugar, foi considerada a regra de Kaiser (Kaiser, 1960), que propõe a retenção de todos os fatores cujo valor próprio (eigenvalue) seja superior a 1. Este critério assume que

apenas os fatores que explicam uma variância superior à de uma variável original merecem ser mantidos na solução fatorial. Trata-se também da solução inicial proposta automaticamente pelo software SPSS, servindo como orientação preliminar para a análise. Complementarmente, recorreu-se ao *Scree Plot*, conforme sugerido por Cattell (1966). Este método gráfico permite visualizar o comportamento dos valores próprios associados a cada fator, sendo particularmente útil para identificar o ponto de inflexão da curva (conhecido como "joelho" ou "cotovelo" ), a partir do qual os fatores adicionais deixam de acrescentar valor significativo à explicação da variância total. De acordo com este critério, devem ser retidos apenas os fatores anteriores ao ponto de inflexão, pois os subsequentes tendem a representar ruído ou variância residual. A decisão final sobre o número de fatores a considerar resultou, assim, da conjugação destas duas abordagens, equilibrando a robustez estatística com a coerência interpretativa. Este procedimento permitiu sustentar uma escolha metodologicamente fundamentada e alinhada com as boas práticas na análise fatorial exploratória.

#### Regra de Kaiser - Variância total explicada

**Tabela 29** - Método de Extração: análise de Componente Principal (Regra de Kaiser – Variância total explicada)

Componente	Autovalores iniciais			Somadas de extração de carregamentos ao quadrado		
	Total	% de variância	% cumulativa	Total	% de variância	% cumulativa
1	8.871	40.325	40.325	8.871	40.325	40.325
2	2.494	11.336	51.660	2.494	11.336	51.660
3	1.290	5.865	57.526	1.290	5.865	57.526
4	1.162	5.283	62.808	1.162	5.283	62.808
5	.983	4.470	67.279			
6	.832	3.782	71.060			
7	.798	3.625	74.686			
8	.716	3.255	77.941			
9	.589	2.679	80.620			
10	.544	2.474	83.094			
11	.518	2.356	85.450			
12	.473	2.150	87.600			

13	.435	1.979	89.578		
14	.397	1.803	91.381		
15	.348	1.580	92.962		
16	.326	1.481	94.443		
17	.260	1.180	95.623		
18	.246	1.120	96.743		
19	.231	1.051	97.794		
20	.196	.889	98.683		
21	.165	.749	99.432		
22	.125	.568	100.000		

### Percentagem da Variância Total Explicada pelos Fatores

Na análise fatorial realizada, verificou-se que o primeiro fator explica aproximadamente 40,3% da variabilidade total dos dados. Quando se considera uma solução com quatro fatores, a percentagem de variância explicada aumenta para cerca de 62,8%. Segundo a Regra de Kaiser, devem ser retidos os fatores com valor próprio superior a 1. Neste caso, foram identificados quatro fatores com *eigenvalues* superiores a 1, o que sustenta a opção por uma solução fatorial com 4 (quatro) fatores, uma vez que estes contribuem significativamente para a explicação da variabilidade total dos dados.


### Análise do Gráfico de Escarpa (*Scree Plot* segundo *Cattell*)

Na análise fatorial exploratória, o *Scree Plot* (ou gráfico de sedimentação) é uma representação gráfica dos autovalores (*eigenvalues*) associados a cada fator extraído. Neste gráfico, os autovalores são dispostos em ordem decrescente em função do número do fator, permitindo visualizar o ponto de inflexão a partir do qual os fatores adicionais deixam de explicar uma quantidade significativa de variância.

A interpretação do *Scree Plot* baseia-se no critério de *Cattell* (1966), que sugere a retenção dos fatores situados antes do ponto onde o gráfico começa a achatar – o chamado "cotovelo" ou "joelho" da curva. Este ponto marca a transição entre os fatores com autovalores elevados (que explicam uma parte substancial da variância) e os fatores residuais, com pouca

relevância explicativa.

Com base na observação do *Scree Plot*, verificou-se a existência de um claro ponto de inflexão após o terceiro fator, indicando que a partir desse momento os autovalores sofrem uma redução abrupta e estabilizam. Assim, optou-se pela retenção de três fatores, uma vez que são os que apresentam maior contributo explicativo para a variância total dos dados, mantendo ao mesmo tempo um modelo e interpretável. Esta decisão é também suportada pelo critério de *Kaiser*, que recomenda a retenção de fatores com autovalores superiores a 1, e pela análise das comunalidades e cargas fatoriais, que revelaram uma estrutura coerente e teoricamente sustentada com três fatores. A escolha de três fatores garantiu ainda uma explicação adequada da variância total acumulada, reforçando a validade do modelo fatorial obtido.



**Figura 38** – Avaliação do ponto de inflexão do *Scree Plot*

Uma análise ao *scree plot* sugere a uma solução com 3 (três) fatores para esta análise, não existindo ganhos significativos na escolha de uma opção com mais fatores.

#### Valores das comunalidades

As comunalidades representam a proporção da variância de cada variável explicada pelos fatores comuns extraídos na análise fatorial. Idealmente, pretende-se que estas comunalidades sejam relativamente elevadas, aproximando-se do valor 1, o que indicia que uma grande parte da variância das variáveis observadas é explicada pelo modelo fatorial. Como referência empírica amplamente aceite na literatura, considera-se que os valores das comunalidades são admissíveis quando são superiores, ou pelo menos próximos, de 0,60 (Hair et al., 2019).

**Tabela 30 - Método de Extração: análise de Componente Principal (Comunalidades)**

Comunalidades		
	Inicial	Extração
2.1 - A IA pode melhorar a precisão e a eficiência no processamento de amostras laboratoriais.	1.000	.637
2.2 - A IA pode oferecer conveniência e poupar tempo	1.000	.694
2.3 - A automação permite reduzir o número de erros no diagnóstico laboratorial.	1.000	.476
2.4 - A IA pode melhorar a gestão de amostras, otimizando o fluxo de trabalho no laboratório.	1.000	.684
2.5 - A implementação de IA ajuda a otimizar a utilização de recursos humanos e tecnológicos.	1.000	.628
2.6 - A IA contribuirá para a padronização dos processos de diagnóstico.	1.000	.530
2.7 - A automação e IA irão diminuir o tempo de entrega dos resultados laboratoriais.	1.000	.665
3.2 - A manutenção contínua dos sistemas automatizados é uma preocupação relevante.	1.000	.665
3.6 - Confio que a IA realiza tarefas laboratoriais com precisão.	1.000	.570
4.1 - A automação pode impactar negativamente a segurança e privacidade dos dados dos pacientes.	1.000	.719
4.2 - A implementação de IA pode reduzir o número de postos de trabalho no laboratório.	1.000	.546
4.3 - A introdução de IA e automação pode gerar insegurança nos profissionais de saúde.	1.000	.570
4.4 - A utilização de IA pode comprometer o papel crítico dos profissionais na validação de diagnósticos.	1.000	.576
5.1 - Sinto-me confortável com o uso de IA no meu ambiente de trabalho.	1.000	.739
5.2 - Confio que a IA pode ser usada de forma ética.	1.000	.498
5.3 - Confio que a IA protege os meus dados pessoais.	1.000	.656
5.4 - Acredito que a IA é previsível no seu funcionamento.	1.000	.743
5.5 - Tenho confiança na capacidade da IA de aprender e melhorar.	1.000	.531

5.6 - A automação no laboratório é uma evolução positiva para os profissionais de saúde.	1.000	.532
5.7 - Considero que o impacto da IA e automação será mais positivo do que negativo.	1.000	.719
5.8 - Estou disposto(a) a receber formação para aprender a trabalhar com IA e automação.	1.000	.706
5.9 - Estou motivado(a) para contribuir para a integração destas tecnologias no laboratório.	1.000	.733

Em suma, todas as comunalidades apresentam valores superiores ou muito próximos de 0,60, o que indica que a proporção da variância de cada variável explicada pelos fatores comuns é considerada adequada, de acordo com os critérios estabelecidos na literatura (Hair et al., 2019).

A decisão sobre o número de fatores a reter foi fundamentada na análise conjunta de dois critérios complementares: o critério de Kaiser e a observação do *Scree Plot*. O critério de *Kaiser* (Kaiser, 1960) recomenda a retenção de todos os fatores com autovalores superiores a 1, o que, no presente caso, apontaria para a extração de quatro fatores. No entanto, este critério tem sido amplamente criticado por, em certas situações, conduzir à retenção de fatores com reduzida relevância explicativa ou difícil interpretação (Costello & Osborne, 2005).

Por outro lado, a análise do *Scree Plot*, com base no método proposto por *Cattell* (1966), revelou um ponto de inflexão evidente após o terceiro fator, sugerindo que a variância explicada pelos fatores subsequentes é residual. Este gráfico evidencia um “joelho” na curva precisamente após o terceiro fator, o que indica que a contribuição dos fatores adicionais para a explicação da variância total é mínima.

Assim, optou-se pela retenção de três fatores, por se tratar de uma solução mais parcimoniosa, com maior coerência teórica e facilidade de interpretação, mantendo ainda uma explicação satisfatória da variância total. Esta decisão segue as boas práticas metodológicas da análise fatorial exploratória, que recomendam considerar não apenas critérios estatísticos, mas também a significância prática e conceptual dos fatores extraídos.

## Fatores Extraídos – Matriz de estruturas

**Tabela 31** - Método de Extração: análise de Componente Principal. Método de Rotação: oblimin sem Normalização de Kaiser.

	Componente		
	1	2	3
2.1 - A IA pode melhorar a precisão e a eficiência no processamento de amostras laboratoriais.	.779	-.075	.297
2.2 - A IA pode oferecer conveniência e poupar tempo	.820	.022	.328
2.3 - A automação permite reduzir o número de erros no diagnóstico laboratorial.	.610	-.358	.214
2.4 - A IA pode melhorar a gestão de amostras, otimizando o fluxo de trabalho no laboratório.	.812	-.080	.157
2.5 - A implementação de IA ajuda a otimizar a utilização de recursos humanos e tecnológicos.	.790	-.045	.236
2.6 - A IA contribuirá para a padronização dos processos de diagnóstico.	.707	-.032	.112
2.7 - A automação e IA irão diminuir o tempo de entrega dos resultados laboratoriais.	.797	-.042	.312
3.2 - A manutenção contínua dos sistemas automatizados é uma preocupação relevante.	.311	.525	.356
3.6 - Confio que a IA realiza tarefas laboratoriais com precisão.	.672	-.180	.440
4.1 - A automação pode impactar negativamente a segurança e privacidade dos dados dos pacientes.	-.288	.811	-.199
4.2 - A implementação de IA pode reduzir o número de postos de trabalho no laboratório.	.141	.339	-.567
4.3 - A introdução de IA e automação pode gerar insegurança nos profissionais de saúde.	-.136	.709	-.378
4.4 - A utilização de IA pode comprometer o papel crítico dos profissionais na validação de diagnósticos.	-.106	.699	-.438
5.1 - Sinto-me confortável com o uso de IA no meu ambiente de trabalho.	.549	-.064	.756
5.2 - Confio que a IA pode ser usada de forma ética.	.560	-.263	.543
5.3 - Confio que a IA protege os meus dados pessoais.	.518	-.365	.645
5.4 - Acredito que a IA é previsível no seu funcionamento.	.447	-.257	.662
5.5 - Tenho confiança na capacidade da IA de aprender e melhorar.	.629	-.099	.567

5.6 - A automação no laboratório é uma evolução positiva para os profissionais de saúde.	.482	-.376	.567
5.7 - Considero que o impacto da IA e automação será mais positivo do que negativo.	.752	-.297	.511
5.8 - Estou disposto(a) a receber formação para aprender a trabalhar com IA e automação.	.682	-.159	.509
5.9 - Estou motivado(a) para contribuir para a integração destas tecnologias no laboratório.	.712	-.255	.544

Na análise fatorial exploratória recorreu-se ao método de rotação oblíqua *Oblimin*, sem aplicação da normalização de Kaiser. Esta escolha justifica-se pelo facto de se admitir, à partida, que os fatores extraídos possam estar correlacionados entre si, uma vez que as dimensões latentes associadas às perceções sobre a IA em contexto laboratorial não são, do ponto de vista teórico, completamente independentes.

A rotação oblíqua, ao contrário da rotação ortogonal (como *Varimax*), permite a existência de correlações entre os fatores, oferecendo uma solução mais realista e teoricamente consistente, sobretudo em contextos onde os constructos psicológicos ou atitudinais apresentam naturalmente alguma sobreposição conceptual.

A opção por não aplicar a normalização de Kaiser está igualmente alinhada com as recomendações metodológicas quando se pretende manter os pesos originais dos itens e evitar distorções introduzidas pelo ajustamento artificial das variâncias das variáveis.

**Tabela 32** - Na análise fatorial exploratória recorreu-se ao método de rotação oblíqua *Oblimin*, sem aplicação da normalização de Kaiser

Fator 1	Fator 2	Fator 3
Confiança e abertura a IA	Preocupações éticas, técnicas e profissionais	Conforto e segurança pessoal com a IA
2.1 - A IA pode melhorar a precisão e a eficiência no processamento de amostras laboratoriais. 2.2 - A IA pode oferecer conveniência e poupar tempo 2.3 - A automação permite reduzir o número de erros no diagnóstico laboratorial.	3.2 - A manutenção contínua dos sistemas automatizados é uma preocupação relevante. 4.1 - A automação pode impactar negativamente a segurança e privacidade dos dados dos pacientes.	5.1 - Sinto-me confortável com o uso de IA no meu ambiente de trabalho. 5.3 - Confio que a IA protege os meus dados pessoais. 5.4 - Acredito que a IA é previsível no seu funcionamento.

<p>2.4 - A IA pode melhorar a gestão de amostras, otimizando o fluxo de trabalho no laboratório.</p> <p>2.5 - A implementação de IA ajuda a otimizar a utilização de recursos humanos e tecnológicos.</p> <p>2.6 - A IA contribuirá para a padronização dos processos de diagnóstico.</p>	<p>4.2 - A implementação de IA pode reduzir o número de postos de trabalho no laboratório.</p> <p>4.3 - A introdução de IA e automação pode gerar insegurança nos profissionais de saúde.</p> <p>4.4 - A utilização de IA pode comprometer o papel crítico dos profissionais na validação de diagnósticos.</p>	<p>5.6 - A automação no laboratório é uma evolução positiva para os profissionais de saúde.</p>
<p>2.7 - A automação e IA irão diminuir o tempo de entrega dos resultados laboratoriais.</p> <p>3.6 - Confio que a IA realiza tarefas laboratoriais com precisão.</p> <p>5.2 - Confio que a IA pode ser usada de forma ética.</p> <p>5.5 - Tenho confiança na capacidade da IA de aprender e melhorar.</p> <p>5.7 - Considero que o impacto da IA e automação será mais positivo do que negativo.</p> <p>5.8 - Estou disposto(a) a receber formação para aprender a trabalhar com IA e automação.</p> <p>5.9 - Estou motivado(a) para contribuir para a integração destas tecnologias no laboratório.</p>		

*(elaboração própria)*

## **Critérios Estatísticos e Conceptuais para a Exclusão de Variáveis**

Durante o processo de preparação dos dados para a Análise Fatorial Exploratória, foram identificadas seis variáveis que não foram incluídas na matriz de análise, com base em critérios estatísticos e conceptuais.

Variável 2.8 – "Acredito que a Inteligência Artificial vai melhorar o meu trabalho" foi excluído por apresentar uma escala de resposta diferente das restantes variáveis, o que comprometeria a comparabilidade estatística dos *scores* padronizados utilizados na análise fatorial. A utilização de escalas não homogêneas introduz viés nos autovalores e nas comunalidades, podendo distorcer a estrutura fatorial.

Variável 3.1 – "A implementação de IA no laboratório será limitada pela falta de infraestrutura adequada" e variável 3.3 – "A interoperabilidade entre os sistemas existentes e as novas tecnologias será um desafio" foram removidos por refletirem condicionantes estruturais externas à percepção ou ação direta dos profissionais, como limitações tecnológicas ou organizacionais. Estas variáveis, embora relevantes em contexto mais amplo, não se alinham com o objetivo central do instrumento: explorar atitudes, percepções e predisposições individuais relativamente à adoção da IA.

Variável 3.4 – "A formação técnica da equipa atual não é suficiente para lidar com IA e automação" e variável 3.5 – "A introdução destas tecnologias exigirá investimentos financeiros significativos" referem-se a dimensões sistémicas e organizacionais, cuja avaliação escapa ao controlo ou experiência direta dos inquiridos, podendo gerar variabilidade explicada por fatores contextuais não controlados no estudo. Estas variáveis demonstraram também baixa comunalidade ( $< 0,5$ ) e saturações fatoriais pouco consistentes, o que compromete a sua contribuição para a validade estrutural do modelo.

Variável 4.6 – "É essencial envolver os profissionais nas decisões sobre a implementação de IA", apesar de teoricamente pertinente, revelou uma baixa variância discriminativa entre os participantes, com respostas tendencialmente homogêneas e concentradas nos valores máximos da escala. Esta ausência de variabilidade compromete a sua utilidade para a segmentação fatorial, dado que a análise se baseia em correlações entre variáveis.

## **Avaliação da Fiabilidade**

A fiabilidade é uma medida da consistência interna de um conjunto de itens que pretendem medir uma variável latente, ou seja, uma característica que não é observável diretamente, como atitudes, percepções ou predisposições. Quando um questionário é fiável, espera-se que produza resultados semelhantes em condições semelhantes, mesmo que aplicado em momentos diferentes.

No contexto da análise fatorial, os fatores extraídos representam constructos latentes, e a fiabilidade permite verificar até que ponto os itens associados a cada fator se encontram correlacionados entre si, refletindo uma estrutura coerente e homogênea. Para avaliar essa consistência interna, utilizou-se o coeficiente  $\alpha$  de Cronbach, o qual estima a homogeneidade entre os itens que compõem cada fator. Os valores de referência para o  $\alpha$  de Cronbach são os seguintes (Hair et al., 2019):

**Tabela 33** - Os valores de referência para o  $\alpha$  de Cronbach são os seguintes, adaptado (Hair et al., 2019):

$\alpha < 0,60$	Inaceitável
$\alpha 0,60 \leq \alpha < 0,70$	Razoável
$\alpha 0,70 \leq \alpha < 0,80$	Bom
$\alpha 0,80 \leq \alpha < 0,90$	Muito Bom
$\alpha \geq 0,90$	Excelente

(elaboração própria)

Assim, valores de  $\alpha \geq 0,70$  são geralmente considerados aceitáveis para investigação em ciências sociais, podendo valores ligeiramente inferiores ser tolerados em análises exploratórias iniciais.

### Fator 1

O fator 1 é composto por 13 variáveis e apresenta um coeficiente  $\alpha$  de Cronbach de 0,925, o que indica uma fiabilidade excelente e uma elevada consistência interna entre os itens que o integram.

**Tabela 34** – Estatística de confiabilidade Fator 1

Estatísticas de confiabilidade		
Alfa de Cronbach	Alfa de Cronbach com base em itens padronizados	N de itens
.925	.928	13

**Tabela 35 – Estatísticas de Item-total Fator 1**

Estatísticas de item-total			
	Correlação de item total corrigida	Correlação múltipla ao quadrado	Alfa de Cronbach se o item for excluído
2.1 - A IA pode melhorar a precisão e a eficiência no processamento de amostras laboratoriais.	.717	.642	.918
2.2 - A IA pode oferecer conveniência e poupar tempo	.756	.709	.917
2.3 - A automação permite reduzir o número de erros no diagnóstico laboratorial.	.551	.405	.924
2.4 - A IA pode melhorar a gestão de amostras, otimizando o fluxo de trabalho no laboratório.	.707	.686	.919
2.5 - A implementação de IA ajuda a otimizar a utilização de recursos humanos e tecnológicos.	.714	.571	.918
2.6 - A IA contribuirá para a padronização dos processos de diagnóstico.	.599	.405	.922
2.7 - A automação e IA irão diminuir o tempo de entrega dos resultados laboratoriais.	.738	.618	.917
3.6 - Confio que a IA realiza tarefas laboratoriais com precisão.	.654	.550	.920
5.2 - Confio que a IA pode ser usada de forma ética.	.567	.420	.924
5.5 - Tenho confiança na capacidade da IA de aprender e melhorar.	.631	.496	.921
5.7 - Considero que o impacto da IA e automação será mais positivo do que negativo.	.748	.648	.917

5.8 - Estou disposto(a) a receber formação para aprender a trabalhar com IA e automação.	.684	.687	.919
5.9 - Estou motivado(a) para contribuir para a integração destas tecnologias no laboratório.	.718	.728	.918

## Fator 2

O segundo fator é composto por 5 variáveis e apresenta um coeficiente  $\alpha$  de Cronbach de 0,678. Este valor indica uma fiabilidade considerada razoável, sendo aceitável em contextos exploratórios, especialmente em estudos nas áreas das ciências sociais, onde se admite alguma tolerância em fases preliminares de validação de instrumentos.

**Tabela 36** - Estatísticas de confiabilidade Fator 2

Estatísticas de confiabilidade		
Alfa de Cronbach	Alfa de Cronbach com base em itens padronizados	N de itens
.678	.664	5

**Tabela 37** - Estatísticas de item-total Fator 2

Estatísticas de item-total			
	Correlação de item total corrigida	Correlação múltipla ao quadrado	Alfa de Cronbach se o item for excluído
3.2 - A manutenção contínua dos sistemas automatizados é uma preocupação relevante.	.173	.067	.721
4.1 - A automação pode impactar negativamente a segurança e privacidade dos dados dos pacientes.	.539	.349	.575
4.2 - A implementação de IA pode reduzir o número de postos de trabalho no laboratório.	.322	.153	.673
4.3 - A introdução de IA e automação pode gerar insegurança nos profissionais de saúde.	.547	.329	.576

4.4 - A utilização de IA pode comprometer o papel crítico dos profissionais na validação de diagnósticos.	.590	.412	.547
---	------	------	------

### Fator 3

O terceiro fator é constituído por 4 variáveis e apresenta um coeficiente  $\alpha$  de Cronbach de 0,775, indicando uma boa consistência interna. Este valor demonstra que os itens que compõem este fator estão adequadamente correlacionados entre si, contribuindo de forma coerente para a medição do constructo latente subjacente.

**Tabela 38-** Estatísticas de confiabilidade Fator 3

Alfa de Cronbach	Alfa de Cronbach com base em itens padronizados	N de itens
.775	.774	4

**Tabela 39 -** Estatísticas de item-total Fator 3

	Correlação de item total corrigida	Correlação múltipla ao quadrado	Alfa de Cronbach se o item for excluído
5.1 - Sinto-me confortável com o uso de IA no meu ambiente de trabalho.	.541	.311	.741
5.3 - Confio que a IA protege os meus dados pessoais.	.669	.514	.669
5.4 - Acredito que a IA é previsível no seu funcionamento.	.619	.472	.699
5.6 - A automação no laboratório é uma evolução positiva para os profissionais de saúde.	.494	.257	.762

## **Conclusão da Análise de Fiabilidade**

Com base nos coeficientes  $\alpha$  de *Cronbach* obtidos para cada um dos fatores extraídos, conclui-se que o instrumento apresenta um bom nível de fiabilidade. O primeiro fator revelou uma fiabilidade excelente ( $\alpha = 0,925$ ), o segundo uma fiabilidade razoável ( $\alpha = 0,678$ ), e o terceiro uma fiabilidade boa ( $\alpha = 0,775$ ). Estes valores são considerados adequados para estudos de natureza exploratória em ciências sociais, reforçando a robustez estatística do modelo fatorial e a coerência conceptual dos fatores identificados. A consistência interna observada permite afirmar que os fatores extraídos medem de forma fiável os constructos subjacentes às perceções dos profissionais sobre a adoção da Inteligência Artificial no contexto laboratorial.

## **Análise de Clusters**

Com o objetivo de identificar o número ótimo de *clusters*, foi inicialmente realizada uma Análise de *Clusters* Hierárquica, utilizando como variáveis de entrada os fatores extraídos previamente na Análise Fatorial. Esta abordagem permitiu explorar a estrutura subjacente dos dados e identificar padrões naturais de agrupamento entre os participantes. Para garantir uma decisão mais robusta, foram testados vários métodos de ligação, nomeadamente o método de *Ward*, a ligação simples (*single linkage*), a ligação completa (*complete linkage*) e a ligação média (*average linkage*), todos baseados na distância euclidiana ao quadrado. A representação gráfica dos dendrogramas gerados por cada método evidenciou padrões consistentes de fusão entre casos, destacando saltos significativos que indicam a presença de uma estrutura de agrupamento bem definida. Com base na análise comparativa dos dendrogramas, foi definida a retenção de 3 (três) *clusters*, número que se revelou teoricamente coerente e estatisticamente sustentado. De seguida, foi aplicada a técnica de *K-means clustering*, utilizando os três *clusters* como *input*, com o objetivo de consolidar os agrupamentos identificados e obter grupos mais homogêneos e estáveis do ponto de vista estatístico. Esta abordagem combinada – análise hierárquica seguida de *K-means* – é amplamente reconhecida na literatura especializada (Hair et al., 2019) como uma estratégia metodológica robusta, contribuindo para uma segmentação mais fiável, interpretável e teoricamente consistente.

## **Análise Comparativa dos Dendrogramas**

Com o intuito de garantir a robustez da solução de agrupamento, foram gerados e analisados 24 dendrogramas, recorrendo à combinação de diferentes métodos de ligação e critérios de

normalização. Esta abordagem exploratória permitiu observar a estabilidade das estruturas de *clusters* obtidas sob diferentes condições.

A análise comparativa revelou que, em 17 dos 24 dendogramas ( $\approx 71\%$ ), a estrutura mais evidente correspondia à divisão em três *clusters*. Os restantes dendogramas sugeriram quatro *clusters* em 4 casos e cinco *clusters* em 3 casos. Esta predominância da solução de três *clusters* reforça a consistência empírica e estatística da opção adotada na análise subsequente com *K-means*.

Dos 24 dendogramas realizados obtiveram-se:

**Tabela 40** – *Análise de Dendogramas*

<i>3 Clusters</i>	<i>4 Clusters</i>	<i>5 Clusters</i>
17 dendogramas	4 dendogramas	3 dendogramas
70,8%	16,7%	12,5%

Com base na análise exploratória efetuada através da Análise de *Clusters* Hierárquica, e tendo em conta que a maioria dos dendogramas gerados (17 em 24) indicava uma estrutura natural de três agrupamentos, procedeu-se à aplicação do método *K-means clustering*, utilizando como input o número de três *clusters*.


O método *K-means* foi escolhido por permitir a consolidação estatística dos agrupamentos identificados, produzindo grupos mais homogêneos internamente e mais distintos entre si, com base na minimização da variância intra-*cluster*. Esta abordagem sequencial, hierárquica seguida de *K-means*, é metodologicamente validada e amplamente recomendada na literatura para melhorar a estabilidade e interpretabilidade das soluções de segmentação (Hair et al., 2019).

A utilização dos fatores extraídos na análise fatorial como variáveis de entrada permitiu garantir uma base estatisticamente robusta e teoricamente coerente para a segmentação, assegurando que os *clusters* obtidos refletem perfis distintos de perceção e atitude dos profissionais de saúde face à Inteligência Artificial em contexto laboratorial.

**Tabela 41 - Número de casos em cada cluster**

Cluster	1	27
	2	27
	3	64
Válido		118

### **Análise da confiança e Abertura à IA por Clusters**



**Figura 39 - Análise do Fator 1 – Confiança e Abertura à IA por Cluster**

A figura 39 apresenta a distribuição dos *scores* fatoriais padronizados relativos ao Fator 1 – Confiança e Abertura à IA, em função dos três *clusters* identificados na análise de segmentação. Este fator agrega um conjunto de variáveis que refletem atitudes positivas face à IA em contexto laboratorial, tais como percepções de utilidade, eficiência, confiança na tecnologia e predisposição para formação.

Observa-se que o *Cluster 1* apresenta uma mediana claramente negativa ( $\approx -1$ ), com elevada dispersão dos *scores* e presença de um *outlier* extremo (caso 22), o que evidencia um perfil marcadamente reticente em relação à adoção da IA. Este grupo inclui os profissionais com maior resistência, traduzida numa percepção predominantemente negativa quanto à integração da IA nos processos laboratoriais.

Por contraste, o *Cluster 2* revela uma mediana positiva e elevada, situada acima de +0,5, com uma distribuição relativamente concentrada e simétrica. Este grupo caracteriza-se por uma forte confiança na IA e abertura à sua implementação, sendo composto pelos profissionais mais recetivos à transformação tecnológica no setor laboratorial.

Já o *Cluster 3* posiciona-se de forma intermédia, com uma mediana próxima de zero e uma variabilidade mais acentuada, incluindo um *outlier* negativo (caso 56). A heterogeneidade interna deste *cluster* sugere um perfil ambivalente, onde coexistem profissionais com percepções positivas moderadas e outros com reservas pontuais. Este grupo poderá representar uma zona de transição, suscetível de ser influenciada por ações de comunicação e capacitação específicas.

Em síntese, a análise dos scores do Fator 1 evidencia uma segmentação clara e estatisticamente sustentada das percepções dos profissionais quanto à confiança e abertura à IA, o que reforça a utilidade desta dimensão na compreensão dos diferentes perfis de atitude face à adoção tecnológica


Porque mantemos *outliers*?

O objetivo é compreender a diversidade real das percepções na amostra, incluindo casos extremos que podem ser relevantes do ponto de vista interpretativo. A amostra não é muito grande (n=118), e eliminar casos pode comprometer a representatividade.

Os *outliers* não distorcem significativamente a média ou a variância e estão contextualmente justificados (ex.: pessoas com experiências muito negativas ou muito positivas com IA).

Dada a abordagem exploratória, como é comum em ciências sociais, onde a variabilidade humana é parte do fenómeno estudado.

Devemos assinalar a existência dos *outliers* na análise e reforçar que foram mantidos por refletirem realidades minoritárias, mas legítimas.




**Figura 40** - Análise do Fator 2 – Preocupações Éticas, Técnicas e Profissionais por Cluster

A figura 40 representa a distribuição dos scores fatoriais padronizados relativos ao Fator 2 – Preocupações Éticas, Técnicas e Profissionais, segmentados pelos três *clusters* identificados na análise de agrupamento. Este fator integra variáveis que refletem receios relacionados com a adoção da IA, nomeadamente preocupações com a segurança e privacidade dos dados, o impacto sobre o emprego, a insegurança dos profissionais e o eventual comprometimento do papel crítico dos técnicos na validação diagnóstica.

O *Cluster 1* apresenta uma mediana positiva, indicando um grupo de profissionais com maior sensibilidade e preocupação face aos riscos éticos, técnicos e profissionais associados à IA. A distribuição revela uma amplitude moderada, com os valores centrados entre -1 e +1. Estes profissionais evidenciam um perfil mais crítico e cauteloso perante os potenciais impactos da tecnologia no contexto laboratorial.

Em contraste, o *Cluster 2* destaca-se por uma mediana significativamente negativa, com a totalidade dos *scores* abaixo de zero e um *outlier* identificado (caso 36) com *score* particularmente baixo. Este grupo representa os profissionais menos preocupados com as implicações da IA, revelando um posicionamento mais confiante ou indiferente em relação aos riscos éticos e técnicos. A homogeneidade dos *scores* reforça a consistência deste perfil.

O *Cluster 3* apresenta uma mediana ligeiramente positiva e uma dispersão mais alargada, incluindo três *outliers* (casos 62, 64 e 82) com *scores* elevados. Esta configuração indica um grupo moderadamente preocupado, com percepções de risco menos intensas do que as observadas no *Cluster 1*, mas ainda assim relevantes. A presença de *outliers* sugere variações internas e possíveis subgrupos com preocupações mais acentuadas. Em suma, o Fator 2 evidencia uma segmentação clara das percepções éticas e profissionais perante a IA. O *Cluster 1* assume um perfil crítico, o *Cluster 2* um perfil despreocupado, e o *Cluster 3* um perfil intermédio. Esta diferenciação reforça a necessidade de estratégias adaptadas à realidade de cada grupo, promovendo abordagens comunicacionais e formativas que reconheçam a diversidade de atitudes e preocupações no seio das equipas laboratoriais.



**Figura 41** - Análise do Fator 3 – Conforto e Segurança Pessoal com a IA por Cluster

A figura 41 apresenta a distribuição dos *scores* fatoriais padronizados do Fator 3 – Conforto e Segurança Pessoal com a IA, em função dos três *clusters* anteriormente definidos. Este fator compreende variáveis relacionadas com o conforto individual na utilização da IA, a confiança na proteção de dados pessoais, a previsibilidade do seu funcionamento e a percepção da automação como uma evolução positiva para os profissionais de saúde.

O *Cluster 1* revela uma mediana negativa, com uma distribuição assimétrica concentrada entre -2,5 e +0,5. Este grupo corresponde aos profissionais que demonstram menor conforto e segurança pessoal face à IA, evidenciando uma atitude mais reservada, com menor confiança subjetiva na tecnologia e nas suas implicações diretas no ambiente de trabalho.

Por sua vez, o *Cluster 2* apresenta uma mediana positiva, com valores dispersos entre cerca de -2 e +2. Este *cluster* representa os profissionais que manifestam níveis mais elevados de conforto pessoal com a IA, demonstrando confiança na tecnologia e maior segurança quanto à sua utilização no quotidiano laboratorial. A amplitude dos *scores* sugere alguma variabilidade interna, mas a mediana elevada indica uma perceção globalmente favorável.

O *Cluster 3* revela igualmente uma mediana positiva, com valores concentrados num intervalo semelhante ao do *Cluster 2*, mas com uma distribuição ligeiramente mais compacta. Este grupo expressa também sentimentos positivos em relação à IA, nomeadamente no que respeita ao bem-estar individual, previsibilidade e fiabilidade da tecnologia. A menor dispersão relativa dos dados neste grupo pode indicar uma perceção mais estável e consensual entre os seus membros.

Em termos comparativos, o Fator 3 permite distinguir claramente os perfis de conforto subjetivo com a IA: o *Cluster 1* é o mais inseguro, o *Cluster 2* apresenta o maior nível de conforto, e o *Cluster 3* ocupa uma posição também positiva, embora ligeiramente mais homogénea. Estes resultados sublinham a importância de considerar não apenas as atitudes cognitivas ou éticas, mas também os aspetos emocionais e subjetivos na análise da aceitação da IA em contexto clínico.

## **Caracterização de Clusters**

### ***Cluster 1***

O *Cluster 1*, composto por 27 profissionais (23% da amostra), corresponde ao grupo mais reticente em relação à adoção da IA. A maioria dos participantes encontra-se alocada ao Hospital de São José (55,6%), seguindo-se o Hospital de Dona Estefânia (18,5%) e outros polos de forma residual. Em termos de experiência profissional, 37% exercem funções há mais de 20 anos em laboratórios de patologia clínica, embora coexistam também profissionais com 1 a 5 anos (18,5%) e com 11 a 15 anos de experiência (22,2%), o que denota uma composição relativamente diversificada em termos de senioridade. Quanto à idade, predominam os indivíduos entre os 40 e 49 anos (48,1%), com 11,1% acima dos 60 anos. O grupo é maioritariamente feminino (77,8%), com 14,8% de profissionais do sexo masculino e 7,4% que optaram por não declarar o género. Do ponto de vista académico, 88,9% possuem licenciatura e 11,1% mestrado, não se verificando doutoramentos neste grupo. Este *cluster* distingue-se por uma atitude mais crítica e desconfiada face à IA, revelando preocupações acentuadas de natureza ética e técnica, e menor conforto subjetivo com a tecnologia, o que o posiciona como o segmento mais resistente à transformação digital no contexto laboratorial.

P6.1 - Habitualmente está alocado ao laboratório de que polo hospitalar?

**Tabela 42** – Número de casos de Cluster 1

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	HCC	3	11.1	11.1	11.1
	HDE	5	18.5	18.5	29.6
	HSAC	3	11.1	11.1	40.7
	HSJ	15	55.6	55.6	96.3
	MAC	1	3.7	3.7	100.0
	Total	27	100.0	100.0	

P6.2 - Há quantos anos trabalha num laboratório de patologia clínica.

**Tabela 43** - Número de caso de cluster 1

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	1 - 5 anos	5	18.5	18.5	18.5
	11 - 15 anos	6	22.2	22.2	40.7
	16 - 20 anos	3	11.1	11.1	51.9
	6 - 10 anos	3	11.1	11.1	63.0
	Mais de 20 anos	10	37.0	37.0	100.0
	Total	27	100.0	100.0	

P6.3 - Idade:

**Tabela 44**- Número de caso de cluster 1

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	30 - 39 anos	6	22.2	22.2	22.2
	40 - 49 anos	13	48.1	48.1	70.4
	50 - 59 anos	5	18.5	18.5	88.9
	Mais de 60 anos	3	11.1	11.1	100.0
	Total	27	100.0	100.0	

P6.4 – Gênero

**Tabela 45** - Número de caso de cluster 1

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	Feminino	21	77.8	77.8	77.8
	Masculino	4	14.8	14.8	92.6
	Prefiro não dizer	2	7.4	7.4	100.0
	Total	27	100.0	100.0	

P6.5 - Formação

**Tabela 46** - Número de caso de cluster 1

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	Licenciatura	24	88.9	88.9	88.9
	Mestrado	3	11.1	11.1	100.0
	Total	27	100.0	100.0	

## Cluster 2

O *Cluster 2* integra igualmente 27 profissionais (23% da amostra) e representa o grupo mais entusiasta e confiante relativamente à adoção da IA. A esmagadora maioria dos elementos deste *cluster* está afeta ao Hospital de São José (81,5%), sendo os restantes distribuídos pelo Hospital de Dona Estefânia (11,1%) e pelo Hospital Curry Cabral (7,4%). Do ponto de vista da experiência profissional, 59,3% dos participantes acumulam mais de 20 anos de trabalho em laboratórios de patologia clínica, o que revela uma forte presença de profissionais seniores com predisposição positiva para a inovação tecnológica. Em termos etários, o grupo apresenta uma distribuição equilibrada, embora com maior concentração nas faixas dos 30 aos 59 anos, e com 29,6% de profissionais com mais de 60 anos. Quanto ao género, 81,5% são mulheres e 18,5% homens. No que respeita ao nível de qualificação académica, destaca-se como o *cluster* com maior percentagem de formação avançada: 33,3% possuem mestrado e 3,7% doutoramento, enquanto 63% têm licenciatura. Este perfil evidencia um conjunto de profissionais com elevada confiança na IA, reduzidas preocupações éticas e técnicas, e elevado conforto na sua utilização, posicionando-se como um segmento estratégico para liderar processos de transformação digital no setor laboratorial.

P6.1 - Habitualmente está alocado ao laboratório de que polo hospitalar?

**Tabela 47** - Número de caso de *cluster 2*

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	HCC	2	7.4	7.4	7.4
	HDE	3	11.1	11.1	18.5
	HSJ	22	81.5	81.5	100.0
	Total	27	100.0	100.0	

P6.2 - Há quantos anos trabalha num laboratório de patologia clínica.

**Tabela 48**- Número de caso de *cluster 2*

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	1 - 5 anos	3	11.1	11.1	11.1
	11 - 15 anos	2	7.4	7.4	18.5
	16 - 20 anos	2	7.4	7.4	25.9
	6 - 10 anos	4	14.8	14.8	40.7
	Mais de 20 anos	16	59.3	59.3	100.0
	Total	27	100.0	100.0	

P6.3 - Idade:

**Tabela 49** - Número de caso de *cluster 2*

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	Menos 30 anos	1	3.7	3.7	3.7
	30 – 39 anos	6	22.2	22.2	25.9
	40 – 49 anos	6	22.2	22.2	48.1
	50 – 59 anos	6	22.2	22.2	70.3
	Mais de 60 anos	8	29.6	29.6	100.0
	Total	27	100.0	100.0	

P6.4 - Género

**Tabela 50** - Número de caso de *cluster 2*

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	Feminino	22	81.5	81.5	81.5
	Masculino	5	18.5	18.5	100.0
	Total	27	100.0	100.0	

P6.5 – Formação

**Tabela 51** - Número de caso de *cluster 2*

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	Doutoramento	1	3.7	3.7	3.7
	Licenciatura	17	63.0	63.0	66.7
	Mestrado	9	33.3	33.3	100.0
	Total	27	100.0	100.0	

**Cluster 3**

O *Cluster 3*, composto por 64 profissionais (54% da amostra), constitui o grupo mais numeroso e heterogéneo, refletindo uma posição moderada ou ambivalente face à adoção da IA. Os profissionais deste *cluster* estão distribuídos por vários polos hospitalares, com maior incidência no Hospital de São José (45,3%) e no Hospital de Dona Estefânia (23,4%), seguidos pelo MAC (12,5%), Hospital de Santa Marta (7,8%), Hospital Curry Cabral (6,3%) e Hospital de Santo António dos Capuchos (4,7%). Em termos de experiência profissional, quase metade (48,4%) conta com mais de 20 anos de prática em laboratório, coexistindo com uma proporção significativa de profissionais com menos de 10 anos de experiência (26,6%), o que reforça o carácter diversificado deste grupo. A distribuição etária também é variada: predominam os profissionais entre os 30 e 59 anos (79,7%), com 17,2% acima dos 60 anos e 3,1% com menos de 30. Quanto ao género, 82,8% são mulheres, 12,5% homens e 4,7% preferiram não responder. No que respeita à formação académica, 73,4% têm licenciatura e 26,6% mestrado. Este *cluster* representa um segmento intermédio em termos de atitude face à IA, onde coexistem perceções positivas e algumas reservas técnicas ou éticas, traduzindo-se num grupo com potencial de desenvolvimento e elevada relevância estratégica para ações de capacitação, comunicação e envolvimento progressivo nos processos de transição tecnológica

P6.1 - Habitualmente está alocado ao laboratório de que polo hospitalar?

**Tabela 52** - Número de caso de *cluster* 3

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	HCC	4	6.3	6.3	6.3
	HDE	15	23.4	23.4	29.7
	HSAC	3	4.7	4.7	34.4
	HSJ	29	45.3	45.3	79.7
	HSM	5	7.8	7.8	87.5
	MAC	8	12.5	12.5	100.0
	Total	64	100.0	100.0	

P6.2 - Há quantos anos trabalha num laboratório de patologia clínica.

**Tabela 53** - Número de caso de *cluster* 3

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	1 - 5 anos	9	14.1	14.1	14.1
	11 - 15 anos	11	17.2	17.2	31.3
	16 - 20 anos	5	7.8	7.8	39.1
	6 - 10 anos	8	12.5	12.5	51.6
	Mais de 20 anos	31	48.4	48.4	100.0
	Total	64	100.0	100.0	

P6.3 - Idade:

**Tabela 54**- Número de caso de *cluster* 3

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	30 - 39 anos	20	31.3	31.3	31.3
	40 - 49 anos	10	15.6	15.6	46.9
	50 - 59 anos	21	32.8	32.8	79.7
	Mais de 60 anos	11	17.2	17.2	96.9
	Menos de 30 anos	2	3.1	3.1	100.0
	Total	64	100.0	100.0	

P6.4 - Género

**Tabela 55** - Número de caso de *cluster* 3

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	Feminino	53	82.8	82.8	82.8
	Masculino	8	12.5	12.5	95.3
	Prefiro não dizer/Não responde	3	4.7	4.7	100.0
	Total	64	100.0	100.0	

P6.5 – Formação

**Tabela 56** - Número de caso de *cluster* 3

		Frequência	Percentagem	Percentagem válida	Percentagem acumulativa
Válido	Licenciatura	47	73.4	73.4	73.4
	Mestrado	17	26.6	26.6	100.0
	Total	64	100.0	100.0	

1.1 - Já teve contacto prévio com sistemas de IA ou automação no seu local de trabalho?

**Tabela 57** - *Análise de contato prévio com sistemas de IA por Cluster*

		Cluster 1	Cluster 2	Cluster 3	Total
1.1 - Já teve contacto prévio com sistemas de IA ou automação no seu local de trabalho?	Não	17	7	22	46
	Sim	10	20	42	72
Total		27	27	64	118

Tabela 58 - Chi-Square Test

Chi-Square Tests

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	9.034 <sup>a</sup>	2	.011
Likelihood Ratio	8.942	2	.011
Linear-by-Linear Association	4.662	1	.031
N of Valid Cases	118		

0 cells (0.0%) have expected count less than 5. The minimum expected count is 10.53

Para testar a existência de uma relação entre a pertença a um dos *clusters* atitudinais e o contacto prévio com sistemas de Inteligência Artificial, foram formuladas as seguintes hipóteses:

$H_0$ : Não existe associação estatisticamente significativa entre o cluster e o contacto prévio com IA (variáveis independentes).

$H_1$ : Existe associação estatisticamente significativa entre o cluster e o contacto prévio com IA (variáveis dependentes).

Conclusão: Como  $p = 0,011 < 0,05$ , rejeita-se a hipótese nula ( $H_0$ ).

Dado que o valor de significância obtido no teste do *qui-quadrado* de *Pearson* foi  $p = 0,011$ , inferior ao nível de significância estabelecido ( $\alpha = 0,05$ ), conclui-se que existe uma associação estatisticamente significativa entre o *cluster* atitudinal e o contacto prévio com sistemas de IA. Assim, rejeita-se a hipótese nula ( $H_0$ ) e aceita-se a hipótese alternativa ( $H_1$ ), indicando que as variáveis não são independentes.

Deste modo, o teste do *qui-quadrado* revela que existe uma associação estatisticamente significativa entre a pertença a um dos *clusters* e o contacto prévio com sistemas de IA. Assim, estas variáveis não são independentes, sugerindo que a experiência prévia com tecnologia pode estar relacionada com as atitudes face à sua adoção.

## APÊNDICE D - ANÁLISE DETALHADA POR QUESTÃO

### 1.1 - Já teve contacto prévio com sistemas de IA ou automação no seu local de trabalho?

**Tabela 19** – Contacto prévio com tecnologias de Inteligência Artificial ou automação no local de trabalho (Frequência absoluta)

	Frequência	Percentagem
Não	46	39.0
Sim	72	61.0
Total	118	100.0

Do total de 118 participantes, 72 (61,0%) afirmaram já ter tido contacto com IA ou automação no seu local de trabalho, enquanto 46 (39,0%) indicaram nunca ter tido essa experiência. A maioria da amostra revela ter alguma experiência prévia com IA, o que pode indicar familiaridade crescente com estas tecnologias em ambiente clínico.

### 1.2. - Já participou em formações ou eventos relacionados com a IA ou automação?

**Tabela 20** – Participação dos profissionais em ações de formação ou eventos sobre IA e automação. (Frequência absoluta)

	Frequência	Percentagem
Não	66	55.9
Sim	52	44.1
Total	118	100.0

Cerca de 52 participantes (44,1%) indicaram já ter participado em formações ou eventos relacionados com IA, enquanto a maioria (66, correspondente a 55,9%) respondeu negativamente.

Apesar do contacto com IA, a maioria dos profissionais ainda não teve formação formal sobre o tema.

### 1.3. - O laboratório onde trabalha atualmente utiliza tecnologias de IA?

Tabela 21 – Existem tecnologias de Inteligência Artificial atualmente no seu laboratório. (Frequência absoluta)

	Frequência	Porcentagem
Não	75	63.6
Sim	43	36.4
Total	118	100.0

43 dos 118 inquiridos (36,4%) indicaram que o seu laboratório já utiliza IA, enquanto 75 (63,6%) afirmaram que tal ainda não acontece.

Os dados revelam uma presença ainda limitada de tecnologias de IA nos laboratórios, apesar do interesse crescente.

### 1.4. - Tenho conhecimentos sobre:





Figura 4 - Distribuição percentual das áreas tecnológicas que os inquiridos afirmaram conhecer, no contexto de Inteligência Artificial, Automação e Big Data.

- Automação foi a área mais referida (40,7%).
- Inteligência artificial foi assinalada por 31,4% dos participantes.
- Nenhuma das anteriores foi indicada por 21,2%, refletindo ausência de contacto declarado.
- Apenas 11,9% indicaram conhecimento em *Big Data*.

A maioria dos profissionais declara ter conhecimentos em áreas diretamente aplicáveis ao laboratório, como automação e IA. O conhecimento sobre *Big Data* é menos prevalente, enquanto uma parte considerável da amostra (mais de 1 em cada 5) não se identifica com nenhuma das opções apresentadas.

## 2.1. - A IA pode melhorar a precisão e a eficiência no processamento de amostras laboratoriais.




**Figura 5** - Distribuição das respostas dos profissionais à afirmação "A IA pode melhorar a precisão e a eficiência no processamento de amostras laboratoriais."

- A maioria dos participantes concorda (60,2%) com a afirmação.
- 18,6% concordam totalmente.
- 14,4% mantêm posição neutra.
- Apenas 3,4% discordam ou discordam totalmente.
- A média das respostas foi de 3,94 numa escala de 1 a 5.

Os dados revelam uma percepção marcadamente positiva por parte dos profissionais, com mais de três quartos da amostra a concordar ou concordar totalmente com o potencial da IA para melhorar a precisão e eficiência em processos laboratoriais.

## 2.2. - A IA pode oferecer conveniência e poupar tempo.




**Figura 6** - Distribuição das respostas à afirmação "A IA pode oferecer conveniência e poupar tempo", segundo a percepção dos profissionais.

- 54,2% dos inquiridos concordam com a afirmação.
- 25,4% concordam totalmente.
- 15,3% mantêm-se neutros ("nem concordo nem discordo").
- Apenas 2,5% dos participantes demonstraram algum grau de discordância (1,7% discordam e 0,8% discordam totalmente).

- A média geral das respostas foi de 4,04 (escala de 1 a 5).

A maioria expressiva dos participantes reconhece o potencial da IA para trazer conveniência e otimizar o tempo em ambiente laboratorial, refletido numa média elevada e baixa taxa de discordância.

### 2.3 - A automação permite reduzir o número de erros no diagnóstico laboratorial.




**Figura 7-** Distribuição das respostas dos profissionais à afirmação “A automação permite reduzir o número de erros no diagnóstico laboratorial”.

- A média geral das respostas foi de 3.99 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- Os valores indicam uma tendência acentuada para o acordo, sugerindo que a maioria dos profissionais reconhece o valor da automação na minimização de erros humanos.

A média elevada revela uma percepção amplamente positiva sobre o impacto da automação na redução de erros diagnósticos, o que reforça a sua importância como ferramenta de apoio à qualidade laboratorial.

### 2.4 - A IA pode melhorar a gestão de amostras, otimizando o fluxo de trabalho no laboratório.




**Figura 8 -** Distribuição das respostas à afirmação “A IA pode melhorar a gestão de amostras, otimizando o fluxo de trabalho no laboratório”.

- A média das respostas foi de 4.03 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- Este valor posiciona-se acima do ponto médio da escala, o que indica uma percepção positiva generalizada quanto ao potencial da IA para melhorar a gestão laboratorial.

Os profissionais demonstram concordância com a ideia de que a IA pode trazer melhorias organizacionais no fluxo de trabalho, especialmente na gestão de amostras, o que pode contribuir para maior eficiência e rastreabilidade.

## 2.5 - A implementação de IA ajuda a otimizar a utilização de recursos humanos e tecnológicos.




**Figura 9** - Distribuição das respostas à afirmação “A implementação de IA ajuda a otimizar a utilização de recursos humanos e tecnológicos”.

- A média das respostas foi de 3.86 numa escala de 1 a 5.
- Este valor reflete uma tendência para o acordo, embora ligeiramente menos expressiva do que em outras variáveis da mesma secção.

A percepção dos profissionais revela que a maioria concorda com a ideia de que a IA pode contribuir para uma gestão mais eficiente de recursos no contexto laboratorial, ainda que de forma um pouco mais moderada em comparação com outras afirmações.

## 2.6 - A IA contribuirá para a padronização dos processos de diagnóstico




**Figura 10** - Distribuição das respostas dos profissionais à afirmação "A IA contribuirá para a padronização dos processos de diagnóstico".

- A média das respostas foi de 3.77 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- Este valor indica uma tendência positiva, embora mais moderada, na percepção dos profissionais sobre o impacto da IA na padronização dos procedimentos laboratoriais.

A maioria dos participantes tende a concordar com a afirmação, sugerindo que veem na IA um instrumento potencial de uniformização e coerência nos processos diagnósticos.

## 2.7 - A automação e IA irão diminuir o tempo de entrega dos resultados laboratoriais.



**Figura 11** - Distribuição das respostas à afirmação "A automação e IA irão diminuir o tempo de entrega dos resultados laboratoriais".

- A média das respostas foi de 3.97 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- O valor médio revela uma opinião maioritariamente favorável, próxima do patamar de "concordo".
- Os dados sugerem que os profissionais acreditam que a introdução de IA e automação poderá agilizar significativamente os tempos de resposta no contexto laboratorial, contribuindo para maior eficiência no serviço ao utente.

## 2.8 - Acredito que a Inteligência Artificial vai melhorar o meu trabalho.




Figura 12 - Distribuição das respostas à expectativa de melhoria do trabalho com IA


Tabela 22 - Frequência e porcentagem das respostas à expectativa de melhoria do trabalho com IA

	Frequência	Porcentagem	Porcentagem acumulativa
1	2	1.7	1.7
2	4	3.4	5.1
3	3	2.5	7.6
4	6	5.1	12.7
5	16	13.6	26.3
6	12	10.2	36.4
7	23	19.5	55.9
8	36	30.5	86.4
9	8	6.8	93.2
10	8	6.8	100.0
Total	118	100.0	

- A média das respostas foi de 6.75 em 10, evidenciando uma tendência globalmente positiva.
- As respostas mais frequentes situaram-se nos níveis 7, 8 e 5.
- Apenas uma pequena percentagem pontuou entre 1 e 3.

A maioria dos profissionais demonstra otimismo moderado a elevado quanto ao impacto positivo da IA no seu trabalho. Embora não seja uma concordância total, os valores revelam uma disposição favorável à integração destas tecnologias no contexto laboral.

### 3.1 - A implementação de IA no laboratório será limitada pela falta de infraestrutura adequada.




**Figura 13** - Distribuição das respostas dos profissionais à afirmação "A implementação de IA no laboratório será limitada pela falta de infraestrutura adequada".

- A média das respostas foi de 3.87 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- A maioria dos participantes demonstrou algum grau de concordância, posicionando a média próxima do nível "concordo".

Os profissionais consideram, em geral, que a infraestrutura atual pode representar um obstáculo relevante à adoção plena de sistemas baseados em IA nos laboratórios clínicos.

### 3.2 - A manutenção contínua dos sistemas automatizados é uma preocupação relevante.




**Figura 14** - Distribuição das respostas à afirmação "A manutenção contínua dos sistemas automatizados é uma preocupação relevante".

- A média das respostas foi de 4.07 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- Este valor revela um elevado grau de concordância, refletindo uma preocupação transversal entre os participantes.

Os dados mostram que a manutenção contínua dos sistemas é amplamente reconhecida como uma barreira relevante à implementação sustentável de tecnologias de automação e IA em laboratórios.

### 3.3 - A interoperabilidade entre os sistemas existentes e as novas tecnologias será um desafio.




**Figura 15** - Distribuição das respostas à afirmação “A interoperabilidade entre os sistemas existentes e as novas tecnologias será um desafio”, no contexto da adoção de IA e automação nos laboratórios.

- A média das respostas foi de 4.27 numa escala de 1 a 5.
- Este valor é o mais elevado da secção 3, indicando forte concordância por parte dos inquiridos.

Os profissionais manifestam clara preocupação com a integração entre sistemas antigos e novas soluções tecnológicas, vendo a interoperabilidade como uma das principais barreiras técnicas à transformação digital no ambiente laboratorial.

### 3.4 - A formação técnica da equipa atual não é suficiente para lidar com IA e automação.



**Figura 16** - Distribuição das respostas à afirmação “A formação técnica da equipa atual não é suficiente para lidar com IA e automação”.

- A média das respostas foi de 3.40 numa escala de 1 a 5.
- Este valor indica uma perceção tendencialmente concordante, embora com maior dispersão de opiniões em comparação com outras questões da secção.

Os dados sugerem que uma parte significativa dos profissionais considera a formação técnica atual insuficiente para acompanhar os avanços em IA e automação, embora exista uma margem relevante de respostas mais neutras ou incertas.

### 3.5 - A introdução destas tecnologias exigirá investimentos financeiros significativos.




**Figura 17** - Distribuição das respostas à afirmação “A introdução destas tecnologias exigirá investimentos financeiros significativos”.

- A média foi de 4.35 numa escala de 1 a 5, o valor mais elevado desta secção.
- A maioria dos participantes concorda ou concorda totalmente com a afirmação.

Os profissionais reconhecem de forma quase consensual que a adoção de IA e automação exigirá investimentos substanciais, o que poderá representar uma barreira crítica à implementação destas tecnologias.

### 3.6 - Confio que a IA realiza tarefas laboratoriais com precisão.




**Figura 18** - Distribuição das respostas à afirmação “Confio que a IA realiza tarefas laboratoriais com precisão”, no contexto da perceção dos profissionais sobre a fiabilidade tecnológica.

- A média das respostas foi de 3.68 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- A maioria dos participantes tende a concordar, embora com algum grau de reserva.

Os dados revelam uma perceção globalmente positiva sobre a precisão da IA em tarefas laboratoriais, mas ainda com espaço para reforçar a confiança plena dos profissionais na fiabilidade destas tecnologias.

#### 4.1 - A automação pode impactar negativamente a segurança e privacidade dos dados dos pacientes.




**Figura 19** - Distribuição das respostas à afirmação "A automação pode impactar negativamente a segurança e privacidade dos dados dos pacientes".

- A média foi de 3.07 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- O valor aproxima-se do ponto médio, indicando opiniões divididas entre concordância e discordância.

Os resultados sugerem que, embora exista alguma preocupação com a segurança e privacidade dos dados na automação, não há consenso pleno entre os profissionais sobre a gravidade deste risco.

#### 4.2 - A implementação de IA pode reduzir o número de postos de trabalho no laboratório.




**Figura 20** - Distribuição das respostas à afirmação "A implementação de IA pode reduzir o número de postos de trabalho no laboratório".

- A média das respostas foi de 3.71 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).

- O valor indica uma tendência para a concordância, ainda que não seja unânime.

Os dados revelam que uma parte significativa dos profissionais acredita que a adoção de IA poderá resultar na redução de postos de trabalho, embora exista também um grupo que não partilha desta visão.

#### 4.3 - A introdução de IA e automação pode gerar insegurança nos profissionais de saúde.

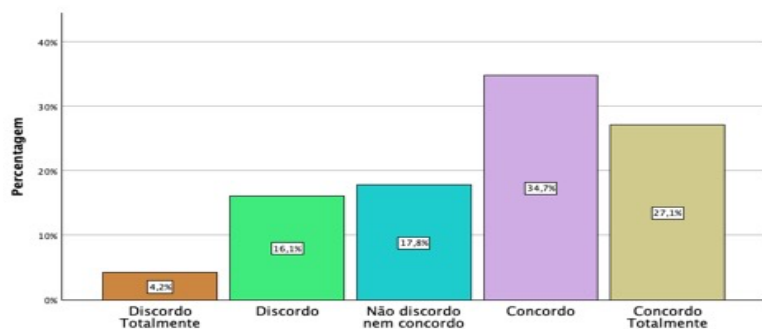


**Figura 21** - Distribuição das respostas à afirmação "A introdução de IA e automação pode gerar insegurança nos profissionais de saúde".

- A média das respostas foi de 3.47 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- O valor situa-se ligeiramente acima do ponto médio, sugerindo opiniões mistas, com tendência para a concordância.

Os dados indicam que parte dos profissionais reconhece a possibilidade de a IA e a automação gerarem algum grau de insegurança profissional, embora este não seja um sentimento generalizado.

#### 4.4 - A utilização de IA pode comprometer o papel crítico dos profissionais na validação de diagnósticos.




**Figura 22** - Distribuição das respostas à afirmação "A utilização de IA pode comprometer o papel crítico dos profissionais na validação de diagnósticos".

- A média das respostas foi de 3.64 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- O valor reflete uma tendência para a concordância, ainda que não seja unânime.

Os resultados mostram que uma parte significativa dos profissionais receia que a IA possa reduzir a sua intervenção direta e o papel crítico na validação de diagnósticos, embora esta percepção não seja absoluta.

#### 4.5 - É essencial envolver os profissionais nas decisões sobre a implementação de IA.

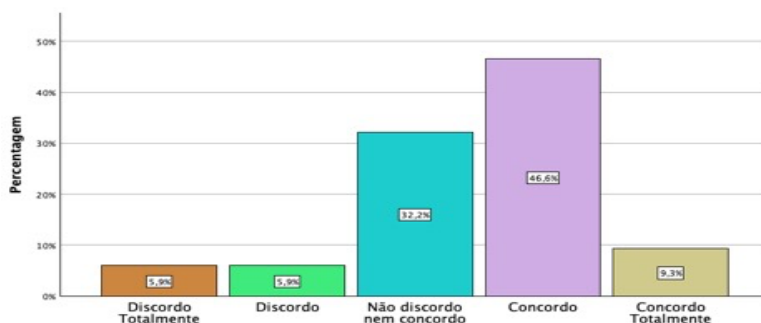


**Figura 23** - Distribuição das respostas à afirmação “É essencial envolver os profissionais nas decisões sobre a implementação de IA”.

- A média das respostas foi de 4.62 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- Este é um dos valores mais elevados do questionário, demonstrando forte concordância por parte da amostra.

Os dados evidenciam consenso quase total entre os profissionais sobre a necessidade de participação ativa nas decisões relativas à introdução de IA, reforçando a importância de uma abordagem colaborativa.

#### 5.1 - Sinto-me confortável com o uso de IA no meu ambiente de trabalho.




**Figura 24** - Distribuição das respostas à afirmação “Sinto-me confortável com o uso de IA no meu ambiente de trabalho”.

- A média foi de 3.47 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- O valor está ligeiramente acima do ponto médio, indicando uma tendência para a concordância, mas com opiniões divididas.

Os dados mostram que, embora exista uma aceitação moderada da IA no ambiente laboral, há também um grupo relevante de profissionais que não manifesta conforto total na sua utilização.

## 5.2. - Confio que a IA pode ser usada de forma ética.

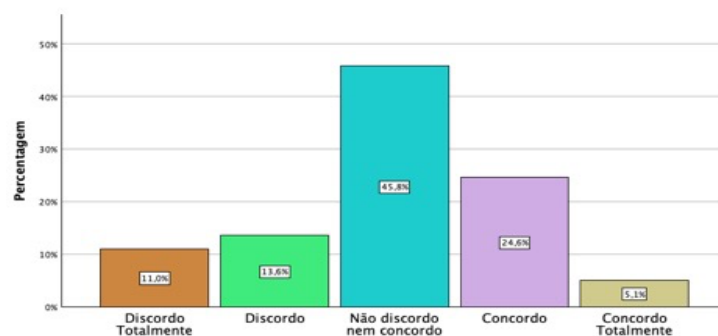


**Figura 25** - Distribuição das respostas à afirmação “Confio que a IA pode ser usada de forma ética”.

- Média de 3.54 numa escala de 1 a 5.
- Tendência para a concordância, embora não muito acentuada.

Os profissionais manifestam uma confiança moderada na utilização ética da IA, com algum espaço para melhorar a perceção de segurança e responsabilidade.

## 5.3 - Confio que a IA protege os meus dados pessoais.



**Figura 26** - Distribuição das respostas à afirmação “Confio que a IA protege os meus dados pessoais”.

- Média de 2.99, ligeiramente abaixo do ponto médio da escala.
- Indica um nível de confiança reduzido na proteção de dados pessoais por sistemas de IA.

Existe ceticismo significativo relativamente à segurança dos dados pessoais, refletindo uma área sensível para a aceitação destas tecnologias.

#### 5.4 - Acredito que a IA é previsível no seu funcionamento.




Figura 27 - Distribuição das respostas à afirmação "Acredito que a IA é previsível no seu funcionamento".

- Média de 3.29, próxima do ponto médio.
- Percepção mista entre previsibilidade e imprevisibilidade dos sistemas de IA.

Os profissionais demonstram uma confiança moderada, mas não plena, na consistência operacional da IA.

#### 5.5 - Tenho confiança na capacidade da IA de aprender e melhorar.





Figura 28 - Distribuição das respostas à afirmação "Tenho confiança na capacidade da IA de aprender e melhorar".

- Média de 3.62, denotando concordância moderada.
- Reflete percepção positiva do potencial de evolução da IA.

A amostra reconhece que a IA tem capacidade de aperfeiçoamento contínuo, o que favorece a sua integração a longo prazo.

### 5.6 - A automação no laboratório é uma evolução positiva para os profissionais de saúde.




**Figura 29** - Distribuição das respostas à afirmação "A automação no laboratório é uma evolução positiva para os profissionais de saúde".

- Média de 4.06, refletindo concordância elevada.
- Uma das percepções mais positivas da secção.

A maioria dos profissionais vê a automação como um avanço benéfico na prática laboratorial.

### 5.7 - Considero que o impacto da IA e automação será mais positivo do que negativo.




**Figura 30** - Distribuição das respostas à afirmação "Considero que o impacto da IA e automação será mais positivo do que negativo".

- Média de 3.85, mostrando clara tendência para a concordância.

Os profissionais tendem a avaliar o impacto global da IA e automação de forma favorável.

### 5.8 - Estou disposto(a) a receber formação para aprender a trabalhar com IA e automação.

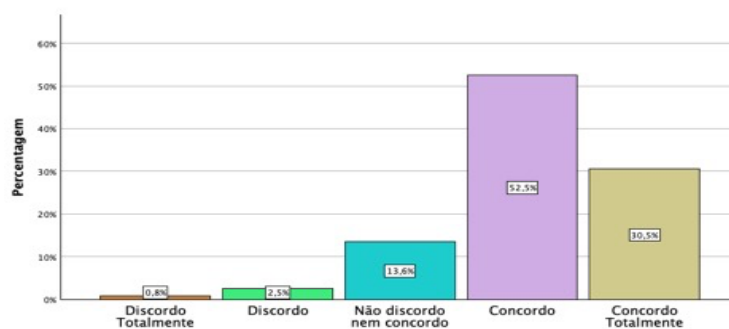


**Figura 31** - Distribuição das respostas à afirmação "Estou disposto(a) a receber formação para aprender a trabalhar com IA e automação".

- Média de 4.38, uma das mais altas do estudo.
- Indica forte predisposição para formação.

Existe elevada motivação para adquirir competências que permitam lidar com novas tecnologias no laboratório.

### 5.9 - Estou motivado(a) para contribuir para a integração destas tecnologias no laboratório.




**Figura 32** - Distribuição das respostas à afirmação "Estou motivado(a) para contribuir para a integração destas tecnologias no laboratório".

- Média de 4.09, indicando concordância elevada.

Os profissionais revelam forte motivação para participar ativamente na integração da IA e automação no contexto laboral.

### 5.10 - Na sua opinião, quais são os principais obstáculos à adoção de tecnologias emergentes no Laboratório de Patologia Clínica?




**Figura 33** – Distribuição das respostas “quais são os principais obstáculos à adoção de tecnologias emergentes no Laboratório de Patologia Clínica?”

Os participantes foram convidados a identificar, em resposta múltipla, os principais obstáculos à adoção de tecnologias emergentes no contexto dos laboratórios de patologia clínica. A leitura da figura 33 revela que o custo elevado das tecnologias surge como o obstáculo mais frequentemente assinalado, seguido da infraestrutura inadequada. Estes dois fatores refletem uma preocupação estrutural e organizacional por parte dos profissionais, que reconhecem que a transição tecnológica não pode ocorrer sem investimento significativo em equipamentos, sistemas de informação e interoperabilidade técnica.

Logo de seguida, surge como terceiro fator mais referido a falta de formação adequada dos profissionais, o que reforça a necessidade de capacitação contínua e segmentada. Sem esta preparação, mesmo os investimentos tecnológicos mais robustos podem falhar na sua adoção eficaz. A estas barreiras acrescem ainda preocupações éticas, sobretudo ligadas à privacidade de dados, à transparência dos algoritmos e à eventual substituição de funções humanas, bem como a resistência à mudança, identificada como o último obstáculo mais citado.

### 5.11 - Em que áreas do laboratório considera que estas tecnologias terão maior impacto?




**Figura 34** – Distribuição das repostas a “Em que áreas do laboratório considera que estas tecnologias terão maior impacto?”

Esta pergunta procurou identificar as áreas do laboratório onde os profissionais consideram que as tecnologias emergentes, como a Inteligência Artificial, poderão ter maior impacto. Os dados obtidos evidenciam que a automação de tarefas repetitivas foi a categoria mais assinalada pelos participantes, revelando uma percepção clara de que a IA poderá ser especialmente útil em processos que exigem repetibilidade, conferência sistemática e monitorização de padrões.

Em segundo lugar surge a gestão de amostras, uma função crítica para garantir a rastreabilidade e integridade dos processos laboratoriais. Também foram amplamente referidas as áreas de triagem inicial, interpretação de resultados e organização de dados clínicos, sugerindo que os profissionais reconhecem o potencial da IA para otimizar fluxos de trabalho, reduzir o erro humano e melhorar a eficiência global das operações laboratoriais.

## 5.12 - De uma forma geral, acha que a IA é essencial para o futuro da medicina laboratorial?




**Figura 35** - Distribuição das respostas à afirmação "De uma forma geral, acha que a IA é essencial para o futuro da medicina laboratorial".

- A média das respostas foi de 3.94 numa escala de 1 (discordo totalmente) a 5 (concordo totalmente).
- O valor indica uma tendência clara para a concordância.

A maioria dos profissionais considera que a IA desempenhará um papel essencial na evolução futura da medicina laboratorial, reforçando a percepção positiva sobre a sua importância estratégica.

## 6. - Descrição das variáveis sociodemográficas


### 6.1 - Habitualmente está alocado ao laboratório de que polo hospitalar?



**Figura 36** - Distribuição dos profissionais segundo o polo hospitalar onde trabalham habitualmente.

Mais de metade da amostra pertence ao Hospital de São José, o que reflete o seu peso relativo dentro da ULS S. José.

## 6.2 - Há quantos anos trabalha num laboratório de patologia clínica?



**Figura 37** - Distribuição dos profissionais segundo o tempo de experiência em laboratório.

A maioria da amostra apresenta elevada experiência profissional, com quase metade a trabalhar há mais de 20 anos na área.

## 6.3 – Idade

**Tabela 23** - Frequência absoluta, relativa e acumulativa da distribuição etária dos profissionais inquiridos.

	Frequência	Percentagem válida	Percentagem acumulativa
30 - 39 anos	32	27.1	27.1
40 - 49 anos	29	24.6	51.7
50 - 59 anos	32	27.1	78.8
Mais de 60 anos	22	18.6	97.5
Menos de 30 anos	3	2.5	100.0
Total	118	100.0	

A amostra apresenta uma distribuição equilibrada entre faixas etárias dos 30 aos 59 anos, com menor representação de jovens com menos de 30.

## 6.4 – Gênero

Tabela 24 - Distribuição por gênero dos participantes.

	Frequência	Porcentagem
Feminino	96	81.4
Masculino	17	14.4
Prefiro não dizer/Não responde	5	4.2
Total	118	100.0

A maioria dos profissionais é do gênero feminino, refletindo a tendência nacional do setor da saúde e diagnóstico laboratorial.

## 6.5 – Formação

Tabela 25 - Distribuição do nível de formação dos participantes.

	Frequência	Porcentagem
Doutoramento	1	.8
Licenciatura	88	74.6
Mestrado	29	24.6
Total	118	100.0

Todos os profissionais possuem formação superior, destacando-se a licenciatura como grau mais frequente.

## 6.6 - Qual é a sua classe profissional?

Tabela 26 - Distribuição da classe profissional dos participantes.

	Frequência	Porcentagem
Outro	2	1.7
Médico(a)/Patologista Clínico	22	18.6
Técnico Superior de Diagnóstico e Terapêutica em Análises Clínicas	94	79.7
Total	118	100.0

Os técnicos de análises clínicas representam a grande maioria da amostra, seguidos por médicos/patologistas.

## **APÊNDICE E - GUIÃO DE ENTREVISTAS**

### **Perguntas Comuns a todos os *Clusters***

1. Já teve contacto direto com alguma ferramenta de Inteligência Artificial ou automação no laboratório onde trabalha?
2. Que imagem geral tem da IA? Se pudesse descrevê-la com uma metáfora ou palavra, qual seria?
3. Na sua opinião, que benefícios a IA pode trazer para o trabalho laboratorial?
4. E que riscos ou desafios identifica? (ex: segurança, ética, fiabilidade, postos de trabalho).
5. Sente-se confortável com a ideia de trabalhar com ferramentas de IA no seu dia a dia? Porquê?
6. Já sentiu ansiedade ou receio relacionado com a introdução da IA no laboratório?
7. Sente-se motivado(a) para colaborar com esta transição tecnológica?
8. Que tipo de formação ou apoio consideraria útil para se sentir mais confiante e envolvido(a)?
9. Gostaria de ser envolvido(a) nas decisões sobre a introdução da IA na sua organização?
10. Como imagina o seu papel daqui a 5 anos, com a IA mais integrada no laboratório?

### **Perguntas por *Cluster***

#### ***Cluster 1 - Os Reticentes***

Perfil: entrevistados que demonstram pouca motivação, resistência à mudança ou receios difusos.

1. Há algo que o(a) faz hesitar ou ter dúvidas quanto à adoção da IA? O quê?
2. Acha que existe algum preconceito ou visão negativa generalizada sobre a IA entre os colegas? Quais?
3. O receio de perda de postos de trabalho é algo que pesa nas suas preocupações?
4. Considera que o nível de literacia tecnológica influencia essa resistência?
5. Consegue identificar alguma medida concreta que pudesse contribuir para aumentar a sua aceitação? Qual seria?

## **Cluster 2 — Os Entusiastas**

Perfil: os entrevistados demonstram motivação e aceitação à mudança.

1. Relativamente à IA a que atribui a sua confiança? Tem experiência? Teve alguma formação prévia?
2. Considera que a experiência profissional facilita ou dificulta a adaptação à nova tecnologia?
3. Acha que os profissionais mais jovens estão melhor preparados para lidar com estas ferramentas?
4. Estaria disponível para ser embaixador da mudança?

## **Cluster 3 — Os Ambivalentes**

Perfil: profissionais preocupados com o seu futuro, mais sensíveis à estabilidade e ao apoio institucional.

1. A introdução da IA levanta-lhe preocupações relativamente à segurança do seu emprego?
2. Que tipo de garantias gostaria de receber por parte da instituição para se sentir protegido(a)?
3. Que medidas concretas (formação, políticas internas, comunicação) poderiam reforçar os níveis de conforto?
4. Acredita que o seu papel poderá ser valorizado ou diminuído com a introdução da IA? 5. O que consideraria uma transição justa e ética neste processo?

## APÊNDICE F - ANÁLISE INDIVIDUAL POR ENTREVISTADO (MAXQDA)



**Figura 42**– Retrato de documento MAXQDA individual para cada entrevistado.

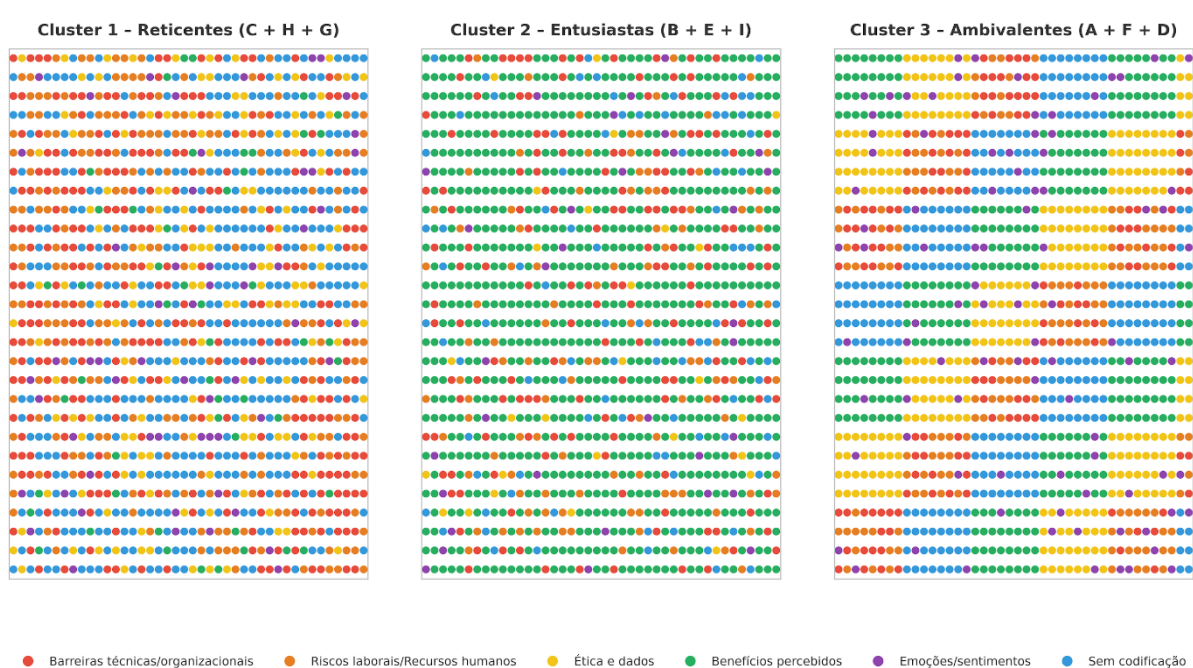
Através da funcionalidade *Retrato de Documento (Document Portrait)* do MAXQDA, foi possível observar a distribuição das principais categorias temáticas codificadas nas entrevistas: benefícios/eficiência (verde), riscos técnicos/infraestrutura (vermelho), riscos

éticos/privacidade (rosa), recursos humanos/impacto laboral (roxo), formação/literacia (amarelo) e liderança/gestão (laranja). Esta representação gráfica permite visualizar não apenas a frequência, mas também o peso relativo que cada dimensão assumiu no discurso dos participantes.

Os retratos evidenciam padrões distintos: em entrevistas como a F, predominam referências a ganhos de eficiência e redução de erros (“Se a máquina consegue evitar que eu repita um erro, é bem-vinda”), enquanto em H destaca-se a preocupação com impacto nos recursos humanos (“Se for tudo automático, o nosso trabalho perde valor”). A entrevista E apresenta forte incidência em riscos éticos e técnicos, refletindo receios relacionados com dados e infraestrutura (“Tenho medo de onde vão parar os nossos dados”). Já a entrevista I revela um equilíbrio entre benefícios, ética e liderança, traduzindo uma visão estratégica (“Se o novo hospital não for IA, já nasce velho”). Em contraste, a entrevista C reflete insegurança perante a falta de contacto prévio, onde os temas de literacia e risco surgem de forma dominante (“Nunca usei, por isso não sei se confio”).

Em síntese, os retratos confirmam a heterogeneidade de perceções: alguns discursos centram-se em ganhos de eficiência, outros em receios éticos ou laborais, enquanto um terceiro grupo conjuga abertura com prudência, enfatizando a importância da formação e da supervisão humana. Estes resultados visuais reforçam a segmentação identificada estatisticamente nos clusters e sublinham a necessidade de estratégias diferenciadas para cada perfil profissional.

## Retrato documental MAXQDA por Cluster



**Figura 43 - Retrato de documento MAXQDA para cada Cluster**

Visualização comparativa das entrevistas codificadas por grupo atitudinal: Cluster 1 – Reticentes (C+H+G), Cluster 2 – Entusiastas (B+E+I) e Cluster 3 – Ambivalentes (A+F+D). Cada cor representa uma categoria de análise (barreiras, riscos laborais, ética e dados, benefícios percebidos, emoções/sentimentos e segmentos não codificados).

Através da funcionalidade *Retrato de Documento* do software MAXQDA, foi possível representar graficamente a distribuição das principais categorias temáticas codificadas nas entrevistas: benefícios e eficiência (verde), riscos técnicos e de infraestrutura (vermelho), riscos éticos e de privacidade (rosa), recursos humanos e impacto laboral (roxo), formação e literacia (amarelo) e liderança e gestão (laranja). Esta visualização permite não apenas identificar a frequência de ocorrência das categorias, mas também o peso relativo que cada uma delas assumiu no discurso dos participantes, proporcionando uma leitura densa da diversidade temática.

Os retratos revelam padrões diferenciados entre entrevistados. Na entrevista F, observa-se uma predominância de referências a ganhos de eficiência e redução de erros, como ilustrado pela afirmação: “*Se a máquina consegue evitar que eu repita um erro, é bem-vinda*”. Já a entrevista H evidencia maior concentração de códigos ligados ao impacto nos recursos humanos, refletindo preocupações laborais (“*Se for tudo automático, o nosso trabalho perde valor*”). A entrevista E apresenta elevada incidência de riscos éticos e técnicos, denotando

receios relacionados com privacidade de dados e infraestrutura tecnológica (“*Tenho medo de onde vão parar os nossos dados*”). Por sua vez, a entrevista I revela um equilíbrio entre benefícios, ética e liderança, traduzindo uma visão estratégica da inovação (“*Se o novo hospital não for IA, já nasce velho*”). Em contraste, a entrevista C demonstra insegurança perante a ausência de contacto prévio com estas tecnologias, concentrando-se sobretudo nas dimensões de literacia e risco (“*Nunca usei, por isso não sei se confio*”).

Em síntese, os retratos temáticos confirmam a heterogeneidade das percepções: alguns discursos privilegiam ganhos de eficiência, outros enfatizam receios éticos ou laborais, enquanto um terceiro grupo evidencia simultaneamente abertura e cautela, sublinhando a necessidade de formação e de supervisão humana. Estes resultados visuais reforçam a segmentação atitudinal identificada na análise estatística dos *clusters* e evidenciam a pertinência de estratégias diferenciadas para cada perfil profissional. Importa ainda salientar que o padrão linear mais visível no *Cluster 3* decorre da concentração sequencial de códigos semelhantes, não devendo ser interpretado como expressão de homogeneidade conceptual.

## **APÊNDICE G - PLANO DE AÇÃO PARA A IMPLEMENTAÇÃO DA IA NO LABORATÓRIO DE PATOLOGIA CLÍNICA**

Este Plano de Ação foi construído com base nos resultados empíricos apresentados nos Capítulos 3 e 4, nomeadamente na identificação dos três perfis atitudinais (Reticentes, Ambivalentes e Entusiastas), nas barreiras e benefícios percecionados, e nos achados da análise bivariada que demonstrou a influência da experiência prévia nas atitudes face à IA. As recomendações aqui apresentadas decorrem diretamente desses dados e visam responder de forma diferenciada às necessidades de cada perfil profissional.

Com base nos resultados empíricos, nos contributos qualitativos e nas orientações internacionais (WHO, 2021; AI Act; PNDS, 2022), delinea-se um plano de ação estruturado em cinco eixos estratégicos, concebido para responder de forma equilibrada às necessidades técnicas, éticas e humanas identificadas.

### **1 Capacitação e formação profissional**

A promoção e implementação destes programas de formação deve ser assumida de forma partilhada por vários agentes institucionais. A direção e gestão do HLO tem a responsabilidade de criar as condições organizacionais e alocar os recursos necessários, integrando a formação em IA nos planos estratégicos de desenvolvimento profissional. Os coordenadores e diretores técnicos e clínicos do Serviço de Patologia Clínica devem liderar a implementação a nível operacional, identificando necessidades específicas e monitorizando a adesão. Reguladores profissionais, nomeadamente a ACSS e/ou a associação dos Técnicos Superiores de Diagnóstico e Terapêutica em Análises Clínicas (APTAC) e a Ordem dos Médicos, têm um papel relevante na acreditação de formações e na definição de competências digitais como requisito de atualização profissional contínua. Finalmente, os profissionais Entusiastas (*Cluster 2*), pela sua familiaridade tecnológica, devem ser mobilizados como formadores internos e embaixadores da mudança, numa lógica de tutoria entre pares que a literatura reconhece como particularmente eficaz na redução de resistências (Holden & Karsh, 2010; Gerlich, 2023).

- Desenvolver programas de literacia digital adaptados aos diferentes perfis atitudinais identificados nos *clusters*.
- Para os Reticentes (*Cluster 1*): formação gradual, com exemplos práticos e foco na explicabilidade da IA, apoiada por sessões de escuta ativa que permitam esclarecer dúvidas e reduzir inseguranças.
- Para os Ambivalentes (*Cluster 3*): programas aplicados e orientados para *quick wins*, evidenciando benefícios tangíveis (redução de erros, maior eficiência).

- Para os Entusiastas (*Cluster 2*): formação avançada e papel ativo como “embaixadores da mudança”, promovendo tutoria entre pares e apoiando os colegas mais resistentes.
- Integrar dimensões emocionais e culturais na formação, reconhecendo que a aceitação da tecnologia depende também de confiança, segurança e valorização do papel humano.

## **2 Infraestrutura tecnológica e interoperabilidade**

- Avaliar a maturidade dos sistemas atuais e planejar uma integração faseada de soluções baseadas em IA, assegurando a compatibilidade com os LIS.
- Reforçar medidas de cibersegurança e conformidade com o RGPD e o *AI Act*, assegurando que a proteção de dados é garantida e comunicada de forma transparente.
- Implementar soluções interoperáveis que evitem redundâncias e assegurem a integração entre plataformas antigas e novos módulos baseados em IA.

## **3 Ética, governança e supervisão institucional**

- Criar um Comité de Ética e Inovação Tecnológica, multidisciplinar, que inclua representantes dos três *clusters*, gestores, especialistas em TI e peritos em bioética.
- Estabelecer um Código de Conduta que contemple princípios de transparência, explicabilidade, supervisão humana significativa e não-discriminação.
- Implementar auditorias regulares e práticas de IA explicável (*explainable AI*), mitigando o ceticismo detetado em relação à proteção de dados e aumentando a confiança institucional.

## **4 Comunicação interna e gestão da mudança**

- Desenvolver campanhas de comunicação claras e acessíveis sobre o papel da IA, utilizando linguagem simples e suportes visuais (infográficos, vídeos, manuais).
- Promover sessões de escuta ativa e workshops de discussão ética e prática, valorizando a participação dos profissionais em todas as fases do processo.
- Comunicar benefícios tangíveis e *quick wins* (como a diminuição do tempo de resposta ou a redução de erros), reforçando a perceção de utilidade real da tecnologia.
- Utilizar os Entusiastas como facilitadores e embaixadores da mudança, apoiando os Reticentes e Ambivalentes.

## 5 Monitorização contínua e avaliação dinâmica

- Implementar mecanismos de auscultação regulares (inquéritos periódicos, grupos focais, entrevistas), avaliando a evolução das perceções e identificando resistências emergentes.
- Definir indicadores de desempenho claros (tempo médio de resposta, taxa de erros, satisfação profissional e confiança percebida) que permitam medir objetivamente o impacto da IA.
- Reajustar continuamente as estratégias com base nos dados recolhidos, assegurando uma abordagem dinâmica, participativa e *data-driven*.

Estes eixos, sintetizados na tabela 25, configuram um quadro operativo orientador para uma transição digital eticamente responsável, sustentável e ajustada às especificidades organizacionais e humanas do contexto estudado.

Em síntese, a implementação da IA no novo Laboratório de Patologia Clínica do HLO deve assentar numa articulação entre inovação tecnológica e valorização do capital humano. O plano de ação aqui proposto integra medidas dirigidas à capacitação, infraestrutura, ética, comunicação e monitorização contínua, procurando assegurar que a transição digital seja inclusiva, ética e sustentável. O desafio central não reside apenas na aquisição de novas máquinas ou algoritmos, mas em garantir que os profissionais independentemente do *cluster* a que pertencem se sintam preparados, seguros e valorizados neste processo de transformação.

**Tabela 51 - Síntese dos eixos estratégicos para a implementação da IA no Laboratório de Patologia Clínica**

<b>Eixo de Ação</b>	<b>Principais Recomendações</b>	<b>Clusters prioritários</b>
<b>Capacitação e formação profissional</b>	- Programas modulares de literacia digital (básico, intermédio, avançado) - Formação gradual com exemplos práticos e foco na explicabilidade - Tutoria entre pares: Entusiastas como embaixadores da mudança - Integração de dimensões emocionais e culturais na aprendizagem	<i>Cluster 1</i> (Reticentes): literacia gradual, escuta ativa <i>Cluster 3</i> (Ambivalentes): <i>quick wins</i> e evidência aplicada <i>Cluster 2</i> (Entusiastas): formação avançada e papel de formadores
<b>Infraestrutura tecnológica e interoperabilidade</b>	- Avaliação da maturidade tecnológica dos sistemas atuais - Integração faseada de IA com LIS interoperáveis - Elevados padrões de cibersegurança (RGPD, AI Act) - Garantir compatibilidade entre plataformas antigas e novas	Todos os <i>clusters</i> (foco em gestores e liderança técnica)
<b>Ética, governança e supervisão institucional</b>	- Criação de Comité de Ética e Inovação Tecnológica multidisciplinar - Elaboração de Código de Conduta sobre IA em saúde - Inclusão de representantes dos três clusters no planeamento - Auditorias regulares e implementação de IA explicável (XAI)	Todos os <i>clusters</i> , com atenção à representatividade equitativa
<b>Comunicação interna e gestão da mudança</b>	- Estratégia de comunicação clara e acessível (infográficos, vídeos, manuais) - Sessões de escuta ativa e workshops de debate ético e prático - Valorização de <i>quick wins</i> (redução de erros, rapidez nos resultados) - Uso de Entusiastas como facilitadores internos	<i>Cluster 1</i> (Reticentes): foco em transparência e confiança <i>Cluster 3</i> (Ambivalentes): foco em evidências práticas
<b>Monitorização contínua e avaliação dinâmica</b>	- Inquéritos periódicos e grupos focais de acompanhamento - Indicadores de desempenho claros (tempo de resposta, taxa de erros, satisfação profissional, confiança percebida) - Ajuste dinâmico e <i>data-driven</i> das estratégias	Todos os <i>clusters</i> , com atenção especial às resistências emergentes

(elaboração própria)