



INSTITUTO
UNIVERSITÁRIO
DE LISBOA

Inteligência Artificial na Gestão de Recursos Humanos: O Impacto do *People Analytics* na Retenção de Talento

Mariana de Sousa Ramos dos Santos Silva

Mestrado em Gestão,

Orientadores:

Professor Doutor Renato Lopes da Costa, Professor Auxiliar,
ISCTE- Instituto Universitário de Lisboa

Professor Doutor Rui Gonçalves, Professor Convidado,
ISCTE- Instituto Universitário de Lisboa

Outubro, 2022

Departamento de Marketing, Operações e Gestão Geral

Inteligência Artificial na Gestão de Recursos Humanos: O Impacto do *People Analytics* na Retenção de Talento

Mariana de Sousa Ramos dos Santos Silva

Mestrado em Gestão,

Orientadores:

Professor Doutor Renato Lopes da Costa, Professor Auxiliar,
ISCTE- Instituto Universitário de Lisboa

Professor Doutor Rui Gonçalves, Professor Convidado,
ISCTE- Instituto Universitário de Lisboa

Outubro, 2022

Agradecimentos

Criar e desenvolver a presente dissertação foi desafiante, mas gratificante. Concluí-la marca o fim de uma etapa bastante importante que só foi possível pela inspiração e motivação a quem eu deixo o meu profundo agradecimento.

Aos meus orientadores, Professor Doutor Renato Lopes da Costa e Professor Doutor Rui Gonçalves, pela sua orientação e apoio em todo o processo de desenvolvimento.

À minha mãe, por ser o meu porto de abrigo, quem me inspira com todo o seu amor e bondade, por sempre acreditar em mim.

Ao meu pai, por ser o melhor parceiro e amigo neste longo percurso, pelo seu apoio, disponibilidade e inspiração.

À minha irmã, a minha grande fonte de inspiração e admiração, que sempre me potencia a ser mais e melhor.

À minha avó Maria, por sempre me inspirar com a sua fé, amor e resiliência.

Ao Pablo, o meu melhor amigo e apoio incondicional, por toda a sua compreensão e tranquilidade.

Ao Diniz, que mesmo já não estando presente sei, como sempre, estará orgulhoso e a meu lado.

Aos meus amigos, por sempre estarem presentes com toda a motivação, energia e alegria.

A todas as pessoas que participaram no presente estudo e que me ajudaram não só na participação no inquérito como também na partilha de ideias e conhecimentos ao longo do desenvolvimento da dissertação.

A todos, um sentido e profundo obrigada.

Resumo

As pessoas são cada vez mais percebidas como um dos fatores mais importantes para as organizações serem competitivas, como tal alinhar a Gestão de Recursos Humanos aos objetivos estratégicos é fundamental. No entanto, existem diversos desafios complexos a compreender e estudar para que a gestão consiga responder em tempo útil às necessidades das pessoas e organização. Através desta necessidade surgiu o *People Analytics*, que integra Inteligência Artificial na Gestão de Recursos Humanos. Assim, a presente investigação pretende analisar o impacto do *People Analytics* nas organizações, bem como a compreensão do seu impacto na identificação e retenção de talento, desafio urgente a ser compreendido e solucionado.

Para tal, foram desenvolvidos dois modelos conceituais para cada uma das questões de pesquisa. A primeira tem como objetivo identificar quais os fatores que mais influenciam a possibilidade de implementar *People Analytics* na GRH e consequentemente o seu impacto. A segunda com a possibilidade de identificar e reter talento através da implementação de *People Analytics*. O estudo compreendeu a integração da revisão da literatura existente sobre os temas, com a análise estatística de 106 respostas a um inquérito direcionado. Os resultados obtidos demonstram que os benefícios e a perceção dos utilizadores têm uma influência significativamente positiva na possibilidade de implementar *People Analytics* na GRH, bem como na identificação e retenção de talento.

Palavras-Chave: Gestão de Recursos Humanos; *People Analytics*; Inteligência Artificial; Retenção de Talento

Classificação JEL:

- **M50** *General*
- **O32** *Management of Technological Innovation and R&D*

Abstract

People are increasingly perceived as one of the most vital factors for organisations to be competitive, so aligning Human Resources Management (HRM) with strategic objectives is fundamental. Nevertheless, there are several complex challenges yet to understand and study so that management can answer in a timely manner to the needs of both people and the organisation. Bearing this in mind, People Analytics emerged as an alliance between Artificial Intelligence and HRM. However, the understanding of its impact on talent identification and retention remains an urgent challenge to be understood and solved. Thus, this research aims to analyse the impact of People Analytics in organisations as well as the ability to identify and promote talent retention.

To this end, two conceptual models were developed for each of the research questions. The first aims to identify which factors can influence the most People Analytics implementation in HRM and consequently its impact, while the second with the possibility of identifying and retaining talent. The study comprised a literature review on the topics, with statistical analysis of 106 responses to a targeted survey. The results obtained show that the benefits and the perception of users have a significantly positive influence on the possibility of implementing People Analytics in HRM, as well as on talent identification and retention.

Keywords: Human Resources Management; People Analytics; Artificial Intelligence; Talent Retention

JEL Classification:

- **M50** General
- **O32** Management of Technological Innovation and R&D

ÍNDICE

CAPÍTULO I - INTRODUÇÃO.....	1
1.1 Enquadramento	1
1.2 Problemática de Investigação	2
1.3 Objetivo de Investigação	4
1.4 Estrutura da Tese.....	4
CAPÍTULO II - REVISÃO DA LITERATURA	6
2.1 Inteligência Artificial.....	6
2.1.1. <i>Machine Learning</i>	9
2.1.2. <i>Deep Learning e Artificial Neural Network</i>	11
2.1.3. <i>Big Data</i>	12
2.1.4 <i>Data Mining</i>	13
2.2 Gestão de Recursos Humanos.....	14
2.2.1 Definição de Talento.....	14
2.2.2 Gestão de Talento	15
2.2.3 Retenção de Talento.....	17
2.3 Inteligência Artificial na Gestão de Recursos Humanos	19
2.3.1 História do <i>People Analytics</i>	20
2.3.2 Impacto do <i>People Analytics</i> no negócio e nas Organizações.....	22
2.3.3 <i>People Analytics</i> e a Gestão de Dados	24
2.3.4 Modelo de <i>People Analytics</i>	27
2.3.5 <i>People Analytics</i> na Retenção de Talento	30
2.4 Limitações da Inteligência Artificial na Retenção de Talento	31
CAPÍTULO III - ABORDAGEM TEÓRICA.....	33
3.1 Objetivos e Questões de Pesquisa	33
CAPÍTULO IV - METODOLOGIA	36
4.2 Modelo de Investigação	37
4.3 Inquérito	44
4.4 Descrição da Amostra.....	45
CAPÍTULO V - APRESENTAÇÃO E DISCUSSÃO DE RESULTADOS.....	46
5.1 QP1- Qual a possibilidade de implementar <i>People Analytics</i> na GRH?	46
5.1.1 Análise Estatística.....	46
5.1.2 Resultados Quantitativos	47
5.1.3 Discussão de Resultados	48
5.2 QP2- Qual a possibilidade de identificar e reter talento através da implementação de <i>People Analytics</i> na GRH?	51

5.2.1 Análise Estatística	51
5.2.2 Resultados Quantitativos	53
5.2.3. Discussão de Resultados	54
CAPÍTULO VI - CONCLUSÃO	56
6.1 Considerações Finais	56
6.2 Contribuição para a gestão empresarial.....	59
6.3 Limitações do Estudo.....	60
6.4 Sugestões para futuras investigações	60
BIBLIOGRAFIA.....	61

Índice de Figuras

Figura 2.1 - Informação para o processo de tomada de decisão	21
Figura 2.2 - Processo de gestão de dados e tomada de decisão com People Analytics	26
Figura 2.3 - Modelo Insight222: Nove dimensões para a excelência no People Analytics	28
Figura 4.1 - Design do modelo de pesquisa	37
Figura 4.2 - Modelo concetual de Q1 e hipóteses a testar com o SmartPLS 3	40
Figura 4.3- Modelo concetual de Q2 e hipóteses a testar com o SmartPLS 3	42

Índice de Tabelas

Tabela 3.1 - Relação entre OE, QP e RL	35
Tabela 4.1 - Relações entre variáveis do modelo concetual Q1 e as perguntas do inquérito ..	41
Tabela 4.2 - Relações entre variáveis do modelo concetual Q2 e as perguntas do inquérito ..	43
Tabela 4.3 - Caracterização sociodemográfica da amostra.....	45
Tabela 5.1 - Verificações de CR, AVE, correlações e validade discriminante de Q1	46
Tabela 5.2 - Avaliação do modelo estrutural de Q1	48
Tabela 5.3 - Resultados do Bootstrap para os efeitos indiretos dos constructos de Q1.....	48
Tabela 5.4 - Verificações de CR, AVE, correlações e validade discriminante de Q2	52
Tabela 5.5 - Avaliação do modelo estrutural Q2	53

Lista de Abreviaturas

AGI- *Artificial General Intelligence*

ANI- *Artificial Narrow Intelligence*

ASI- *Artificial Super Intelligence*

AVE- *Average Variance Extracted*

CR- *Composite Reliability*

DP- *Deep Learning*

EC- Experiência do Colaborador

EU- União Europeia

GERH- Gestão Estratégica de Recursos Humanos

GPS- *General Problem Solver*

GRH- Gestão de Recursos Humanos

GTRH- Gestão Tradicional de Recursos Humanos

H- Hipótese

HTMT- *Heterotrait-Monotrait ratio*

IA- Inteligência Artificial

ML- *Machine Learning*

OE- Objetivo do Estudo

PA- *People Analytics*

PLS- *Partial Least Squares*

QP- Questão de Pesquisa

RAA- *Rational Agent Approach*

RBV- *Resource-Based View*

RGPD- Regulamento Geral de Proteção de Dados da União Europeia

RH- Recursos Humanos

RL- Revisão da Literatura

ROI- *Return on Investment*

RT– Retenção de Talento

SEM- *Structural Equations Model*

TI- Tecnologias de Informação

VIF- *Variance Inflation Factor*

CAPÍTULO I - INTRODUÇÃO

1.1 Enquadramento

A globalização, o desenvolvimento tecnológico e as cíclicas crises económicas vividas em várias geografias, transportam as organizações para novos desafios, exponenciando a competitividade e a necessidade de atração e retenção de talento (RT). Este novo paradigma potenciou a alteração das práticas laborais para mais estratégicas, centradas na satisfação e desenvolvimento dos colaboradores permitindo responder às necessidades de desenvolvimento tecnológico-digital, onde a inovação e o dinamismo imperam, sendo estratégico a atração e retenção contínua de talentos (Inamdar, 2021).

A Inteligência Artificial (IA) é composta por inúmeras ramificações que auxiliam a gestão de diversificadas funções empresariais, através da análise, tratamento e gestão de dados facilitando a identificação e deteção de melhorias (Lokanan, Tran, & Vuong, 2019). Para determinar o papel da IA, ao nível das operações têm sido realizados diversos estudos das funções empresariais, ao nível da gestão, marketing, logística e recursos humanos, permitindo com os dados recolhidos melhorar a eficácia na tomada de decisão devido ao aumento da eficiência e precisão que permitem. No entanto, em comparação com outras áreas da gestão, a IA e *Big Data* na gestão de recursos humanos tem sido subutilizada na prática e a menos investigada, representando apenas 2% dos estudos no campo da gestão (Gonçalves et al., 2021; Sheng, Amankwah-Amoah, & Wang, 2017). Este acontecimento é explicado pela perceção que as organizações possuíam da gestão das suas pessoas, sendo inicialmente encarada como uma área administrativa, tendo-se modificado ao longo do tempo para uma área cada vez mais estratégica (Ferrar & Green, 2021).

A análise que leva à construção dos dados observa parâmetros qualitativos e quantitativos, existindo a possibilidade de desmistificar que a aplicação da IA na área de recursos humanos, não é identificada como um desperdício de recursos, mas sim uma área estratégica essencial para a vantagem competitiva das organizações (Charan, Barton, & Carey, 2018; Isson & Harriott, 2016; Shrivastava, Nagdev, & Rajesh, 2018). A alteração do paradigma da gestão tradicional de Recursos Humanos (GTRH) para a atual gestão estratégica, tem proporcionado aos gestores de recursos humanos (RH) a possibilidade de criar conhecimentos através da gestão estratégica de dados (Lawler III, Levenson, & Boudreau, 2004).

Existem cada vez mais estudos por parte da comunidade científica sobre a importância da retenção de talento, no entanto existem poucas evidências práticas nas organizações de que

estão a ser implementadas políticas eficazes na sua gestão, devido às elevadas taxas de rotatividade nas empresas (Alshehhi, Zawbaa, Abonamah, & Tariq, 2021). As organizações devem, assim, alinhar as suas estratégias de negócio com as estratégias de recursos humanos, numa perspetiva preventiva para que não sejam desperdiçados talentos.

Surgiu, através desta necessidade, a partir do *Business Intelligence* e do *Big Data* a área de *People Analytics* (PA), utilizada pelos gestores de RH para identificar e quantificar a influência dos fatores humanos nas organizações (Inamdar, 2021; Isson & Harriott, 2016) através de análises descritivas, preditivas e prescritivas de dados (Likhitar & Verma, 2020). Esta ferramenta possibilita a conversão de dados numa linguagem inteligível, através da produção de tendências, definição de estratégias e identificação das áreas que carecem de mudança, apoiando na tomada de decisão (Angrave, Charlwood, Kirkpatrick, Lawrence, & Stuart, 2016; Gupta, Leszkiewicz, Kumar, Bijmolt, & Potapov, 2020). O *People Analytics* é um aliado dos gestores de RH, na medida que contribui para melhorar os processos de atração e retenção de talento, com resultados positivos ao nível da motivação e da produtividade dos colaboradores (Yahia, Hlel, & Colomo-Palacios, 2021).

O objetivo do presente estudo pretende analisar os fatores mais significativos na possibilidade de desenvolver e implementar *People Analytics* nas organizações. Para tal, é analisada a perceção dos utilizadores, os benefícios e as limitações inerentes à implementação de *People Analytics* na Gestão de Recursos Humanos (GRH) e o seu impacto para as pessoas e organizações. Consequentemente, a presente investigação pretende também analisar o impacto da utilização de *People Analytics* na retenção de talento, avaliando os seus possíveis benefícios e limitações.

1.2 Problemática de Investigação

Existe uma discrepância entre os benefícios percecionados e verificados em relação à implementação de *People Analytics* face aos baixos níveis da sua implementação nas organizações (Stubbing, Sethi, & Brown, 2018).

O tema de investigação “Inteligência Artificial na Gestão de Recursos Humanos: O Impacto do *People Analytics* na Retenção de Talento”, pretende analisar a possibilidade de implementar *People Analytics* na GRH, bem como analisar a possibilidade de identificar e reter talento através da implementação de *People Analytics*. Com o objetivo de perceber a utilidade do *People Analytics* na gestão estratégica de recursos humanos, este estudo é relevante pela importância dos estudos científicos sobre a IA na GRH e na compreensão do seu impacto na

identificação e retenção de talento, problema urgente a ser percebido, compreendido e solucionado nas organizações.

Assim, o presente estudo pretende avaliar numa fase preliminar quais os benefícios, limitações e percepção dos colaboradores na implementação de *People Analytics* na GRH, com o objetivo de concluir quais os parâmetros e as sinergias que mais influenciam a necessidade de tornar a área de RH num parceiro estratégico nas organizações. Numa segunda fase, o objetivo do estudo é analisar a possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH, considerando benefícios e limitações na sua utilização.

Existem diversas possíveis razões apontadas nos estudos científicos que influenciam a possível implementação de *People Analytics* na GRH por parte das organizações (Davenport, Harris, & Shapiro, 2010; Ferrar & Green, 2021; Rasmussen & Ulrich, 2015). É imperativo refletir e investigar as respostas às questões: Quais as razões pelas quais algumas organizações ainda não utilizam de forma eficiente os dados sobre os seus colaboradores, para análises integradas e em tempo real? Porque é que o *People Analytics* ainda é uma prática rara na área de recursos humanos? Com a finalidade de tornar a área de recursos humanos num parceiro estratégico, existem diversos fatores que afetam essa mudança.

Os autores Ferrar e Green (2021), criaram o modelo *Insight222 Nine Dimensions for Excellence in People Analytics*. Este modelo, que se baseia nas diferentes dimensões, coopera para uma análise focada dos RH, permitindo às organizações identificar o caminho e os objetivos a perseguir com resultados que tenham impacto e criem valor. Os autores pretendem, através da gestão de dados da força de trabalho, valorizar as pessoas e as organizações. A compreensão das dimensões do *People Analytics*, permitirá que as organizações identifiquem os objetivos e assim adaptem os planos estratégicos para a mudança.

Apesar da existência de *People Analytics* ser já uma realidade para algumas empresas, o conhecimento, o desenvolvimento e os efeitos na área de RH, são ainda escassos na literatura disponível. Para o *People Analytics* tornar-se uma mais-valia para as empresas é necessário que seja alvo de análise empresarial como um todo (Rasmussen & Ulrich, 2015).

Do ponto de vista prático, este estudo poderá ajudar os profissionais e as empresas que estão a considerar adotar *People Analytics*, a potenciar o seu conhecimento, através da avaliação prévia dos possíveis benefícios e limitações em relação à sua capacidade no cumprimento dos requisitos necessários para o efeito.

1.3 Objetivo de Investigação

As políticas e práticas de RH têm efeitos nas organizações que afetam a gestão de talento. A título destes destacam-se o clima e a cultura organizacional, bem como a visão e a missão das organizações. As estratégias implementadas pelas organizações sofrem a influencia destes e outros fatores intrínsecos que impactam a motivação, os valores, o propósito e todo o ambiente das relações laborais.

São gerados cada vez mais dados nas organizações, no entanto geri-los eficientemente é a chave para o sucesso de todas as áreas sem exceção. Associar IA com a área de RH irá permitir adaptar as decisões estratégicas com as necessidades dos colaboradores e das organizações (Shrivastava *et al.*, 2018; Tamizharasi & Rani, 2014) através da análise integrada de diversas fontes (Ferrar & Green, 2021; Isson & Harriott, 2016). A saída de colaboradores das organizações é um processo impactante por diversas razões, desde os custos elevados, tempo desperdiçado e investimento em processos de recrutamento e seleção, à perda de *know-how* estratégico para a concorrência (Alshehhi *et al.*, 2021).

Assim, o objetivo do presente estudo é investigar o impacto da IA na GRH e consequentemente na identificação e retenção de talento nas organizações, analisando os fatores positivos e negativos bem como os seus principais efeitos práticos que influenciam a implementação do *People Analytics* nas organizações.

Com o objetivo de responder às perguntas desta investigação, foi utilizada uma metodologia quantitativa através de um inquérito a profissionais de recursos humanos, gestores de equipas, investigadores académicos e gestores especialista em *People Analytics*.

1.4 Estrutura da Tese

A presente dissertação é composta pela seguinte estrutura: No capítulo I, é apresentada a introdução, onde está exposto o enquadramento da dissertação, bem como a problemática de investigação e os objetivos que motivaram ao desenvolvimento da mesma. No capítulo II consta a revisão de literatura, sobre a Inteligência Artificial, Gestão de Recursos Humanos, Retenção de Talento e *People Analytics*, onde são apresentados os principais conceitos e autores das áreas, são abordados as principais vantagens e desvantagens e a interligação dos tópicos em estudo. No capítulo III é definida a abordagem teórica, com os objetivos do estudo, as questões de pesquisa e as respetivas hipóteses, resultado da anterior revisão da literatura.

O capítulo IV trata da metodologia, onde também é abordado o modelo de investigação, os modelos conceituais para cada questão de pesquisa, as hipóteses correspondentes a cada modelo, a relação entre cada pergunta do inquérito e cada indicador, bem como o seu conteúdo e a descrição da amostra. O capítulo V mostra como é realizada a apresentação e discussão de resultados, através da análise estatística dos resultados do inquérito em linha com a confirmação das hipóteses dos modelos conceituais, permitindo responder às questões de investigação através de uma discussão integrada da teoria e dos resultados obtidos. Por último, o capítulo VI, reúne as principais conclusões da presente investigação em conjunto com as contribuições para a gestão empresarial, limitações do estudo e as sugestões para futuras investigações.

CAPÍTULO II - REVISÃO DA LITERATURA

2.1 Inteligência Artificial

Na literatura, existem diversas investigações relacionadas com o estudo da inteligência humana e os seus processos cognitivos associados, bem como sobre a construção de sistemas inteligentes, sendo exemplo disso a Inteligência Artificial (IA). A inteligência humana é estimulada pelos cinco sentidos e processada pelo cérebro, a Inteligência Artificial, por outro lado, auxilia a capacidade humana na agregação e processamento para posterior tratamento de dados e processos rotineiros permitindo uma gestão mais eficiente dos mesmos. Não existe na literatura apenas uma linha de investigação sobre o tema, no entanto este centra-se nas 4 principais componentes-chave da inteligência humana, a aprendizagem, o raciocínio, a resolução de problemas e a percepção (Simon, 2019). Possibilitando assim, treinar máquinas com pensamento cognitivo, sendo, no entanto, necessário a intervenção humana para a sua implementação. Torna-se, primordial interligar inteligência emocional com inteligência artificial (Yellapantula & Ayachit, 2019).

Russel & Norving (2021) definem os sistemas de IA segundo quatro dimensões, ao nível do pensamento e ação humana bem como no pensamento e ação racional. Em relação ao comportamento humano (*Acting Humanly*), os autores inserem nesta dimensão os estudos de Turing. Com o objetivo de encontrar uma definição operacional sobre a inteligência, Turing (1950), colocou a seguinte questão *can machines think?* para obter uma resposta fundamentada desenvolveu um teste hipotético com o objetivo de avaliar a inteligência de uma máquina em relação à inteligência do ser humano. Este teste foi apelidado de *Turing Test* (Turing, 1950).

O autor definiu como comportamento inteligente, a capacidade de a máquina alcançar o comportamento humano em todas as tarefas cognitivas, para tal acontecer esta tinha que possuir um comportamento impercetível face ao humano. O teste seria então considerado bem-sucedido se o computador conseguisse induzir em erro o interrogador, sendo este incapaz de diferenciar as respostas provenientes da máquina e do humano. Concluindo, assim, que a máquina continha inteligência. Para o computador estar habilitado este necessitava de possuir determinadas capacidades, tais como: (1) *natural language processing* para conseguir comunicar na linguagem humana; (2) representação do conhecimento, para armazenar a informação fornecida antes e durante o interrogatório; (3) *automated reasoning*, para utilizar a informação armazenada de modo a conseguir responder às perguntas e desenhar novas conclusões; (4)

machine learning, para se adaptar a novas circunstâncias, bem como na detecção de padrões (Russel & Norving, 2021).

A categoria correspondente ao pensamento humano (*Thinking Humanly*), é baseada na ciência cognitiva. Esta tem um impacto imprescindível na determinação dos fatores que ajudam a compreender a mente humana, pois se as máquinas são programadas com o pensamento humano, este tem que ser profundamente compreendido através de parâmetros ao nível da introspeção (análise de pensamentos) e experiências psicológicas (observação das ações humanas). Assim é possível programar máquinas baseadas no pensamento humano. É exemplo disso, o GPS (General Problem Solver) os criado para a correta resolução de problemas, como também na compreensão dos diversos raciocínios possíveis (Newell & Simon, 1961).

Por sua vez, a categoria do pensamento racional (*Thinking Rationally*), baseada na abordagem das leis do pensamento, derivaram do estudo de grandes filósofos como Aristóteles, com o objetivo de codificar os processos de raciocínio lógico tendo por base a razão. Foram assim, desenvolvidas ao longo do tempo, teorias sobre a lógica do ponto de vista aritmético bem como, a classificação e relação entre diversos objetos. A criação de sistemas inteligentes, baseiam-se assim na fundamentação lógica dentro da IA. No entanto, existem alguns pontos menos favoráveis como a dificuldade em transpor o conhecimento informal nos termos formais exigidos pela lógica, bem como na passagem da resolução teórica para a prática (Russel & Norving, 2021).

Por último, a quarta categoria referente à ação racional (*Acting Rationally*), tem por base a *Rational Agent Approach* (RAA). Os autores consideram que um agente racional, atua de forma a atingir o melhor resultado ou o resultado esperado. Para que um agente seja eficaz este tem que operar autonomamente, perceber o ambiente e adaptar-se à mudança, bem como, delinear e atingir os objetivos expectáveis. Contrariamente à abordagem anterior do pensamento racional, a presente abordagem baseia-se não somente em deduções corretas (premissas corretas que originam uma conclusão lógica acertada) como também em formas de agir que podem não ser corretas, mas necessárias numa determinada situação, bem como, formas de operar racionalmente sem envolver dedução, como são exemplo as ações ato-reflexo. Esta abordagem, em relação às do pensamento e comportamento humano é mais flexível e favorável ao desenvolvimento científico (Russel & Norving, 2021).

O conceito de Inteligência Artificial foi conotado pela primeira vez na conferência de Dartmouth, em 1956, por John McCarthy (Jones, 2009). Ao longo dos anos o desenvolvimento tecnológico tem tido um crescimento exponencial. Existe na literatura diversas definições sobre IA não sendo consensual na comunidade científica, facto que permitiu ao longo do tempo um

constante processo evolutivo até ao que conhecemos hoje. Segundo Mccarthy (2004), a IA pode ser definida como a ciência e a engenharia de construir máquinas e programas informáticos inteligentes, em que são utilizados computadores para compreender a inteligência humana, não sendo a IA limitada apenas a métodos biológicos observáveis (Mccarthy, 2004). A IA baseia-se no entendimento da inteligência humana, ao nível das mais diversas capacidades cognitivas do ser humano, são exemplos, a percepção, raciocínio, aprendizagem, comunicação e ação em ambientes complexos (Nilsson, 1998). Um dos objetivos a longo prazo da IA passa pelo desenvolvimento das máquinas ao nível da inteligência humana ou até mesmo superá-la.

Na perspetiva de Russel & Norving (2021), a IA é o estudo que desenha e constrói agentes inteligentes, em que o agente percebe o ambiente através de sensores, atuando no ambiente através de agentes. Um agente inteligente tem em consideração a melhor ação numa determinada situação, selecionando a que melhor maximizará aquela determinada medida para a tomada de decisão. A IA pode ser dividida em dois tipos, a fraca e a forte. A IA fraca, também denominada por *Artificial Narrow Intelligence* (ANI), é programada para realizar tarefas específicas sendo relacionada maioritariamente com a IA que nos rodeia no quotidiano (IBM, 2020).

A fraca IA define que as máquinas podem simular o pensamento e atuar como inteligentes (Russel & Norving, 2021), não pretendendo imitar o cérebro humano (Amini, Chen, Cox, Oliva, & Torralba, 2020). Esta IA é programada para seguir a lógica do pensamento humano com o objetivo de realizar o tratamento estatístico de grande quantidade de dados (Eriksson, Bigi, & Bonera, 2020). Com impacto ao nível da tomada de decisão, a IA fraca, ainda que não seja uma IA robusta, consegue suportar a tomada de decisão quando a questão a abordar é de natureza racional, podendo fornecer previsões e propor diferentes cenários possíveis. Para o tipo de tomada de decisão supracitado, pode também ser possível automatizar totalmente a decisão final (Jarrahi, 2018). Este tipo de IA é caracterizado pelas seguintes aplicações, a Siri da Apple, a Alexa da Amazon, os automóveis autónomos e o IBM's Watson. O último exemplo é uma plataforma de IA que combina *machine Learning* (ML) e *natural language processing* (Jarrahi, 2018).

Em contraste a IA forte sugere que as máquinas têm consciência e estão habilitadas a conseguir pensar (Russel & Norving, 2021), no entanto ainda não existe na prática (Paschen, Kietzmann, & Kietzmann, 2019). Esta é composta por *Artificial General Intelligence* (AGI) e *Artificial Super Intelligence* (ASI). A AGI corresponde à constatação teórica de que a IA de uma máquina teria uma inteligência igual à dos seres humanos, com capacidade de planear,

aprender e resolver problemas. A ASI refere-se à superação da inteligência e capacidade do cérebro humano por parte da máquina (IBM, 2020).

2.1.1. *Machine Learning*

A IA não é um produto, uma aplicação ou um sistema operativo. Não existe um *software* específico de IA mas sim soluções de IA que se baseiam na combinação de *software* e *hardware* que cria diversos *softwares* (Amini *et al.*, 2020). Classificada como sendo uma área que interliga processos de inteligência complexos, a IA é composta por diversas subáreas essenciais na resolução de problemas com diferentes tipos de aplicações, ao nível da automatização de processos e no auxílio da tomada de decisão. A *machine learning* é um subcampo da IA enquanto a *deep learning* é um subcampo da *machine learning*, as redes neuronais artificiais (*artificial neural network*) por sua vez, constituem a estrutura dos algoritmos de *deep learning* (Kavlakoglu, 2020).

Com o avanço tecnológico a gestão de dados tem vindo a sofrer grandes alterações, ao nível do armazenamento e processamento, alterando a quantidade de dados a gerir, bem como, a sua gestão. A produção avultada de dados é realizada a partir de diversos dispositivos, como computadores, telemóveis, métodos de pagamento, bem como, aparelhos eletrónicos existentes nos carros e casas, sendo essa informação transmitida a milhares de centros de dados que a armazenam, analisam e verificam continuamente (Faroukhi, El Alaoui, Gahi, & Amine, 2020). O crescimento da importância *Big Data*, proporcionou o aumento da utilização de *machine learning* e algoritmos, permitindo uma análise e compreensão mais profunda sobre os dados facilitando a deteção de anomalias (Lokanan *et al.*, 2019).

Machine learning é um ramo da IA que possibilita um sistema aprender a partir de dados sem serem explicitamente programados (Samuel, 1959) o termo foi desenvolvido pelo autor através da sua investigação pioneira usando um jogo de xadrez. Relacionada com o desenvolvimento de algoritmos e métodos de aprendizagem, esta tem como base a inteligência humana, melhorando gradualmente a sua precisão (Shi & Zheng, 2006). Um algoritmo é um conjunto de instruções explícitas que um computador executa, capaz de aprender a partir dos próprios dados (Jakhar & Kaur, 2018). Existem diversos algoritmos que são adaptados aos diferentes tipos de *machine learning* sendo adequados conforme o tipo de problema. São exemplos, as árvores de decisão caracterizadas pela sua transparência na compreensão do raciocínio seguido pela máquina, oposta à abordagem das redes neuronais que produzem uma

resposta sendo difícil a visualização do raciocínio (Segaran, 2007). São assim utilizados algoritmos para colmatar erros e maximizar a eficiência das previsões (Jakhar & Kaur, 2019).

Assim, a ML, pretende treinar máquinas através de dados e algoritmos, aprendendo com a experiência e encontrando padrões sobre a análise das propriedades de um conjunto de dados. Os padrões existem em número substancial nos dados não aleatórios, sendo utilizados posteriormente para realizar previsões sobre diversas bases de dados (Segaran, 2007), automatizando a construção de modelos analíticos (Missy, Cummings, & Stimpson, 2019). Pois a *machine learning* ao ser dinâmica tem a capacidade de se modificar e moldar quando inseridos novos dados (Jakhar & Kaur, 2018). Em suma, a *machine learning* auxilia os seus utilizadores a gerir as bases de dados melhorando os modelos estatísticos utilizados (Perols, 2011).

Estudos sobre *machine learning* têm aumentado gradualmente com resultado no desenvolvimento de algoritmos precisos e eficientes utilizados para *data mining* e automatização de tarefas (Shi & Zheng, 2006). A *machine learning* pode ser classificada segundo três categorias, *supervised learning*, *unsupervised learning* e *reinforcement learning*. A categoria de *supervised learning* é definido pela utilização de um conjunto de dados previamente rotulados e classificados pelos utilizadores, com o objetivo de formar algoritmos que permitam classificar os dados orientando-os no processo de aprendizagem (Boussemart, Cummings, Fargeas, & Roy, 2011). Todos os algoritmos aprendem padrões a partir da base de dados de treino que são posteriormente aplicados na base de dados de teste para prever ou classificar (Batta, 2020).

Na última década, o modelo de *supervised machine learning* tem-se tornado popular ao nível dos sistemas de informação (Kühl, Hirt, Baier, Schmitz, & Satzger, 2021), devido à maior eficiência do modelo em relação ao *unsupervised learning*, bem como a existência de dados pré-rotulados permite ao modelo *supervised learning* ter uma base de dados confiável com mais informação (Boussemart *et al.*, 2011).

Esta categoria permite às organizações resolver uma variedade de problemas do mundo real à escala, como classificar o *spam* em separado à caixa de entrada. Alguns modelos de *supervised learning* incluem redes neuronais, regressão linear, florestas aleatórias (Batta, 2020). A *unsupervised learning* utiliza a informação contida num determinado conjunto de dados não rotulados para extrair um conjunto ótimo de parâmetros (Boussemart *et al.*, 2011). Estes algoritmos identificam padrões sem a necessidade da intervenção humana, extraindo e apresentando a estrutura dos dados mais apropriada. Quando novos dados são introduzidos, utiliza características aprendidas para reconhecer a classe dos dados, sendo habitualmente utilizado para *clustering* e redução do número de características de um modelo através do

processo de redução de dimensionalidade (Batta, 2020). A sua capacidade de descobrir semelhanças ou diferenças na informação torna-a a solução ideal para análise exploratória de dados, segmentação de clientes, reconhecimento de imagem e padrões (IBM, 2020).

O modelo de *reinforcement learning* procura encontrar a melhor forma de atingir um objetivo definido, bem como melhorar o desempenho de uma tarefa específica, para tal os dados são geridos segundo um sistema de tentativa e erro com base na qualidade da tomada de decisão face ao objetivo a seguir. Uma sequência de resultados bem-sucedida será reforçada para desenvolver a melhor recomendação para a solução de um problema (IBM, 2020). O *reinforcement learning* é composto por quatro componentes, política, sistema de recompensa, mapeamento de valores e um modelo sobre o ambiente (Shi & Zheng, 2006). O sistema IBM Watson é um exemplo (IBM, 2020).

2.1.2. Deep Learning e Artificial Neural Network

O termo *deep learning* (DL) é uma componente da ML, com capacidade de aprender e classificar dados mais rapidamente e com maior nível de precisão que os humanos (Zhao & Flenner, 2019). A *deep learning* incorpora modelos computacionais e algoritmos que imitam a arquitetura das redes neuronais do cérebro humano. O cérebro para processar a informação recebida compara-a com a informação que já foi anteriormente processada de modo a direcioná-la no sentido correto. Assim, o cérebro rotula a informação para posteriormente a dividir por grupos e categorias, como acontece na componente de *deep learning* usando a arquitetura das redes neuronais artificiais para o efeito (Jakhar & Kaur, 2019). Uma rede neuronal é composta por quatro componentes, tais como: entradas, pesos, *bias* e saídas (Kavlakoglu, 2020). Estas redes são compostas por neurónios artificiais interligados que realizam cálculos relativamente aos dados de entrada. As camadas são construídas segundo uma estrutura em rede em que os dados inseridos na primeira camada ativam respetivamente os seus neurónios, enquanto a saída desses neurónios ativa a camada seguinte, sendo o processo contínuo até obter uma saída. No entanto o modelo pode ser treinado no sentido inverso (saída-entrada) denominado por *backpropagation*, este processo permite calcular o erro associado a cada neurónio, permitindo ajustar o algoritmo corretamente (Kavlakoglu, 2020).

Os algoritmos das redes neuronais artificiais, têm facilitado o reconhecimento do discurso, classificação de imagens e vídeos (Simon, 2019). O significado de “*deep*”, refere-se à quantidade de camadas existentes nas redes neuronais artificiais, existindo três tipos de camadas, a camada de entrada referente aos dados que entram, a camada de saída referente ao

resultado proveniente do processamento de dados e a camada oculta que extrai os padrões existentes dos dados (Kavlakoglu, 2020).

2.1.3. *Big Data*

O interesse em *Big Data* tem sido exponencial. As organizações estão cada vez mais a adotar decisões estratégicas fundamentadas pela análise e exploração dos dados a fim de melhorar os modelos de tomada de decisão (Nocker & Sena, 2019). Para atingir vantagem competitiva os recursos de tecnologias de informação (TI) são necessários, mas não suficientes, é necessário que as organizações interliguem as suas capacidades e recursos com os recursos de TI (Lin, Kunnathur, & Li, 2020).

A ML tem sofrido um crescimento exponencial com o aumento da importância do *Big Data*, o conceito pode ser definido como a capacidade de processar grande quantidade de dados (Nocker & Sena, 2019). As decisões de *Big Data* são influenciadas segundo diversas dimensões, nomeadamente, a arquitetura de TI, o modelo de dados utilizado, o modelo de negócio e o tipo de competências necessárias para os projetos com *Big Data* (Bughin, 2016). Na presente era, os processos são cada vez mais digitalizados o que faz com que se girem cada vez mais dados através de um vasto número de fontes (Fernandez & Gallardo-Gallardo, 2021). O tratamento de dados permite às empresas perceber determinadas tendências aplicando essa informação no negócio.

O processamento de dados pode ser definido segundo 4 critérios: volume, velocidade, variedade e veracidade. Tal como o nome indica, *Big Data* refere-se a um grande volume de dados que pode ter diversas fontes com unidades de medida (*gigabytes, terabytes e petabytes*). A variedade corresponde às diferentes formas de um conjunto de dados estruturados e não estruturados. Os dados estruturados são maioritariamente bem organizados, como por exemplo os dados financeiros. Em oposição os dados não estruturados são representados por imagens, texto e áudio, sendo aleatórios e difíceis de analisar. No entanto, são os dados que existem em maior quantidade devido à produção crescente de dados durante a utilização da *internet*. Em relação à veracidade, esta característica representa a qualidade dos dados, podendo ser inconsistente, ambígua ou incompleta, é definido uma classificação como boa, má e indefinida (Hariri, Fredericks, & Bowers, 2019).

2.1.4 *Data Mining*

O processo de *data mining* identifica tendências de grande quantidade de dados brutos, que são posteriormente convertidos em informação relevante para encontrar padrões e gerar novos dados, para a tomada de decisão. No processo de gestão do conhecimento numa organização, a técnica de *data mining* pode ser utilizada para identificar e extrair a informação valiosa de grande quantidade de dados (Jantan, Razak, & Ali, 2011). Existem diversas técnicas dentro do *data mining*, nomeadamente: classificação e previsão; descrição de conceitos; associação de regras; análise de *clusters*; análise de *outliers*; análise de tendências e avaliação; análise estatística (Jantan *et al.*, 2011).

A classificação e a capacidade de previsão são duas técnicas de análise de dados utilizadas para extrair modelos, para posteriormente descrever as classes dos dados e prever as tendências futuras (Han, Kamber, & Pei, 2012). O processo de classificação tem duas fases, a primeira corresponde ao processo de aprendizagem, os algoritmos de formação são analisados pelo algoritmo de classificação. O modelo resultante será representado segundo regras de classificação. Na segunda, os dados de teste são utilizados para estimar a precisão do modelo de classificação, se o resultado for aceitável, o modelo pode ser aplicado na classificação de novos dados (Jantan *et al.*, 2011).

2.2 Gestão de Recursos Humanos

O desenvolvimento das tecnologias de informação impactou diretamente e de forma significativa a evolução de diversas áreas da gestão, nomeadamente na GRH. Este impacto provocou mudanças nas políticas e nas práticas implementadas nas organizações, sendo um desafio necessário no auxílio aos profissionais de RH. Para que esta mudança organizacional resulte e tenha sucesso é imprescindível que exista um equilíbrio entre a implementação tecnológica e a manutenção de um clima saudável e de bem-estar dos colaboradores na organização.

A GRH gere toda a abrangência de aspetos de como as pessoas são geridas, tendo como principais pressupostos apoiar a organização na realização dos seus objetivos, alinhando e integrando a estratégia de recursos humanos à da empresa, bem como a contribuição para o desenvolvimento de uma cultura de alto desempenho num clima organizacional positivo e potenciador, capaz de assegurar a motivação e o desenvolvimento dos colaboradores (Armstrong & Taylor, 2014).

O desenvolvimento tecnológico tem transportado as organizações para novos desafios, aumentando a competitividade e a necessidade de atração e retenção de talentos. O conceito de talento foi estudado e desenvolvido segundo diversos autores e apesar de não existir um conceito consensualmente aceite, quase todos eles concordam que os talentos são pessoas com competências e capacidade de evolução, passíveis de serem diferenciados dos demais, criam valor e potenciam as organizações a atingir e a manter vantagem competitiva (Tansley *et al.*, 2007).

A gestão de talento é hoje uma das principais prioridades nas organizações, é desenvolvida pelas diferentes áreas contidas na gestão de recursos humanos que têm como objetivo a atração, o desenvolvimento e a retenção de talentos (Tansley & Tietze, 2013). O reconhecimento do prestígio no mercado por parte das organizações, é imprescindível para o sucesso dos processos de retenção de talento, importa que a comunicação externa e interna seja eficaz ao nível da cultura, dos valores e missão da organização e sobretudo seja percebida.

2.2.1 Definição de Talento

As pessoas consideradas talentosas são um fator estratégico e vital para a sobrevivência e competitividade das organizações. É cada vez mais importante criar e gerir equipas diversificadas e multidisciplinares, talentosas, flexíveis, com capacidades de adaptação à

mudança, focadas nas soluções e alinhadas com os objetivos. Os colaboradores com talento diferenciam-se dos demais na manifestação das suas características, como a entrega na função desempenhada, na mobilização de esforços para a obtenção dos resultados propostos ao nível pessoal e organizacional, destacando-se na satisfação, no envolvimento e paixão na execução das suas funções, permitindo atingir uma excelente performance. Para Tansley *et al.* (2007), talento é composto por pessoas que marcam pela diferença a médio e longo prazo ao nível organizacional, desempenhando potenciais níveis de *performance*.

Todos os talentos têm que conter competências, comprometimento e contribuição. No primeiro, os talentos têm de possuir o conhecimento necessário para realizar a função, no segundo têm o foco na criação de valor na execução das suas funções, no terceiro o sentimento de que têm um contributo positivo para a organização (Ulrich & Allen, 2014).

No entanto, o talento pode ser um fator intrínseco, que se desenvolve sem necessidade de apreciação de terceiros (Pruis, 2011). Este é único e essencial para o desenvolvimento e crescimento da organização, sendo influenciado por diversos fatores como, a sua natureza, o próprio indivíduo e a sua relação com a equipa de trabalho. Cada organização tem um modelo distinto de gerir talentos, procurando implementar processos eficientes que auxiliem na maximização do desenvolvimento e satisfação dos colaboradores. Segundo os autores, talento pode ser definido como as melhores pessoas para uma determinada função, segundo diversos fatores ao nível das competências, capacidades, *engagement* que corretamente geridos potenciam o desenvolvimento organizacional e consequentemente contribuem para atingir os objetivos estratégicos bem delineados e de excelência.

2.2.2 Gestão de Talento

O conceito *War of Talent* surgiu em 1997, criado pela consultora McKinsey devido à escassez de talento no final dos anos 90. Assim, impulsionado pela imperatividade do tema, diversos investigadores, consultores e gestores tiveram oportunidade de desenvolver estratégias de como gerir o talento. As empresas por sua vez, para entrar e/ou permanecer no mercado à escala global sentiram a necessidade de possuir fontes de vantagem competitiva para sobreviver (Beechler & Woodward, 2009). O talento estratégico está relacionado com as funções diretamente relevantes, com o *corebusiness*, sendo crucial no sucesso e competitividade organizacional.

A cultura organizacional é constituída pelo conjunto de valores e normas de comportamento que regem a forma como as pessoas interagem na organização. A cultura e o

ambiente organizacional são fatores determinantes para o sucesso das práticas de gestão de talento implementadas. A Gestão de Talento compreende estratégias e procedimentos na atração, identificação, recrutamento e seleção, bem como na retenção e desenvolvimento de talentos, representando recursos fundamentais para a organização (Tansley *et al.*, 2007). Assim de forma a atrair, reter e desenvolver os seus talentos, requer da organização uma estruturação na implementação das estratégias na sua gestão. As organizações agrupam os talentos por grupos de talento (*talent pool*). Esta divisão depende de empresa para empresa, podendo ser classificados em grupos sénior e júnior para diferentes posições ou a criação de um grupo específico de talentos.

Ter o número certo de pessoas no sítio certo, no tempo certo e com as competências e motivações adequadas é fundamental para a gestão de talento. Para maximizar esta gestão do talento é necessário existir paralelamente um sistema com práticas eficazes de recursos humanos que auxiliem no seu desenvolvimento. A gestão de talento pode também ser indicada como uma estratégia desenvolvida pelo empregador para criar uma abordagem coesa, tecnológica e estratégica da gestão de recursos humanos (Hughes & Rog, 2008).

Segundo a análise dos autores Iles *et al.* (2010) e Cappelli (2008), foram delineadas três possíveis definições sobre a gestão de talento. Numa primeira abordagem a possibilidade de a gestão de talento ser um *rebranding* da GRH, passando a ser mais estratégica. Em oposição, a perspetiva de que a utilização conjunta por parte da gestão de talento utilizar os mesmos instrumentos que a gestão de recursos humanos, bem como do desenvolvimento organizacional, existindo uma diferença notória em que a gestão de talento se foca exclusivamente no grupo de talentos. E por último, o foco da gestão de talentos estar direcionado aos fluxos de talentos, ou seja, as estratégias estão direcionadas para criar e desenvolver talentos específicos e criar sucessão na organização (Cappelli, 2008; Iles, Preece, & Chuai, 2010)

A gestão de talento tem em conta diversos fatores chave para desenvolver planos estratégicos com métricas de recursos humanos. Para manter e criar uma reputação positiva para a atração de talentos nas organizações é necessário desenvolver um conjunto de medidas que facilitem a sua implementação na prática, através da construção de um clima organizacional positivo, dinâmico, alinhado com um local de trabalho seguro. É essencial que os indicadores que contribuem para um clima organizacional dinâmico sejam expressos pela organização e reconhecidos pelos colaboradores (Li & Bryan, 2010).

O *engagement* é um fator imprescindível para o sucesso das organizações. Este pode ser definido como a construção motivacional positiva, ou seja, o colaborador que gosta do seu trabalho terá uma atitude potencialmente mais motivadora e positiva na realização das suas

tarefas, nos níveis de dedicação e empenho superiores. O *engagement* é assim estabelecido segundo a relação emocional entre o colaborador e a organização (Ismail, Arumugan, Kadir, & Alhosani, 2021).

A gestão de talentos deve estar alinhada com a estratégia da empresa. As organizações necessitam criar um modelo holístico que satisfaça as necessidades estratégicas globais, incrementando o desempenho organizacional (Van Zyl, Mathafena, & Ras, 2017). A criação de um processo de gestão de talento tem em conta as diferentes necessidades dos colaboradores dependendo do estágio da sua carreira profissional. A gestão multigeracional é desafiante e necessária, as organizações devem ter em conta as diferentes necessidades e critérios a satisfazer de cada geração (Van Zyl *et al.*, 2017).

2.2.3 Retenção de Talento

A retenção de talento é uma das principais áreas na gestão do talento. É assim imprescindível adaptar estratégias de retenção tendo em conta as diversas características dos colaboradores, de modo a impulsionar o cumprimento dos objetivos e consequentemente a elevada *performance*. Para tal, reter talento e diminuir o *turnover* deve ser um *target* imperativo para as organizações.

A saída de colaboradores das organizações é um processo com impacto, pois implica custos e tempo, com investimento em processos de recrutamento, seleção e formação de talentos, bem como a alteração dos fluxos de trabalho e a perda de *know-how* para a concorrência (Alshehhi *et al.*, 2021).

Como já referido, atrair e reter talentos são duas das principais áreas da gestão de talento (Iles *et al.*, 2010). No entanto, algumas organizações focam-se na atração e desenvolvimento deixando de parte a retenção. Este tipo de práticas impacta negativamente na reputação da organização, bem como na perda de *know-how* e do retorno do investimento (ROI) associado (Poorhosseinzadeh & Subramaniam, 2013).

As estratégias de retenção devem estar focadas nos fatores que afetam a saída ou a permanência dos colaboradores na organização. São diversos os fatores e intervenientes que contribuem para a retenção de talento, nomeadamente a cultura e identidade organizacional, a liderança reconhecida dos gestores de linha, a aprendizagem e as oportunidades, bem como o reconhecimento e recompensas (Whelan & Carcary, 2011). A formação e o desenvolvimento são também fatores chave na retenção de talento nas diversas gerações (Sinha & Sinha, 2012).

Para identificar talentos é necessário um acompanhamento do processo evolutivo dos colaboradores, ao nível das suas competências, atitudes, valores tendo em conta os requisitos

previamente definidos pela organização. Para delinear as métricas de RH para a gestão de talento é necessário definir os aspetos que caracterizam o talento tendo em conta os objetivos organizacionais, bem como identificar os indicadores de performance associados, monitorizando-os e analisando-os.

A gestão cuidada destes fatores assegura a atratividade e permanência dos colaboradores na organização e assim assegurar a diversidade, inclusão, o *work-life balance* e as oportunidades de crescimento pessoal e profissional que influenciam os resultados (Armstrong & Taylor, 2014). O sucesso do processo de retenção de talento é determinado pelo envolvimento dos colaboradores com os objetivos individuais ao nível da função e coletivos ao nível dos objetivos globais da organização.

As reuniões são estruturadas tendo em conta a performance e o potencial dos indivíduos pertencentes ao grupo de talentos (Van Zyl *et al.*, 2017). O plano de sucessão de carreiras tem em conta diversas perspetivas, segundo determinados autores este corresponde ao planeamento de sucessão para formar equipas de *senior managers*, enquanto que para outros é o conjunto adequado de talentos para o recrutamento interno (Poorhosseinzadeh & Subramaniam, 2013).

O planeamento de sucessão de carreira classifica a força de trabalho com potencial, segundo a análise de competências, valores e performance com o objetivo de estes ocuparem posições chave de liderança na organização. O planeamento deve antever as necessidades individuais do colaborador e os objetivos estratégicos da organização, essenciais para manter a vantagem competitiva. Segundo (Hills, 2009), a estratégia implementada na sucessão de carreira deve integrar a aquisição de competências chave e a construção de talentos. Embora atrair e recrutar talento tenham custos elevados, com possível retorno na aquisição de novas competências e inovação, ao reter, desenvolver e reconhecer talento a organização constrói oportunidades aumentando o *engagement* dos colaboradores e a sua felicidade.

Para o processo ser bem-sucedido é necessário que a organização tenha uma comunicação clara, explicitando as competências e comportamentos necessários para o desenvolvimento dos colaboradores, alinhado com o compromisso leal de desenvolver e satisfazer essas especificações. Existe, portanto, a necessidade de redefinir e desenvolver políticas e práticas de recursos humanos que respondam às necessidades dos colaboradores em tempo real. Para tal, é necessário identificar crenças e valores que estejam em conformidade não só com os objetivos estratégicos, mas também alinhados com a satisfação das necessidades dos colaboradores.

A teoria *resource-based view* (RBV) combina a análise dos recursos internos das empresas com a análise externa da indústria e do ambiente competitivo. A teoria RBV reforça o princípio da estratégia de recursos humanos que mostra que a variedade de recursos de uma organização

incluindo os recursos humanos, criam a natureza distintiva da organização e a sua vantagem competitiva. Para tal, as organizações devem focar-se na gestão dos recursos e capacidades internas como principal fonte de vantagem competitiva (Assensoh-Kodua, 2019).

A RBV analisa as organizações como conjuntos bastante distintos de ativos tangíveis, intangíveis e capacidades. Não existem duas empresas iguais, estas distinguem-se ao nível da experiência passada, dos ativos adquiridos, bem como no desenvolvimento da cultura organizacional. A gestão dos recursos estratégicos, determinam a eficiência e eficácia da *performance* organizacional e consequentemente a vantagem em relação à concorrência (Collins & Montgomery, 2008). A vantagem competitiva é alcançada quando os recursos têm valor, são raros e difíceis de imitar para esta ser sustentável deve depender das propriedades e competências únicas em relação à concorrência no mesmo ambiente (Barney, 1995).

A RBV sugere que a vantagem competitiva sustentável pode também ser alcançada quando a organização tem uma força de trabalho que é impossível de ser copiada pela concorrência. Assim é essencial alinhar a teoria RBV com a gestão estratégica de recursos humanos (GERH), adequando os recursos humanos aos objetivos estratégicos e operacionais da organização (Assensoh-Kodua, 2019). O know-how é assim uma fonte de vantagem competitiva, sendo imprescindível as organizações certificarem-se de que possuem as capacidades de localizar, integrar, compensar e manter talento (Ulrich, 1998).

2.3 Inteligência Artificial na Gestão de Recursos Humanos

Para organizar os recursos internos estes têm que estar detalhadamente discriminados e alinhados, analisados e anexados de tal modo especificados que permitam aos profissionais de RH e aos gestores o rápido acesso à informação, possibilitando uma gestão mais eficiente, prevendo a necessidade de entrada de novos recursos, bem como o desenvolvimento dos já existentes. Alinhado a este processo, é importante que as organizações formalizem propostas aliciantes à entrada e na permanência na organização. Isto significa que para potenciar o desenvolvimento e a eficácia destes processos, a utilização de IA torna-se um dos principais aliados na tomada de decisão sobre a gestão de pessoas. Assim, os avanços tecnológicos ao nível do *People Analytics* apresentam um grande potencial na área de RH, através da tomada de decisão com base em informações precisas e significativas, com impacto no planeamento estratégico dos talentos num ambiente dinâmico e em constante mudança (Jiang & Akdere, 2021).

2.3.1 História do *People Analytics*

Para melhor perceber o conceito e a importância do *People Analytics*, é necessário compreender os acontecimentos passados que deram origem à sua evolução. Existem, segundo Ferrar e Green (2021), cinco eras do *People Analytics*. A origem da análise de pessoas pode ser traçada desde os desenvolvimentos de Taylor (1911). O autor procurava otimizar tarefas, com objetivo de tornar os processos mais eficientes maximizando a produtividade dos trabalhadores através da medição de tempos. Nos anos 40, década após guerra, as organizações estabeleceram a industrialização em massa, destacando o papel do psicólogo de organizações industriais (Taylor, 1911). Nas décadas de 1980 e 1990 o departamento de RH muda o seu foco de funções administrativas para passar a gerir o recrutamento, o desenvolvimento e a gestão do desempenho.

A crise de 2008 potenciou a mudança de paradigma, alinhado ao crescimento em *Big Data* e a utilização da análise de dados combinada com o objetivo de monitorizar todos os processos com um nível adequado de eficiência e eficácia. Empresas como a Google, Microsoft e IBM, utilizaram o seu desenvolvimento tecnológico para o desenvolvimento do *People Analytics*, concentrando-se em projetos de análise preditiva (Ferrar & Green, 2021). As organizações como a Google, Netflix e Sprint utilizam o *People Analytics* para analisar dados sobre os seus colaboradores ao nível do *engagement*, desgaste, de forma a atingir vantagem competitiva (Davenport *et al.*, 2010).

Em 2010, a Google desenvolveu o Projeto Oxygen (Shrivastava *et al.*, 2018), este comunicava cientificamente a crença comum das características dos gestores para a empresa, modificando a forma como os executivos percecionavam o valor nos processos de recursos humanos e como os analistas podiam prever as capacidades e comportamentos necessários para alcançar vantagem competitiva.

Rasmussen e Ulrich (2015) enalteceram princípios importantes para a utilização e implementação do *People Analytics* não cair em moda. isto é, ser uma mais-valia para fornecer *insights* poderosos para os gestores de equipas e líderes de RH que tomam decisões chave sobre talento. A análise de pessoas tem como principal objetivo substituir os modismos por iniciativas baseadas em provas, ou seja, a tomada de decisão com base em dados, interligar a gestão académica com a prática, priorizar o impacto dos investimentos em RH, trazer rigor à área de RH e complementá-la com objetividade (Rasmussen & Ulrich, 2015).

Para o *People Analytics* tornar-se uma mais-valia para as empresas é necessário que este transcenda a área de RH, tornando-se apenas relevante se adotar a abordagem *outside in*, ou

seja passar a ser alvo de análise empresarial como um todo (Rasmussen & Ulrich, 2015). Os autores explicitam alguns exemplos de riscos que tornam o *People Analytics* numa moda, nomeadamente: a falta de análise sobre a análise, grande volume de dados sem o uso acertado dos mesmos, implementação de medidas inapropriadas face às necessidades do negócio.

A primeira medida do processo é começar com o problema do negócio, o *People Analytics* não deve começar com dados ou com uma abordagem preconcebida dos problemas empresariais, mas sim com um desafio empresarial. A Figura 2.1, ilustra que as análises e os dados são apenas partes integradas no diagnóstico geral. A análise deve concentrar-se nas três a cinco questões de grande valor para o negócio e não em questões de menor valor, como previsões do volume de negócio, análises simples de ligação de inquéritos, etc.

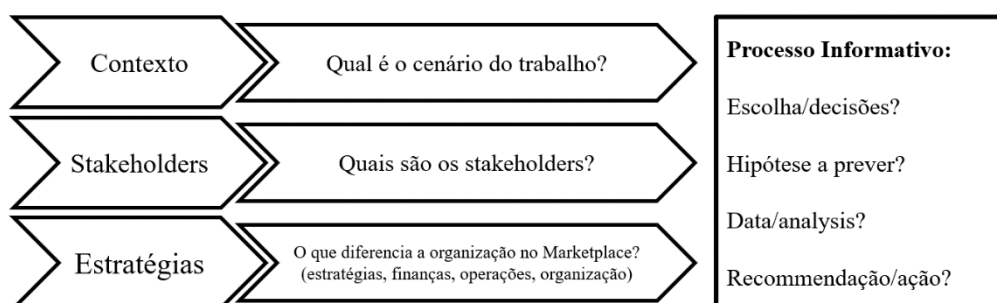


Figura 2.1- Informação para o processo de tomada de decisão

Fonte: Adaptado de Rasmussen e Ulrich, (2015)

A segunda medida refere-se a retirar a análise de RH dos RH, à qual os autores se referem como uma medida drástica, mas necessária tendo em conta o amadurecimento da análise integrar outros departamentos como o financeiro e operações. A análise de RH tem que transcender as questões de RH tal como a análise de outras funções. Para tal, acontecer é necessário um crescimento das competências analíticas na área de RH, de modo a conseguir responder às necessidades da análise multifuncional dos dados em tempo real (Rasmussen & Ulrich, 2015). A terceira medida, lembrar do “humano” em recursos humanos. As pessoas têm a tendência de escolher as suas crenças mesmo com a evidencia contrária dos dados, a mentalidade tem que estar praticamente direcionada para a mudança e não apenas na teoria (Rasmussen & Ulrich, 2015).

A Era da Inovação foi caracterizada pelo aparecimento de novas tecnologias, novos modelos de especialização foram criados bem como profissionais mais aptos para as exigências estratégicas de análises de pessoas (Ferrar & Green, 2021). O *Global Human Capital Trends*

Report de 2018 da Deloitte identificou e classificou o “*People Data*” como a tendência mais importante (Lahiri & Schwartz, 2018).

Em 2019 um relatório do World Economic Forum identificou seis imperativos empresariais a implementar pelos recursos humanos alinhado com toda a organização, nomeadamente, desenvolver novas capacidades de liderança, gerir e integrar a tecnologia no local de trabalho, melhorar a experiência no trabalho, construir uma cultura de aprendizagem, estabelecer métricas para a valorização do capital humano e incorporar a diversidade (World Economic Forum, 2019). A pandemia COVID-19 potenciou o *People Analytics* para uma nova era de desenvolvimento, pela urgência e precisão necessária para as funções do dia a dia, bem como de planeamento estratégico a longo prazo (Ferrar & Green, 2021).

2.3.2 Impacto do *People Analytics* no negócio e nas Organizações

As empresas têm implementado, cada vez mais, IA nos processos rotineiros permitindo aos colaboradores focarem-se nos processos de tomada de decisão (Nawaz, 2020). Assim, os gestores de RH podem de uma forma mais eficaz alinhar a visão corporativa com os objetivos individuais dos colaboradores, assegurando o bem-estar da força de trabalho, alavancando a tecnologia nas diversas práticas de RH (Inamdar, 2021). Neste contexto, o *People Analytics* é considerado como uma área essencial para os gestores e área de RH, bem como também uma ferramenta importante na criação de valor estratégico para a organização (Angrave *et al.*, 2016).

O *People Analytics* não se foca apenas na área de recursos humanos, mas sim no negócio. Tem como objetivo fornecer valor comercial, aos colaboradores e líderes através da tomada de decisão com base em dados sobre as pessoas de cada empresa. O *People Analytics*, cria impacto no conselho de administração, nos investidores e nas sociedades em geral (Ferrar & Green, 2021). Os principais fatores que contribuíram para a alteração de paradigma da GRH foram nomeadamente, o aumento da participação dos gestores de topo nas decisões sobre a gestão de pessoas, na perceção crescente de tornar a área de RH com análises mais quantitativas alinhadas ao conhecimento estratégico do negócio, tomando decisões com base na análise e avaliação de todos os parâmetros relacionados com a gestão de pessoas (Shrivastava *et al.*, 2018).

Com a alteração de paradigma na gestão de grande quantidade de dados bem como na respetiva análise e na sua aplicabilidade à GRH. O *Data Science* e o *Big Data* potenciaram a utilização do *People Analytics* auxiliando as organizações e os profissionais de RH a reduzir o *turnover* e a modificar a forma de atrair e reter talento (Yahia *et al.*, 2021).

O *People Analytics* surgiu do *Business Intelligence* e do *Big Data*, este tem por base a identificação e quantificação sistemática da influência dos fatores humanos na atividade organizacional (Isson & Harriott, 2016). Pode também ser definido na literatura como *HR analytics* e *workforce analytics* (Cascio & Boudreau, 2016; Tursunbayeva, Di Lauro, & Pagliari, 2018). Existem diversos fatores importantes que o *People Analytics* consegue responder, tais como: 1) quais as competências necessárias para atingir os objetivos empresariais; 2) que talento deve ser desenvolvido, recompensado e promovido; 3) quais devem ser as principais fontes para atrair e reter talento; 4) como desenvolver o *engagement* na organização; 5) quais os colaboradores a reter; 6) qual o prejuízo resultante da rotatividade (Isson & Harriott, 2016).

O *People Analytics* interliga a análise do capital humano com a estratégia, quantificando e identificando as pessoas que mais contribuem para o sucesso dos resultados do negócio. Para tal, são utilizados os dados sobre as características, desempenho e comportamentos dos colaboradores, permitindo aos gestores RH compreenderem melhor os diversos departamentos bem como os colaboradores individualmente (Pape, 2016).

É essencial identificar quais os parâmetros que mais impacto têm na permanência dos colaboradores na organização com o principal objetivo de ter os colaboradores certos, na função certa, no tempo certo. Assim, o *People Analytics* utiliza um conjunto de técnicas que definem, criam e transformam os dados digitais em relatórios e análises, auxiliando os profissionais de RH e os gestores no desenvolvimento das práticas e políticas de recursos humanos enquadradas com as necessidades das pessoas e do negócio (Gupta *et al.*, 2020).

As organizações têm cada vez mais presente que a utilização de tecnologia alinhada a todas as áreas e departamentos, potencia uma gestão de dados mais criteriosa, aumentando a vantagem competitiva (Charan *et al.*, 2018). Quando as hipóteses são validadas, soluções são criadas, previsões calculadas e as recomendações transferidas, então o verdadeiro desafio começa. A tecnologia é fundamental para escalar, produzir e personalizar o *People Analytics*. As experiências dos consumidores são baseadas em modelos de produção, reforçados com interfaces intuitivas para o utilizador e experiências altamente personalizadas. Por sua vez, o *People Analytics* está a seguir o mesmo caminho de desenvolvimento. Desenvolver um produto para os colaboradores implica que o *design* seja *user-friendly*, com o objetivo de melhorar a experiência dos colaboradores como um todo. Para que esta transformação seja bem-sucedida é importante alterar o paradigma da utilização de *People Analytics* como uma serie de experiências ou projetos para produtos ou ofertas (Ferrar & Green, 2021).

O marketing é uma das áreas que alterou o paradigma de perceber os clientes para consumidores. Na área de recursos humanos a mudança está em perspetivar os colaboradores como consumidores. Com acesso a análises de dados e tecnologia, as organizações têm presentemente a capacidade de personalizar a resposta a cada colaborador (Howell, 2020). As organizações estão, cada vez mais, a aumentar o foco na experiência do colaborador (EC), Mark Levy líder da EC do Airbnb em entrevista para a Forbes defendeu a criação de um grupo de experiência ao colaborador, dado que a Airbnb já tem um grupo de experiência ao consumidor (Morgan, 2016). A experiência dos colaboradores deve ser encarada com e pelos colaboradores. A EC e o *People Analytics* são as duas tendências mais importantes que estão a mudar a forma de atrair e reter talento. Estão ambas interligadas e são em parte dependentes (Linkedin Talent Solutions, 2022).

O *People Analytics* tem um papel fundamental e significativo na consumerização dos RH, com quatro tipos de responsabilidades ao nível dos colaboradores individualmente, da força de trabalho como consumidor dos processos de RH, dos gestores como consumidores dos dados dos colaboradores e os executivos como consumidores dos *insights* sobre os colaboradores (Gonçalves et al., 2021). Em suma, segundo Ferrar e Green (2021), é impossível medir, personalizar, produzir e consequentemente melhorar a EC sem analisar os dados sobre as pessoas.

2.3.3 *People Analytics* e a Gestão de Dados

People Analytics compreende a análise dos colaboradores e da força de trabalho para gerar conhecimento e fornecer recomendações para melhorar os resultados organizacionais (Ferrar & Green, 2021). O *People Analytics* consiste na gestão de múltiplas atividades e resultados. Durante a análise de atividades esta é caracterizada pela partilha de informação e análise de dados sobre pessoas através de *dashboards* e relatórios com um formato formal, estandardizado e repetitivo. Os indicadores chave de performance (*key performance indicators* ou KPIs) medem as métricas mais importantes e com maior valor para o negócio. A análise preditiva usa técnicas matemáticas e estatísticas para prever e criar cenários futuros. As análises avançadas e de IA, providenciam *insights* e recomendações, através da utilização de *machine learning*, IA, *deep learning* e computação cognitiva (Ferrar & Green, 2021).

Em relação aos resultados, estes podem ser ao nível das experiências de trabalho dos colaboradores, na democratização dos dados, bem como os conhecimentos entregues aos executivos e a melhoria da performance. Construir uma cultura analítica, ao sensibilizar a

importância do *People Analytics* nos RH, por meio do desenvolvimento das competências analíticas dos profissionais de recursos humanos e gestores da empresa é imperativo. Os resultados ao nível da performance empresarial são compostos pelo impacto financeiro, gestão de risco e o crescimento da quota de mercado. Ao nível social permite aferir resultados sobre a inclusão, igualdade e as remunerações mediante o género. As equipas de *People Analytics* focam-se nos tópicos mais estratégicos e operacionais sobre as pessoas no negócio (Ferrar & Green, 2021).

O *People Analytics* tem como objetivo empresarial planear a gestão de talento, para o efeito integra fontes de dados diferenciados de modo a criar previsões futuras aplicadas à tomada de decisão e ao planeamento de ações estratégicas (Isson & Harriot, 2016). Assim, o *People Analytics* alinhado à experiência e intuição humana auxilia as organizações a compreender e gerir os seus colaboradores prevendo problemas organizacionais complexos através da aplicação de IA a um grande conjunto de dados. A monitorização da utilização de computadores é uma forma adotada por algumas empresas para recolher dados. O teletrabalho potenciou essa ação, no entanto devido à sensibilidade da informação dos dados relativos às pessoas, as organizações devem reger-se pela lei de proteção de dados afim de não violar a privacidade dos seus colaboradores (Inamdar, 2021).

A ética e a privacidade dos dados são dois dos tópicos mais importantes no *People Analytics*. Os autores Ferrar e Green (2021), recomendam que os líderes de *People Analytics* sejam transparentes sobre a ética e privacidade na gestão de dados sobre as suas pessoas. A criação de um conselho de ética e privacidade, é constituído pelo líder de *People Analytics*, representante dos colaboradores, líder do departamento de privacidade e IT. Tem como objetivo providenciar diretrizes à organização sobre a gestão ética e criteriosa dos dados. A transparência aumenta significativamente os níveis de confiança e *engagement* dos colaboradores, indicador importante na utilização bem-sucedida de *People Analytics*. Desde 2018, a União Europeia implementou o Regulamento Geral de Proteção de Dados da União Europeia (RGPD da UE) com o objetivo de proteger os dados pessoais e assegurar a privacidade dos dados dos seus cidadãos. A diretiva RGPD de 2019 difere da anterior na medida que aplica sanções às empresas que não cumpram com a lei no tratamento e recolha de dados dos residentes da EU (GDPR, 2019).

As fontes de dados existem segundo três categorias: dados sobre a força de trabalho, a empresa e o mercado de trabalho. São integrados alguns dos seguintes exemplos sobre os dados do capital humano, nomeadamente dados sobre as estruturas organizacionais, liderança, custos de recrutamento, remuneração e benefícios, rotatividade, avaliação do histórico do

desempenho, bem-estar da força de trabalho. Sobre os dados da empresa estes incluem, desempenho das vendas, receitas, bases de clientes, quota de mercado, diversidade de produtos, preço das ações. Por último, os dados sobre o mercado de trabalho incluem dados estatísticos sobre o salário, taxas de emprego e desemprego, PIB e rotatividade. Estes dados dependem da indústria, dimensão da empresa e o país (Isson & Harriot, 2016).

A interligação de todos os dados na construção do planeamento organizacional é fundamental para estruturar planos de ação eficazes em relação aos objetivos e necessidades da empresa. É necessário que as empresas traduzam as questões e os dados em ações mensuráveis, através da integração dos dados sobre as pessoas e o negócio (Figura 2.2).




Figura 1.2- Processo de gestão de dados e tomada de decisão com *People Analytics*

Fonte: Adaptado de Isson & Harriot (2016)

Assim o *People Analytics* tem a capacidade de compreender, através da informação do passado, o que aconteceu. No presente, através da compreensão dos fatores atuais transformando-os em conhecimento. Para no futuro, antecipar o que potencialmente pode vir a acontecer, desenvolvendo inteligência na análise. A integração destas dimensões descreve o que deve ser feito com base nas previsões (Isson & Harriot, 2016). Os dados devem conter informação sobre os colaboradores retidos e os não retidos, assim o modelo pode ser programado para reconhecer as diferenças, aprendendo os padrões de cada uma e desenvolvendo previsões futuras mais precisas (Isson & Harriot, 2016).

A análise descritiva, utiliza *business intelligence*, para resumir ou transformar os dados em informação relevante, permitindo o estudo e análise dos acontecimentos ocorridos no passado. A análise preditiva, por sua vez, prevê os acontecimentos futuros. Esta análise impacta positivamente na tomada de decisão e na obtenção de benefícios para a organização, com a

particularidade de ser imparcial e sem preconceito, potenciando a transparência (Likhitar & Verma, 2020), como a melhoria do compromisso organizacional e a produtividade (Shrivastava *et al.*, 2018) característica tem aumentado com o uso crescente de *machine e deep learning*.

A análise preditiva da retenção de talento é uma das soluções mais desenvolvidas e implementadas nas previsões sobre os dados da força de trabalho. Durante a realização do trabalho os colaboradores emitem sinais que permitem aos gestores através dos dados, construir análises preditivas e estatísticas que permitam compreender o comportamento e prevejam a rotatividade (Schweyer, 2018). Através destes *insights* os gestores conseguem prever quais os talentos que têm a intenção de sair da organização, tendo a possibilidade de agir através de incentivos, recompensas e reconhecimento (Grillo, 2015).

A análise preditiva tem a potencialidade de trazer mudanças significativas com impacto no sucesso organizacional, ao nível das práticas de RH (Tamizharasi & Rani, 2014). A análise de RH tem um papel fundamental na retenção de talento, possibilitando classificar o nível de desgaste de cada colaborador através de um modelo preditivo, com capacidade de identificar elevados desempenhos e posteriormente assegurar a sua retenção e *engagement* (King, 2016). Para a aplicação da análise preditiva, é necessário que os gestores de RH tenham informação sistemática e organizada, adaptada às necessidades da empresa.

A análise prescritiva, por sua vez, tenta identificar o efeito das decisões futuras com o objetivo de aconselhar sobre possíveis resultados antes da tomada de decisão (Likhitar & Verma, 2020). Para a utilização do *People Analytics* ser eficaz é necessário existir uma grande quantidade de dados, no entanto no contexto da gestão de recursos humanos o tamanho não é necessariamente a premissa mais importante, mas sim a inteligência dos dados (Angrave *et al.*, 2016). Através da criação de *insights* a partir do tratamento de dados, a inteligência extrai, interpreta e age sobre os dados (Isson & Harriot, 2016).

2.3.4 Modelo de *People Analytics*

Os autores Ferrar e Green (2021), criaram o modelo “*Insight222 Nine Dimensions for Excellence in People Analytics*”. Este modelo procura ajudar as organizações a responder a três

perguntas relacionadas com a definição do foco, melhoria do impacto e a criação de valor. O modelo é dividido em 3 categorias, fundação, recursos e valor e por nove dimensões




Figura 2.2- Modelo Insight222: Nove dimensões para a excelência no *People Analytics*

Fonte: Adaptado de Ferrar e Green (2021)

O *People Analytics* requer uma base sólida com os elementos certos para o sucesso futuro, ao nível da governação, definição clara das metodologias e a gestão eficaz dos *stakeholders*, correspondente à fundação. A administração (*governance*) refere-se aos mecanismos, processos e procedimentos em que o *People Analytics* opera. Esta sustenta todas as análises e assegura que as pessoas certas definem corretamente o caminho a seguir, verifica se a estrutura da gestão de dados está corretamente implementada e se a gestão de riscos é realizada adequadamente.

A metodologia, por sua vez, foca-se nos processos e enquadramentos que devem ser estabelecidos na utilização repetitiva e dinâmica de *People Analytics*. Esta dimensão inclui a gestão da priorização do trabalho, bem como a definição e utilização de critérios eficazes e transparentes, a gestão do envolvimento dos *stakeholders* e a gestão de equipas alinhadas à criação de impacto e entrega de valor. A gestão de *stakeholders*, discute os diferentes tipos de intervenientes com os quais as equipas de análise de pessoas irão interagir para criar impacto e fornecer valor. Para tal, é criado um mapa de *stakeholders* com objetivos específicos ao nível do envolvimento e condução de reuniões eficazes, bem como delineados a longo prazo os objetivos necessários na construção de relações produtivas e sustentáveis.

O *People Analytics* para ser credível tem que ter impacto. É imprescindível possuir os recursos certos, são exemplos, as competências chave, as tecnologias apropriadas e dados

robustos e extensos. A dimensão das competências foca-se na equipa de *People Analytics*. É discutido as competências do líder de *People Analytics*, o modelo operacional da equipa e o conjunto de competências chave que possibilitam a tradução da linguagem empresarial e de recursos humanos para linguagem analítica e vice-versa.

A dimensão tecnológica, consiste no conjunto de todos os tipos de tecnologia necessária para o sucesso do *People Analytics*. Aborda o tema “construir versus comprar”, utilizando tecnologia para escalar soluções analíticas e tecnologias emergentes para acelerar a recolha de dados, análises, insights e democratização de dados. A gestão de dados, tem como principal objetivo fornecer mais valor para o negócio. A utilização de fontes de dados, especialmente de dados emergentes acrescenta valor incremental e expande a análise de pessoas além do foco nas políticas e processos de recursos humanos para questões empresariais mais complexas.

O *People Analytics* tem como responsabilidade entregar valor às organizações e à força de trabalho, ou seja, às pessoas. Esta responsabilidade é traduzida através de melhores experiências à força de trabalho, criando impacto através dos resultados do negócio e desenvolvendo uma cultura orientada para a análise de dados. A dimensão das experiências da força de trabalho descreve como os diversos intervenientes numa organização beneficiam do *People Analytics*. Analisa a influência da personalização das experiências dos colaboradores, a democratização dos dados ao alcance de todos os gestores bem como a forma de os motivar a utilizar análises interativas e por último a mudança dos processos organizacionais na melhoria das experiências da força de trabalho.

Os resultados do negócio descrevem a lógica e as técnicas que conduzem à obtenção de resultados, proveniente da atividade de *People Analytics*. Os resultados são perceções e recomendações acionáveis, de valor financeiro e com melhorias tangíveis para o negócio. Por último, a cultura está focada na construção e desenvolvimento de pessoas com conhecimentos analíticos e das funções inerentes à área de recursos humanos. Para tal, são definidas as competências e mentalidade necessária para os futuros profissionais de RH, bem como o desenvolvimento da estrutura necessária, como base à inovação e criação de valor.

2.3.5 *People Analytics* na Retenção de Talento

Empresas como a Google, Disney, Amazon, Apple e Microsoft têm integrado nos seus processos organizacionais análises avançadas de recursos humanos (Likhitar & Verma, 2020) com a integração de IA e *Big Data* (Yahia *et al.*, 2021). A Google é um dos líderes mundiais no domínio do *People Analytics* com impactos positivos nos resultados organizacionais. Os dados e as análises substituíram o fator dúbio e arbitrário das opiniões humanas, sentimentos e intuições dos gestores, tornando-se na base para a tomada de decisão (Ferrar & Green, 2021). A empresa desenvolveu um algoritmo matemático para prever proativamente e com sucesso quais os colaboradores com maior probabilidade de intenção de saída. Esta prática possibilita à organização ser pró-ativa no processo de retenção de talento, bem como implementar práticas personalizadas de acordo com o perfil de cada colaborador (Shrivastava *et al.*, 2018).

A IBM desenvolveu em parceria com a Watson um programa em que prevê a intenção de saída dos colaboradores, através de análises preditivas com a prescrição de ações no sentido de reter ou contratar em tempo real. Os resultados demonstram que as previsões estão com um intervalo de precisão de 95%, o sucesso segundo a CEO Ginni Rometty, deve-se à análise de diversos dados em diversos pontos. Por exemplo, ao compreender melhor os padrões dos dados das aptidões adjacentes, o plano de desenvolvimento e de sucessão de carreira é estruturado sob uma base fundamentada de dados e análises sobre as pessoas, alinhado às suas necessidades e preferências (Rosenbaum, 2019).

Segundo um estudo dos autores Holtom *et al.*, (2017), constaram que na sua grande maioria os esforços de retenção são baseados em duas ferramentas, nas entrevistas de saída e nos inquéritos anuais do clima organizacional. As entrevistas de saída são realizadas para compreender as razões de saída. Os inquéritos anuais por sua vez são utilizados para medir o compromisso organizacional. O problema destas ferramentas é que não produzem dados em tempo real sobre a intenção de saída dos colaboradores, as perguntas dos inquéritos podem não passar a mensagem pretendida e por outro lado os colaboradores podem não ser sinceros. Foi assim, desenvolvido com base em *Big Data* e *machine learning*, o índice de rotatividade dos indivíduos. Este indicador traduz em tempo real quem tenciona sair da organização (Holtom, Goldberg, Allen, & Clark, 2017)

Estudos realizados, comprovaram que as duas principais razões para a saída de colaboradores eram primeiramente os “choque de rotatividade” representados por determinados acontecimentos que conduziam à incerteza na permanência na organização, nomeadamente alterações na liderança e ao nível de mudanças externas como uma proposta mais aliciante. A

integração na organização, medida segundo o nível de comprometimento dos colaboradores através da qualidade das relações sociais e na percepção do trabalho realizado, tendo em conta os interesses pessoais e valores percebidos. Medido através do número de empregos passados, antiguidade e função, competências e geografia (Holtom *et al.*, 2017). O índice de rotatividade, identifica os colaboradores que estão em risco de saída. Esta análise em tempo real permite aos líderes ter uma atitude pró-ativa, desenvolvendo práticas eficazes de retenção desse talento.

2.4 Limitações da Inteligência Artificial na Retenção de Talento

Um dos desafios para as equipas de RH, é encontrar o equilíbrio entre a tecnologia e a ação humana nas organizações, tendo por objetivo torná-los convergentes e não divergentes. No entanto, são apontadas algumas limitações na literatura científica sobre a implementação de *People Analytics*. Segundo os autores, existe um certo ceticismo por parte de alguns profissionais de RH na monitorização dos colaboradores ser resumida a métricas (Angrave *et al.*, 2016; Davenport *et al.*, 2010). As empresas devem evitar a manipulação das métricas para obter os resultados esperados, bem como a utilização de métricas demasiado simplistas que geralmente não conseguem prever com precisão os resultados de determinados indicadores (Davenport *et al.*, 2010).

Os gestores de RH devem aumentar as competências, sobre a gestão dos dados de RH disponíveis e a obter (CIPD, 2013). São as competências analíticas, aquelas que são consideradas as necessárias para traduzir os dados em resultados (Harriot & Isson, 2016). Em determinadas organizações e em algumas áreas existe ainda uma percepção equivocada sobre a importância e o impacto dos recursos humanos na vantagem competitiva, existindo muitas vezes alguma dificuldade na implementação de medidas inovadoras na gestão de pessoas (Angrave *et al.*, 2016). A falta de suporte executivo impacta negativamente na aplicação do *People Analytics* nas organizações. Torna-se essencial que as organizações estejam alinhadas em concentrar esforços para a persecução dos objetivos definidos, caso contrário poderá falhar por não conseguir definir prioridades face às políticas a implementar, não dando resposta às responsabilidades corporativas (Harriot & Isson, 2016).

No entanto, esta percepção é potenciada pela dificuldade na partilha de informação, dentro da mesma organização, impedindo a combinação dos dados de RH com outras áreas (Angrave *et al.*, 2016). Um dos principais desafios na implementação de *People Analytics* é a gestão eficiente dos dados, na maioria dos casos pela utilização de sistemas e ferramentas não

integradas, difíceis e/ou onerosas de integrar, dificultando a análise e a obtenção dos resultados necessários (Harriot & Isson, 2016).

Esta dificuldade é consequência de como os sistemas de recursos humanos são promovidos e vendidos, propiciando alguma confusão na análise de RH (Angrave *et al.*, 2016). Existem *softwares* usados pelas organizações, cujo objetivo é desenvolver e automatizar processos de RH que do ponto de vista estratégico apenas responde a um conjunto limitado de perguntas, com base em relatórios operacionais, sem permitir fazer uma análise geral dos possíveis problemas nem das melhorias necessárias (Angrave *et al.*, 2016). Para obter análises completas, é imprescindível que independentemente da complexidade de transformar os dados qualitativos em quantitativos, estes não sejam ignorados ou manipulados (Davenport *et al.*, 2010). A ausência de monitorização, antes e depois da tomada de decisão e das medidas implementadas, impacta negativamente na melhoria contínua dos processos (Davenport *et al.*, 2010).

Um dos principais desafios da utilização de *People Analytics* é a deficiência de dados empíricos, ao nível do número de amostras e das suas características, o que não permite criar um modelo fiável baseado num conjunto de dados reduzido. As pequenas e médias empresas podem não ter dados de RH de alta qualidade e não ter capacidade analítica para adaptar ferramentas e técnicas, utilizadas habitualmente para a gestão de grandes quantidades de dados (Yahia *et al.*, 2021).

As empresas estão a investir cada vez mais em previsões analíticas (DiClaudio, 2019). No entanto, se as organizações não tiveram capacidade de passar a *HR Analytics* de um nível descritivo para prescritivo, correm o risco de passar pelo estigma de estar a incorrer no que é denominado por “moda de gestão” (Rasmussen & Ulrich, 2015).

CAPÍTULO III - ABORDAGEM TEÓRICA

3.1 Objetivos e Questões de Pesquisa

A Revisão da Literatura do capítulo I, reúne e interliga diversos modelos, definições de conceitos e ideias desenvolvidas e estudadas sobre a IA, os recursos humanos, a interligação de ambos com o *People Analytics* e o impacto deste na retenção de talento. Baseada na informação recolhida e analisada foi proposto responder a duas questões de pesquisa com o objetivo de responder aos dois objetivos principais do estudo. Em relação ao primeiro começou por ser definido, perceber quais os fatores que influenciam a possibilidade de implementar *People Analytics* na GRH. Para posteriormente analisar o segundo objetivo de verificar a possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH.

A globalização, o desenvolvimento tecnológico e as diversas crises económicas, transportam as organizações para novos desafios. A teoria RBV sugere que as organizações podem atingir vantagem competitiva sustentável através de uma força de trabalho única, impossível de imitar pela concorrência. Para tal ser possível, é necessário alinhar a teoria com a GERH, posicionando a GRH face aos objetivos estratégicos e operacionais das organizações (Assensoh-Kodua, 2019). Para as organizações se certificarem que possuem o know-how necessário é determinante ter a capacidade de localizar, integrar, compensar e manter talento (Ulrich, 1998). Para potenciar o desenvolvimento e a eficácia destes processos, a utilização de IA tornou-se um dos principais aliados na tomada de decisão sobre a gestão de pessoas. O crescimento em *Big Data* e a necessidade de realizar análises de dados integradas permite monitorizar todos os processos, com resultados positivos ao nível da tomada de decisão.

Surge assim as estratégias de *People Analytics*, na área de recursos humanos alinhada à gestão do negócio. Tem como objetivo fornecer valor, aos colaboradores e líderes através da tomada de decisão com base na análise dos colaboradores e da força de trabalho com o propósito de gerar conhecimento e fornecer recomendações às organizações sobre potenciais melhorias estratégicas (Ferrar & Green, 2021). Um estudo levado a cabo pela Deloitte identificou e classificou o “*People Data*” como a tendência mais importante (Lahiri & Schwartz, 2018).

São identificados, na literatura, diversos benefícios na utilização de IA. Esta permite às organizações uma gestão de dados mais criteriosa proporcionando o aumento de vantagem competitiva (Charan *et al.*, 2018). Por sua vez, o *People Analytics* auxilia as organizações a compreender e a gerir os seus colaboradores tendo a capacidade de prever problemas complexos (Inamdar, 2021), a análise preditiva utiliza técnicas matemáticas e estatísticas para prever e

criar cenários futuros, enquanto as análises avançadas de IA, providenciam *insights* e recomendações (Ferrar & Green, 2021). Esta inovação impacta positivamente na produtividade organizacional (Shrivastava *et al.*, 2018). É possível verificar alguns efeitos ao nível do trabalho, com a implementação de IA. As funções tornam-se cada vez mais automatizadas permitindo aos colaboradores dispensar mais tempo nas tarefas estratégicas (Nawaz, 2020). Nos processos de tomada de decisão tem a capacidade de aumentar a imparcialidade e diminuir o preconceito (Isson & Harriot, 2016; Likhitar & Verma, 2020).

São identificados pelos autores algumas limitações a diversos níveis na implementação de *People Analytics*. Esta não deve começar a partir de uma abordagem preconcebida dos possíveis problemas empresariais, mas sim com um desafio empresarial (Rasmussen & Ulrich, 2015). Os autores identificam o défice na preparação da estrutura organizacional na transformação de dados descritivos para prescritivos. Por sua vez, o défice de competências analíticas na área de RH é um imperativo a mudar, os autores defendem que a análise de RH tem que transcender as suas questões de RH, em conformidade com as restantes áreas dentro da organização (Davenport *et al.*, 2010; Isson & Harriot, 2016; Rasmussen & Ulrich, 2015). Assim para analisar o impacto dos fatores que influenciam a implementação de *People Analytics* na GRH, surgiu a primeira questão de pesquisa.

(Q1) Quais os fatores que influenciam a possibilidade de implementar *People Analytics* na GRH?

No seguimento do estudo, após compreender como um todo o impacto da implementação do *People Analytics* na GRH, surgiu o interesse em perceber o seu efeito ao nível da retenção de talento, tema urgente a ser compreendido e solucionada nas organizações. Por sua vez, a análise preditiva da retenção de talento é uma das soluções mais desenvolvidas e implementadas nas previsões sobre os dados da força de trabalho, permitindo compreender o comportamento e prever a rotatividade (Schweyer, 2018), bem como o seu prejuízo (Isson & Harriot, 2016). A organização, tem assim em tempo real a possibilidade de identificar o talento que deve ser desenvolvido, recompensado, promovido e retido (Grillo, 2015; King, 2016). Através do *People Analytics* os profissionais de RH têm a capacidade de identificar as principais motivações e competências dos colaboradores (Pape, 2016; Schweyer, 2018).

Através da experiência do consumidor na área de marketing, ao nível do desenvolvimento de interfaces intuitivas para o utilizador e nas experiências personalizadas. O *People Analytics* está a seguir o exemplo, na perspetiva de encarar o colaborador como consumidor com o objetivo de melhorar a sua experiência como um todo. A personalização da resposta por parte

da organização às necessidades individuais de cada colaborador é possível através de análises avançadas de dados (Howell, 2020, Inamdar, 2021).

No entanto, a manipulação das métricas para obter resultados esperados ou a utilização simplista das mesmas, interceta negativamente a implementação de *People Analytics* (Davenport *et al.*, 2010). A ausência de alinhamento estratégico, entre as diversas hierarquias prejudica a implementação de medidas necessárias na gestão de pessoas (Angrave *et al.*, 2016); (Harriot & Isson, 2016).

A Google é um dos líderes mundiais no domínio do *People Analytics*, a empresa desenvolveu um algoritmo matemático que prevê proativamente e com sucesso os colaboradores com maior probabilidade de intenção de saída. Esta prática permite ter uma resposta antecipada e personalizada (Shrivastava *et al.*, 2018). A IBM através da análise preditiva, consegue prever com um intervalo de precisão de 95% a intenção de saída dos seus colaboradores (Rosenbaum, 2019). Deste modo, afim de estudar os fatores que influenciam a possibilidade, por parte dos gestores, em identificar e reter talento através da implementação de *People Analytics*, surgiu a segunda questão de pesquisa.

(Q2) Qual a possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH?

Na Tabela 3.1, é possível verificar os objetivos do estudo (OE), as questões de pesquisa (QP), as respectivas hipóteses (H) de cada QP e a respetiva revisão de literatura (RL).

Tabela 4.1- Relação entre OE, QP e RL

Objetivos do Estudo (OE)	Questões de Pesquisa (QP)	Hipóteses (H)	Revisão da Literatura
OE1-Perceber quais os fatores que mais influenciam a possibilidade de implementar <i>People Analytics</i> na GRH.	QP1- Qual a possibilidade de implementar <i>People Analytics</i> na GRH?	Influência da perceção dos utilizadores e o seu impacto no negócio e na organização	(Nawaz, 2020; Isson & Harriot, 2016; Ferrar & Green, 2021; Likhitar & Verma, 2020; Tamizharasi & Rani, 2014; Shrivastava <i>et al.</i> , 2018)
		Influência dos benefícios gerados pela implementação de PA na GRH	(Charan <i>et al.</i> , 2018; Inamdar, 2021; Shrivastava <i>et al.</i> , 2018; Ferrar & Green, 2021)
		Influência das limitações geradas pela implementação de PA na GRH	(Angrave <i>et al.</i> , 2016; Davenport <i>et al.</i> , 2010; Harriot & Isson, 2016; Rasmussen & Ulrich, 2015; Ferrar & Green, 2021)
OE2- Verificar a possibilidade de identificar e reter talento através da implementação de <i>People Analytics</i> na GRH.	QP2- Qual a possibilidade de identificar e reter talento através da implementação de <i>People Analytics</i> na GRH?	Influência dos benefícios em identificar e reter talento através da utilização de PA na GRH	(Isson & Harriot, 2016; Grillo, 2015; King, 2016; Shrivastava <i>et al.</i> , 2018; Ferrar & Green, 2021)
		Influência das limitações em identificar e reter talento através da utilização de PA na GRH	(Davenport <i>et al.</i> , 2010; Angrave <i>et al.</i> , 2016; Harriot & Isson, 2016; Inamdar, 2021; Yahia <i>et al.</i> , 2021)

Fonte: Elaboração do autor

CAPÍTULO IV - METODOLOGIA

A metodologia de investigação é uma forma de resolver sistematicamente o problema de investigação. O método ou processo científico é constituído por determinadas práticas utilizadas e comprovadas pela comunidade científica sobre a exposição e confirmação de uma teoria em consonância com a lógica (Kothari, 2004).

O método científico define o raciocínio adotado no processo de investigação, são exemplos o método dedutivo e indutivo (Prodanov & Freitas, 2013). Enquanto que o método dedutivo permite ao investigador prever conclusões particulares através da análise de teorias, princípios e acontecimentos previamente estabelecidos (Marconi & Lakatos, 2003), ou seja, não é pretendido obter conclusões verdadeiras através de premissas verdadeiras (Carmo & Ferreira, 2008). No método indutivo, este é responsável por generalizações, a partir de dados particulares e verificados é inferida uma verdade geral ou universal (Marconi & Lakatos, 2003) em outras palavras mede um conjunto de fenómenos sociais em estudo com o objetivo de alcançar um conjunto de probabilidades que seja possível fazer comparações e descobrir possíveis relações (Carmo & Ferreira, 2008).

As abordagens tiveram um carácter indutivo, uma vez que foram testadas hipóteses, conduzidas a partir de uma amostra não probabilística por conveniência. Ou seja, o tipo de amostragem não é representativo da população, isto é, acontece quando a participação é voluntária ou a amostra é selecionada por uma questão de conveniência. A amostra do presente estudo é constituída por um conjunto de pessoas pertencentes aos seguintes grupos: profissionais de recursos humanos, gestores de equipas, investigadores académicos e gestores especialista em *People Analytics*.

A Figura 4.1 representa a estrutura do presente estudo. Primeiramente foi estudada e analisada a revisão da literatura sobre os principais temas. Seguidamente foi efetuado a componente prática com a elaboração de um inquérito através do conteúdo extraído da revisão bibliográfica e tendo em conta os objetivos das QP. Para verificar a correta aplicação dos conceitos foram realizadas reuniões com profissionais especialistas em IA, profissionais de recursos humanos, investigadores académicos e especialistas em *People Analytics*. Por fim, procedeu-se tratamento e análise dos dados obtidos no inquérito.




Figura 4.1- Design do modelo de pesquisa

Fonte: Elaboração do Autor

4.2 Modelo de Investigação

Como referido anteriormente, segundo a análise da revisão da literatura surgiram diversas hipóteses para cada QP. Com o intuito de obter respostas, foi realizado um inquérito com duas secções principais distintas, a primeira com o propósito de responder ao primeiro objetivo “Perceber quais os fatores que influenciam a possibilidade de implementar *People Analytics* na GRH” e a segunda com o intuito de responder ao segundo objetivo “Possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH”.

Para analisar as respostas obtidas no inquérito, foi aplicado um modelo de equações estruturais (*Structural Equations Model* designado por SEM), que permite estabelecer relações entre variáveis dependentes e independentes, através da combinação de análises de fatores e de regressão simultaneamente (Hair Jr., Matthews, Matthews, & Sarstedt, 2017; Sarstedt & Christian M. Ringle, 2017) medindo o efeito das variáveis independentes na dependente. SEM tem como objetivo compreender as relações entre os constructos latentes (variáveis) que são indicadas por determinadas medidas (Dash & Paul, 2021). Os constructos ou variáveis latentes, são elementos em modelos estatísticos que representam variáveis concetuais que os investigadores definem nos seus modelos teóricos. Os constructos representados por círculos em modelos de caminho são ligados por setas que representam as relações preditivas. Por sua vez, os indicadores, visualizados por retângulos são variáveis diretamente medidas ou

observadas representando os dados em bruto (respostas de inquéritos) (Sarstedt *et al.*, 2017). O modelo é normalmente utilizado para explicar múltiplas relações estatísticas paralelamente através da visualização e validação de modelos, adotando uma abordagem confirmatória em vez de uma abordagem exploratória (Dash & Paul, 2021).

A aplicação do modelo tem vindo a ter um uso crescente em diversas disciplinas inclusive nas ciências sociais e comportamentais (Sosik, Kahai, & Piovoso, 2009), auxiliando na explicação e previsão de comportamentos específicos de indivíduos, grupos ou organizações (Tarka, 2018). Reconhecendo as circunstâncias dos intervenientes, os investigadores conseguem através do modelo identificar tendências específicas de desenvolvimento e caracterizar as especificidades do meio. Uma das vantagens da utilização do modelo SEM é a facilidade no estudo de modelos complexos com diversos constructos e variáveis, especialmente quando o objetivo da análise é a previsão (Dash & Paul, 2021). Outra vantagem identificada é a elevada flexibilidade ao nível dos requisitos dos dados e das especificações nas relações entre variáveis (Sarstedt *et al.*, 2017).

Para determinar a relação causa-efeito entre as variáveis e a complexidade da realidade social, este modelo através de comparações estatísticas relevantes entre teorias e modelos suficientemente sofisticadas revela-se útil na análise individual e posteriormente agregada das questões de investigação numa discussão integrada de resultados. A SEM foi utilizada para testar o modelo concetual desenvolvido na dissertação, mais especificamente através dos mínimos quadrados parciais (*Partial Least Squares* ou PLS), técnica de modelagem de equações estruturais baseada na variância. A abordagem PLS tornou-se bastante popular entre os investigadores devido à sua relação ser baseada na variância e não pela covariância (Hair Jr. *et al.*, 2017). Para o efeito foi utilizado o *software* SmartPLS 3. A análise e interpretação de resultados teve duas etapas, primeiramente a avaliação da qualidade do modelo de medição através da análise da confiabilidade dos indicadores individuais, da validade convergente, confiabilidade de consistência interna e validade discriminante (Hair *et al.*, 2017).

O modelo concetual desenvolvido para o OE1 e QP1, tem na Figura 4.2 e Tabela 4.1 a informação utilizada para o seu desenvolvimento, sendo definido pelas seguintes hipóteses:

H1- Os benefícios gerados pela implementação de People Analytics na GRH influencia positivamente a intenção de implementar People Analytics na GRH

H1a- Os benefícios gerados pela implementação de People Analytics na GRH influencia positivamente a perceção dos utilizadores e o seu impacto no negócio e na organização

H1b- A percepção dos utilizadores e o seu impacto no negócio e na organização medeia o efeito entre os benefícios gerados pela implementação de People Analytics na GRH e a possibilidade de implementar People Analytics na GRH

H2- As limitações geradas pela implementação de People Analytics na GRH influencia negativamente a possibilidade de implementar People Analytics na GRH

H3- A percepção dos utilizadores e o seu impacto no negócio e na organização impacta positivamente a possibilidade de implementar People Analytics na GRH

O modelo concetual desenvolvido para o OE2 e QP2, tem na Figura 4.3 e Tabela 4.2 a informação utilizada para o seu desenvolvimento, sendo definido pelas seguintes hipóteses:

H1- Os benefícios gerados na retenção de talento pela utilização de People Analytics na GRH impacta positivamente a possibilidade de identificar e reter talento através da implementação de People Analytics na GRH.

H2- As limitações geradas na retenção de talento pela utilização de People Analytics na GRH impacta negativamente a possibilidade de identificar e reter talento através da implementação de People Analytics na GRH.




Figura 4.2- Modelo conceitual de Q1 e hipóteses a testar com o SmartPLS 3

Fonte: Elaboração do autor

Tabela 4.1- Relações entre variáveis do modelo conceitual de Q1 e as perguntas do inquérito

Variável Dependente		Afirmações do Inquérito (resposta de 1 a 5)
Possibilidade de Implementar <i>People Analytics</i> na GRH.		Implementar estratégias de <i>People Analytics</i> na GRH é uma mais valia para as organizações.
Variável Independente	Indicador	Afirmações do Inquérito (resposta de 1 a 5)
Perceção dos utilizadores e o seu impacto no negócio e na organização	Classificação eficiente dos processos rotineiros e estratégicos (Nawaz, 2020)	O <i>People Analytics</i> permite analisar um conjunto vasto de dados classificando eficientemente os processos rotineiros e estratégicos.
	Utilização de tecnologia na integração de dados de fontes diferenciadas na gestão de talento (Isson & Harriot, 2016; Ferrar & Green, 2021)	O <i>People Analytics</i> permite integrar dados de fontes diferenciadas na gestão do talento.
	Criação de previsões futuras na tomada de decisão (Isson & Harriot, 2016; Ferrar & Green, 2021)	O <i>People Analytics</i> permite criar previsões futuras aplicadas aos processos de tomada de decisão e planeamento estratégico das organizações.
	Aumenta a imparcialidade e diminui o preconceito (Isson & Harriot, 2016; Likhitkar & Verma, 2020)	O <i>People Analytics</i> diminui a parcialidade e o preconceito nos processos de tomada de decisão.
	Potencia o desenvolvimento de políticas e práticas de GRH alinhadas com a estratégia do negócio (Tamizharasi & Rani, 2014; Shrivastava <i>et al.</i> , 2018; Ferrar & Green, 2021)	O <i>People Analytics</i> potencia o desenvolvimento das políticas e práticas de GRH alinhadas com a estratégia do negócio.
Benefícios gerados pela implementação de <i>People Analytics</i> na GRH	Aumento da vantagem competitiva (Charan <i>et al.</i> , 2018)	A aplicação de <i>People Analytics</i> na área de RH aumenta a probabilidade de as empresas atingirem vantagem competitiva.
	Previsão de problemas complexos (Inamdar, 2021)	O <i>People Analytics</i> alinhado com a experiência e intuição humana auxilia as organizações a prever problemas organizacionais complexos.
	Melhoria da produtividade (Shrivastava <i>et al.</i> , 2018)	A análise do capital humano através de <i>People Analytics</i> é uma ferramenta com impacto na gestão e melhoria da produtividade.
	Tomada de decisão rápida com informação real e atualizada (Ferrar & Green, 2021)	A análise e gestão de dados permite diminuir o fator dúvida e arbitrário das opiniões humanas, proporcionando o aumento da rapidez e qualidade na tomada de decisão com informação real e atualizada.
Limitações geradas pela implementação de <i>People Analytics</i> na GRH	Ceticismo dos gestores ao resumir a monitorização dos colaboradores a métricas e dados (Angrave <i>et al.</i> , 2016; Davenport <i>et al.</i> , 2010)	Existe, na utilização de <i>People Analytics</i> um certo ceticismo por parte de alguns profissionais de RH na monitorização dos colaboradores ser resumida a métricas e dados.
	Implementar o <i>People Analytics</i> com uma abordagem preconcebida dos problemas empresariais (Rasmussen & Ulrich, 2015)	A definição de problemas sem recurso à análise de dados influencia negativamente a organização.
	Défice de competências analíticas (Davenport <i>et al.</i> , 2010; Harriot & Isson, 2016)	O défice de competências analíticas dos profissionais de RH limita a implementação da área de <i>People Analytics</i> na GRH.
	Dificuldade de partilha de informação na organização (Angrave <i>et al.</i> , 2016)	A dificuldade na partilha de informação, dentro da mesma organização, impede a combinação dos dados de RH com outras áreas e obstaculiza a implementação de <i>People Analytics</i> .
	Falta de monitorização, antes e depois da tomada de decisão e das medidas implementadas (Davenport <i>et al.</i> , 2010)	A ausência de monitorização, antes e depois da tomada de decisão e das medidas implementadas, impacta negativamente na melhoria contínua dos processos.
	Défice na preparação da estrutura organizacional na transformação dos dados de descritivos para prescritivos (Rasmussen & Ulrich, 2015)	O défice na preparação da estrutura organizacional impede a transformação dos dados de um nível descritivo para um nível prescritivo, com impacto significativo para as organizações.

Fonte: Elaboração do autor




Figura 4.3- Modelo concetual de Q2 e hipóteses a testar com o SmartPLS 3

Fonte: Elaboração do autor

Tabela 4.2- Relações entre variáveis do modelo concetual de Q2 e as perguntas do inquérito

Variável Dependente		Afirmações do Inquérito (resposta de 1 a 5)
Possibilidade de identificar e reter talento através da implementação de <i>People Analytics</i> na GRH.		É uma mais valia para as organizações, identificar e reter talento através da implementação de estratégias de <i>People Analytics</i> na GRH.
Variável Independente	Indicador	Afirmações do Inquérito (resposta de 1 a 5)
Benefícios gerados na retenção de talento pela utilização de <i>People Analytics</i> na GRH	Identificar o talento que deve ser desenvolvido, recompensado, promovido e retido (Ferrar & Green, 2021; Grillo, 2015)	O <i>People Analytics</i> facilita a identificação do talento que deve ser desenvolvido, recompensado, promovido e retido nas organizações.
	Identificar as principais fontes para atrair e reter talento (Grillo, 2015)	O <i>People Analytics</i> possibilita a identificação mais eficiente das principais fontes de como atrair e reter talento.
	Desenvolver o <i>engagement</i> na organização (Isson & Harriot, 2016)	Com o <i>People Analytics</i> , as organizações conseguem perceber como aumentar o nível de <i>engagement</i> .
	Calcular o prejuízo resultante da rotatividade (Isson & Harriot, 2016)	O <i>People Analytics</i> permite calcular o prejuízo resultante da rotatividade e o seu impacto.
	Classificar o nível de desgaste de cada colaborador através de um modelo preditivo, com a capacidade de identificar elevados desempenhos e assegurar a sua retenção e <i>engagement</i> (King, 2016; Ferrar & Green, 2021; Holtom & Allen 2019; Rosenbaum, 2019)	Com a introdução de estratégias de <i>People Analytics</i> é possível classificar o nível de desgaste de cada colaborador em tempo real.
	Organizar proativamente o processo de retenção de talento e implementar práticas personalizadas de acordo com o perfil de cada colaborador (Shrivastava <i>et al.</i> , 2018; Ferrar & Green, 2021)	O <i>People Analytics</i> permite implementar práticas personalizadas que conduzam à satisfação dos colaboradores de acordo com o seu perfil.
Limitações geradas na retenção de talento pela utilização de <i>People Analytics</i> na GRH	Manipulação das métricas para obter os resultados esperados e a utilização de métricas simplistas que geralmente não conseguem prever com precisão os resultados de determinados indicadores (Davenport <i>et al.</i> , 2010)	A manipulação do cálculo das métricas, bem como a utilização simplista das mesmas, limita a precisão dos indicadores no output das estratégias de <i>People Analytics</i> .
	Considerar a lei e a ética durante a monitorização e recolha de dados (Inamdar, 2021)	Considerar a lei e a ética durante a monitorização e recolha de dados é uma condicionante na eficácia de <i>People Analytics</i> .
	Ausência de Alinhamento Estratégico (Angrave <i>et al.</i> , 2016; Harriot & Isson, 2016)	A ausência de suporte executivo impacta negativamente na implementação de estratégias de <i>People Analytics</i> nas organizações.
	Ferramentas e processos desintegrados (Angrave <i>et al.</i> , 2016)	Uma das principais limitações na implementação de <i>People Analytics</i> é a utilização de sistemas e ferramentas desintegradas dificultando a análise e obtenção de resultados.
	Défice de dados fundamentais (Yahia <i>et al.</i> , 2021)	Determinadas organizações podem ter dificuldade na implementação de estratégias de <i>People Analytics</i> devido ao défice de dados relevantes.

Fonte: Elaboração do autor

4.3 Inquérito

A população-alvo da presente dissertação é constituída por portugueses, a trabalhar em Portugal, com contacto profissional (direto e/ou indireto) e/ou académico com a área de recursos humanos e de *People Analytics*. A amostra contém profissionais de recursos humanos, gestores de equipas, investigadores académicos e gestores especialista em *People Analytics*. Na recolha de dados foi desenvolvido um inquérito alinhado com os conceitos e modelos da revisão da literatura. Antes da sua publicação o inquérito foi analisado e revisto, através de duas etapas.

A primeira, relativamente à abordagem empregue na criação do modelo através da revisão da literatura. Para tal, primeiramente reuni com um especialista em IA para perceber se a aplicação dos conceitos estava atualizada e em conformidade com a prática. Posteriormente reuni com um profissional de recursos humanos e com três investigadores académicos para validar os conceitos e pressupostos na criação dos modelos. Por fim, reuni com um gestor especialista em *People Analytics* onde obtive a validação do modelo final, bem como do respetivo inquérito e com quatro gestores de equipa afim de averiguar se a linguagem estava elegível o suficiente para líderes de outras áreas. No decorrer da partilha do inquérito, em conversas informais via LinkedIn, alguns dos inquiridos voluntariaram-se pela relevância do estudo em partilhar a sua experiência e conhecimento sobre os tópicos abordados.

Na segunda etapa foi realizado um pré-teste antes da submissão do questionário, a uma amostra de conveniência, afim de obter *insights* em relação ao design, estrutura e conteúdo. Este teve como base uma estrutura com quatro secções. Primeiramente uma secção introdutória a especificar os objetivos do estudo, a duração do preenchimento, a amostra selecionada, a escala de 1 a 5, sendo 1 discordo plenamente e 5 concordo plenamente (Likert, 1932), bem como a conduta ética e legal seguida na recolha e tratamento de dados da presente investigação científica. Com o objetivo de caracterizar a amostra, o inquérito começou com perguntas sociodemográficas. Posteriormente, foi dividido em duas secções, a primeira destinada à QP1 e a segunda à QP2 (Tabela 4.1 e 4.2), cada uma subdividida pelas variáveis independentes correspondentes.

O inquérito foi desenvolvido via Google Forms e partilhado via LinkedIn e WhatsApp, entre 26 de Maio a 16 de Junho de 2022, tendo sido recolhidas, no total, 106 respostas durante o respetivo período.

4.4 Descrição da Amostra

Com o objetivo de caracterizar a população da amostra, com 106 participantes, foram elaboradas questões sociodemográficas relativamente ao género, idade, nível de escolaridade, anos de experiência e área profissional. O inquérito foi totalmente anónimo, a recolha deste tipo de dados é importante para perceber as características da população em estudo em relação à sua natureza e heterogeneidade de dados, bem como relativamente às conclusões teóricas e empíricas retiradas no estudo. Relativamente ao género, a distribuição da amostra contém 51 pessoas (48%) do sexo feminino enquanto que 55 (52%) representam o sexo masculino. Em relação à idade (em anos) dos inquiridos, 45 (43%) têm “entre 18 e 24”, 28 (26%) têm “entre 25 e 31”, 13 (12%) têm “entre 32 e 40”, 15 (14%) têm “entre 41 e 53” e 5 (5%) têm “mais de 53 anos”. Quanto às habilitações académicas, 8 (7%) têm o secundário, 52 (49%) têm a licenciatura, 43 (41%) têm o mestrado e 3 (3%) têm o doutoramento. Sobre os dados dos anos de experiência da amostra, 22 (21%) têm “menos de 1” ano de experiência, 23 (22%) têm “entre 1 a 2” anos, 23 (22%) têm “entre 3 a 5” anos, 11 (10%) têm “entre 6 a 10” anos e 27 (25%) têm “mais de 10” anos. Sobre a área profissional, 53 (50%) são profissionais de recursos humanos, 24 (22%) são gestores/ as de equipa, 5 (5%) investigadores/ as académicos/as e 24 (23%) são gestores/as especialistas em *People Analytics*.

Tabela 2.3- Caracterização sociodemográfica da amostra

		N	%
Género	Feminino	51	48
	Masculino	55	52
Faixa etária	18-24	45	43
	25-31	28	26
	32-40	13	12
	41-53	15	14
	>53	5	5
Nível de formação	Secundário	8	7
	Licenciatura	52	49
	Mestrado	43	41
	Doutoramento	3	3
Anos de experiência	<1	22	21
	1-2	23	22
	3-5	23	22
	6-10	11	10
	>10	27	25
Área profissional	Profissional de recursos humanos	53	50
	Gestor/a de equipa	24	22
	Investigador/a académico/a	5	5
	Gestor/a especialista em <i>People Analytics</i>	24	23

Fonte: Elaboração do autor

CAPÍTULO V - APRESENTAÇÃO E DISCUSSÃO DE RESULTADOS

5.1 QP1- Qual a possibilidade de implementar *People Analytics* na GRH?

5.1.1 Análise Estatística

Relativamente ao modelo conceitual criado em relação à primeira questão de pesquisa “Qual a possibilidade de implementar *People Analytics* na GRH?”, este foi testado através de um inquérito online com uma escala de Likert de 1 a 5 (Likert, 1932). Depois dos resultados obtidos, o modelo conceitual foi testado com o modelo SEM, mais especificamente o estudo dos mínimos quadrados parciais (PLS), caracterizada por ser uma técnica que estuda a variância através do Smart PLS 3 (Ringle, Wende, & Will, 2015). Primeiramente, foi avaliada a fiabilidade e validade do modelo para posteriormente avaliar o modelo estrutural.

Para tal, foram avaliados os indicadores individuais de fiabilidade, a fiabilidade de consistência interna, a validade convergente e a validade discriminante (Hair, Hult, Ringle, & Sarstedt, 2017). Os resultados evidenciaram que as cargas fatoriais padronizadas de todos os indicadores estavam acima de 0.6 à exceção do indicador “ceticismo dos gestores ao resumir a monitorização dos colaboradores a métricas e dados” (Angrave *et al.*, 2016; Davenport *et al.*, 2010) com um valor de 0.242. Após o indicador ser removido a fiabilidade foi assegurada uma vez que a carga dos fatores padronizados de cada indicador individualmente era superior a 0.6 (Tabela 5.1) (Hair *et al.*, 2017). Relativamente à fiabilidade de consistência interna, esta foi assegurada, uma vez que todos os valores de Cronbach *alphas* (α) e de fiabilidade composta (*Composite Reliability* ou CR) dos constructos ultrapassaram o valor mínimo de 0.7 (Hair *et al.*, 2017), conforme exposto na Tabela 5.1.

Tabela 3.1- Verificações de CR, AVE, correlações e validade discriminante de Q1

Variáveis Latentes	α	CR	AVE	1	2	3	4
(1) Benefícios de Implementar PA	0.799	0.869	0.625	0.791	0.613	0.826	0.616
(2) Limitações de Implementar PA	0.815	0.872	0.578	0.613	0.760	0.566	0.470
(3) Percepção de Implementar PA	0.778	0.850	0.534	0.826	0.566	0.731	0.624
(4) Possibilidade de Implementar PA	1.000	1.000	1.000	0.616	0.470	0.624	1.000

Nota: α - Cronbach Alpha; CR- Fiabilidade composta; AVE- Variância média extraída. Os números a negrito representam as raízes quadradas de AVE. Abaixo dos elementos a negrito na diagonal estão as correlações entre os constructos. Acima dos elementos estão os valores de HTMT.

Fonte: Elaboração do autor

A validade convergente foi confirmada por três razões. As duas primeiras razões foram verificadas anteriormente, na medida que foi provada a fiabilidade dos indicadores individuais, bem como a fiabilidade da consistência interna. A terceira razão está evidenciada na Tabela 5.1, a variância média extraída (AVE) para todos os constructos excedeu 0.50 (Bagozzi & Yi, 1988).

Para avaliar a validade discriminante, foi utilizado primeiramente o critério de Fornier e Larcker, que requer que a raiz quadrada de AVE de um constructo (exposto na diagonal com os valores a negrito na Tabela 5.1. Em segundo lugar, utilizou-se o critério do rácio HTMT (*Heterotrait-Monotrait ratio*) (Hair *et al.*, 2017; Henseler, Ringle, & Sarstedt, 2015). Como representado na Tabela 5.1, todos os rácios HTMT são inferiores a 0.85 (Hair *et al.*, 2017; Henseler *et al.*, 2015).

O modelo estrutural foi também avaliado utilizando o sinal, magnitude e significância dos coeficientes do caminho estrutural; a magnitude do valor de R^2 para cada variável endógena como uma medida da precisão preditiva do modelo; e os valores Q^2 de Stone-Geisser como uma medida da relevância preditiva do modelo (Hair *et al.*, 2017). Verificou-se ainda a colinearidade antes de avaliar o modelo estrutural (Hair *et al.*, 2017). Os valores VIF (*Variance Inflation Factor*), não indicaram colinearidade, variaram entre 1.000 e 2.077, todos inferiores ao valor crítico de 5 (Hair *et al.*, 2017).

O coeficiente de determinação R^2 relativamente às duas variáveis endógenas, da perceção dos utilizadores e o seu impacto no negócio e na organização bem como a possibilidade de implementar *People Analytics* na GRH foram de 68.2% e 43.0% respetivamente, ultrapassando o valor mínimo de 10% (Falk & Miller, 1992). Os valores de Q^2 para as variáveis endógenas (0.357 e 0.393, respetivamente) foram acima de zero, o que indica a relevância preditiva do modelo (Hair *et al.*, 2017).

5.1.2 Resultados Quantitativos

Os resultados da Tabela 5.2 evidenciam que os benefícios de implementar PA na GRH têm um efeito significativamente positivo na perceção dos utilizadores e o seu impacto no negócio e na organização ($\beta = 0.829$, $p < 0.001$), bem como na possibilidade de implementar PA na GRH ($\beta = 0.258$, $p < 0.05$). Os resultados confirmam as hipóteses H1a e H1. No caso das limitações de implementar PA na GRH não se pode comprovar estatisticamente que estas tenham impacto na implementação de PA na GRH, ou seja, o nosso modelo não apoia a hipótese H2 ($\beta = 0.137$, $p > 0.05$), uma vez que o valor de p é superior a 0.05. Por fim, a perceção dos utilizadores e o seu

impacto no negócio e na organização tem um efeito significativamente positivo na possibilidade de implementar PA na GRH ($\beta=0.337$, $p < 0.05$), suportando a hipótese H3.

Tabela 5.2- Avaliação do modelo estrutural de Q1

Path	Path Coefficient	Standard Deviation	t statistics	p values
Benefícios de Implementar PA -> Percepção de Implementar PA	0.829	0.030	27.788	0.000
Benefícios de Implementar PA-> Possibilidade de Implementar PA	0.258	0.141	1.888	0.049
Limitações de Implementar PA -> Possibilidade de Implementar PA	0.137	0.106	1.090	0.276
Percepção de Implementar PA -> Possibilidade de Implementar PA	0.337	0.138	2.452	0.014

Fonte: Elaboração do autor

Com o objetivo de testar a hipótese de mediação (H1b), foi utilizado um procedimento de *bootstrapping* no SmartPLS3 (Hair et al., 2017; Preacher & Hayes, 2008). A Tabela 5.3 apresenta o resultado do efeito de mediação. Os efeitos indiretos associados aos benefícios gerados pela implementação de PA na GRH por meio do mediador percepção dos utilizadores e o seu impacto no negócio e na organização são significativos ($\beta= 0.285$, $p < 0.05$), apoiando a hipótese H1b.

Tabela 5.3- Resultados do Bootstrap para os efeitos indiretos dos constructos de Q1

Efeitos Indiretos	Estimate	Standard Deviation	t statistics	p values
Benefícios gerados de Implementar PA-> Percepção de Implementar PA -> Possibilidade de Implementar PA	0.285	0.120	2.334	0.020

Fonte: Elaboração do autor

5.1.3 Discussão de Resultados

O modelo concetual desenvolvido pretende responder à primeira questão de pesquisa -*Qual a possibilidade de implementar People Analytics na GRH?* Como demonstrado na Figura 4.1, foram identificados com base na revisão da literatura três constructos, nomeadamente 1) a percepção dos utilizadores e o seu impacto no negócio e na organização (Nawaz, 2020; Isson & Harriot, 2016; Ferrar & Green, 2021; Likhitar & Verma, 2020; Tamizharasi & Rani, 2014; Shrivastava *et al.*, 2018), 2) os benefícios de implementar PA na GRH (Charan *et al.*, 2018;

Inamdar, 2021; Shrivastava *et al.*, 2018; Ferrar & Green, 2021), 3) as limitações de implementar PA na GRH (Angrave *et al.*, 2016; Davenport *et al.*, 2010; Isson & Harriot, 2016; Rasmussen & Ulrich, 2015; Ferrar & Green, 2021). A variável referente à possibilidade de implementar *People Analytics* na GRH, foi baseada no inquérito em linha e foi adicionada para testar o nosso modelo. As variáveis latentes identificadas anteriormente foram testadas com o SmartPLS 3 (Ringle *et al.*, 2015). A fiabilidade individual de cada indicador pertencente a cada fator, foi provada, ou seja, os indicadores foram considerados como fiáveis e relevantes para o estudo, ao atingirem valores acima de 0.6 e todos significativos a $p < 0.001$ (Hair *et al.*, 2017).

Relativamente à perceção dos utilizadores e o seu impacto no negócio e na organização em relação à implementação de *People Analytics* na GRH, foi percecionado pelos resultados os indicadores com mais impacto tendo em conta a sua classificação. Por ordem decrescente em relação aos indicadores com mais relevância apoiados pela literatura identificada, os resultados provaram que o indicador referente ao “desenvolvimento de políticas e práticas de GRH alinhadas com a estratégia de negócio” (Ferrar & Green, 2021; Tamizharasi & Rani, 2014; Shrivastava *et al.*, 2018) obteve um valor de 0.796, posteriormente o indicador “classificação eficiente dos processos rotineiros e estratégicos” (Nawaz, 2020) com um valor de 0.794, o indicador “criação de previsões futuras na tomada de decisão” (Isson & Harriot, 2016; Ferrar & Green, 2021) com 0.774, o indicador “integração de dados de fontes diferenciadas na gestão de talento” (Isson & Harriot, 2016; Ferrar & Green, 2021) com 0.675 e por último o indicador referente à “diminuição da parcialidade e preconceito” nos processos de tomada de decisão (Likhitar & Verma, 2020; Isson & Harriot, 2016), com um valor de 0.600.

Em relação aos benefícios gerados pela implementação de *People Analytics* na GRH, os resultados estão em consonância com a revisão da literatura estudada pelos autores. Após a classificação, os resultados demonstraram que os indicadores com maior relevância foram: a “previsão de problemas complexos” (Inamdar, 2021) com um valor de 0.838, o indicador “aumento da vantagem competitiva” (Charan *et al.*, 2018) com uma classificação de 0.786, o indicador “tomada de decisão rápida com informação real e atualizada” (Ferrar & Green, 2021) com 0.772 e por último a “melhoria da produtividade” com 0.764. As evidências provenientes da revisão da literatura demonstram que os benefícios são importantes para a aplicação de *People Analytics* nas organizações bem como para o aumento de interesse sobre o tema, contribuindo para a possibilidade de implementar *People Analytics* na gestão de recursos humanos.

Quanto às limitações geradas pela implementação de *People Analytics* na GRH, os resultados estão em linha com a revisão da literatura estudada, à exceção de um indicador. De

acordo com a classificação dos indicadores, os resultados provaram que os indicadores com maior relevância foram: a “dificuldade na partilha de informação nas organizações” (Angrave *et al.*, 2016) com um valor de 0.816, “défice de competências analíticas” (Davenport *et al.*, 2010; Isson & Harriot, 2016; Rasmussen & Ulrich, 2015; Ferrar & Green, 2021) com 0.809, “défice na estrutura organizacional na transformação dos dados descritivos para prescritivos” (Rasmussen & Ulrich, 2015) com 0.799, “ausência de monitorização, antes e depois da tomada de decisão e das medidas implementadas” (Davenport *et al.*, 2010) com 0.686 e por último a “abordagem preconcebida dos problemas organizacionais” (Rasmussen & Ulrich, 2015) com 0.678. De acordo com o modelo concetual o indicador “ceticismo dos gestores ao resumir a monitorização dos colaboradores a métricas e dados” (Angrave *et al.*, 2016; Davenport *et al.*, 2010) na influência de implementar *People Analytics* na GRH, tendo sido excluído do modelo.

Após identificar os três principais fatores com impacto na possibilidade de implementar *People Analytics* na GRH, procedeu-se à testagem de hipóteses formuladas no capítulo da metodologia. No que se refere aos efeitos diretos do modelo concetual (Tabela 5.2), os resultados demonstram que os benefícios gerados pela implementação de *People Analytics* na GRH impactam positivamente na perceção dos utilizadores e o seu impacto no negócio e na organização, confirmando a hipótese H1a do modelo. Ou seja, como referido pelos autores quanto maior for a perceção e impacto dos benefícios de implementar *People Analytics* nas organizações mais predisposição e consciência das potenciais mais valias existirá para implementar eficazmente este tipo de sistema. As pessoas são o “ativo” mais importante para o negócio, portanto as decisões que impactem os colaboradores têm um impacto único e direto no negócio (Ferrar & Green, 2021; Shrivastava *et al.*, 2018; Isson & Harriot, 2016). Como demonstrado existe cada vez mais a perceção real sobre a necessidade e os benefícios associados à implementação de *People Analytics*, é, no entanto, preciso igualmente aumentar o conhecimento profundo sobre este tipo de tecnologia por forma a potenciar a sua utilização na prática (Charan *et al.*, 2018, Ferrar & Green, 2021, Nawaz, 2020; Deloitte, 2014; Rasmussen & Ulrich, 2015).

Com base nos resultados é possível concluir que os benefícios gerados pela implementação de PA na GRH impactam positivamente na possibilidade de implementar PA na GRH, confirma assim a H1 do modelo. A consciência dos benefícios aumenta a disponibilidade e aceitação por parte das organizações em implementar *People Analytics*, são diversos os potenciais benefícios associados, como a previsão de problemas complexos, o aumento da vantagem competitiva e a tomada de decisão com informação real e atualizada (Inamdar, 2021; Charan *et al.*, 2018; Ferrar & Green, 2021).

Os resultados não corroboram a revisão da literatura, não apoiando a hipótese H2 referente às limitações geradas pela implementação de PA na GRH impactarem negativamente a implementação de *People Analytics*, tal facto pode ser justificado através da revisão da literatura pela subutilização ainda na prática e a falta de investigação representando apenas 2% dos estudos no campo da gestão (Sheng *et al.*, 2017). No entanto, é importante frisar o otimismo em relação às potenciais limitações não serem um fator limitativo, , mas sim encaradas como um desafio, sendo que a mentalidade deve estar na prática direcionada para a mudança e não apenas na teoria (Rasmussen & Ulrich, 2015).

Por fim, os resultados relativos à percepção dos utilizadores e o seu impacto no negócio e na organização têm um efeito significativamente positivo na possibilidade de implementar PA na GRH, suportando a hipótese H3. O alinhamento organizacional relativamente à percepção dos utilizadores sobre os efeitos positivos de implementar *People Analytics* no negócio e na organização irá como demonstrado na (Figura 4.2) motivar a sua implementação. Existe uma percepção positiva dos utilizadores em relação à entrega de valor proveniente da utilização de *People Analytics* nas diferentes áreas do negócio (Ferrar & Green, 2021).

Quanto ao estudo dos efeitos indiretos da hipótese H1b (Tabela 5.3), associados aos benefícios gerados pela implementação de PA na GRH por meio do mediador percepção dos utilizadores e o seu impacto no negócio e na organização, no qual os resultados provam uma influência significativamente positiva. É possível afirmar que os esforços e investimento nos benefícios gerados pela implementação de *People Analytics* na GRH, têm a capacidade de impactar positivamente no grau de percepção da utilização e do impacto desta tecnologia no negócio e na organização, potenciando a possibilidade da sua implementação, tal como é defendido pelos autores (Ferrar & Green, 2021; Rasmussen & Ulrich, 2015; Inamdar, 2021; Charan *et al.*, 2018; Nawaz, 2020).

5.2 QP2- Qual a possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH?

5.2.1 Análise Estatística

O modelo concetual criado relativamente à segunda questão de pesquisa “*Qual a possibilidade de identificar e reter talento através da implementação de People Analytics na GRH?*” foi testado através de um inquérito online com uma escala de Likert de 1 a 5 (Likert, 1932). Após a recolha e tratamento dos dados obtidos o modelo concetual foi testado utilizando a modelação

de equações estruturais (SEM), mais especificamente o estudo dos mínimos quadrados parciais (PLS) através da utilização do software SmartPLS 3 (Ringle *et al.*, 2015), como referido anteriormente. Em primeiro lugar, foi avaliada a fiabilidade e validade do modelo de medição para posteriormente avaliar o modelo estrutural. Deste modo, para aferir a qualidade do modelo de medição, examinaram-se os indicadores individuais de fiabilidade, a fiabilidade de consistência interna, a validade convergente e a validade discriminante (Hair *et al.*, 2017).

Os resultados demonstraram que as cargas fatoriais padronizadas de todos os indicadores estavam acima de 0.6 e eram todos significativos a $p < 0.001$, verificando a fiabilidade dos indicadores individuais (Tabela 5.4) (Hair *et al.*, 2017). Os constructos demonstram possuir fiabilidade de consistência interna porque todos os valores de Cronbach alphas e de fiabilidade composta dos constructos ultrapassaram o valor mínimo de 0.7 (Hair *et al.*, 2017), conforme demonstrado na Tabela 5.4.

Tabela 5.4- Verificações de CR, AVE, correlações e validade discriminante de Q2

Variáveis Latentes	α	CR	AVE	1	2	3
(1)Benefícios na RT de utilizar PA	0.866	0.897	0.594	0.771	0.574	0.418
(2)Limitações na RT de utilizar PA	0.712	0.802	0.451	0.574	0.672	0.391
(3)Possibilidade de identificar/ reter talento por Implementar PA	1.000	1.000	1.000	0.418	0.391	1.000

Nota: α - Cronbach Alpha; CR- Fiabilidade composta; AVE- Variância média extraída. Os números a negrito representam as raízes quadradas de AVE. Abaixo dos elementos a negrito na diagonal estão as correlações entre os constructos. Acima dos elementos estão os valores HTMT.

Fonte: Elaboração do autor

A validade convergente foi confirmada tendo em consideração três razões. Primeiramente todos os indicadores foram positivos e significativos nos seus respetivos constructos, provando a fiabilidade dos indicadores individuais. Seguidamente os constructos demonstraram ter fiabilidade de consistência interna. As duas primeiras razões foram confirmadas anteriormente. A terceira razão, identificada na Tabela 5.4, demonstra que AVE para todos os constructos excedeu 0.50 (Bagozzi & Yi, 1988), à exceção de um constructo (“Limitações geradas na retenção de talento pela utilização de PA”) em que o respetivo valor 0.451 estava ligeiramente abaixo de 0.50. No entanto, a validade convergente é confirmada, uma vez que a fiabilidade composta é de 0.802, suficientemente forte para mitigar este valor (Fornell & Larcker, 1981).

Com o objetivo de avaliar a validade discriminante, foi utilizado em primeiro lugar o critério de Fornier e Larcker, que requer que a raiz quadrada de um constructo de AVE (exposto

na diagonal com os valores a negrito na Tabela 5.4) seja maior do que a sua maior correlação com qualquer constructo (Fornell & Larcker, 1981). A Tabela 5.4 demonstra que este critério é satisfeito para todas as construções. Em segundo lugar, utilizamos o critério do rácio HTMT (Hair *et al.*, 2017; Henseler *et al.*, 2015). Como representado na Tabela 5.4, todos os rácios HTMT são inferiores a 0.85 (Hair *et al.*, 2017; Henseler *et al.*, 2015).

O modelo estrutural foi também avaliado utilizando o sinal, magnitude e significância dos coeficientes do caminho estrutural; a magnitude do valor de R^2 para cada variável endógena como uma medida da precisão preditiva do modelo; e os valores Q^2 de Stone-Geisser como uma medida da relevância preditiva do modelo (Hair *et al.*, 2017). Verificou-se ainda a colinearidade antes de avaliar o modelo estrutural (Hair *et al.*, 2017). Os valores VIF não identificaram colinearidade, situando-se entre 1.211 e 3.146, todos inferiores ao valor crítico de 5 (Hair *et al.*, 2017). O coeficiente de determinação R^2 relativamente à variável endógenas, da possibilidade de identificar e reter talento através da implementação de PA na GRH foi de 20.9%, ultrapassando o valor mínimo de 10% (Falk & Miller, 1992). O valor de Q^2 para a variável endógena (0.158) foi acima de zero, o que indica a relevância preditiva do modelo (Hair *et al.*, 2017).

5.2.2 Resultados Quantitativos

Os resultados da Tabela 5.5 evidenciam que os benefícios gerados na retenção de talento pela utilização de PA na GRH têm um efeito significativamente positivo na possibilidade de identificar e reter talento através da implementação de PA na GRH ($\beta = 0.289$, $p < 0.05$). Os resultados confirmam a hipótese H1. Quanto às limitações geradas na retenção de talento pela utilização de PA na GRH existe impacto na possibilidade de identificar e reter talento através da implementação de PA na GRH ($\beta = 0.251$, $p < 0.05$), suportando a hipótese H2.

Tabela 5.5- Avaliação do modelo estrutural Q2

Path	Path coefficient	Standard Deviation	t statistics	p values
Benefícios na RT de utilizar PA -> Possibilidade de identificar/reter talento por Implementar PA	0.289	0.097	2.974	0.003
Limitações na RT de utilizar PA -> Possibilidade de identificar/reter talento por Implementar PA	0.251	0.096	2.327	0.020

Fonte: Elaboração do autor

5.2.3. Discussão de Resultados

O modelo conceitual desenvolvido pretende responder à segunda questão de pesquisa - *Qual a possibilidade de identificar e reter talento através da implementação de People Analytics na GRH?* Como demonstrado na Figura 4.3, foram identificados com base na revisão da literatura dois constructos, nomeadamente 1) benefícios gerados na retenção de talento pela utilização de PA na GRH (Isson & Harriot, 2016; Grillo, 2015; King, 2016; Shrivastava *et al.*, 2018; Ferrar & Green, 2021; Holtom & Allen, 2019; Rosenbaum, 2019) e 2) limitações geradas na retenção de talento pela utilização de PA na GRH (Davenport *et al.*, 2010; Angrave *et al.*, 2016; Isson & Harriot, 2016; Inamdar, 2021; Yahia *et al.*, 2021). A variável referente à possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH, foi baseada no inquérito em linha e foi adicionada para testar o modelo conceitual. As variáveis latentes identificadas anteriormente foram testadas com o SmartPLS 3 (Ringle *et al.*, 2015). A fiabilidade individual de cada indicador pertencente a cada fator, foi provada, ou seja, os indicadores foram considerados como fiáveis e relevantes para o estudo, ao atingirem valores acima de 0.6 e todos significativos a $p < 0.001$ (Hair *et al.*, 2017).

Relativamente aos benefícios gerados na retenção de talento pela utilização de PA na GRH, foi percecionado pelos resultados os indicadores com mais impacto tendo em conta a sua classificação. Os resultados provaram que o indicador referente ao “desenvolvimento do *engagement* na organização” (Isson & Harriot, 2016) obteve um valor de 0.820, posteriormente o indicador “identificar as principais fontes para atrair e reter talento” (Grillo, 2015) com um valor de 0.807, o indicador “organizar proativamente o processo de retenção de talento e implementar práticas personalizadas de acordo com o perfil de cada colaborador” (Shrivastava *et al.*, 2018; Ferrar & Green, 2021) com 0.805, o indicador “classificar o nível de desgaste de cada colaborador através de um modelo preditivo” (Isson & Harriot, 2016; Ferrar & Green, 2021; Holtom & Allen, 2019) com 0.747, o indicador referente ao “cálculo do prejuízo resultante da rotatividade” nos processos de tomada de decisão (Isson & Harriot, 2016), com um valor de 0.734 e por último o indicador “identificar o talento que deve ser desenvolvido, recompensado, promovido e retido” (Ferrar & Green, 2021; Grillo, 2015) com um valor de 0.704.

Quanto às limitações geradas na retenção de talento pela utilização de PA na GRH, os resultados estão em linha com a revisão da literatura estudada. De acordo com a classificação dos indicadores, os resultados provaram que os indicadores com maior relevância foram: a “falta de alinhamento estratégico” (Angrave *et al.*, 2016 Isson & Harriot, 2016) com um valor de 0.815, o “défice de dados fundamentais” (Yahia *et al.*, 2021) com um valor de 0.689,

“ferramentas e processos desintegrados” (Angrave *et al.*, 2016) com um valor de 0.643,”manipulação das métricas para obter os resultados esperados e a utilização de métricas simplistas que geralmente não conseguem prever com precisão os resultados de determinados indicadores” (Davenport *et al.*, 2010) com um valor de 0.603 e “considerar a lei e a ética durante a monitorização e recolha de dados” (Inamdar, 2021) com um valor de 0.600.

Após identificar os principais fatores com impacto na possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH, avançou-se para a testagem de hipóteses formuladas no capítulo da metodologia. No que se refere aos efeitos diretos do modelo concetual (Tabela 5.5), os resultados demonstram que os benefícios gerados na retenção de talento pela utilização de *People Analytics* na GRH impactam positivamente na possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH, confirmando a hipótese H1 do modelo. Como provado a evidência dos benefícios na retenção de talento pela implementação de *People Analytics* aumentam a probabilidade da sua implementação, pois permite às organizações desenvolver o *engagement*, identificar as principais fontes para atrair e reter talento, personalizar as práticas de RH de forma a responder às necessidades dos colaboradores, bem como prever o nível de desgaste de cada colaborador em tempo real (Isson & Harriot, 2016; Grillo, 2015; Shrivastava *et al.*, 2018; Ferrar & Green, 2021; Holtom & Allen, 2019). Diversas empresas que implementaram *People Analytics* conseguem prever a intenção de saída dos colaboradores através de análises preditivas com a prescrição de ações no sentido de reter ou contratar em tempo real, os resultados demonstraram que as previsões atingiram um intervalo de precisão de 95% (Rosenbaum, 2019). Os benefícios cada vez mais percecionados da implementação de *People Analytics* aumentam consideravelmente a possibilidade de adotar por parte das organizações este tipo de sistemas.

Os resultados relativamente às limitações geradas na retenção de talento pela utilização de PA na GRH impactam negativamente na possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH, suportando a hipótese H2. Apesar dos benefícios inerentes à implementação de *People Analytics* na GRH existem algumas limitações associadas, conforme expresso na literatura estudada. As limitações impedem que muitas vezes a identificação e retenção de talento através da implementação de *People Analytics* seja bem-sucedida, devido a determinados riscos, desafios e limitações, ou pré-requisitos não cumpridos antes, durante e após a implementação, tais como, a falta de alinhamento estratégico, défice na existência de dados fundamentais, ferramentas e processos desintegrados, bem como a manipulação das métricas e a utilização simplista das mesmas (Angrave *et al.*, 2016 Isson & Harriot, 2016; Yahia *et al.*, 2021; Davenport *et al.*, 2010).

CAPÍTULO VI - CONCLUSÃO

6.1 Considerações Finais

As organizações sofrem o impacto da dinâmica global e são grandemente influenciadas pelo contexto socioeconómico, político e geográfico em que se situam. Assim, para conseguirem ser competitivas e dar resposta aos desafios com vantagem competitiva, tornou-se fundamental adaptar estratégias em tempo real (Inamdar, 2021). Na prossecução desses objetivos, possuir uma força de trabalho adequada (*enablement*) às exigências, num ambiente colaborativo (*engagement*) e dinâmico passou a ser essencial (Assensoh-Kodua, 2019). A gestão eficaz do *know-how* requer a capacidade por parte das organizações de identificar, integrar, compensar e manter talento (Ulrich, 1998). Nesse sentido a área de RH é cada vez mais percecionada como estratégica para dar resposta às necessidades de antecipar os desafios das organizações, dos seus colaboradores, dos *stakeholders* e dos restantes *players* em mercado. Foi através da utilização de Inteligência Artificial, *Big Data* e *Business Intelligence* e da articulação com a área de RH que espoltou o *People Analytics* (Ferrar & Green, 2021).

A presente investigação teve como principal propósito o estudo do impacto do *People Analytics* na GRH, com o impacto e eficácia na identificação e retenção de talento. Um dos principais desafios a ser compreendido e solucionado nas organizações. No seguimento da revisão da literatura sobre os principais temas, Inteligência Artificial, Gestão de Recursos Humanos, Retenção de Talento e *People Analytics* e após a análise do inquérito com uma amostra de 106 respostas, na população-alvo em Portugal. Foi o objetivo principal, poder avaliar a perceção e opinião dos participantes, tendo em conta a sua experiência e conhecimento, relativamente à importância e impacto que o *People Analytics* tem para as pessoas, os negócios e as organizações. Confrontando os resultados com as várias teorias analisadas e verificadas a partir da revisão bibliográfica. As hipóteses formuladas, com exceção de uma, foram confirmadas, apresentando as restantes uma relação forte e positiva entre a vontade e possibilidade de implementar *People Analytics* nas organizações.

A formulação e validação das hipóteses propostas foi possível através da análise estatística das respostas ao inquérito. Em relação ao primeiro objetivo que se focou em perceber quais os fatores que mais influenciam a possibilidade de implementar *People Analytics* na GRH, referente à primeira questão de pesquisa - *Qual a possibilidade de implementar People Analytics na GRH?*, foi possível concluir através da análise do modelo concetual, criado e testado, que os principais constructos que influenciam a possibilidade de implementar são, os

benefícios inerentes à implementação de PA e a percepção dos utilizadores e o seu impacto no negócio e na organização, por outro lado não foi provado que as limitações de implementar PA, têm uma influência significativa nessa possibilidade.

Relativamente à percepção dos utilizadores e o seu impacto no negócio e na organização, os resultados mostram-se alinhados com a teoria, este fator é suportado pelos seguintes indicadores: desenvolver políticas e práticas de GRH alinhadas com a estratégia de negócio (Ferrar & Green, 2021; Tamizharasi & Rani, 2014; Shrivastava *et al.*, 2018), classificação eficiente dos processos rotineiros e estratégicos (Nawaz, 2020), criação de previsões futuras na tomada de decisão (Isson & Harriot, 2016; Ferrar & Green, 2021), integração de dados de fontes diferenciadas na gestão de talento (Isson & Harriot, 2016; Ferrar & Green, 2021) e por último o indicador referente à diminuição da parcialidade e preconceito nos processos de tomada de decisão (Likhitkar & Verma, 2020; Isson & Harriot, 2016).

Em relação aos principais benefícios gerados pela implementação de PA na GRH, os resultados demonstraram estar alinhados com a literatura proposta pelos autores estudados, identificando os seguintes: a previsão de problemas complexos (Inamdar, 2021), o aumento da vantagem competitiva (Charan *et al.*, 2018), tomada de decisão rápida com informação real e atualizada (Ferrar & Green, 2021) e a melhoria da produtividade (Shrivastava *et al.*, 2018).

Por fim, relativamente às limitações geradas pela implementação de *People Analytics* na GRH, os resultados corroboram a revisão da literatura estudada. As principais limitações identificadas foram: a dificuldade na partilha de informação nas organizações (Angrave *et al.*, 2016), défice de competências analíticas (Davenport *et al.*, 2010; Isson & Harriot, 2016; Rasmussen & Ulrich, 2015; Ferrar & Green, 2021), o défice na estrutura organizacional na transformação dos dados descritivos para prescritivos (Rasmussen & Ulrich, 2015), a ausência de monitorização, antes e depois da tomada de decisão e das medidas implementadas (Davenport *et al.*, 2010), a abordagem pré-concebida dos problemas organizacionais (Rasmussen & Ulrich, 2015).

Em suma, em relação aos efeitos diretos do modelo concetual, os resultados demonstraram que os benefícios gerados pela implementação de *People Analytics* na GRH, têm impacto positivo na percepção dos utilizadores, no negócio e na organização. E ambos os constructos influenciam positivamente a possibilidade de implementar PA na GRH. Assim, em conformidade com os autores estudados, quanto maior a percepção sobre os benefícios maior será a intencionalidade de implementar, devido à consciência das vantagens percecionadas para os colaboradores e organização (Ferrar & Green, 2021; Shrivastava *et al.*, 2018; Isson & Harriot, 2016).

Por outro lado, as limitações não demonstraram ter impacto na possibilidade de implementar PA na GRH. Diversas razões podem ser apontadas na literatura como possíveis causas, nomeadamente a subutilização na prática e a falta de investigação representando apenas 2% dos estudos no campo da gestão (Sheng *et al.*, 2017). No entanto, é importante frisar o otimismo em relação às potenciais limitações não serem um fator limitativo, sendo que a mentalidade deve estar na prática direcionada para a mudança e não apenas na teoria (Rasmussen & Ulrich, 2015).

O segundo objetivo da presente dissertação, surgiu com a intenção de perceber o impacto da implementação do *People Analytics* em relação a um desafio estratégico comum a ser solucionado nas organizações. Assim, pretendeu-se analisar e verificar a possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH, que espoletou a segunda questão de pesquisa- *Possibilidade de identificar e reter talento através da implementação de PA na GRH*. Através da análise do modelo concetual, foi possível verificar que os benefícios e as limitações são dois constructos que influenciam esta possibilidade.

Relativamente, aos benefícios gerados na retenção de talento pela utilização de PA na GRH, os resultados mostram-se alinhados com a teoria, este fator é suportado pelos seguintes indicadores principais: desenvolvimento do *engagement* na organização (Isson & Harriot, 2016), identificar as principais fontes para atrair e reter talento (Grillo, 2015) organizar proativamente o processo de retenção de talento e implementar práticas personalizadas de acordo com o perfil de cada colaborador (Shrivastava *et al.*, 2018; Ferrar & Green, 2021), classificar o nível de desgaste de cada colaborador através de um modelo preditivo (Isson & Harriot, 2016; Ferrar & Green, 2021; Holtom & Allen, 2019), cálculo do prejuízo resultante da rotatividade nos processos de tomada de decisão (Isson & Harriot, 2016) e por último identificar o talento que deve ser desenvolvido, recompensado, promovido e retido (Ferrar & Green, 2021).

Quanto às limitações geradas na retenção de talento pela utilização de PA na GRH, os resultados demonstraram estar em alinhamento com a literatura estudada, identificando os seguintes indicadores: falta de alinhamento estratégico (Angrave *et al.*, 2016 Isson & Harriot, 2016), o défice de dados fundamentais (Yahia *et al.*, 2021), ferramentas e processos desintegrados (Angrave *et al.*, 2016), manipulação das métricas para obter os resultados esperados e a utilização de métricas simplistas que geralmente não conseguem prever com precisão os resultados de determinados indicadores (Davenport *et al.*, 2010).

Em suma, em relação aos efeitos diretos do modelo concetual os benefícios gerados na retenção de talento pela utilização de *People Analytics* na GRH impactam positivamente na possibilidade de identificar e reter talento através da implementação de *People Analytics* na

GRH. Com impacto no desenvolvimento do *engagement*, na identificação das principais fontes para atrair e reter talento, personalizando as práticas de RH de forma a responder às necessidades dos colaboradores, bem como prever o nível de desgaste de cada colaborador em tempo real (Isson & Harriot, 2016; Grillo, 2015; Shrivastava *et al.*, 2018; Ferrar & Green, 2021; Holtom & Allen, 2019). Diversas empresas que implementaram *People Analytics* conseguem prever a intenção de saída dos colaboradores através de análises preditivas com a prescrição de ações no sentido de reter em tempo real (Rosenbaum, 2019).

Os resultados relativamente às limitações geradas na retenção de talento pela utilização de PA na GRH impactam negativamente na possibilidade de identificar e reter talento através da implementação de *People Analytics* na GRH. As limitações impedem que muitas vezes a identificação e retenção de talento através da implementação de *People Analytics* seja bem-sucedida, devido a determinados desafios e pré-requisitos não cumpridos antes, durante e após a implementação, nomeadamente, a falta de alinhamento estratégico, défice na existência de dados fundamentais, ferramentas e processos desintegrados, bem como a manipulação das métricas e a utilização simplista das mesmas (Angrave *et al.*, 2016; Isson & Harriot, 2016; Yahia *et al.*, 2021; Davenport *et al.*, 2010). É assim possível concluir que o *People Analytics* influencia positivamente a eficácia na retenção de talento, sempre que as condições para a sua correta implementação estejam satisfeitas.

6.2 Contribuição para a gestão empresarial

As organizações estão constantemente a ser desafiadas a adaptar as suas estratégias para conseguir responder adequadamente aos desafios em tempo real. Assim, o presente estudo visa contribuir para a discussão de um conjunto de conhecimentos sobre a Inteligência Artificial na Gestão de Recursos Humanos, ou seja, o *People Analytics*, abordando os principais conceitos, fatores chave, benefícios, limitações e a própria perceção dos utilizadores, com o objetivo de analisar a potencialidade de implementar *People Analytics* na GRH e mais especificamente na retenção de talento, bem como as consequências inerentes.

Este estudo poderá também ajudar os profissionais e as empresas que estão a considerar adotar *People Analytics*, a potenciar o seu conhecimento, através da avaliação prévia dos possíveis benefícios e limitações em relação à sua capacidade no cumprimento dos requisitos necessários para o efeito. Por fim, a investigação levanta questões relativamente à continuação da possível alteração de paradigma da GTRH para a GERH e como esta se pode reinventar e melhorar a qualidade da tomada de decisão sobre as pessoas nas organizações.

6.3 Limitações do Estudo

O presente estudo foi desenvolvido com base na literatura estudada e na análise das respostas dos inquéritos. Algumas limitações foram identificadas, os estudos da Inteligência Artificial na Gestão de Recursos Humanos e consequentemente na retenção de talento são relativamente recentes e ainda em quantidade reduzida comparativamente com as outras áreas da Gestão. Os estudos sobre *People Analytics* ainda são escassos, assim como a implementação por parte das empresas, como tal mais estudos e mais tempo seriam favoráveis à presente investigação. Em relação ao inquérito, as limitações são sobretudo relativamente à população alvo, que embora heterogénea, é reduzida em termos de tamanho e representa apenas o contexto em Portugal. Existe ainda pouca informação e conhecimento sobre o tema, no entanto a presente investigação demonstrou a intenção positiva por parte dos diversos intervenientes (profissionais de RH, gestores de equipa e gestores especialistas em *People Analytics*) em implementá-lo nas organizações. A aceitação é bastante relevante para a evolução.

6.4 Sugestões para futuras investigações

Como referido anteriormente, é imprescindível mais investigações sobre o *People Analytics* em diversas dimensões, impacto e implicações. Sendo uma área inovadora e ainda com escassos estudos, é necessário primeiramente mais investigação para compreender com amplitude todas as dimensões que devem estar satisfeitas para implementar com sucesso *People Analytics*, uma vez que o presente estudo demonstra a aceitação e importância de o implementar, seria relevante existirem mais estudos sobre o que poderá efetivamente potenciar as organizações a implementar este tipo de sistemas na prática, ou seja face à percentagem de otimismo qual a percentagem de implementação.

Outra das possíveis sugestões seria como aumentar o conhecimento nesta área e que tipo de competências e ações são necessárias por parte das organizações para as implementarem. A presente investigação foi realizada apenas em Portugal, seria interessante a expansão para outras geografias, através da possível relação de causalidade e transversalidade através da comparação de variáveis entre as diversas geografias. Por fim, durante a recolha de informação para a presente investigação foi possível identificar uma sugestão para uma futura investigação, relacionada com os principais desafios e como colmatá-los aquando o tratamento de dados dos colaboradores nas diferentes geografias, mais especificamente Estados Unidos da América versus Europa versus Índia.

BIBLIOGRAFIA

- Alshehhi, K., Zawbaa, S. Bin, Abonamah, A. A., & Tariq, M. U. (2021). Employee Retention Prediction in Corporate Organizations Using Machine Learning Methods. *Academy of Entrepreneurship Journal*, 27(Special Issue 2), 1–23.
- Amini, L., Chen, C.-H., Cox, D., Oliva, A., & Torralba, A. (2020). Experiences and Insights for Collaborative Industry- Academic Research in Artificial Intelligence. *AI Manazine*, 41(1), 70–81.
- Angrave, D., Charlwood, A., Kirkpatrick, I., Lawrence, M., & Stuart, M. (2016). HR and analytics: why HR is set to fail the big data challenge. *Human Resource Management Journal*, 26(1), 1–11. <https://doi.org/10.1111/1748-8583.12090>
- Armstrong, M., & Taylor, S. (2014). Armstrong's Handbook of Human Resource Management Practice. Em *Kogan Page* (13th ed.). <https://doi.org/10.4135/9780857021496>
- Assensoh-Kodua, A. (2019). The resource-based view: A tool of key competency for competitive advantage. *Problems and Perspectives in Management*, 17(3), 143–152. [https://doi.org/10.21511/ppm.17\(3\).2019.12](https://doi.org/10.21511/ppm.17(3).2019.12)
- Bagozzi, R. P., & Yi, Y. (1988). On the evaluation of structural equation models. *Journal of the Academy of Marketing Science*, 16(1), 74–94. <https://doi.org/10.1007/BF02723327>
- Barney, J. B. (1995). Looking inside for competitive advantage. *Academy of Management Executive*, 9(4), 49–61. <https://doi.org/10.2222/jsv.50.47>
- Batta, M. (2020). Machine Learning Algorithms - A Review. *International Journal of Science and Research (IJ)*, 9(1), 381–386. <https://doi.org/10.21275/ART20203995>
- Beechler, S., & Woodward, I. C. (2009). The global «war for talent». *Journal of International Management*, 15(3), 273–285. <https://doi.org/10.1016/j.intman.2009.01.002>
- Boussemart, Y., Cummings, M. L., Fargeas, J. Las, & Roy, N. (2011). Supervised vs Unsupervised Learning for Operator State Modeling in Unmanned Vehicle Settings. *Journal of Aerospace Computing, Information, and Communication*, 8, 71–85.
- Bughin, J. (2016). Big data, Big bang? *Journal of Big Data*, 3(1), 1–14. <https://doi.org/10.1186/s40537-015-0014-3>
- Cappelli, P. (2008). *Talent on demand: managing talent in an age of uncertainty*. Boston: Harvard Business School Press.
- Carmo, H., & Ferreira, M. (2008). *Metodologia da investigação - Guia para Auto-aprendizagem*.
- Cascio, W. F., & Boudreau, J. W. (2016). The search for global competence: From

- international HR to talent management. *Journal of World Business*, 51(1), 103–114.
<https://doi.org/10.1016/j.jwb.2015.10.002>
- Charan, R., Barton, D., & Carey, D. (2018). *Talent Wins*.
- CIPD. (2013). Talent analytics and big data – the challenge for HR. Em *Cipd*. Obtido de
https://www.cipd.co.uk/Images/talent-analytics-and-big-data_2013-challenge-for-hr_tcm18-9289.pdf
<http://www.oracle.com/us/products/applications/human-capital-management/talent-analytics-and-big-data-2063584.pdf>
- Collins, D. J., & Montgomery, C. A. (2008). Competing on Resources - Harvard Business Review. *Harvard Business Review*, (September), 138–157. Obtido de
<http://hbr.org/2008/07/competing-on-resources/ar/1>
- Dash, G., & Paul, J. (2021). CB-SEM vs PLS-SEM methods for research in social sciences and technology forecasting. *Technological Forecasting and Social Change*, 173(August), 121092. <https://doi.org/10.1016/j.techfore.2021.121092>
- Davenport, T. H., Harris, J., & Shapiro, J. (2010). Competing on Talent Analytics. *Harvard Business Review*.
- DiClaudio, M. (2019). People analytics and the rise of HR: how data, analytics and emerging technology can transform human resources (HR) into a profit center. *Strategic HR Review*, 18(2), 42–46. <https://doi.org/10.1108/shr-11-2018-0096>
- Eriksson, T., Bigi, A., & Bonera, M. (2020). Think with me, or think for me? On the future role of artificial intelligence in marketing strategy formulation. *TQM Journal*, 32(4), 795–814. <https://doi.org/10.1108/TQM-12-2019-0303>
- Falk, R. F., & Miller, N. B. (1992). *A primer for soft modelling*. University of Akron Press.
- Faroukhi, A. Z., El Alaoui, I., Gahi, Y., & Amine, A. (2020). Big data monetization throughout Big Data Value Chain: a comprehensive review. *Journal of Big Data*, 7(1). <https://doi.org/10.1186/s40537-019-0281-5>
- Fernandez, V., & Gallardo-Gallardo, E. (2021). Tackling the HR digitalization challenge: key factors and barriers to HR analytics adoption. *Competitiveness Review*, 31(1), 162–187. <https://doi.org/10.1108/CR-12-2019-0163>
- Ferrar, J., & Green, D. (2021). *Excellence in People Analytics: How to use workforce data to create business value*. London, UK: Kogan Page.
- GDPR. *General data protection regulation (GDPR) compliance guidelines*. , (2019).
- Gonçalves, R., Silva, B., Pereira, L., Lopes da Costa, R., Dias, Á., & Teixeira, N. (2021). Analytical Methods as a Source of Value in Human Resource Management in Consulting Companies. *International Journal of Knowledge and Learning*, 15(1), 67–88.

- Grillo, M. (2015). What Types of Predictive Analytics are Being Used in Talent Management Organizations? *Cornell University, IRL School*.
- Gupta, S., Leszkiewicz, A., Kumar, V., Bijmolt, T., & Potapov, D. (2020). Digital Analytics: Modeling for Insights and New Methods. *Journal of Interactive Marketing*, 51, 26–43. <https://doi.org/10.1016/j.intmar.2020.04.003>
- Hair, J. F., Hult, G. M., Ringle, C., & Sarstedt, M. (2017). *A primer on partial least squares structural equation modeling*. Sage Publications.
- Hair Jr., J. F., Matthews, L. M., Matthews, R. L., & Sarstedt, M. (2017). PLS-SEM or CB-SEM: updated guidelines on which method to use. *International Journal of Multivariate Data Analysis*, 1(2), 107. <https://doi.org/10.1504/ijmda.2017.10008574>
- Han, J., Kamber, M., & Pei, J. (2012). Data mining: Concepts and Techniques. Em *Data Management Systems* (3th ed.). <https://doi.org/10.1109/ICMIRA.2013.45>
- Hariri, R. H., Fredericks, E. M., & Bowers, K. M. (2019). Uncertainty in big data analytics: survey, opportunities, and challenges. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0206-3>
- Henseler, J., Ringle, C. M., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115–135. <https://doi.org/10.1007/s11747-014-0403-8>
- Hills, A. (2009). Succession planning – or smart talent management? *Industrial and Commercial Training*, 41(1), 3–8. <https://doi.org/10.1108/00197850910927697>
- Holtom, B., Goldberg, C. B., Allen, D. G., & Clark, M. A. (2017). How Today's Shocks Predict Tomorrow's Leaving. *Journal of Business and Psychology*, 32(1), 59–71. <https://doi.org/10.1007/s10869-016-9438-9>
- Howell, D. (2020). The costumer of one: How Persnalisation is the Key to Long Term Profitability. *Silicon Technology Powering Business*.
- Hughes, J. C., & Rog, E. (2008). Talent management: A strategy for improving employee recruitment, retention and engagement within hospitality organizations. *International Journal of Contemporary Hospitality Management*, 20(7), 743–757. <https://doi.org/10.1108/09596110810899086>
- IBM. (2020). Artificial Intelligence. *IBM Cloud Education*.
- Iles, P., Preece, D., & Chuai, X. (2010). Talent management as a management fashion in hrd: Towards a research agenda. *Human Resource Development International*, 13(2), 125–145. <https://doi.org/10.1080/13678861003703666>
- Inamdar, A. (2021). How The HR Team Can Help Create Human-Centric Digital

Transformation.

- Ismail, F., Arumugan, N. A. P., Kadir, A. A., & Alhosani, A. A. H. (2021). Impact of leadership styles toward employee engagement among Malaysian civil defence force. *International Journal of Business and Society*, 22(3), 1188–1210.
<https://doi.org/10.33736/ijbs.4294.2021>
- Isson, J. P., & Harriott, J. S. (2016). *People Analytics in the Era of Big Data*. Hoboken, New Jersey: John Wiley & Sons, Inc.
- Jakhar, D., & Kaur, I. (2019). Artificial intelligence, machine learning and deep learning: definitions and differences. *Clinical and Experimental Dermatology*, 45(1), 131–132.
<https://doi.org/10.1111/ced.14029>
- Jantan, H., Razak, A., & Ali, Z. (2011). Data Mining Classification Techniques for Human Talent Forecasting. *Knowledge-Oriented Applications in Data Mining*.
<https://doi.org/10.5772/14007>
- Jarrahi, M. H. (2018). Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. *Business Horizons*, 61(4), 577–586.
<https://doi.org/10.1016/j.bushor.2018.03.007>
- Jones, M. T. (2009). *Artificial Intelligence: A Systems Approach*. Sudbury, Massachusetts: Jones and Bartlett Publishers.
- Kavlakoglu, E. (2020). AI vs. Machine Learning VS. Deep Learning vs. Neural Networks: What's the Difference? *IBM Journal of Research and Development*.
- King, K. G. (2016). Data Analytics in Human Resources: A Case Study and Critical Review. *Human Resource Development Review*, 15(4), 487–495.
<https://doi.org/10.1177/1534484316675818>
- Kothari, C. R. (2004). *Research Methodology: Methods and Techniques* (2nd ed.). New Delhi: New Age International Publishers.
- Kühl, N., Hirt, R., Baier, L., Schmitz, B., & Satzger, G. (2021). How to conduct rigorous supervised machine learning in information systems research: The supervised machine learning report card. *Communications of the Association for Information Systems*, 48, 589–615. <https://doi.org/10.17705/1CAIS.04845>
- Lahiri, G., & Schwartz, J. (2018). *Global Human Capital Trends: People data: How far is too far?* Obtido de <https://www2.deloitte.com/us/en/insights/focus/human-capital-trends/2018/people-data-analytics-risks-opportunities.html>
- Lawler III, E. E., Levenson, A., & Boudreau, J. (2004). Effective Organizations HR Metrics and Analytics: Uses and Impacts. *Center for Effective Organizations*, 6, 1–17.

- Li, X., & Bryan, L. (2010). On becoming an employer of choice: Gauging employee satisfaction through climateQUAL®. *Library Trends*, 59(1–2), 256–268.
- Likert, R. (1932). Technique for the Measurement of Attitudes. Em R. S. WOODWORTH (Ed.), *New York University: Archives of Psychology*.
<https://doi.org/10.4135/9781412961288.n454>
- Likhitkar, P., & Verma, P. (2020). Advances in Intelligent Systems and Computing: New Paradigm in Decision Science and Management. Em S. Patnaik, A. W. H. Ip, M. Tavana, & V. Jain (Eds.), *Advances in Intelligent Systems and Computing* (Vol. 1030, pp. 165–170). https://doi.org/10.1007/978-981-13-9330-3_40
- Lin, C., Kunnathur, A. S., & Li, L. (2020). The Big Data bandwagon: How Big Data can benefit organizational practices. *International Journal of Accounting & Information Management*, 36(10), 13–14. <https://doi.org/10.1108/SD-08-2020-0144>
- LinkedIn Talent Solutions. (2022). *The Reinvention of Company Culture 2022 Global Talent Trends*. 67.
- Lokanan, M., Tran, V., & Vuong, N. H. (2019). Detecting anomalies in financial statements using machine learning algorithm: The case of Vietnamese listed firms. *Asian Journal of Accounting Research*, 4(2), 181–201. <https://doi.org/10.1108/AJAR-09-2018-0032>
- Marconi, M., & Lakatos, E. (2003). Fundamentos de metodologia científica. Em *Editora Atlas S. A.* <https://doi.org/10.1590/S1517-97022003000100005>
- Mccarthy, J. (2004). *WHAT IS ARTIFICIAL INTELLIGENCE?* Obtido de <http://www-formal.stanford.edu/jmc/>
- Missy, M. L. ", Cummings, ", & Stimpson, A. (2019). *Identifying Critical Contextual Design Cues Through a Machine Learning Approach*.
- Morgan, J. (2016). The Global Head of Employee Experience at Airbnb on why thwy got rid of human resources. *Forbes*.
- Nawaz, N. (2020). Exploring Artificial Intelligence Applications in Human Resource Management. *Journal of Management Information and Decision Sciences*, 23(5), 552–563.
- Newell, A., & Simon, H. A. (1961). *GPS: a program that simulates human thought*. Munich: R. Oldenbourg KG: Lernende Auto-maten, H. Billing ed.
- Nilsson, N. J. (1998). Artificial Intelligence, A New Synthesis. Em *Harcourt Asia Ltd.* Singapore.
- Nocker, M., & Sena, V. (2019). Big data and human resources management: The rise of talent analytics. *Social Sciences*, 8(10). <https://doi.org/10.3390/socsci8100273>

- Onday, O. (2016). Creating Employee Engagement Through Talent Management: 4 Links Between Talent M. *International Journal of Academic Value Studies (Javstudies JAVS)*, 2(4), 90–103. <https://doi.org/10.23929/javs.21>
- Pape, T. (2016). Prioritising data items for business analytics: Framework and application to human resources. *European Journal of Operational Research*, 252(2), 687–698. <https://doi.org/10.1016/j.ejor.2016.01.052>
- Paschen, J., Kietzmann, J., & Kietzmann, T. C. (2019). Artificial intelligence (AI) and its implications for market knowledge in B2B marketing. *Journal of Business and Industrial Marketing*, 34(7), 1410–1419. <https://doi.org/10.1108/JBIM-10-2018-0295>
- Perols, J. (2011). Financial statement fraud detection: An analysis of statistical and machine learning algorithms. *Auditing*, 30(2), 19–50. <https://doi.org/10.2308/ajpt-50009>
- Poorhosseinzadeh, M., & Subramaniam, I. D. (2013). Talent Management Literature Review. *Australian Journal of Basic and Applied Sciences*, 7(6), 330–338.
- Preacher, K. J., & Hayes, A. F. (2008). Asymptotic and resampling strategies for assessing and comparing indirect effects in multiple mediator models. *Behavior Research Methods*, 40(3), 879–891. <https://doi.org/https://doi.org/10.3758/BRM.40.3.879>
- Prodanov, C. C., & Freitas, E. C. (2013). *Metodologia do Trabalho Científico: Métodos e Técnicas de Pesquisa e do Trabalho Acadêmico* (2.^a ed.). Feevale.
- Pruis, E. (2011). The five key principles for talent development. *Industrial and Commercial Training*, 43(4), 206–216. <https://doi.org/10.1108/00197851111137825>
- Rasmussen, T., & Ulrich, D. (2015). Learning from practice: How HR analytics avoids being a management fad. *Organizational Dynamics*, 44(3), 236–242. <https://doi.org/10.1016/j.orgdyn.2015.05.008>
- Ringle, C. M., Wende, S., & Will, A. (2015). *SmartPLS3.0*. Obtido de www.smartpls.de.
- Rosenbaum, E. (2019). IBM Artificial Intelligence can predict with 95% accuracy which workers are about to quit their job. *CNBC Work*.
- Russel, S., & Norving, P. (2021). Artificial Intelligence: A Modern Approach. Em *Pearson Education, Inc* (4th ed.). Hoboken, New Jersey.
- Samuel, A. L. (1959). Some Studies in Machine Learning. *IBM Journal of Research and Development*, 3(3), 210–229. Obtido de <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5392560>
- Sarstedt, M., & Christian M. Ringle, and J. F. H. (2017). Partial least squares structural equation modeling with R. Em *Practical Assessment, Research and Evaluation* (Vol. 21).

- Schweyer, A. (2018). Predictive analytics and artificial intelligence in people management. *Incentive Research Foundation*, 1–18.
- Segaran, T. (2007). *Programming Collective Intelligence: Building Smart Web 2.0 Applications*. Em *O' Reilly Media, Inc* (1th ed.). Sebastopol, CA.
- Sheng, J., Amankwah-Amoah, J., & Wang, X. (2017). A multidisciplinary perspective of big data in management research. *International Journal of Production Economics*, 191(November 2016), 97–112. <https://doi.org/10.1016/j.ijpe.2017.06.006>
- Shi, Z.-Z., & Zheng, N.-N. (2006). Progress and Challenge of Artificial Intelligence. *J. Comput. Sci. & Technol.*, 21(5), 810–822.
- Shrivastava, S., Nagdev, K., & Rajesh, A. (2018). Redefining HR using people analytics: the case of Google. *Human Resource Management International Digest*, 26(2), 3–6. <https://doi.org/10.1108/HRMID-06-2017-0112>
- Simon, J. P. (2019). Artificial intelligence: scope, players, markets and geography. *Digital Policy, Regulation and Governance*, 21(3), 208–237. <https://doi.org/10.1108/DPRG-08-2018-0039>
- Sinha, C., & Sinha, R. (2012). Factors Affecting Employee Retention : A Comparative Analysis of two Organizations from Heavy Engineering Industry. *European Journal of Business and Management*, 4(3), 145–163.
- Sosik, J. J., Kahai, S. S., & Piovosio, M. J. (2009). Silver bullet or voodoo statistics?: A primer for using the partial least squares data analytic technique in group and organization research. *Group and Organization Management*, 34(1), 5–36. <https://doi.org/10.1177/1059601108329198>
- Stubbing, C., Sethi, B., & Brown, J. (2018). Preparing for tomorrow ' s workforce , today. *PricewaterhouseCoopers GmbH*, 36. Obtido de www.pwc.com/people
- Tamizharasi, K., & Rani, D. (2014). Employee Turnover Analysis with Application of Data Mining Methods. *International Journal of Computer Science and Information Technologies*, 5(1), 562–566. Obtido de www.ijcsit.com
- Tansley, C., Stewart, J., Turner, P., Foster, C., Harris, H., & Sempik, A. (2007). *Talent: Strategy, Management, Measurement*. London, UK: CIPD.
- Tansley, C., & Tietze, S. (2013). Rites of passage through talent management stages: an identity work perspective. *International Journal of Human Resource Management*, 24(9), 1799–1815.
- Tarka, P. (2018). An overview of structural equation modeling: Its beginnings, historical development, usefulness and controversies in the social sciences. *Quality and Quantity*,

52(1), 313–354.

- Taylor, F. W. (1911). *The Principles of Scientific Management*. New York: Harper & Brothers Publishers.
- Turing, A. M. (1950). COMPUTING MACHINERY AND INTELLIGENCE. Em *Computing Machinery and Intelligence. Mind* (Vol. 49).
- Tursunbayeva, A., Di Lauro, S., & Pagliari, C. (2018). People Analytics- a scoping review of conceptual boundaries and value propositions. *International Journal of Informations Management*, 43, 224–247.
- Ulrich, D. (1998). A new mandate for human resources. *Harvard business review*, 76(1), 124–134.
- Ulrich, D., & Allen, J. (2014). Talent accelerator: Understanding how talent delivers performance for Asian firms. *South Asian Journal of Human Resources Management*, 1(1), 1–23. <https://doi.org/10.1177/2322093714526666>
- Van Zyl, E. S., Mathafena, R. B., & Ras, J. (2017). The development of a talent management framework for the private sector. *SA Journal of Human Resource Management*, 15(0), 1–19. <https://doi.org/10.4102/sajhrm.v15i0.820>
- Whelan, E., & Carcary, M. (2011). Integrating talent and knowledge management: Where are the benefits? *Journal of Knowledge Management*, 15(4), 675–687. <https://doi.org/10.1108/13673271111152018>
- World Economic Forum. (2019). HR4.0: Shaping People Strategies in the Fourth Industrial Revolution. Em *WEForum*. Obtido de <https://www.weforum.org/reports/hr4-0-shaping-people-strategies-in-the-fourth-industrial-revolution>
- Yahia, N. Ben, Hlel, J., & Colomo-Palacios, R. (2021). From Big Data to Deep Data to Support People Analytics for Employee Attrition Prediction. *IEEE Access*, 9, 60447–60458. <https://doi.org/10.1109/ACCESS.2021.3074559>
- Yellapantula, K., & Ayachit, M. (2019). Significance of Emotional Intelligence in the Era of Artificial Intelligence: A Study on the Application of Artificial Intelligence in Financial and Educational Services Sector. *Ushus - Journal of Business Management*, 18(1), 35–48. <https://doi.org/10.12725/ujbm.46.3>
- Zhao, Y., & Flenner, A. (2019). *Editorial Introduction to the Special Articles on Applying Deep Learning to Security II Deep Models, Machine Learning, and Artificial Intelligence Applications in National and International Security-Part Two Deep Learning and Security Editorial*.