



INSTITUTO  
UNIVERSITÁRIO  
DE LISBOA

---

## **Maturidade Analítica das Empresas do Setor da Construção em Portugal**

João Guilherme Dias Rodrigues Estêvão

Mestrado em Business Analytics

Orientador:

Prof. Álvaro Augusto da Rosa, Prof. Associado

ISCTE Business School, Departamento de Marketing, Operações e Gestão Geral

Outubro, 2022



BUSINESS  
SCHOOL

---

Departamento de Métodos Quantitativos para Gestão e Economia

**Maturidade Analítica das Empresas do Setor da Construção em Portugal**

João Guilherme Dias Rodrigues Estêvão

Mestrado em Business Analytics

Orientador:

Prof. Álvaro Augusto da Rosa, Prof. Associado

ISCTE Business School, Departamento de Marketing, Operações e Gestão Geral

Outubro, 2022





## Agradecimentos

*“Consagrai ao Senhor tudo o que fazes, e os teus planos serão bem-sucedidos.”*

Provérbios 16:3

Finda a elaboração deste trabalho, assim como o meu percurso académico, que marca uma tão importante etapa na minha vida, gostaria de agradecer aos que tiveram um papel importante no mesmo.

Em primeiro lugar, gostaria de agradecer ao Dr. Hugo Santos Ferreira, ao Dr. José Botelho Cardoso, e à APPII, sem os quais este trabalho não teria sido realizado, e cujo contributo tanto dignifica o setor da promoção imobiliária e construção.

Gostaria de agradecer ao Prof. Álvaro Augusto da Rosa, orientador deste trabalho, e cuja sabedoria me guiou ao longo destes meses, e ao Prof. Doutor Raul Laureano, pela disponibilidade e dedicação aos alunos e ao mestrado.

À minha mãe, a minha referência para a vida, exemplo de determinação, coragem e valores, que tanto sacrificou ao longo da vida pela família.

Às minhas irmãs por serem as “inimigas” sem as quais não podia viver, e ao meu padrasto por zelar por nós, mesmo quando não está presente.

Aos meus amigos “esquisitos”, que toleram todos os meus defeitos e me ajudam a ser uma pessoa melhor.

Por fim gostaria de agradecer ao meu amigo Filipe, que me acompanhou nestes longos seis anos de ISCTE, e outros tantos que hão de vir.

Eternamente grato,

João D. R. Estêvão



## Resumo

A quantidade de dados que é gerada atualmente traz consigo novas oportunidades de negócio. Cada vez mais, os modelos de negócio das empresas envolvem a criação, tratamento e utilização dos dados para extrair conhecimento e gerar valor.

Este trabalho é feito no âmbito da Indústria 4.0, uma transformação tecnológica que permite às empresas do setor de construção a digitalização de modo a extrair conhecimento dos dados gerados na cadeia de valor. O objetivo é perceber em que ponto se encontra o nível de adoção de *analytics* nas empresas desta indústria. Foi escolhido um modelo de maturidade analítica testado em vários setores e disponível *online*, o TDWI, e após algumas alterações foi disponibilizado a um painel de participantes para resposta.

Através da aplicação do modelo de maturidade, em formato de questionário, é medida a adoção de *analytics*, em 30 empresas do setor da construção, em Portugal. As respostas ao questionário são classificadas tendo em conta os níveis de maturidade do modelo, e analisadas com outras variáveis recolhidas das empresas. Os resultados mostram que a adoção de ferramentas e métodos de *analytics* nas empresas do setor é média, existindo ainda assim um fosso grande entre micro, pequenas e médias empresas, e as empresas de maior dimensão. Para além disso é possível que os resultados sejam enviesados por falta de literacia analítica dos respondentes.

Este trabalho permite perceber como é o nível de adoção analítica das empresas de construção em Portugal, consciencializar o setor para a importância desta temática, sugerir melhorias e gerar novas hipóteses de investigação.

**Palavras Chave:** Business Analytics, Indústria 4.0; Setor da Construção; Maturidade analítica; Digitalização; Modelos de maturidade.

**Classificação JEL:** L85 Serviços de Imobiliário; M15 Gestão de IT.

## **Abstract**

The amount of data that is daily generated brings new business opportunities. An increasing number of business models include the creation or capture, processing and use of data to extract knowledge and generate value.

This paper is developed in the under the Industry 4.0, a technological transformation that concedes the construction industry companies the digitation in order to generate insights from the data that was gathered from the value chain. The objective is to understand in what stage the analytics adoption for the construction industry companies, in Portugal is. The maturity model chosen from multiple available online and academically assessed was TDWI, which after some amendments was sent to the selected companies.

Through the application of the maturity model, in the format of survey, the analytics adoption was measured in thirty companies from the Portuguese construction industry. The responses were classified regarding the stages proposed by the maturity model and analyzed against the companies' attributes. The results show that the adoption of analytics tools and methods is medium, and that there is a big gap in comparison between the micro, small and medium companies, and the bigger ones. Furthermore, it is possible that the results are biased due to lack of analytics literacy from the respondent.

This dissertation helps in understanding the general analytics adoption level in Portuguese construction companies, raise awareness about the importance of the subject, propose enhancements and generate new research hypotheses.

**Keywords:** Business Analytics, Industry 4.0; Construction Industry; Analytics Maturity; Digitation; Maturity Models.

**JEL:** L85 Real Estate Services; M15 IT Management.

# Índice

Principais Abreviaturas Utilizadas.....	vi
Capítulo 1 - Introdução .....	1
1.1 Enquadramento e Motivação.....	1
1.2 Objetivo .....	2
1.3 Perguntas de Investigação.....	2
1.4 Metodologia .....	2
1.5 Estrutura da dissertação.....	3
Capítulo 2 - Revisão de Literatura .....	5
2.1 Indústria 4.0.....	5
2.2 Business Analytics.....	6
2.3 Business Analytics na indústria da construção.....	8
2.3.1 Problemas e frustrações do setor da construção.....	9
2.3.2 Tecnologias e técnicas.....	10
2.4 Modelos de Maturidade .....	12
2.5 Estado da arte.....	14
Capítulo 3 - Abordagem.....	17
3.1 Escolha do modelo de maturidade .....	17
3.2 Obtenção de respostas.....	18
3.3 Tratamento dos dados.....	18
Capítulo 4 - Análise dos Resultados .....	21
4.1 Caracterização da amostra .....	21
4.2 Análise dos resultados.....	26
Capítulo 5 – Conclusão .....	40
5.1 Considerações finais.....	40
5.2 Limitações e Trabalho futuro .....	41
Referências Bibliográficas.....	43
Anexo A.....	50
Anexo B.....	51
Anexo C.....	53
Anexo D.....	54
Anexo E.....	57

## **Principais Abreviaturas Utilizadas**

BA - *Business Analytics*

BD - *Big Data*

BI - *Business Intelligence*

BIM - *Building Information Modeling*

CAD - *Computer Assisted Design*

CEO - *Chief Executive Officer*

DM - *Data Mining*

DW - *Data Warehouse*

ERP - *Enterprise Resource Planning*

GCE - Gestão de construção e engenharia

IA - Inteligência Artificial

I&D – Inovação e Desenvolvimento

INE – Instituto Nacional de Estatística

IoT - *Internet of Things*

I4.0 - Indústria 4.0

MMBA – Modelo de Maturidade de *Business Analytics*

MMBI – Modelo de maturidade de *Business Intelligence*

PLM - *Product-Lifecycle-Management*

PME - Pequenas e Médias Empresas

PRR – Plano de recuperação e resiliência

TI - Tecnologias de Informação

VAB - Valor Acrescentado Bruto

4RI - 4ª Revolução Industrial

## Capítulo 1 - Introdução

### 1.1 Enquadramento e Motivação

Em 2019 a revista Forbes publicou um artigo intitulado " Data Is The New Oil - And That's A Good Thing" (Bhageshpur, K., 2019). Desde então, as disciplinas de *data science*, *business analytics* (BA) ou *business intelligence* (BI), tornaram-se mais mediáticas.

A "indústria 4.0" (I4.0) e a "digitalização das empresas" são expressões que estão na ordem do dia, e têm recebido especial atenção no panorama económico. Segundo a IDC (2020), mais de 59 *zettabytes* de dados foram criados, guardados, copiados e consumidos este ano. Como tal, o valor intrínseco dos dados, e a sua importância para alcançar vantagem competitiva é cada vez mais tido em conta pelas empresas. Autores como Kappelman *et al.* (2014) afirmam BI e BA tem sido uma das maiores prioridades nas organizações.

Estas dedicam a esta área cada vez mais recursos humanos e fundos, e está provado que ela pode ser um catalisador de valor e gerador de retorno financeiro. De tal modo que através do plano de recuperação e resiliência (PRR), para recuperação da economia, a União Europeia prevê apoios de 650 milhões de euros para a digitalização das empresas em Portugal. Estes fundos têm como objetivo a recuperação económica da União, como consequência da crise financeira causada pela pandemia.

Um dos setores alvo de investimento através deste plano é o da construção civil, através de vários megaprojetos de construção de infraestruturas e obras públicas. Segundo o Instituto Nacional de Estatística (INE) (2020), o setor da construção civil representou em 2020, cerca de 4,7% do Valor Acrescentado Bruto (VAB) nacional. Por outro lado, o conjunto dos setores da Construção e de Atividades Imobiliárias representaram 10,6% do número de empresas não financeiras em atividade em Portugal e empregaram 431 589 pessoas, representando 10,2% do pessoal ao serviço, sendo um dos principais setores de atividade em Portugal. Estes dados mostram a importância desta indústria para a economia do nosso país.

O termo "maturidade" foi usado pela primeira vez no âmbito da gestão, por Crosby (1979) que pretendeu descrever o estado de adoção de uma ferramenta, metodologia, negócio ou mercado. Para medir o estado de maturidade, existem ferramentas disponíveis, que, segundo Cosic *et al.* (2012), uniformizam e facilitam o processo de avaliação de capacidades, processos ou recursos e que de acordo com Fraser *et al.* (2002), identificam falhas existentes, para propor melhorias.

Apesar da importância estratégica do setor da construção, este é bastante discreto no que toca à inovação tecnológica, e em especial à digitalização, sendo sempre um dos últimos a adotar as tecnologias mais recentes e inovadoras, em comparação com outras indústrias. Por esta razão, foi escolhido este setor de atividade económica como objeto de estudo.

Esta dissertação pretende perceber em que medida as principais empresas de construção fazem uso dos dados do negócio para tirar conhecimento e gerar valor, com recurso a modelos de maturidade analítica disponíveis.

O resultado deste trabalho dá não apenas uma visão do panorama analítico deste setor, mas também um precioso insight acerca das principais lacunas que as empresas possuem, com vista a, não só melhorar a adoção de BA, como também consciencializar o setor para a importância da disciplina e abrir caminho para um debate sobre eventuais soluções a adotar. Pode valioso para sensibilizar os decisores a adotar uma postura analítica, a procurar melhorar os processos de tomada de decisão e implementar técnicas que permitam recolher, armazenar, e utilizar melhor os dados, quer para as empresas visadas pelo estudo, quer para os restantes players do setor.

Pode também abrir oportunidades de negócio para consultoras especializadas em *Business Analytics*, ou a criação de departamentos internos, cada vez mais frequentes em tantas empresas. Também para fornecedores de ferramentas e soluções de BI e BA será pertinente perceber se há oportunidades dentro deste setor.

Por outro lado, ganha também a academia, com a possibilidade de surgirem novas hipóteses de investigação.

## **1.2 Objetivo**

Face ao exposto, a presente dissertação tem como principal objetivo identificar o panorama da maturidade analítica de empresas do setor da construção, em Portugal, com recurso a um modelo de maturidade analítica.

## **1.3 Perguntas de Investigação**

Atendendo ao objetivo deste trabalho as principais perguntas de investigação definidas são as seguintes:

1. Como é a maturidade analítica das empresas de construção em Portugal, em termos globais?
2. Onde falham as empresas para atingir um nível de maturidade mais elevado?
3. O que pode ser feito para corrigir essas lacunas?

## **1.4 Metodologia**

A metodologia proposta para este trabalho é de investigação por questionário. São recolhidos dados com base num modelo de medição da adoção e capacidade analítica, através de um questionário junto a empresas previamente escolhidas. Adicionalmente surge a necessidade de incorporar questões além das sugeridas pelo modelo escolhido com base na revisão de literatura.

As respostas a este questionário foram recolhidas de empresas do setor da construção, selecionadas junto de associações empresariais do setor, de modo a obter uma amostra que possa representar a realidade económica da construção em Portugal.

O principal desafio nesta etapa foi o contacto com tomadores de decisão e *stakeholders* com conhecimento suficiente dos processos internos, ferramentas e da relação da empresa com dados, sendo que em alguns casos foi necessário reunir com mais do que uma pessoa.

Por se tratar de um estudo quantitativo e descritivo foi pertinente a recolha dados demográficos que nos permitiram tirar outras conclusões acerca das diferenças entre empresas, como a dimensão, faturação/lucros e peso no mercado/setor.

Os dados foram analisados com recurso ao IBM SPSS Statistics 27, que é frequentemente utilizado dado o leque de funcionalidades e a sua relevância para a estatística descritiva. a fim de se poder tirar conclusões acerca da sua maturidade analítica global, e responder às perguntas de investigação.

## **1.5 Estrutura da dissertação**

No primeiro capítulo é explicado o enquadramento do tema escolhido e a motivação do proponente, são apresentadas evidências do nível de investimento em BI e da perceção que profissionais e utilizadores têm sobre os sistemas de BI e Data Warehouse (DW), por fim é exposto o problema identificado.

No segundo capítulo é feita uma revisão da literatura, com a conceptualização dos temas relacionados a BA e à indústria em causa. A revisão da literatura parte de uma abordagem *top-down*, partindo do geral para o particular. Serão resumidos os principais estudos e trabalhos referentes à Indústria 4.0”, seguido de “*Business Analytics*”, aprofundando depois para “*Business Analytics na Construção*”, “Modelos de Maturidade” e por fim, do “Estado da Arte”, onde se procura perceber o que foi desenvolvido quanto à análise de maturidade analítica de empresas.

No terceiro capítulo é descrita a abordagem tomada, detalhando o modelo escolhido e as principais alterações feitas, o processo de recolha de respostas, e de tratamento dos dados obtidos.

No quarto capítulo são apresentados e analisados os dados e resultados obtidos.

Finalmente, o quinto capítulo apresenta as considerações finais e principais conclusões, e serão discutidas as limitações deste estudo, e sugeridas as possibilidades de trabalho futuro.

## Capítulo 2 - Revisão de Literatura

### 2.1 Indústria 4.0

Foi na feira de Hannover, em 2011 que o termo Indústria 4.0 foi pela primeira vez utilizado, referindo-se à 4ª Revolução Industrial (4RI) (Posada *et al.*, 2015). Desde o fim do século XVII, a humanidade pôde assistir à Primeira revolução industrial, com a invenção dos motores a vapor, à Segunda, que acontece com a implementação das linhas de produção, por Henry Ford, e à Terceira no início da década de 70, do século XX, com a utilização dos primeiros computadores e automação da produção. O que distingue esta fase da evolução da indústria, segundo Blanchet *et al.* (2014) é a combinação entre os pontos fortes da produção industrial, herdados da Terceira Revolução Industrial, otimizada com tecnologias de internet de ponta. A indústria 4.0 fundiu o mundo físico, em especial da produção, com a era da informação direcionada por abordagens de sistemas digitais (Alaloul *et al.*, 2018).

As tecnologias que servem de base à I4.0 são a Internet das Coisas (IoT), e Internet dos Serviços. Estes estão integrados no ambiente de produção onde todos os negócios estão conectados e controlam as suas maquinarias, fábricas e armazéns de modo inteligente através de sistemas digitais, que partilham informação e desencadeiam atividades (Gilchrist, 2016). Por esta razão a I4.0 é também apelidada de “produção inteligente”, “internet industrial” ou “indústria integrada”, segundo Maresova (2018). Foi responsável pela deslocação da cadeia de valor das organizações e da gestão para o ciclo de vida dos produtos, integrando dispositivos, máquinas, sensores de rede e *software* complexos, implementados para planear de modo a melhorar os resultados do negócio e sociedade em geral

O potencial da I4.0 é influenciado positivamente através de fatores como customização em massa, o uso de dados não antes utilizados e melhorias nos tempos de produção segundo Lee *et al.* (2014).

Do ponto de vista técnico, a I4.0 pode ser descrita como a crescente digitalização e automação dos ambientes de fabricação assim como a criação de uma cadeia de valor digital que permita a comunicação entre os produtos e os seus ambientes e parceiros de negócio (Lasi *et al.*, 2014; Schmidt *et al.*, 2015).

A 4RI caracteriza-se por ser transversal aos vários setores da indústria. Também na construção civil foram introduzidas tecnologias digitais, sistemas de sensores, maquinaria inteligente e materiais inteligentes, o que levou à dinamização de BIM como um repositório central para recolher dados de projeto como consta no trabalho de Craveiro *et al.* (2019), (King, 2017). Ainda assim, Maskuriy *et al.* (2019) percebeu que há uma falta de compreensão generalizada acerca da importância da indústria 4.0 para a construção, havendo um número de *papers* científicos, estudos e outros trabalhos ainda bastante reduzido.

Com esta revolução industrial e tecnológica, novas áreas de conhecimento surgiram. Em especial, com a automação e aumento da capacidade de produzir dados, assim como os avanços que permitem armazenar e processar uma quantidade cada vez maior de informação, surge a oportunidade de utilizar esses dados para proveito do negócio. BA nasce com essa oportunidade.

## 2.2 Business Analytics

Nos últimos anos tem se observado um aumento no interesse em *Data Analytics*, principalmente devido aos benefícios que pode trazer para o negócio. Atualmente a adoção de BA é de aproximadamente de 30% na maioria das organizações (Howson & Sallam, 2017). Estes números mostram como *Business Intelligence* e BA (BI/BA) tem sido uma das maiores prioridades nas organizações, a nível global, como ferramentas para atingir uma vantagem competitiva e gerar valor (Kappelman *et al.*, 2014), ou caso sejam organizações sem fins lucrativos, para encontrar formas de atingir os seus objetivos de forma mais eficaz e com menos recursos (Seddon, 2017). Os sistemas de *Data Analytics* são importantes investimentos estratégicos para muitas organizações e podem contribuir significativamente para a performance da empresa (Cosic *et al.*, 2012). Muitas delas estão cientes que BA pode trazer vantagem competitiva. Uma cultura analítica madura permite que as empresas usem eficientemente os dados nos processos de tomada de decisões. Por isto, cada vez mais entidades decidem recolher dados, fazer medições, e avaliar a eficácia desses dados e medições para permitir que os processos sejam otimizados, com base em dados e não especulações ou intuição. Por outro lado, esta abordagem permite uma resposta dinâmica a um ambiente de negócios que está em constante mudança (Halper & Stodder, 2014).

Podemos definir BA como o uso de dados de modo a tomar melhores decisões e com base em provas (Holsapple *et al.*, 2014). Divide-se em cinco categorias: (1) análise descritiva, (2) análise de diagnóstico, (3) análise preditiva, (4) análise prescritiva, e (5) análise cognitiva (Król & Zdonek, 2020).

Por sua vez, BI define-se como as ferramentas de IT, como *data warehouses*, *online analytical processing* (OLAP), ferramentas estatísticas e quantitativas, de visualização e de *data mining*, que habilitam e permitem as atividades de BA (Howson, 2011; Negash, 2008; Ramamurthy *et al.*, 2008). Por esta razão os sistemas de BA são mais do que apenas a tecnologia. Os sistemas de BA englobam pessoas, processos e tecnologias envolvidas na captura, análise e transformação de dados utilizada no suporte à decisão de gestão (Negash, 2008; Watson & Wixom, 2007; Jordan & Ellen, 2009).

A BA atual está enraizada nos avanços contínuos de sistemas de suporte à decisão. Estes avanços incluem mecanismos cada vez mais poderosos para adquirir, gerar, assimilar, selecionar e emitir conhecimento relevante para a tomada de decisão. Dada a sua herança de suporte à decisão, a BA participa e explora estes mecanismos (Holsapple, 2014).

Desenvolvimentos recentes, como BI/BA em *cloud*, análise preditiva e em tempo real introduzem novas formas das organizações obterem insights e valor de negócio a partir de uma grande quantidade de dados. Estes avanços tecnológicos são de extrema importância para as iniciativas de BA. Para que sejam extraídos conhecimentos, ideias e valor para as empresas, são necessários dados com qualidade, o que depende de IT e da infraestrutura de dados (Bharadwaj, 2000; Dakin, 1992; Nam *et al.*, 2019).

Contudo, BA é mais do que apenas a tecnologia, e para os esforços das empresas darem frutos, há fatores importantes para além da gestão dos dados, processamento de números, e tecnologia. Estes tópicos refletem se a organização está pronta para adotar BA como um paradigma de tomada de decisão, ou se uma tentativa de adoção possa vir a falhar. Os fatores críticos sugeridos por Holsapple (2014) são: consciência e compromisso para com a visão, missão e estratégia da organização; cultura *analytics-friendly*; uma filosofia de gestão que compreenda e apoie o uso de BA; técnicas para evitar que as provas sejam abafadas por fatores anti analíticos, como apatia, apreensão, coerção, inveja, moda ou ideologia. Segundo Nam, (2019) os fatores organizacionais, obstáculos de gestão e centralização analítica influenciam os níveis superiores de adoção, e assimilação, enquanto fatores do ambiente organizacional e de competição tem um efeito positivo exclusivamente na iniciação.

As organizações procuram desenvolver as suas estratégias analíticas para além das folhas de calculo e *dashboards* de gestão simplistas e tentam criar uma cultura analítica transversal à organização, onde os dados têm um papel importante na tomada de decisão (Halper, & Stodder, 2014). Ainda assim, inúmeras organizações têm vindo a ter dificuldades na estratégia, implementação e medição dos seus esforços em BA (Muller *et al.*, 2016). Poucas organizações têm capacidades analíticas suficientes, incluindo infraestruturas e recursos humanos, assim como as competências necessárias para os gerir, de modo a ir ao encontro com as necessidades analíticas atuais. Além disso, poucas organizações são capazes de estimar a medida em que fazem uso da análise dos dados, ou sabem responder a como podem aumentar a eficácia dos processos de negócio com base em *analytics*. Um crescente número de organizações procura formas de avaliar a maturidade analítica que ajude a conduzir o desenvolvimento das competências e cultura analíticas da empresa (Lahrmann *et al.*, 2010).

Em suma, diversos modelos de maturidade de *Business Analytics* (MMBA) e *Business Intelligence* (MMBI) têm vindo a ser introduzidos para identificar forças e fraquezas no panorama de BA das empresas, e ajudar a tomar medidas corretivas (Muller *et al.*, 2016).

### 2.3 Business Analytics na indústria da construção

O setor da construção contribui de forma significativa para a economia, formação de capital e criação de emprego (Hillebrandt, 2000), sendo um dos grandes setores, tem um papel importante no desenvolvimento e crescimento económico de um país (Giang & Pheng, 2011). Só na União Europeia, com um investimento total de cerca de 1.37 biliões de euros, a construção é um dos principais mercados da construção (Deloitte, 2014).

Esta importância económica do setor deveria levar a uma maior adoção das tecnologias de BA, o que não acontece atualmente ao mesmo ritmo que noutras indústrias. Em parte, este atraso pode dever-se ao facto de ter o mais baixo investimento em I&D (Oesterreich & Teuteberg, 2016), quando comparado com outros setores. De acordo com o *scoreboard* de Inovação e desenvolvimento (I&D) da União Europeia, o setor da construção e materiais está entre os setores que menos investem em I&D, contando com apenas 1% das vendas (Hernández *et al.*, 2015). O facto dos projetos de construção se estarem a tornar cada vez mais complexos – apesar da construção ser uma indústria estável, olhando para as últimas cinco décadas – leva a olhar para a adoção da Indústria 4.0 como uma necessidade (Alaloul *et al.*, 2018; Bock, 2015). Ainda assim a construção não é exceção no que toca à difusão da revolução industrial. O setor está a lidar com um número crescente de dados vindos de várias etapas do ciclo de vida de um edifício.

Segundo Pan e Zhang (2021) há um problema grave de baixa produtividade laboral ao longo do processo, levando ao desperdício de mão de obra, recursos materiais e financeiros. Por outro lado, o setor da construção e engenharia não manteve o ritmo no que toca a oportunidades tecnológicas que possam ajudar a melhorar a produtividade, o que resulta em estagnação da produtividade laboral (Livotov *et al.*, 2019). Como também foi descrito por Dubois e Gadde (2002), a indústria falhou na tentativa de integração de tecnologias e processos de outros setores, que podem contribuir para melhorar a performance e produtividade, nomeadamente: entrega *just-in-time*; parcerias com fornecedores, gestão da cadeia de abastecimento, produção *offsite* e os mais recentes avanços em tecnologias de informação. Apesar dos benefícios que podem trazer, as empresas de construção não conseguiram ainda integrar de modo geral as tecnologias inovadoras de modo a acompanhar os homónimos da indústria automóvel e mecânica (Kraatz *et al.*, 2014). Por exemplo, a cadeia de valor da construção é inteiramente afetada por colaborações próximas com clientes e subempreiteiros, ou outros *stakeholders*. Os projetos de construção são *site-based*, complexos e com grandes esforços individuais, que requerem um elevado nível de

conhecimento especializado. Por outro lado, o setor consiste num elevado número de empresas de pequena e media dimensão (Kraatz *et al.*, 2014).

As empresas acreditam, contudo, na possibilidade de recorrendo a *Business e Data Analytics* poderem resolver todos estes problemas e gerarem valor de negócio

### **2.3.1 Problemas e frustrações do setor da construção**

Apesar do setor gerar uma quantidade enorme de dados ao longo do ciclo de vida de um projeto, a adoção de tecnologia de *Big Data* (BD) está ainda longe do progresso feito noutros setores, de acordo com Rajaraman, (2013).

Os projetos de construção são complexos. Existem várias razões para esta complexidade, que incluem a necessidade de coordenar vários participantes, que são frequentemente pequenas e medias empresas (PME), o facto de o local dos projetos variar, e de requerer um certo nível de conhecimento especializado (Kraatz *et al.*, 2014). De forma mais ampla, as PME compõem uma proporção grande das empresas de construção na maioria das geografias (Kraatz *et al.*, 2014).

A indústria da construção tem várias outras especificidades que podem ser razão de maior vulnerabilidade das empresas a falências, comparativamente a outros setores de atividade. Como referido por Tserng, Liao, Jaselskis, Tsai e Chen (2012), essas características dizem respeito a: (i) desenvolvimento de projetos únicos; (ii) projetos de longa duração; (iii) complexidade dos processos de construção; (iv) envolvimento de equipas específicas, distribuídas por várias empresas diferentes; (v) incerteza e riscos associados à atividade (Horta & Camanho, 2013).

Os fatores (i) e (iii) implicam que, ao contrário da indústria produtiva, os produtos do setor da construção não sejam standardizados, e o processo de produção não seja uniforme, logo, é impossível fazer listas de materiais padrão (Yang 2017).

Muitos desafios internos e externos estão associados aos fatores (ii) e (iv), incluindo o facto de se tratar de uma indústria fragmentada, dificuldade em recrutar mão de obra com talento, relações com fornecedores e empreiteiros insuficientes, e transferências de conhecimento de projeto para projeto inadequadas (Craveiro *et al.*, 2019). Quer a gestão de tecnologia, quer a gestão da construção dependem bastante de conhecimento e experiência individual. Se um gestor ou engenheiro experiente abandonarem a organização, é muitas vezes difícil para o seu sucessor utilizar e ter o mesmo nível de conhecimento e experiência (You *et al.*, 2018).

Relativamente ao desfasamento em inovação face a outros setores Arayici e Coates (2012) constata os seguintes fatores: (i) complexidade – os projetos são esforços complexos devido à quantidade de processos, sub-processos e participantes envolvidos, como

arquitetos, engenheiros, empreiteiros, serventes, clientes, fornecedores, entre outros (Dubois & Gadde, 2002; Arayici & Coates, 2012); (ii) Incerteza – como cada projeto é limitado em tempo, *site-based* e único, e há uma grande complexidade, há uma falta de especificação dos processos e materiais, resultando num ambiente incerto (Dubois & Gadde, 2002); (iii) fragmentação da cadeia de valor. Outra característica específica é a grande fragmentação da cadeia de valor devido à grande quantidade de pequenas e médias empresas com produtos e serviços indiferenciados (Arayici & Coates, 2012) e limitações na capacidade de investir em novas tecnologias (Kraatz *et al.*, 2014); (iv) Pensamento no curto prazo – A estrutura da indústria da construção foi descrita por (Dubois & Gadde, 2002) como sendo um sistema de múltiplos participantes em rede, pouco integro, composto por ligações baseadas em projetos individuais e ligações débeis na rede permanente, que é sustentado por um pensamento no curto prazo – orientado ao projeto - e impede inovação e conhecimento no longo prazo. Assim a natureza descentralizada e de projetos de curta duração é uma barreira à inovação; (v) Cultura – A construção é conhecida pela sua cultura rígida, resiliência e resistência à mudança.

Uma característica importante na cadeia de fornecimento da construção é que todos os atores têm distâncias diferentes, quer físicas quer cognitivas, ao local de produção (Xue *et al.*, 2007). Dainty *et al.* (2001) identificaram fatores distintos que são únicos às cadeias de abastecimento da construção, que requerem tarefas de gestão específicas. A mais notável é o carácter temporário dos projetos. Este fator leva à atitude limitativa “ganha-perde” entre fornecedores e construtores, que se focam nos resultados no curto prazo, e não procuram investir em relações no longo prazo. Este fluxo de informação entre construtores e fornecedores é assim, muitas vezes limitado, devido à pouca transparência, e poucas trocas de informação e comunicação. Isto pode levar a falsas expectativas e prazos de entrega de materiais e equipamentos incertos ou irrealistas (Xue *et al.*, 2007).

De acordo com estudos importantes, as características da Gestão de construção e engenharia (GCE) são cinco: Singularidade (de projetos); Mão de obra intensiva; Dinamismo; Complexidade; Incerteza (Pan & Zhang, 2021).

### **2.3.2 Tecnologias e técnicas**

Oesterreich e Teuteberg, (2016) mostraram que já há um número grande de tecnologias de digitalização e automação que entraram em fase de maturidade e como tal, estão disponíveis para a indústria. Devido ao notável crescimento de ferramentas e de aplicações de AI na área da engenharia civil, têm vindo a ser publicados bastantes estudos científicos acerca deste tópico. Contudo, Pan e Zhang (2021) concluíram que a maior parte deles

sublinha apenas o valor da Inteligência Artificial (IA) numa subárea específica, como engenharia estrutural (Salehi & Burgueno, 2018), *Building Information Modeling* (BIM) (Zou *et al.*, 2017), produção automatizada (Hatami *et al.*, 2019), computer vision (Zhang *et al.*, 2020) entre outras. Ou seja, fornecem apenas uma perspetiva estreita, específica a um grupo pequeno de atividades, em vez de uma visão holística da implementação de Inteligência Artificial na gestão de construção e engenharia.

*Enterprise Resource Planning* (ERP) foi uma ferramenta responsável por muitos sucessos no setor, mas ao contrário da indústria produtiva, a construção é um setor especial, com projetos únicos, locais descentralizados, e mobilidade dos fatores produtivos (como a mão de obra, materiais e equipamentos) (You & Wu, 2019).

O setor da construção é intensivo em dados. Há uma grande quantidade a ser gerada ao longo dos processos, e o seu valor está longe de ser totalmente utilizado (Bilal *et al.*, 2016). Ainda assim, devido à falta de uma Plataforma de gestão de dados unificada, após a conclusão de um projeto, é difícil utilizar os dados desse projeto para extrair valor e aplicá-lo noutros projetos. É então necessário estabelecer um Sistema de gestão de conhecimento (*Knowledge management system*) com base na mineração de dados dos projetos (You & Wu, 2019).

Tradicionalmente, os analistas utilizam técnicas estatísticas para descobrir padrões ou extrair conhecimento dos dados recolhidos. Segundo Bilal (2016), é, todavia, necessária a implementação de mais técnicas de mineração de dados.

Técnicas de *Data Mining* (DM) são uma tendência emergente no setor da construção (Yan *et al.*, 2020). A função de predição é a função de DM mais frequentemente usada, observada na literatura. Por exemplo, previsão de consumo de energia é de grande importância na gestão de energia da construção. Técnicas de DM são comprovadamente eficazes na predição de consumo de energia com base em quantidades enormes de dados operacionais (Reffat *et al.*, 2004).

É de notar que a cada etapa dos projetos são recolhidas grandes quantidades de dados heterogéneos, em especial com o surgimento de *Building Information Modeling* (BIM) e redes de sensores sem fios, e sensores *data-intensive* (Pan & Zhang, 2021). A indústria da construção é um setor onde a capacidade de gerar e recolher dados tem vindo a crescer (Soibelman & Kim, 2002).

Uma tecnologia catalisadora na colaboração e produtividade é BIM (Modelação de Informação de Edifícios), uma modelação prevista para capturar dados *Computer Assisted Design* (CAD) multidimensionais, de forma sistemática para apoiar colaboração multidisciplinar entre os diferentes intervenientes dos projetos (Eadie, 2013). É considerada a tecnologia central para a digitalização do ambiente de construção (Oesterreich & Teuteberg, 2016). A chegada de BIM trouxe várias oportunidades de desenvolvimento para a indústria

(You & Wu, 2019). Apesar de BIM ter melhorado a gestão e colaboração no ciclo de vida do projeto, está ainda limitada a projetos individuais (Eadie *et al.*, 2013). As empresas de construção geralmente têm vários projetos em mão em simultâneo. Porque os custos dos projetos não podem ser estimados com muita precisão, e preços de compras são difíceis de controlar, é geralmente comum haver derrapagens orçamentais.

Além disso, estudos mostram que há falta de processos de gestão do ciclo de vida do projeto, assim como falta de planeamento estratégico, tático e operacional nos sistemas de colaboração e sincronização autónomos (Maskuriy *et al.*, 2019). São necessários estudos nesta área de modo a transformar o setor da construção, e integrar BIM com a indústria 4.0.

De entre outros conceitos e tecnologias associadas à construção são também conceitos como Gestão de Ciclo de vida do Produto (*Product-Lifecycle-Management*, PLM), modularização, robótica e tecnologias de informação como computação móvel e RFID, como uma das principais tecnologias para sistemas cyber-físicos (Oesterreich & Teuteberg, 2016).

## **2.4 Modelos de Maturidade**

A noção de maturidade foi proposta pela primeira vez por Crosby (1979), que descreve o “estado de conclusão, perfeição ou estar pronto” (Simpson & Weiner, 1989). Para atingir o estado de maturidade desejado, é necessário um processo de transformação evolutiva, de um estado inicial para um estágio objetivo, desejado (Fraser *et al.*, 2002).

Modelos de maturidade são ferramentas que facilitam a avaliação do nível de desenvolvimento de capacidades organizacionais, processos e recursos (Cosic *et al.*, 2012). O objetivo dos modelos é identificar a falha existente, que pode depois ser melhorada após a tomada de ações (Fraser *et al.*, 2002).

Os modelos de maturidade consistem num modelo e questionário, que são usados para perceber o nível de desenvolvimento de um ambiente (Pivka, 1996). São instrumentos que facilitam a análise do nível de progresso das capacidades (de Bruin, 2009), processos (Paulk *et al.*, 1993) ou recursos (Nolan, 1973). Na prática muitos modelos de maturidade acabam por ser utilizados em processos de melhoria e não em formas de medir absolutamente a performance (Fraser *et al.*, 2002).

Quando uma empresa quer ter resultados mais precisos no que toca a níveis de maturidade, deve usar diferentes níveis de maturidade para abranger mais áreas diferentes e recolher mais informação acerca do estado atual ou possíveis desafios que devem ser ultrapassados para atingir um nível mais elevado de maturidade, e aumentar o valor de negócio (Rajterič, 2010).

A maturidade combina noções de evolução com patamares formais de processos. Para evitar complexidade e burocracia excessiva, Fraser *et al.* (2002) propõe uma definição de maturidade que dá ênfase na eficácia e repetibilidade.

Atualmente existem mais de 130 modelos diferentes para Sistemas de informação (SI), quer a nível académico ou prático, segundo Mettler e Rohner (2009). Dois modelos muito usados a nível prático são o modelo de níveis de crescimento de Nolan (1973) e *Capability Maturity Model* (CMM) proposto por Paulk *et al.* (1993). Os modelos atuais derivam normalmente do CMM, que foi idealizado para o processo de desenvolvimento de *software*, com base na Tese da Maturidade por Humphrey (1989) pelo *Software Engineering Institute* em Carnegie Mellon University nos EUA (Team, 2006).

Vários modelos de maturidade são baseados em elementos de “boas práticas” derivados de estudos publicados que identificam os fatores associados aos resultados bem-sucedidos (Fraser *et al.*, 2002). Outros têm elementos vindos da “experiência”, baseados em observações de experiências práticas, onde um processo de validação pode já ter ocorrido, ainda que não seja muito rigoroso e metódico. Cooper (1999), sugere que não há ainda concordância quanto à forma correta de garantir sucesso nos resultados, (Montoya-Weiss & Calantone, 1994), apesar da identificação de várias descobertas robustas acerca de formas de medir a maturidade.

Para a área de BA, a maturidade analítica torna-se particularmente importante por várias razões, segundo Grossman (2018). Primeiro, com o crescimento do volume, velocidade e variedade dos dados, ter uma infraestrutura analítica é de enorme importância. Em segundo lugar, em especial em BD, a probabilidade de usar um número maior de modelos analíticos é grande. À medida que o número cresce (às centenas ou milhares, ou mais), torna-se importante ter uma estrutura analítica que possa construir, gerir e implementar esses modelos. Em terceiro lugar, a importância de BD deve-se na medida em que os modelos de previsão produzidos poderem ser implementados em serviços ou produtos, em toda a cadeia de valor, de modo a aumentar vendas, diminuir custos, reduzir os riscos e otimizar as operações, e, como tal, acrescentar um grande valor à organização. Como tal, quanto melhor a maturidade analítica da empresa, maior a probabilidade de isto ocorrer.

Chen e Nath (2018) identificam 3 fatores que coletivamente explicam 77,7% da variância da maturidade de BA. O mais dominante, integração de BA e apoio da gestão, explica 32,6% da variância, o que sugere que a forma como BA é integrada nas operações da empresa e na sua estratégia, e quão empenhada está a gestão para apoiar as iniciativas de BA, são indicadores chave na maturidade analítica. Esta observação é consistente com os modelos de maturidade BA focados na empresa, que dão ênfase ao empenho organizacional e alinhamento estratégico entre BA e negócio.

O segundo fator, benefícios de BA a nível de processo, sugere que a maturidade analítica pode ser particularmente avaliada através da obtenção de melhorias de resultados nos processos suportados por BA. Contrariamente ao senso comum, as capacidades analíticas e tecnológicas de uma empresa são o fator que explica a menor fatia da variância da maturidade de BA (20.4%). Por outro lado, o primeiro fator é o que mostra ter mais correlação com o sucesso de BA, enquanto o terceiro tem o menor grau de associação com sucesso de BA. Estas descobertas sugerem que apenas focando nas aquisições de competências tecnológicas relacionadas com BA não garante maturidade analítica ou sucesso (Chen & Nath, 2018).

O modelo de investigação de Chen e Nath (2018) também revela que a perceção das Tecnologias de Informação (TI) por parte do executivo tem um grande impacto na maturidade analítica. À medida que os órgãos executivos das empresas procuram um papel mais ativo na estratégia de TI e decisões de investimento na atualidade, colocam-se numa posição ideal para determinar como e onde TI cria valor para o negócio. Estes resultados confirmam as alegações feitas em estudos anteriores, de que a perceção de TI por parte dos executivos iria enviesar as suas decisões de investimentos de TI (Broadbent & Weill, 1993).

Król e Zdonek (2020) analisaram onze modelos de maturidade analítica, de entre os quais o modelo DELTA PLUS, por Davenport, (2018), que analisa sete componentes relevantes. No nome do modelo, a letra “D” representa os dados, que são relevantes para a obtenção de valor de negócio, “E” para “Empresa”, e a forma como está orientada para BA, “L” para “Liderança”, “T” para “Objetivos” (Target) estratégicos, que servem de base para a tomada de iniciativas analíticas e “A” para “analistas”. Adicionalmente foram acrescentadas duas novas vertentes: “T”, de “tecnologia” e “A”, de “técnicas analíticas”. Este modelo, para além de ser o que avalia mais dimensões nas empresas, é publico e facilmente acessível.

O modelo TDWI (*Transforming Data With Intelligence*) (Halper & Stodder, 2014) é outro dos modelos mais utilizados no âmbito de BA. Consiste em cinco etapas: nascente, pré-adoção, adoção intermédia, adoção corporativa e madura/visionária, respetivamente do menor para o maior nível de maturidade. O modelo avalia a empresa com base em 5 dimensões, que pontuam entre 0 e 20. Essas dimensões são: Organização, Infraestrutura de Dados, Recursos, *Analytics*, e *Governance*. A principal desvantagem deste modelo, segundo Chuach e Wong (2011) é o ênfase dado à utilização de *datawarehouses*. Este modelo encontra-se disponível *online*, em *Open Source*, não sendo contudo possível ter acesso ao peso das questões dentro de cada grupo.

## 2.5 Estado da arte

O objetivo de Fedouaki *et al.* (2013) foi desenvolver um modelo de maturidade para sistemas de *Business Intelligence* (BI), em PME. O modelo desenvolvido sobre três dimensões: Nível de maturidade, ciclos de vida de implementação do projeto, e fatores críticos de sucesso.

Relativamente aos níveis de maturidade, os autores resumiram em 3: inicial, definido e gerido. Uma empresa no nível inicial, ainda não começou a implementar ferramentas, técnicas e metodologias para extrair valor de dados, ou fá-lo a nível reduzido. No estágio definido, as empresas já iniciaram a caminhada analítica, havendo ainda espaço para melhorias. As empresas que se encontrem no nível gerido usam os dados de forma eficaz, tirando o máximo proveito para a geração de valor para o negócio.

O modelo foi validado com uma PME, numa primeira fase. Após esta iteração os autores chegaram a um questionário composto por 14 variáveis. Estas variáveis estão distribuídos por três fases do ciclo de vida do projeto. Este modelo, em forma de questionário foi respondido por 17 empresas, através de um gestor, de entre de 65 empresas selecionadas.

Os autores concluíram, através do trabalho, que os estágios do ciclo de vida do projeto de implementação de sistemas BI que dependem mais de fatores tecnológicos, atingem níveis de maturidade superiores que os que dependem de fatores organizacionais. Em geral o nível médio é considerado "Definido".

Bibby e Dehe (2018) desenharam e validaram um modelo de maturidade de I4.0 para uma empresa do setor da defesa, em conjunto com doze *stakeholders*.

A construção modelo engloba um conjunto de entrevistas semiestruturadas, workshops e pontuação de itens, numa lógica de caso de estudo para iterativamente validá-lo. Uma vez validado o modelo, catorze especialistas foram convidados a participar na elaboração deste modelo de avaliação.

O modelo final divide-se em três secções: fábrica do futuro, pessoas e cultura, e estratégia. Cada uma conta com 16, 3 e 4 itens em escala de *likert*, respetivamente. Os resultados dividem-se em quatro níveis de maturidade, em que o nível um corresponde a um máximo de pontuação igual a 2 para todas as perguntas, o nível 3 corresponde a um mínimo de 2 e um máximo de 3, e assim sucessivamente.

Foi posteriormente submetido a 12 *stakeholders*, sendo que a pontuação de cada item consiste no consenso encontrado por todos. Para todas as categorias, foi concluído que a empresa reside no segundo nível de maturidade.

Caiado *et al.* (2021) desenvolveram um modelo de maturidade de I4.0 baseado em *Fuzzy-logic* para operações e gestão de cadeias de abastecimento (OGCA). O procedimento incluiu a análise de modelos existentes na literatura, um processo iterativo para seleção de indicadores para o âmbito do trabalho, construção e avaliação do modelo, e aplicação numa empresa.

O questionário desenvolvido é constituído por sete perguntas demográficas sobre os respondentes, duas acerca da perceção de I4.0, e quinze perguntas divididas em sete dimensões de maturidade: consumidor; logística; fornecedor; integração, produção, planeamento e controlo, qualidade; e manutenção, que mais tarde foram resumidas para três: processos, pessoas e tecnologia.

Os autores decidiram usar como base para a avaliação de maturidade o CMM, considerando assim 5 níveis de maturidade. Posteriormente o questionário foi aplicado a 8 respondentes chave de uma empresa da área de OGCA.

O modelo quantitativo baseado em *fuzzy-logic* permite quantificar informações qualitativas, vagas e imprecisas.

Stawiarska *et al.* (2021) avaliaram o nível de maturidade de seis áreas funcionais de I4.0 de empresas do setor automóvel, utilizando um modelo de maturidade.

O modelo desenvolvido pelos autores, validado em conjunto com *stakeholders* de uma empresa, contou com cinco níveis de maturidade, com base numa descrição. Parte do questionário conta com perguntas que abordam o tipo e dimensão da empresa.

O questionário foi respondido por 50 empresas de dimensão grande, média e pequena, na Polónia, respondidos por engenheiros com experiência, enviado por email. A análise das respostas foi feita através de uma análise descritiva. O nível médio de maturidade foi de 3.

Através de uma modelo de maturidade, Pirola, F., e Pinto, R (2020) avaliaram a maturidade digital de 20 PME italianas, do setor de produção industrial. Um primeiro rascunho do modelo foi validado junto de 2 empresas. Após retificação, o novo modelo foi utilizado nas restantes 20 das 22 PME selecionadas. A análise descritiva das avaliações feitas permitiu tirar conclusões e responder às questões de investigação dos autores.

O modelo feito consiste em perguntas de cinco domínios: estratégia, pessoas, processos, tecnologia e integração. O questionário foi enriquecido com perguntas mais específicas acerca de competências e fatores humano competências e fatores humanos, após feedback recebido da primeira validação com empresas. Assim, o modelo final engloba 46 questões. As doze primeiras referem-se a características organizacionais, como dimensão. As seguintes vinte e quatro abordam as cinco dimensões referidas anteriormente, numa escala *likert*. A secção final, de 10 questões de escolha múltipla, questiona acerca de investimentos estratégicos que a empresa esteja a tomar, e afetam o score das outras questões. Este aspeto cobre um gap na literatura relativo à falta de modularidade das avaliações de maturidade.

Os autores concluíram que a gestão de topo é o fator que mais afeta a maturidade analítica, assim como a estratégia da organização.

Gökalp *et al.* (2021) propuseram um modelo de maturidade de *Data Science*, para organizações industriais, posteriormente validado por várias empresas. O objetivo é criar um modelo que possa ser usado para melhorar a produção baseada em dados. O modelo avalia

com base em cinco níveis de maturidade (do um ao cinco), em três dimensões: dimensão de processo, dimensão de capacidade e maturidade organizacional de *data science*. A avaliação foi feita em três organizações com provas de iniciativas de adoção de *data science*, e ambição de otimizar processos. Para evitar enviesamento das respostas a entrevista foi feita num formato semiestruturado, com perguntas abertas avaliadas numa escala de *Likert* de 1 a 5.

## Capítulo 3 - Abordagem

### 3.1 Escolha do modelo de maturidade

O modelo aplicado neste trabalho foi adaptado a partir do TDWI (Halper & Stodder, 2014), por ser dos únicos disponíveis abertamente *online*. Este modelo de medição da adoção de *analytics*, em forma de questionário é composto por 54 questões, divididas em 5 grupos. O primeiro grupo, Organização, é composto por questões acerca da forma como a liderança e organização estão alinhadas para adotar BA. O segundo grupo, Infraestrutura de Dados é referente a como a empresa recolhe, armazena e guarda os dados que são importantes para a criação de valor de negócio. O terceiro grupo Recursos inclui as questões relativas a como a organização investe, mantém e melhora os recursos utilizados para *analytics*, humanos ou materiais, tangíveis ou intangíveis. De seguida, existe um grupo de questões dedicado a perceber o grau de utilização de ferramentas, técnicas e metodologias para a transformação dos dados, em conhecimento, cujo título é *Analytics*. Por fim existe também um grupo de questões *Governance* que procura conhecer a forma como a empresa gere todo o acesso, manutenção e divulgação da informação. Estas questões são em formato de escolha múltipla, entre 3 a 6 opções por pergunta, e diferem quanto às respostas, sendo que nuns casos são pré-definidas pelos criadores do questionário, noutras questões, as respostas são em formato escala de *likert*, i.e., de “Discordo totalmente” a “Concordo totalmente”, de modo a perceber a opinião do respondente quanto ao tópico em questão. O maior grupo é o *Analytics*, com 12 perguntas, e o menor é o de *Governance*, com 9 perguntas. Os restantes têm 11 perguntas cada. No final a pontuação de cada grupo, ou global, é classificada em níveis de maturidade, numa escala de 0-100, em que o primeiro nível, “Nascente”, refere-se à pontuação entre 0 e 20 pontos, inclusive, o segundo, “Pré-adoção”, cobre o intervalo dos 20 pontos (exclusive), a 40 pontos, inclusive, o terceiro, “Estabelecida”, de 40 a 60, o quarto, “Madura”, de 60 a 80 pontos, e o último, que classifica a empresa como “Visionária”, inclui o último patamar, de 80 a 100 pontos.

Para além das 54 perguntas de escolha múltipla, agrupadas em 5 módulos, que foram traduzidas para português, foram acrescentadas 10 questões das quais 8 para análise

demográfica das respostas e duas apenas para futuro contacto e divulgação dos resultados. Estas questões adicionais não atribuem quaisquer pontos.

Para além das opções de resposta originais do questionário, foi incluída, em cada questão, a opção “Não compreendo esta questão”, que resulta na atribuição de 0 pontos, com o objetivo de perceber a literacia dos respondentes em relação aos vários tópicos.

Como referido por Chuah e Wong (2011), um dos problemas do modelo TDWI é o enfoque dado à dimensão da infraestrutura de dados, e mais concretamente, a existência de *datawarehouses*. Sendo o âmbito deste trabalho a disciplina de BA, e a forma como os dados geram valor para o negócio, e dado o modelo ser do tipo *black-box* (i.e., não ter visibilidade sobre a forma como as questões são pontuadas), foi decidido que os grupos Organização, Infraestrutura de Dados, e Recursos teriam um peso de 20% na pontuação final, sendo o grupo de *Analytics* aquele com o maior peso (22%) e *Governance* com menos (18%), já que não foi encontrada uma quantidade significativa de trabalhos que mencionem a importância desta dimensão, na literatura existente. Adicionalmente, foram seleccionadas várias questões que aparentem ser menos pertinentes para com o respetivo grupo, para que pontuem menos que as demais perguntas. No Anexo A.1, podem ver-se as perguntas que foram pontuadas com um ponto, dado serem menos pertinentes para o respetivo grupo de questões. No Anexo A.2 encontram-se as pontuações globais de cada grupo de questões.

### **3.2 Obtenção de respostas**

A obtenção de respostas foi feita em duas fases: a partir de uma lista de principais empresas de construção a operar em Portugal (Infoempresas, 2022) e onde surgiram 7 respostas de 30 contactos, e divulgação do questionário em 3 associações empresariais do setor da construção, a partir dos quais foram obtidas 23 respostas, totalizando 30 respostas.

O questionário foi construído utilizando a ferramenta *Microsoft Forms* e enviado por email para cada candidato. As empresas seleccionadas na primeira fase foram contactadas através de um telefonema. No questionário anónimo, foi pedido um contacto de email para posterior divulgação dos resultados individuais e globais.

Dois dos respondentes levantaram a necessidade de uma sessão de esclarecimento relativo às questões.

### **3.3 Tratamento dos dados**

Após a recolha das respostas, os dados foram submetidos a alguns tratamentos, com o objetivo de facilitar a análise das respostas e dos resultados.

Em primeiro lugar, as respostas às questões do modelo de maturidade, que eram variáveis qualitativas ordinais foram recodificadas de modo a obter a pontuação de cada questão. Sendo que as respostas seguem uma escala de *Likert*, a pontuação foi obtida da seguinte forma:

$$p = \frac{R}{T} \times P \quad (1)$$

em que  $p$  é a pontuação da questão,  $R$  é a resposta na escala de *Likert*,  $T$  é o número total de opções para essa pergunta, e  $P$  é o peso dessa questão na pontuação total. Nos casos em que a resposta foi “Não compreendo esta questão”, a pontuação atribuída foi de 0. Posteriormente, as pontuações de cada questão foram agregadas por grupos (Organização, Estrutura de Dados, Recursos, *Analytics* e *Governance*,) e Total, e foram classificadas pelos níveis de maturidade do modelo TDWI.

Com base nas variáveis “Número de Funcionários” e “Faturação” foi criada a variável binária “É PME”, para classificar as empresas dependendo de serem ou não PME, segundo os critérios do IAPMEI (2019), que são ter um número de funcionários inferior a 250 e um volume de negócios inferior a 50 milhões de euros.

As variáveis Idade da Empresa e Número de Funcionários foram transformadas em variáveis qualitativas com 5 grupos, e foram criadas categorias mais abrangentes para a variável “Estudos do respondente” e para “Departamento do Respondente”.

As variáveis “TotalA” e “TotalG”, que resumem as pontuações totais dos grupos de questões *Analytics* e *Governance*, respetivamente, foram normalizadas para que pudessem ser comparadas com as pontuações dos restantes grupos de questões, cuja escala é de 0 a 20, ao contrário destas, que podem ser pontuadas entre 0 e 22 (*Analytics*) e 0 e 18 (*Governance*). A pontuação total da maturidade analítica permaneceu inalterada, já que estes grupos têm pesos diferentes no resultado.

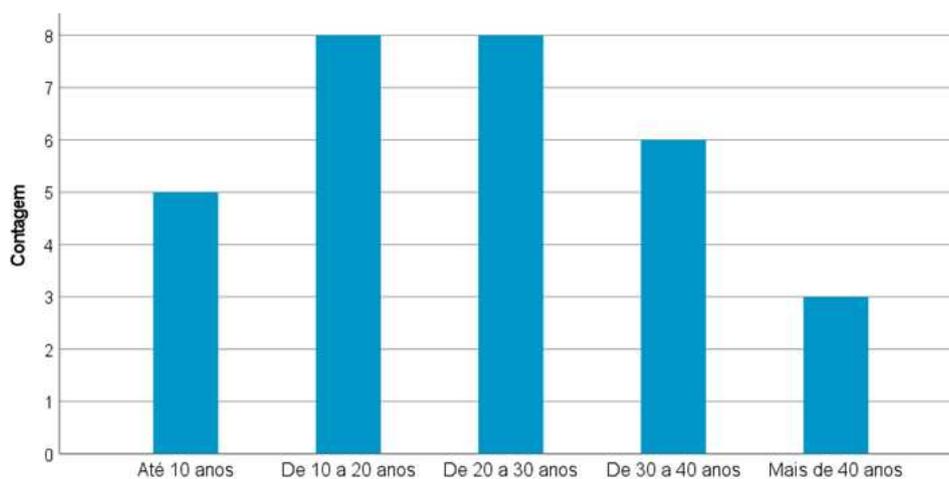
Por fim, de modo a melhor compreender os resultados, os nomes dos níveis de maturidade foram substituídos por algumas expressões utilizadas no modelo DELTA, que melhor espelham o estágio de maturidade. Assim, a etapa “nascente” manteve o nome, assim como “pré-adoção”, “adoção intermédia” foi alterado para “Estabelecida”, “adoção corporativa” foi alterado para “Madura” e “madura/visionária” para “Visionária”.



## Capítulo 4 - Análise dos Resultados

### 4.1 Caracterização da amostra

Foram obtidas 30 respostas de empresas do setor da construção. As empresas respondentes seguem a distribuição ilustrada na *Figura 4.1*. São predominantemente mais velhas, estando a média de idades nos 23 anos, o que é bastante elevado, tendo em conta que cerca de 39,1% das empresas não ultrapassa os 5 anos de idade (INE, 2020).



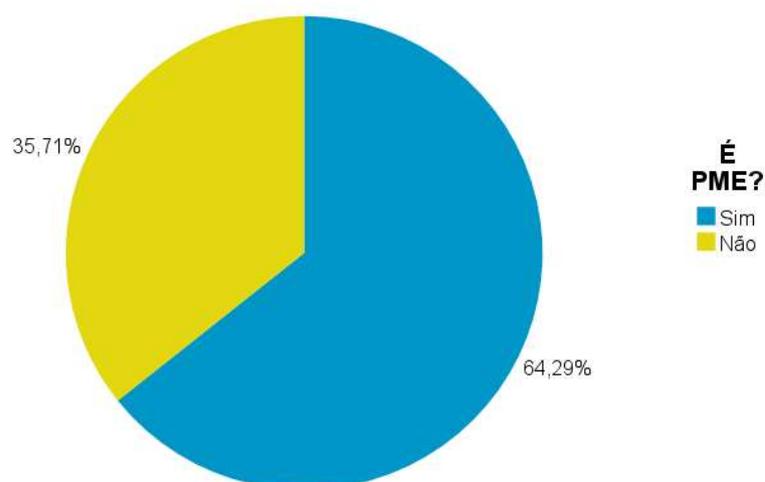
**Figura 4.1 - Distribuição da Idade das Empresas**

O valor de *skewness* (*Tabela 4.1*) mostra que há uma ligeira assimetria positiva na idade das empresas, e a *curtose* evidencia que a variável é platicúrtica, isto é, tem um achatamento maior. Ainda assim, o quociente entre estes indicadores e o respetivo erro sugerem normalidade na distribuição de idade.

**Tabela 4.2 – Estatísticas descritivas da variável “Idade da Empresa”**

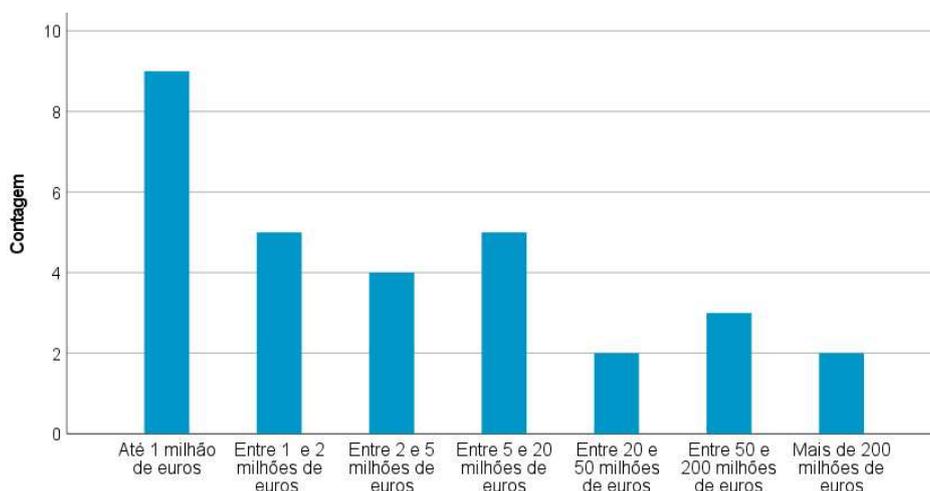
	N	Mínimo	Máximo	Média	Desvio Padrão	Assimetria	Curtose
<b>Idade da empresa</b>	30	4	45	23,73	12,140	0,129	-0,958

Pouco mais de um terço das empresas da amostra, com 36% dos casos, não são PME (*Figura 4.2*). Este valor é substancialmente maior que o do universo, que seria composto por PME em 99,9% em 2020 (INE, 2020).



**Figura 4.2 - Distribuição das empresas quanto ao Tipo**

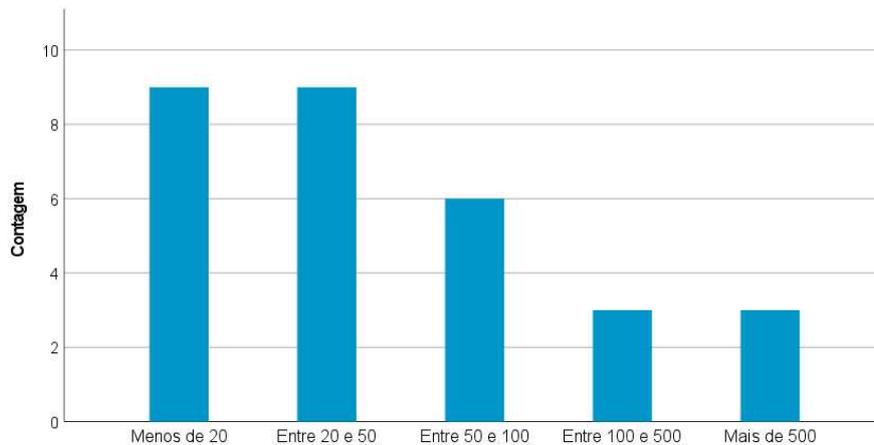
A amostra inclui respondentes de empresas que faturam até 1 milhão de euros por ano (n=9) até empresas que faturam mais de 200 milhões de euros por ano (n=2). Quanto à faturação, a amostra é enviesada à esquerda, como se pode observar na *Figura 4.3*, em que 9 empresas têm um volume de negócios de até 1 milhão de euros, correspondendo a 30% da amostra. A frequência vai progressivamente baixando nos níveis superiores de faturação, sendo que apenas 2 empresas, 6,(6)% da amostra, responderam ter um volume de vendas superior a 200 milhões de euros anuais.



**Figura 4.3 - Distribuição das empresas por nível de faturação**

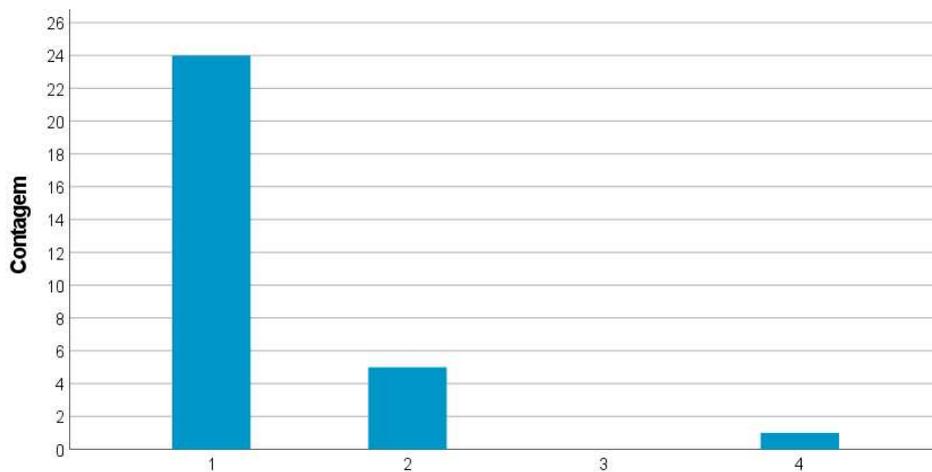
Também a variável “Número de Funcionários” (*Figura 4.4*) é enviesada à esquerda. As categorias com mais resultados correspondem a um número de funcionários de “Menos de

20” e “Entre 20 e 50”, ambas com 9 respostas. 3 empresas responderam ter “Mais de 500” funcionários, e um número igual de firmas respondeu ter “Entre 100 e 500”.



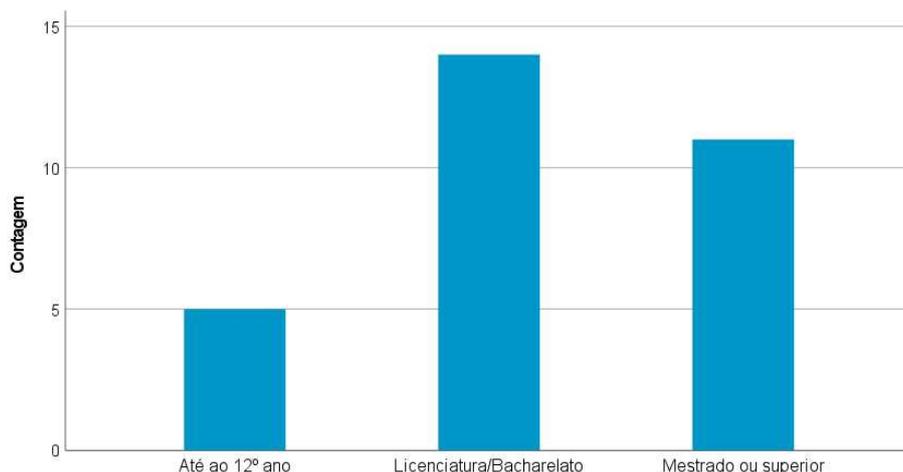
**Figura 4.4 - Distribuição das empresas quanto ao número de Funcionários**

De entre dos 30 respondentes, 24 afirmaram ter respondido individualmente ao questionário, conforme representado na *Figura 4.5*. Apenas 5 fizeram-no a pares, e apenas uma empresa respondeu com o conhecimento de 4 funcionários.



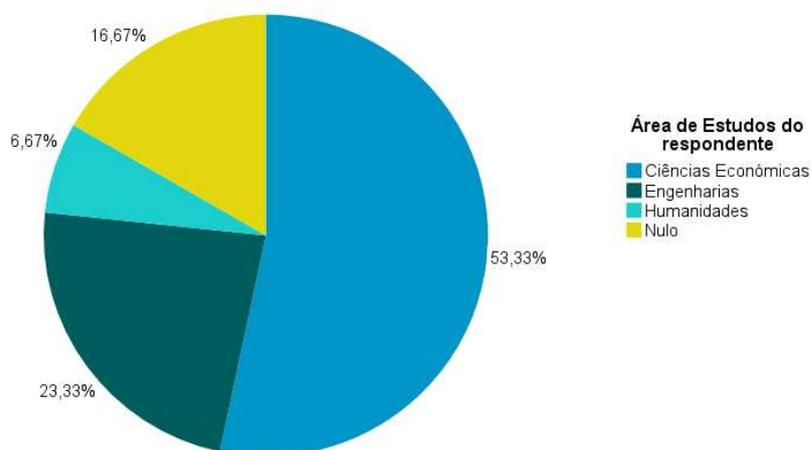
**Figura 4.5 - Distribuição do número de respondentes**

Relativamente ao nível de escolaridade dos respondentes, apenas 5 admitiram ter até ao 12º ano de formação, tendo a maior parte (~83,3%) obtido estudos superiores (*Figura 6*).



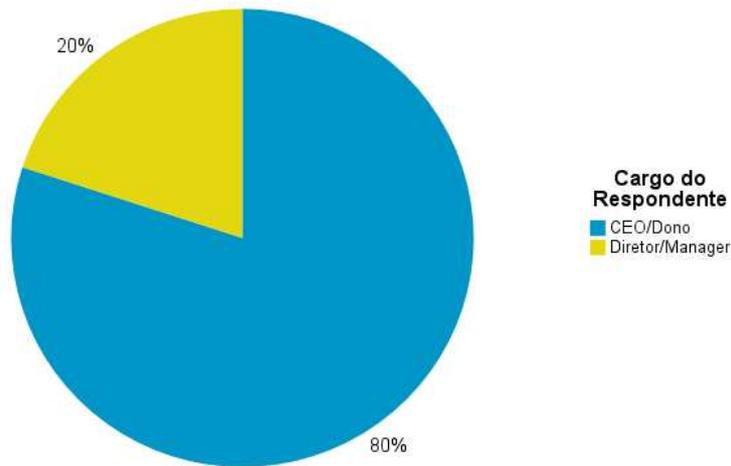
**Figura 4.6 - Distribuição do grau de escolaridade dos respondentes**

A maioria dos respondentes tem formação na área das Ciências Económicas (53,33%), como é possível observar na *Figura 4.7*. A área de estudos que obteve o número mais baixo de respostas foi a das “Humanidades” com apenas 6,67% dos casos. A categoria “Nulo”, que representa 16,67% corresponde a respondentes que não têm formação superior.



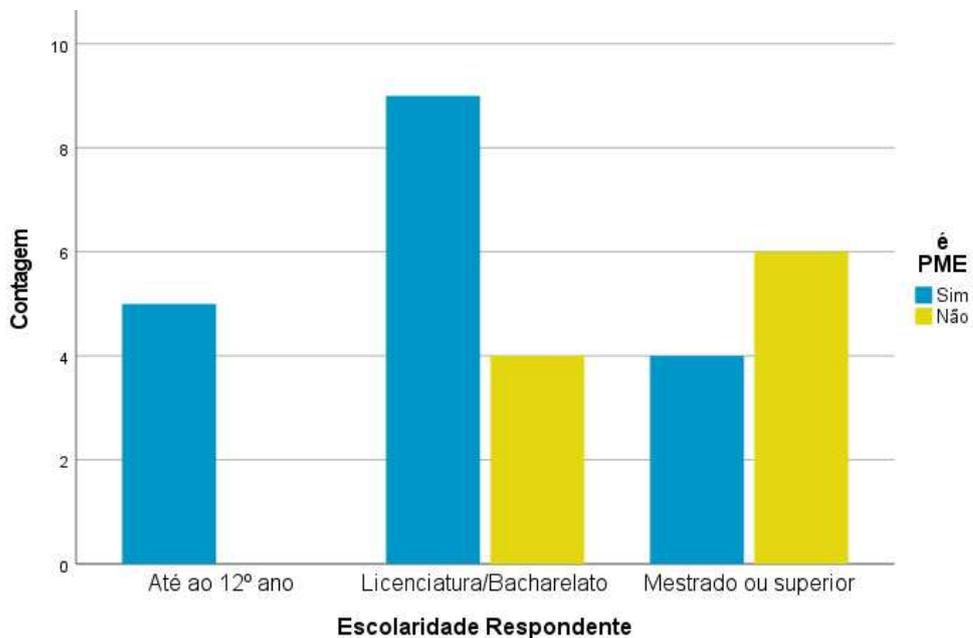
**Figura 4.7 - Distribuição da Área de Estudos dos respondentes**

De entre os respondentes sem formação superior, 80% ocupa o cargo de *Chief Executive Officer* (CEO) ou Dono da empresa, enquanto 20% ocupa cargos de quadros superiores (*Figura 4.8*).



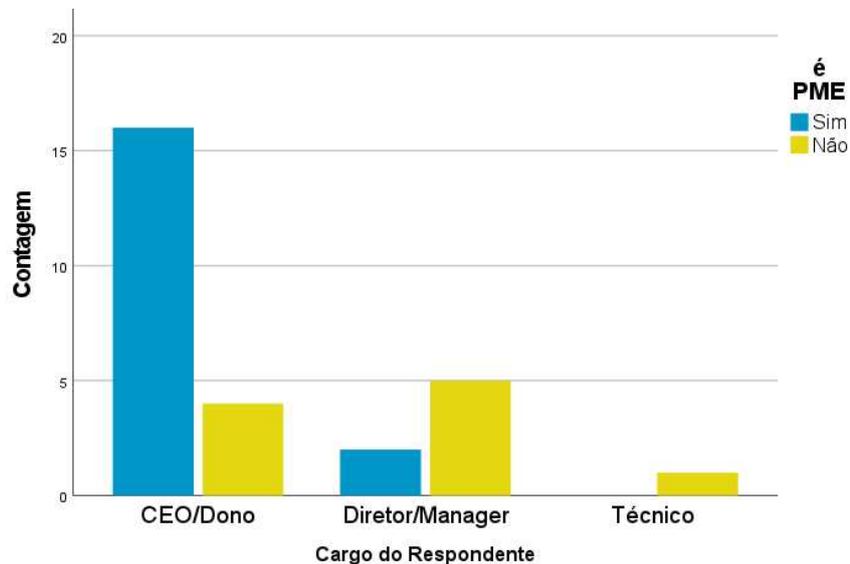
**Figura 4.8 - Distribuição do Cargo do Respondente, para Nível de Escolaridade até ao 12º ano**

Por outro lado, é notável que todos os respondentes com até ao 12º ano de escolaridade sejam de PME, enquanto nos níveis de escolaridade de “Mestrado ou superior” prevaleçam respondentes de não-PME, i.e., empresas de grande dimensão (Figura 4.9).



**Figura 4.9 - Distribuição do nível de escolaridade do respondente, por tipo de empresa**

A *Figura 4.10* mostra que a maioria dos respondentes de quadros superiores (“Diretor/Manager”) ou “Técnicos” representam empresas não-PME, enquanto que, tal como referido anteriormente, é nas PME que se encontram a maior parte dos respondentes que ocupam cargos de CEO ou Donos da empresa.



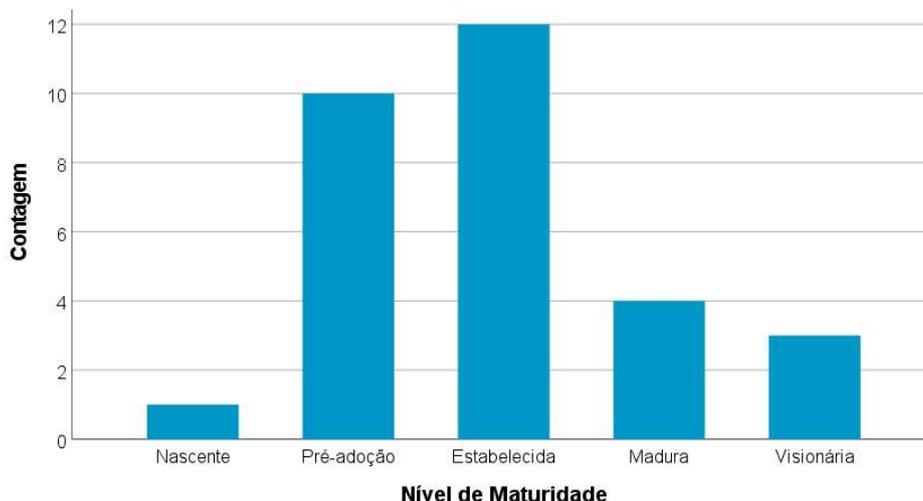
**Figura 4.10 - Distribuição do Cargo do Respondente, por tipo de empresa**

Em suma, o perfil mais comum de respondente é CEO da empresa, fazendo parte da Administração da mesma, tem como escolaridade o grau de Licenciatura ou Bacharelato e tem em média 48,7 anos.

Relativamente à empresa, o perfil mais comum é ser PME, faturar menos de 1 milhão de euros anualmente, ter menos de 20 funcionários, e em média 23,73 anos de existência.

## 4.2 Análise dos resultados

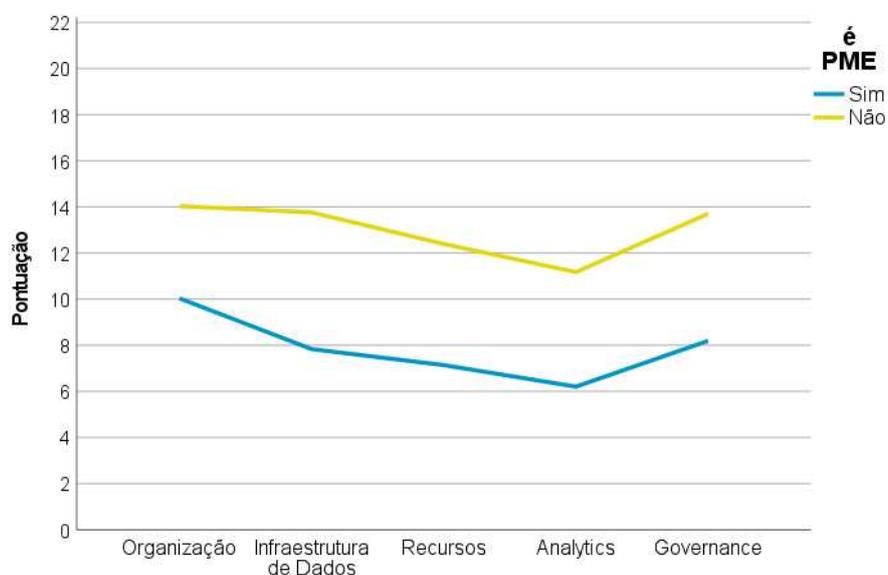
O nível de maturidade mais obtido nos resultados do questionário, ilustrados na *Figura 4.11* foi “Estabelecida”, que corresponde ao nível intermédio de maturidade analítica, seguido de “Pré-adoção”, que representa um intervalo de pontuação entre os 20 e 40 pontos. É notável que o número de empresas que obtiveram o nível de “Nascente” é muito baixo (n=1), relativamente às que obtiveram níveis mais avançados, como “Madura”, com 4 casos, e “Visionário” com 3.



**Figura 4.11 - Distribuição da maturidade analítica**

A pontuação média referente à maturidade analítica é superior em todos os grupos de questões para empresas não-PME face a PME, sendo que a pontuação média total é de 64,82 para empresas não-PME e de 39 (Figura 4.12). É também explícita uma quebra nas pontuações para o grupo de questões Analytics que dá ênfase à aplicação de metodologias, técnicas e ferramentas analíticas. Este fenómeno acontece quer nas PME quer nas empresas de grande dimensão. Para ambos os tipos de firma este grupo de questões foi aquele onde as pontuações foram mais baixas.

Para as análises comparativas das pontuações dos grupos de questões foram utilizadas as pontuações do Grupo A e G normalizadas. Para as análises do nível de maturidade e pontuação global, foram utilizadas as pontuações originais, que variam entre 0 e 22 para o Grupo A, 0 e 18 para o Grupo G, e 0 e 20 para os restantes grupos.



**Figura 4.12 – Pontuação média de cada grupo de questões,  
por tipo de empresa**

Os dois tipos de empresas obtiveram piores resultados no âmbito de Analytics, com uma média de 6,21 pontos para PME e 11,18 pontos para não-PME (*Tabela 4.2*). Importa realçar que as PME obtiveram uma pontuação abaixo de metade dos pontos possíveis em todos os grupos exceto Organização, enquanto que as empresa não-PME pontuaram acima deste *threshold* em todos os grupos.

A diferença mais significativa encontra-se no grupo de questões Analytics (43,07%) seguida do grupo de Infraestrutura de Dados (43,07%). Em termos globais, a diferença da maturidade analítica das empresas não-PME face a PME encontra-se nos 39,51%. O grupo de questões O, que incide sobre a estratégia organizacional foi onde as PME e grandes empresas obtiveram resultados mais próximos, sendo que a diferença de 28,49% não deixa de ser substancial.

**Tabela 4.2 – Estatísticas descritivas para a variável “É PME” por grupo de questões por categoria**

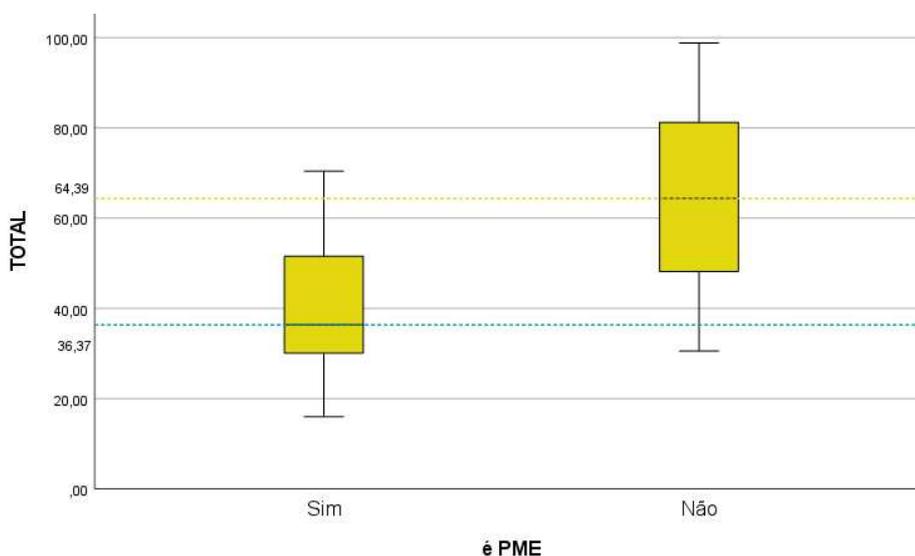
<b>É PME?</b>				
	<b>Sim (Média)</b>	<b>Não (Média)</b>	<b>Varição</b>	<b>Varição (%)</b>
Organização	10,04	14,04	4,00	28,49%
Infraestrutura de dados	7,84	13,76	5,93	43,07%
Recursos	7,14	12,40	5,26	42,40%
Analytics	6,21	11,18	4,97	44,46%
Governance	8,19	13,71	5,51	40,23%
<b>Total</b>	<b>39,21</b>	<b>64,83</b>	<b>25,61</b>	<b>39,51%</b>

Comparando os resultados de cada tipo de empresa face à média global, é notável o desfasamento das PME, em todos os grupos de questões, enquanto as empresas não-PME se encontram muito acima da média de pontuação, também para todas as questões. Conforme se pode retirar da *Tabela 3*, as PME destacam-se negativamente da média no grupo Analytics (-29%), enquanto que as empresas grandes sobressaem nos grupos Governance e “Estrutura de Dados”.

**Tabela 4.3 – Estatísticas descritivas para a variável “É PME” por grupo de questões, por categoria face ao Total**

É PME?					
	SIM		NÃO		
	Média	Varição face a TOTAL (%)	Média	Varição face a TOTAL (%)	TOTAL Média
Organização	10,04	-13%	14,04	22%	11,47
Infraestrutura de Dados	7,84	-21%	13,76	39%	9,94
Recursos	7,14	-21%	12,40	37%	9,04
Analytics	6,21	-29%	11,18	28%	8,74
Governance	8,19	-11%	13,71	49%	9,19
<b>Total</b>	<b>39,21</b>	<b>-19%</b>	<b>64,83</b>	<b>34%</b>	<b>48,38</b>

Também a mediana das pontuações totais é substancialmente inferior para PME face a empresas não-PME. A mediana do nível de maturidade das PME encontra-se nos 36,37 pontos, querendo isto dizer que metade das Pequenas e Médias Empresas pontuaram menos que este valor, que é bastante baixo. sendo as distâncias entre o 1º e 3º Quartis à mediana maiores nas empresas de grande dimensão (respetivamente 48,18 e 81,22) do que nas micro, pequenas e médias empresas, onde o 1º Quartil corresponde a uma pontuação de 30,08 e o 3º Quartil a 51,55 pontos (*Figura 4.13*). Isto reflete um desfasamento de pontuações menor para as PME em comparação às demais.



**Figura 4.13 – Boxplot da Pontuação Total, por tipo de Empresa**

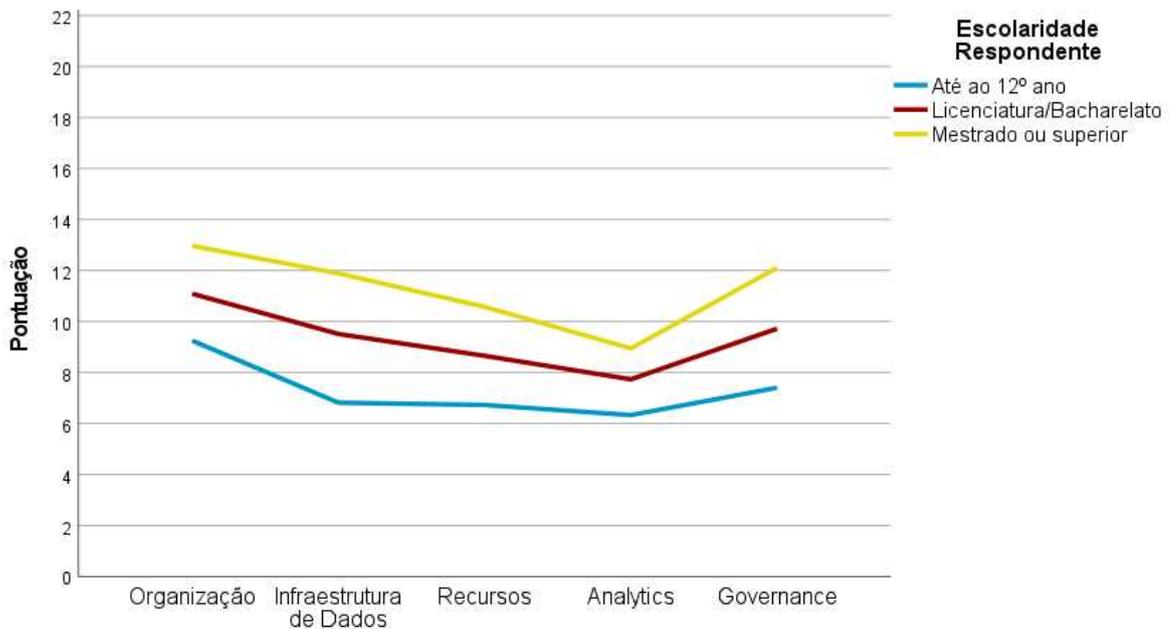
A *Tabela 4.4* expõe que é notável que as empresas apresentam menores pontuações no grupo de Analytics, e melhores no grupo Organização. O valor do 3º quartil para o grupo de

questões, mesmo no global de empresas apresenta valores baixos para o grupo de Analytics, com um valor de 9,73 pontos. Isto indica que mais de 75% das empresas da amostra obtiveram pontuações abaixo dos 10 pontos, neste grupo. Ainda assim este resultado é especialmente superior ao obtido apenas por parte de PME no grupo de questões de Analytics, onde o 3º quartil se encontra nos 7,64 pontos.

**Tabela 4.4 – Medianas e quartis para cada grupo de questões por tipo de empresa**

É PME?									
	Sim			Não			Total		
	Mediana	1º Quartil	3º Quartil	Mediana	1º Quartil	3º Quartil	Mediana	1º Quartil	3º Quartil
Organização	10,05	8,23	11,73	15,72	10,27	16,50	11,10	8,89	14,11
Infraestrutura de dados	8,22	5,33	10,63	14,95	9,30	18,30	9,18	6,26	12,84
Recursos	6,74	5,20	10,03	9,36	9,02	17,00	8,47	5,62	10,18
Analytics	5,24	4,71	7,64	9,92	8,73	13,24	6,82	5,06	9,73
Governance	8,31	5,41	10,89	12,61	10,00	17,78	10,00	7,60	12,25
<b>Pontuação total</b>	<b>36,37</b>	<b>3,08</b>	<b>51,57</b>	<b>64,39</b>	<b>48,18</b>	<b>81,22</b>	<b>47,88</b>	<b>32,73</b>	<b>56,99</b>

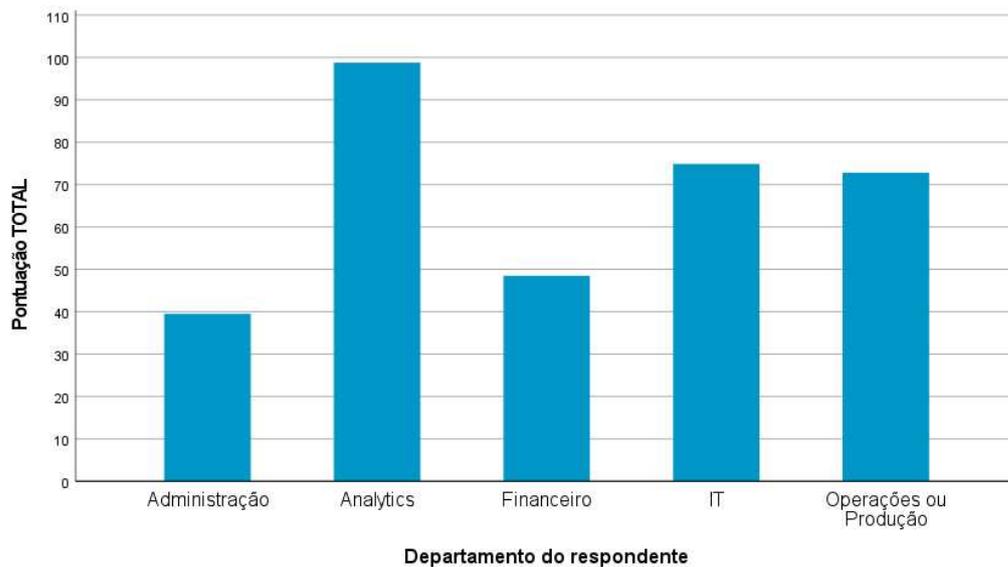
A *Figura 4.14* revela que as empresas onde os respondentes apresentam maior nível de escolaridade têm em geral uma pontuação maior em todos os grupos, não havendo ainda assim um grupo de questões onde essa diferença seja mais discrepante. Isto pode indicar a existência de um fator de interpretação das questões. Salienta-se ainda a quebra, em todas as 3 linhas do gráfico, no grupo de questões de Analytics. Adicionalmente é notável que as pontuações para os grupos Infraestrutura de Dados, Recursos e Analytics sejam bastante próximas quando o respondente possui até ao 12º ano de escolaridade, ao contrário do que acontece nos níveis de formação superiores, onde se verifica um agravamento das pontuações de Analytics face às restantes questões.



**Figura 4.14 – Pontuação média de cada grupo de questões por nível de escolaridade do respondente**

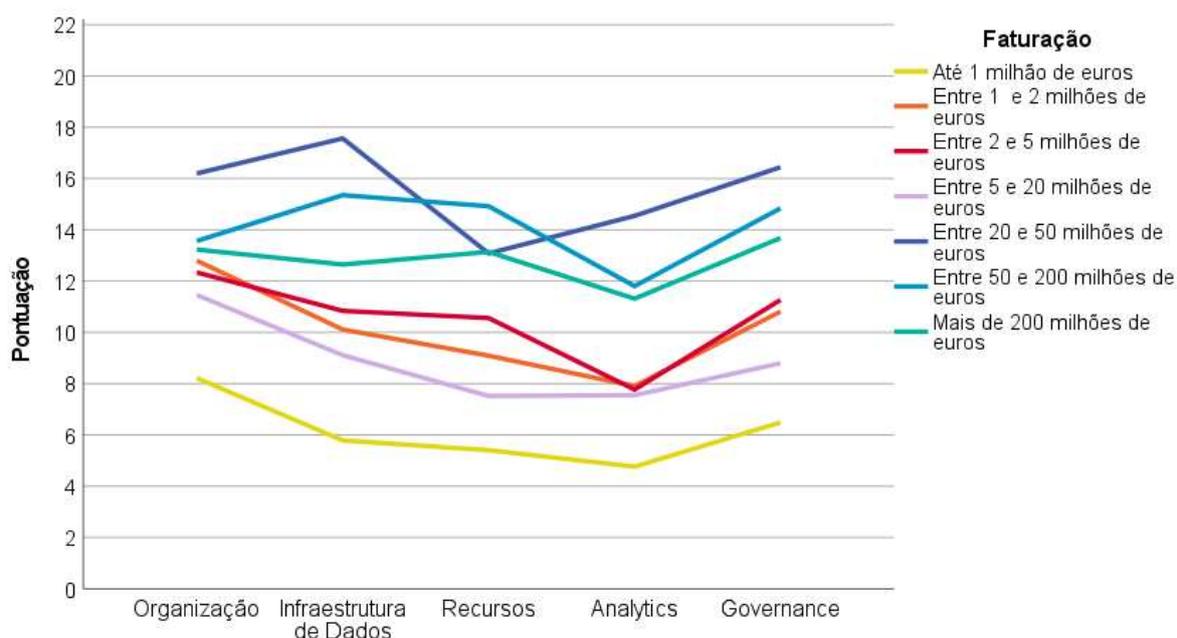
Também a área de estudos dos respondentes se mostra influente na pontuação total, sendo essa diferença mais substancial para o grupo D (“Estrutura de Dados”), que é composto por perguntas de carácter mais técnico. O *Anexo B.1* mostra-nos que os grupos D (“Estrutura de Dados”) e G (Governance) foram os grupos que causaram mais dificuldades, com 10% e 10,74% de respostas “Não compreendo esta questão”, às perguntas do grupo, respetivamente. Por outro lado, no grupo de questões Organização, não houve qualquer questão que tenha gerado dúvidas aos respondentes, como se pode constatar pelo *Anexo B.2*

Quando o respondente pertence a um Departamento de Analytics, a pontuação total de maturidade analítica da empresa é mais alta (*Figura 4.15*). Este resultado é também elevado para os departamentos de Tle Operações ou Produção, sendo que são as respostas vindas de Administração aquelas que obtêm a menor pontuação, levando-nos assim a acreditar que possa existir um fator de conhecimento de causa com impacto na maturidade analítica obtida pelo questionário. O valor de V de Cramer entre “Maturidade total” e “Departamento do respondente” de 0,566 com uma significância <0,05 indica-nos uma associação média-forte para estas variáveis, como evidencia o *Anexo C.1*. Nos *Anexo C.2* e *C.3* é possível verificar uma associação média, para as variáveis “Estudos do respondente” e “Cargo do respondente” respetivamente.



**Figura 4.15 – Pontuação Total média por departamento**

O gráfico da *Figura 4.16* sugere uma associação entre o nível de faturação das empresas e a maturidade. O teste V de Cramer, (*Anexo C.4*) com uma significância  $<0,05$  e um valor de  $p$  de 0,635 confirma esta associação que pode ser considerada de média-forte. Há uma tendência para as empresas com faturações anuais superiores pontuarem mais em cada grupo de questões, conforme graficamente. Ainda assim abre-se a exceção para as empresas que apresentaram uma faturação de “Entre os 20 e 50 milhões de euros”, para as quais se observam pontuações mais altas em todos os grupos, exceto Recursos, e para as empresas que faturam “Entre 5 e 20 milhões de euros”, que pontuaram em média menos que as empresas dos dois patamares de faturação anteriores, “Entre 1 a 2 milhões de euros” e “Entre 2 a 5 milhões de euros”.



**Figura 4.16 – Pontuação média de cada grupo de questões por intervalo de faturação**

As variáveis que mais se correlacionam com a Pontuação total da maturidade analítica são “É PME” e “Número de Funcionários”, com 0,588 e 0,511 de correlação de Pearson (Tabela 4.5). É natural que, dado a que a variável “É PME” é calculada com base no número de funcionários da empresa, esta correlação com a Pontuação Total aconteça. Contudo, torna-se importante notar que a correlação seja mais forte quando comparada com a correlação entre a pontuação total e a variável “Faturação”, pelo que podemos afirmar que a faturação é um fator menos importante para a pontuação total que o número de funcionários.

**Tabela 4.5 – Correlações de Pearson entre algumas variáveis e Pontuação Total**

Correlações de Pearson						
	Pontuação Total	Faturação	Idade do Respondente	Idade da Empresa	Nº de Funcionários	É PME
Faturação	0,373	-				
Idade do Respondente	0,233	0,118	-			
Idade da Empresa	0,109	0,156	0,377	-		
Nº de Funcionários	<b>0,511</b>	0,354	0,349	<b>0,507</b>	-	
É PME	<b>0,588</b>	<b>0,849</b>	0,189	0,071	<b>0,701</b>	-

Já as pontuações dos grupos apresentam, em geral, correlações bastante elevadas entres grupos de questões, e com a pontuação total (Tabela 4.6). Apesar da diminuta diferença, os grupos que se correlacionam mais com a pontuação total da maturidade são

Governance e Infraestrutura de Dados, com 0,966. O grupo que apresenta a correlação mais fraca é o de Organização, sendo ainda assim um valor bastante elevado, de 0,919. Este resultado contradiz Nam (2019), segundo quem os fatores organizacionais influenciam os níveis superiores de adoção da disciplina analítica e de *data science*. É natural que as correlações entre cada um dos grupos com o “Pontuação Total” sejam bastante fortes, sendo que esta é diretamente influenciada pelas pontuações de cada grupo.

No que respeita a correlações inter-grupos, destaca-se como a mais significativa a correlação entre o grupo Governance e Recursos. Em sentido oposto, a pontuação do grupo de questões referentes aos objetivos, ambições e alinhamento da gestão, o “Grupo O” tem a correlação mais fraca com o grupo referente ao investimento e recursos da empresa, o “Grupo R”, sendo contudo bastante significativa.

**Tabela 4.6 – Correlações de Pearson entre pontuações por Grupo de questões**

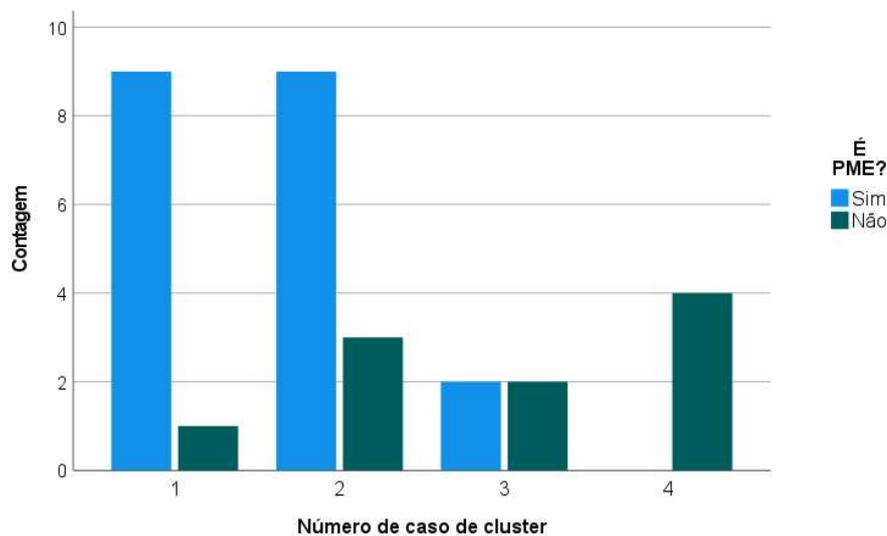
Correlações de Pearson					
	Organização	Infraestrutura de dados	Recursos	Analytics	Governance
Infraestrutura de dados	0,868	-			
Recursos	0,811	0,907	-		
Analytics	0,834	0,866	0,844	-	
Governance	0,870	0,922	0,932	0,849	-
<b>Pontuação total</b>	<b>0,919</b>	<b>0,966</b>	<b>0,953</b>	<b>0,928</b>	<b>0,966</b>

Através das pontuações de cada grupo de questões, as respostas foram classificadas em *clusters*, para segmentar os sujeitos em grupos homogêneos, onde cada empresa se assemelha mais às outras dentro do mesmo cluster, do que às restantes. O dendrograma do Anexo D.1, feito a partir do método de Ward mostra um número de 3 grupos, a uma distância escalonada é próxima de 3, a uma distância acima de 10, o dendrograma sugere a criação de 2 grupos, que são mais heterogêneos, e a uma distância ligeiramente inferior a 3, o dendrograma sugere a criação de 4 clusters. Assim, optou-se pela construção de quatro *clusters* através da opção “K-means” disponível no SPSS (Anexo D.2; Anexo D.3; Anexo D.4). Os maiores clusters obtidos incluem 12 e 10 casos, enquanto que os mais pequenos incluem ambos apenas 4 casos, conforme a Tabela 4.7.

**Tabela 4.7 – Clusters**

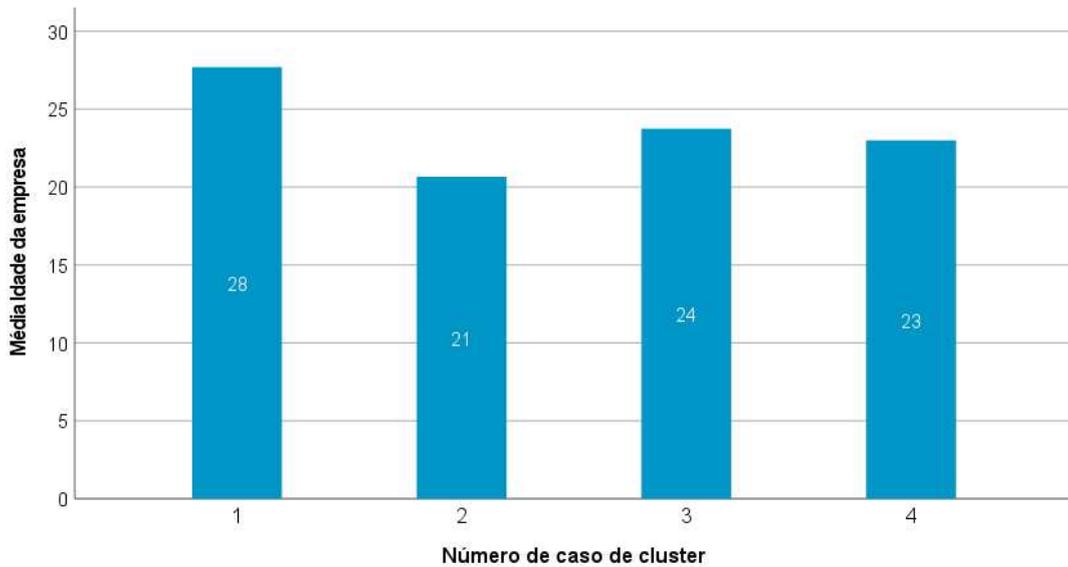
		Número de casos em cada cluster	
Cluster	1	10	
	2	12	
	3	4	
	4	4	
<b>Total</b>		<b>30</b>	

Os quatro *clusters* distinguem-se pela predominância de empresas PME nos clusters “1” e “2”, ainda que o *cluster* “2” inclua mais empresas não-PME que o *cluster* “1”, ao passo que o *cluster* “4” não contém nenhuma PME. O *cluster* “3” tem um número igual de empresas de ambos os tipos (*Figura 4.17*).



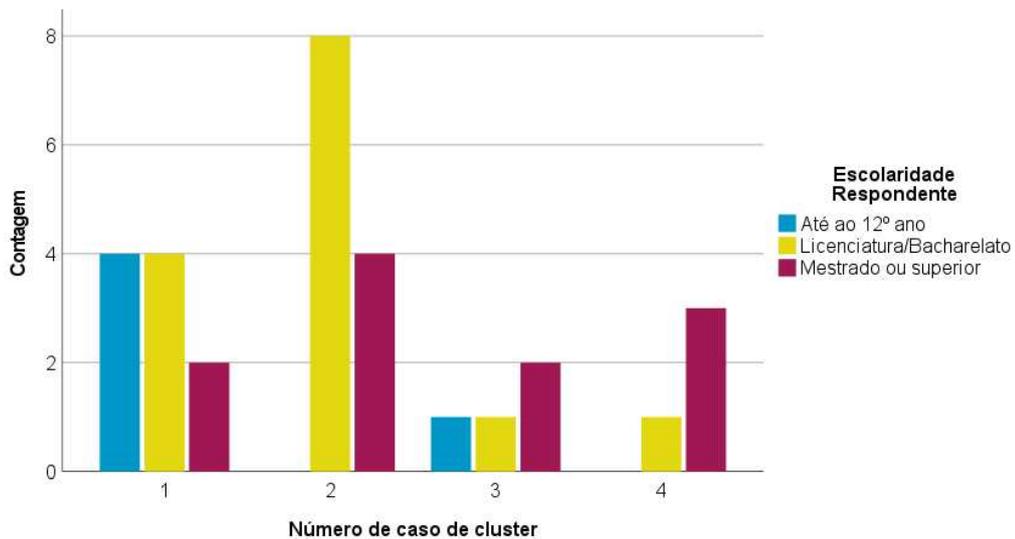
**Figura 4.17 – Distribuição de empresas por tipo, em cada *cluster***

No que respeita a idades, não se verificam grandes diferenças, em média, nos quatro *clusters*. O *cluster* com a idade média maior é o “1”, com 28 anos, sendo que o menor, com uma média de 21 anos é o grupo “2”. Os dois *clusters* de menor dimensão contam com idades médias de 24 e 23 anos, respetivamente o *cluster* “1” e “2” (*Figura 4.18*).



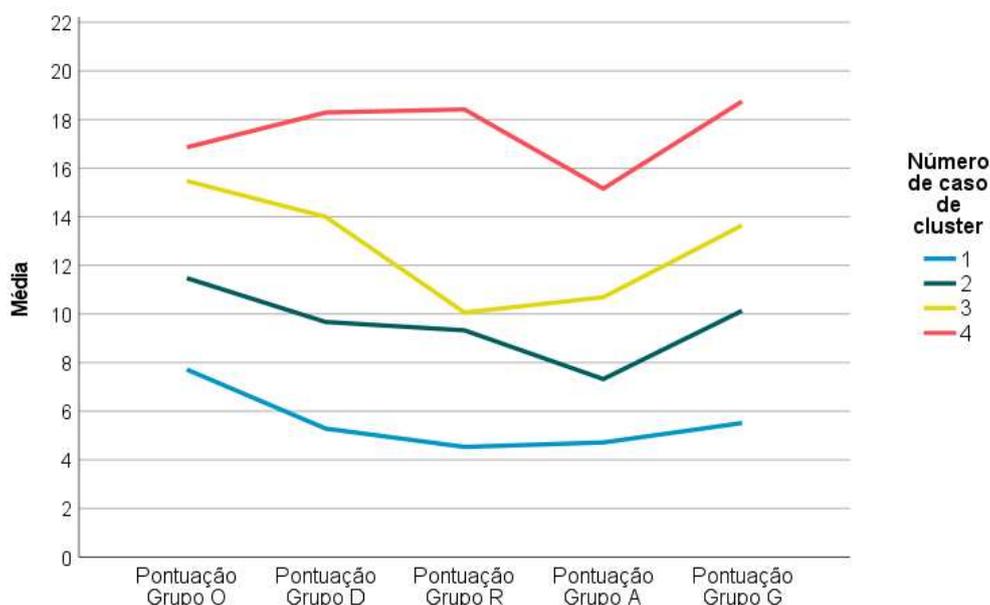
**Figura 4.18 – Idade média das empresas de cada cluster**

“Escolaridade do respondente” é uma das variáveis que diferencia os quatro grupos. É notável a maior frequência de respondentes com até o 12º ano de escolaridade no *cluster* “1”. O *cluster* “2” distingue-se por um número mais elevado de respondentes com o grau de licenciatura, e a inexistência de níveis inferiores de escolaridade. O grupo “3” possui uma distribuição equilibrada dos vários casos, e o *cluster* “4” tem uma prevalência de respondentes com o grau de mestrado (*Figura 4.19*). Pode-se afirmar que dos quatro *clusters* é o “1” o que possui menor instrução, e o “4” o que possui a maior instrução. Os *clusters* “2” e “3” possuem níveis equilibrados de escolaridade, apesar das suas diferenças de população.



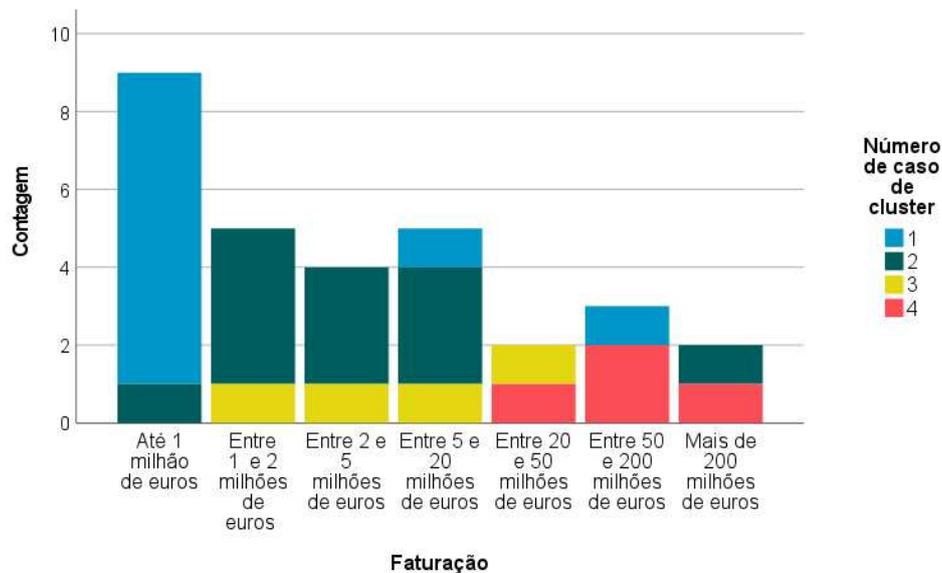
**Figura 4.19 – Distribuição do nível de escolaridade dos respondentes por cluster**

No âmbito das pontuações do questionário, por grupo de questões, os *clusters* distinguem-se facilmente. É no grupo “1” onde se encontram as pontuações mais baixas, seguido do “2”, seguido do “3”, e do “4”, que inclui as pontuações mais altas para todos os grupos de questões. Tal como acontece para o global da amostra, também nos *clusters* se nota uma quebra de pontuações nos grupos Analytics e Recursos face aos restantes, e um valor mais elevado para os grupos Organização e Governance. Ainda assim o *cluster* “4” apresenta uma pontuação média mais elevada no grupo de questões relativas a Recursos (Figura 4.20).



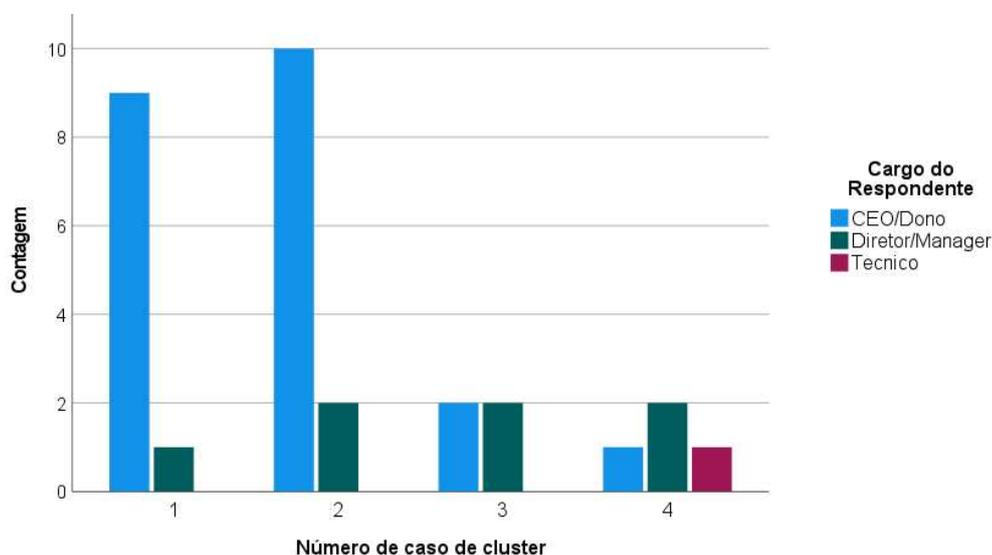
**Figura 4.20 – Pontuações médias de cada grupo de questões por *cluster***

O *cluster* “4” apresenta elementos nos níveis de faturação mais elevados, de acordo com a Figura 4.21. Em sentido oposto, quase todas as empresas que constituem o *cluster* “1” apresentam faturações anuais inferiores a 1 milhão de euros, com apenas duas exceções. Os *clusters* “2” e “3”, também aqui, voltam a figurar nos níveis intermédios.



**Figura 4.21 – Pontuações médias de cada grupo de questões por cluster**

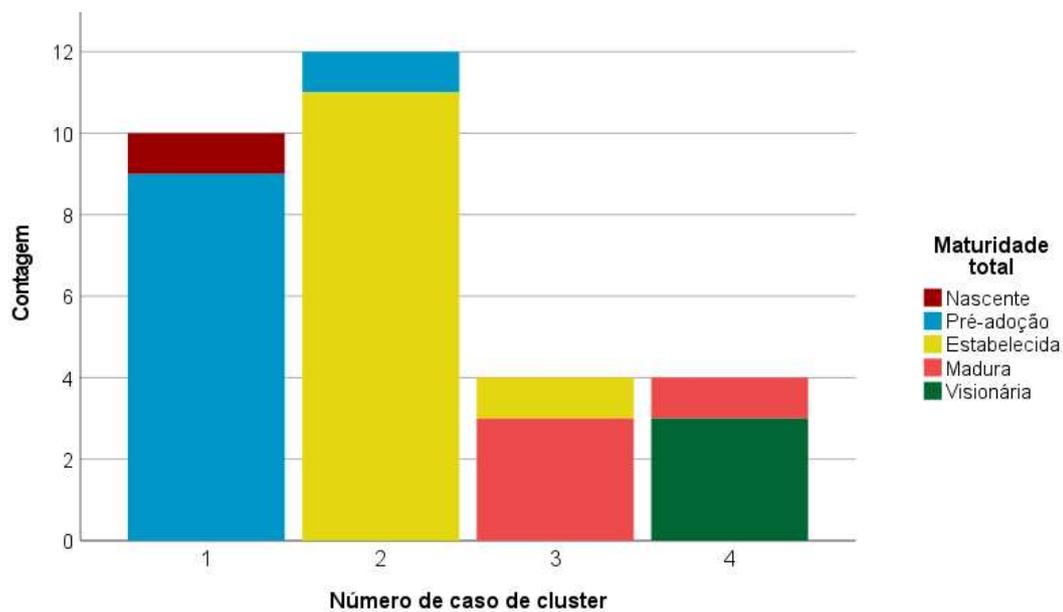
Relativamente ao cargo dos respondentes, não há grandes diferenças entre os grupos “1” e “2”, onde predomina “CEO/Dono”. O grupo “3” não inclui quadros técnicos, e tem um número igual de “CEO/Dono” e “Diretor/Manager”, enquanto o grupo “4” inclui o único “Técnico” respondente, e tem como cargo mais frequente o de “Diretor/Manager” (Figura 4.22).



**Figura 22 – Distribuição dos cargos dos respondentes por cluster**

O cluster “1” possui, de entre todos, as empresas com níveis de maturidade mais baixos, sendo que contém o único caso com o primeiro nível de maturidade. O Cluster “2” é composto maioritariamente por empresas no nível intermédio de adoção, pelo que pode ser classificado como o cluster de maturidade média-baixa, em antítese do cluster “3”, que por incluir uma

empresa do 4º nível, apresenta uma maturidade média-alta. Por fim, o grupo “4”, é o que agrupa as empresas com os níveis de maturidade mais elevados (*Figura 4.23*).



**Figura 4.23 – Distribuição dos níveis de maturidade por cluster**

## Capítulo 5 – Conclusão

### 5.1 Considerações finais

A maturidade analítica das empresas em estudo é baixa: um valor médio de 48,38 pontos, que corresponde ao nível de maturidade “Estabelecida”, o terceiro de cinco níveis do modelo da TDWI. Neste estado, a empresa já começou a pôr em prática algumas metodologias e ferramentas, assim como a investir para atingir patamares mais elevados. O departamento de Tle áreas de negócio já trabalham em conjunto para iniciativas pontuais, mas apenas para níveis de tomada de decisão superiores. Investimentos em infraestrutura tecnológica começam a ser realizados, mas tipicamente não em plataformas dedicadas para *analytics*. A empresa implementou *datamarts* ou *warehouses*, mas ainda utiliza estruturas de dados tradicionais como *spreadsheets*. Foram criados os primeiros *steering committees* para a gestão de dados, mas num processo ainda não muito avançado.

O baixo nível global das empresas de construção deve-se em parte ao peso que as PME têm no setor como tinha sido referido por Kraatz *et al.* (2014). Há uma discrepância grande de resultados obtidos das empresas de grande dimensão face a PME, que obtiveram em média pontuações 38% mais elevadas que a média da amostra.

No global, foi no grupo de questões Organização que as empresas obtiveram resultados mais elevados, revelando que os gestores estão cientes da importância de *Analytics* para o negócio e procuram trazer a disciplina para as empresas. Ainda assim, no que toca à implementação, os resultados são ainda baixos, principalmente para PME, como revelaram as pontuações referentes a Infraestrutura de Dados, *Analytics* e *Governance*.

Os grupos de questões que menores pesos têm no nível de maturidade são o de *Organização* e o de *Analytics*. Enquanto que esta primeira correlação contradiz Nam, (2019) que refere que os fatores organizacionais influenciam os níveis superiores de adoção, e assimilação, a segunda confirma Chen e Nath (2018) que afirma que competências tecnológicas relacionadas com BA não garantem maturidade analítica. É também claro que os fatores Infraestrutura de Dados e *Governance* demonstraram ser de grande importância para o nível de maturidade analítica das empresas obtido no modelo. Tal como referido por Rajaraman, (2013), a adoção de tecnologia de *BD* está ainda longe do progresso feito noutros setores, de modo que as empresas que conseguiram adotar tecnologias e metodologias de captura, gestão e manutenção de maiores quantidades de dados obtém resultados melhores.

A diferença de resultados entre níveis de escolaridade dos respondentes, departamentos e áreas de estudo sugere que pode existir um fator de literacia analítica que afeta os resultados dos modelos. É evidente que as empresas representadas por respondentes com estudos superiores conseguiram pontuações mais elevadas. Por um lado, pois este perfil é mais frequente nas grandes empresas do que em PME – onde a maioria dos respondentes

assume funções de Dono/CEO – por outro lado porque o modelo inclui questões técnicas que causam dificuldades a perfis com pouca literacia de TI ou *Analytics*. A inclusão da possibilidade de assinalar as questões não compreendidas foi importante para perceber que é nos grupos de Infraestrutura de Dados e *Governance* que se encontraram as maiores dificuldades.

As empresas devem encarar o modelo de maturidade como uma forma de medir o progresso no caminho de BA, e resolver as lacunas.

As empresas parecem conscientes dos benefícios de BA, e igualmente empenhadas em dar início ao processo de transformação para fazer melhor e maior uso dos dados, de acordo com os resultados deste estudo. Ainda assim há que pôr em prática essa transformação, investindo em capital humano com conhecimento na área em foco. Grande parte dos líderes têm ainda pouca literacia analítica, ou não têm ainda na empresa alguém com esta competência. Por outro lado, há recursos necessários que muitas vezes exigem um esforço financeiro nem sempre suportável, principalmente pelas entidades mais pequenas. É, contudo, necessário investir nestes recursos e dotar os profissionais de ferramentas e técnicas para poderem dar os primeiros passos.

Ainda assim, apesar de ser uma indústria que pela natureza da cadeia de valor encontra obstáculos no processo de captura, manutenção e uso dos dados, os resultados mostram que foram dados, na maioria dos casos, os primeiros passos neste importante caminho.

## **5.2 Limitações e Trabalho futuro**

Uma das condicionantes encontradas na análise de resultados é a possibilidade de existir um fator de literacia analítica que impossibilite o respondente de responder com total idoneidade e conhecimento relativamente ao real estado da empresa, por exemplo, não compreendendo certas questões, ou até interpretando de forma errada. Com base neste fator surge a proposta de desenvolver uma análise de maturidade através de entrevistas tendo como base o modelo de maturidade utilizado neste trabalho, de modo a reunir evidências que possam comprovar se a resposta do respondente realmente está alinhada com a realidade da empresa. Para garantir o sucesso desse trabalho seria importante reunir um número maior de respondentes para cada empresa, de várias áreas da organização.

Com base numa das limitações deste trabalho, que concerne o modelo de maturidade utilizado, TDWI, que, como referido por Chuah e Wong (2011), enfatiza algumas dimensões face a outras, levanta-se a sugestão de avaliar a maturidade analítica utilizando vários modelos em simultâneo, para cada empresa, de modo a garantir que não exista um enviesamento da pontuação influenciada pelo peso ou incidência de uma dimensão analisada.

Adicionalmente, a amostra recolhida não reflete a realidade demográfica do universo das empresas de construção em Portugal. Ao longo do processo de recolha foi identificado um desinteresse maior de entre das empresas de dimensão mais pequena (PME) face a empresas grandes, que demonstraram disponibilidade para responder. Este fator influenciou os resultados extraídos, que podem não corresponder à realidade. Futuramente seria importante captar as respostas de um conjunto maior de empresas, com destaque nas PME.

## Referências Bibliográficas

- Alaloul, W. S., Liew, M. S., Zawawi, N. A. W. A., & Mohammed, B. S. (2018). Industry revolution IR 4.0: future opportunities and challenges in construction industry. In *MATEC web of conferences* (Vol. 203, p. 02010). EDP Sciences.
- Arayici, Y., & Coates, P. (2012). A system engineering perspective to knowledge transfer: A case study approach of BIM adoption. *Virtual reality–Human computer interaction, 2006*, 179-206.
- Bharadwaj, A. S. (2000). A resource-based perspective on information technology capability and firm performance: an empirical investigation. *MIS quarterly*, 169-196.
- Bhageshpur, K. (2019). Data Is The New Oil, and That's a Good Thing. *Forbes*.
- Bibby, L., & Dehe, B. (2018). Defining and assessing industry 4.0 maturity levels—case of the defence sector. *Production Planning & Control*, 29(12), 1030-1043. <https://doi.org/10.1080/09537287.2018.1503355>
- Bilal, M., Oyedele, L. O., Qadir, J., Munir, K., Ajayi, S. O., Akinade, O. O., Owolabi, H. A., Alaka, H. A., & Pasha, M. (2016). Big Data in the construction industry: A review of present status, opportunities, and future trends. *Advanced engineering informatics*, 30(3), 500-521. <https://doi.org/10.1016/j.aei.2016.07.001>
- Blanchet, M., Rinn, T., Von Thaden, G., & De Thieulloy, G. (2014). Industry 4.0: The new industrial revolution-How Europe will succeed. *Hg. v. Roland Berger Strategy Consultants GmbH. München. Abgerufen am, 11, 2014*
- Bock, T. (2015). The future of construction automation: Technological disruption and the upcoming ubiquity of robotics. *Automation in construction*, 59, 113-121.
- Broadbent, M., & Weill, P. (1993). Improving business and information strategy alignment: Learning from the banking industry. *IBM systems Journal*, 32(1), 162-179. [doi:10.1147/sj.321.0162](https://doi.org/10.1147/sj.321.0162)
- Caiado, R. G. G., Scavarda, L. F., Gavião, L. O., Ivson, P., de Mattos Nascimento, D. L., & Garza-Reyes, J. A. (2021). A fuzzy rule-based industry 4.0 maturity model for operations and supply chain management. *International Journal of Production Economics*, 231, 107883. <https://doi.org/10.1016/j.ijpe.2020.107883>
- Chen, L., & Nath, R. (2018). Business analytics maturity of firms: an examination of the relationships between managerial perception of IT, business analytics maturity and success. *Information Systems Management*, 35(1), 62–77. <https://doi.org/10.1080/10580530.2017.1416948>
- Constâncio, O. J., Colaço, R., Doutora, O., Cabral Da, E. A., Cardoso, R., & Auxiliar, P. (2013.). Caracterização do *Data Darehouse / Business Intelligence* (DW/BI) em Portugal

um estudo sobre os DW/BI das maiores empresas portuguesas. Mestre em Sistemas Integrados de Apoio de Decisão.

- Cosic, R., Shanks, G., Maynard, S. (2012). Towards a business analytics capability maturity model, In Proceedings of the ACIS 2012: The 23rd Australasian Conference on Information Systems ACIS, Geelong, Australia, 3–5 December 2012; pp. 1–11.
- Craveiro, F., Duarte, J. P., Bartolo, H., & Bartolo, P. J. (2019). Additive manufacturing as an enabling technology for digital construction: A perspective on Construction 4.0. *Sustain. Dev*, 4(6).
- Cooper, R. G. (1999). From experience: the invisible success factors in product innovation. *Journal of product innovation management*, 16(2), 115-133.
- Crosby, P. B. (1979). *Quality is free McGraw-Hill Book Company. New York/NY/USA.*
- Dainty, A. R., Millett, S. J., & Briscoe, G. H. (2001). New perspectives on construction supply chain integration. *Supply chain management: An international journal*.
- Dakin, G. (1992). Shaping the future: business design through information technology. *Journal of the Operational Research Society*, 43(9), 1249-1250.
- Davenport, T. (2018). DELTA Plus Model & five stages of analytics maturity: A primer. *International Institute for Analytics*, 1-12.
- De Bruin, T. (2009). *Business process management: theory on progression and maturity* (Doctoral dissertation, Queensland University of Technology).
- Deloitte S.L. (2014). European Powers of Construction, Deloitte S.L., Madrid, Jun.
- Druczkoski, J. C. M., Santos, F. M. B. C. (n.d.). Indústria 4.0 e Modelos de Maturidade Estudo de empresas portuguesas e brasileiras Engenharia e Gestão Industrial (2º ciclo de estudos).
- Dubois, A., & Gadde, L. E. (2002). The construction industry as a loosely coupled system: implications for productivity and innovation. *Construction management & economics*, 20(7), 621-631.
- Eadie, R., Browne, M., Odeyinka, H., McKeown, C., & McNiff, S. (2013). BIM implementation throughout the UK construction project lifecycle: An analysis. *Automation in construction*, 36, 145-151.
- Fedouaki, F., Okar, C., & El Alami, S. (2013). A maturity model for Business Intelligence System project in Small and Medium-sized Enterprises: an empirical investigation. *International Journal of Computer Science Issues (IJCSI)*, 10(6), 61.
- Fraser, P., Moultrie, J., & Gregory, M. (2002, August). The use of maturity models/grids as a tool in assessing product development capability. In *IEEE international engineering management conference* (Vol. 1, pp. 244-249). IEEE.

- Giang, D. T., & Pheng, L. S. (2011). Role of construction in economic development: Review of key concepts in the past 40 years. *Habitat international*, 35(1), 118-125.
- Gilchrist, A. (2016). *Industry 4.0: the industrial internet of things*. Apress.
- Gökalp, M. O., Gökalp, E., Kayabay, K., Koçyiğit, A., & Eren, P. E. (2021). Data-driven manufacturing: An assessment model for data science maturity. *Journal of Manufacturing Systems*, 60, 527-546.
- Grossman, R. L. (2018). A framework for evaluating the analytic maturity of an organization. *International Journal of Information Management*, 38(1), 45-51.
- Halper, F., & Stodder, D. (2014). TDWI analytics maturity model guide. *TDWI research*, 1-20.
- Hatami, M., Flood, I., Franz, B., & Zhang, X. (2019). State-of-the-art review on the applicability of AI methods to automated construction manufacturing. *Computing in Civil Engineering 2019: Data, Sensing, and Analytics*, 368-375.
- Hernández, H., Hervás F., Soriano, Tübke, A., Vezzani, A., Dosso, M., Amoroso, S., Grassano, N., Coad, A., Gkotsis, P. (2015). EU R&D SCOREBOARD. *The Industrial R&D Investment Scoreboard, European Commission – Joint Research Centre*.
- Hillebrandt, P. M. (2000). *Economic theory and the construction industry*. London: Macmillan.
- Holsapple, C., Lee-Post, A., & Pakath, R. (2014). A unified foundation for business analytics. *Decision support systems*, 64, 130-141.
- Horta, I. M., & Camanho, A. S. (2013). Company failure prediction in the construction industry. *Expert Systems with Applications*, 40(16), 6253-6257.
- Howson, C. (2011). *BI scorecard strategic and product summary Q3 2011*. ASK LLC d.b.a. BI Scorecard. [www.BIScorecard.com](http://www.BIScorecard.com)
- Howson, C., Sallam, R. (2017). *Survey analysis: Why bi and analytics adoption remains low and how to expand its reach (G00326220)*. Gartner Research.
- Humphrey, W. S. (1989). *Managing the software process*. Addison-Wesley Longman Publishing Co., Inc..
- IAPMEI – Agência para a Competitividade e Inovação (2019). *Guia do Utilizador Relativo à Definição de PME*. Disponível online em: [https://www.iapmei.pt/getattachment/PRODUTOS-E-SERVICOS/Qualificacao-Certificacao/Certificacao-PME/Como-obter-uma-certificacao-PME/Guia-do-utilizador-relativo-a-definicao-de-PME-\(Comissao-Europeia,-2020\).pdf.aspx](https://www.iapmei.pt/getattachment/PRODUTOS-E-SERVICOS/Qualificacao-Certificacao/Certificacao-PME/Como-obter-uma-certificacao-PME/Guia-do-utilizador-relativo-a-definicao-de-PME-(Comissao-Europeia,-2020).pdf.aspx) DOI:10.2873/246665
- IDC (2020). *IDC's Global DataSphere Forecast Shows Continued Steady Growth in the Creation and Consumption of Data*. (2020).
- INE - Instituto Nacional de Estatística (2020). *Estatísticas da Construção e Habitação 2020*, disponível online em: [https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine\\_publicacoes&PUBLICACOESpub\\_boui=437127876&PUBLICACOESmodo=2](https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_publicacoes&PUBLICACOESpub_boui=437127876&PUBLICACOESmodo=2)

- INE - Instituto Nacional de Estatística (2020). *Empresas em Portugal 2020*, disponível online em:  
[https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine\\_publicacoes&PUBLICACOESpub\\_boui=15413305&PUBLICACOESmodo=2](https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_publicacoes&PUBLICACOESpub_boui=15413305&PUBLICACOESmodo=2)
- Infoempresas (2022). *Diretório de Empresas*. Disponível online em:  
[https://infoempresas.jn.pt/F\\_CONSTRUCAO.html](https://infoempresas.jn.pt/F_CONSTRUCAO.html)
- Jordan, J., & Ellen, C. (2009). Business need, data and business intelligence. *Journal of Digital Asset Management*, 5(1), 10-20.
- Kappelman, L., McLean, E., Johnson, V., & Gerhart, N. (2014). The 2014 SIM IT key issues and trends study. *MIS Quarterly Executive*, 13(4), 237-263.
- King, M. (2017). How industry 4.0 and BIM are shaping the future of the construction environment. *GIM INTERNATIONAL-THE WORLDWIDE MAGAZINE FOR GEOMATICS*, 31(3), 24-25.
- Kraatz, J. A., & Sanchez, A. X. (2014). *R&D investment and impact in the global construction industry*. Routledge.
- Król, K., & Zdonek, D. (2020). Analytics maturity models: An overview. *Information*, 11(3), 142.
- Lahrman, G., Marx, F., Winter, R., & Wortmann, F. (2010). Business Intelligence Maturity Models: An Overview. *Information Technology and Innovation Trends in Organizations. Italian Chapter of AIS*, Naples.
- Lasi, H., Fettke, P., Kemper, H. G., Feld, T., & Hoffmann, M. (2014). Industry 4.0. *Business & information systems engineering*, 6(4), 239-242.
- Lee, J., Kao, H. A., & Yang, S. (2014). Service innovation and smart analytics for industry 4.0 and big data environment. *Procedia cirp*, 16, 3-8.
- Livotov, P., Sekaran, A. P. C., Law, R., Reay, D., Sarsenova, A., & Sayyareh, S. (2019). Eco-innovation in process engineering: contradictions, inventive principles and methods. *Thermal Science and Engineering Progress*, 9, 52-65.
- Marques, P. N. P. (2013). *Avaliação de modelos de maturidade de sistemas de Business Intelligence: caso de estudo TAP Portugal* (Doctoral dissertation).
- Maresova, P., Soukal, I., Svobodova, L., Hedvicakova, M., Javanmardi, E., Selamat, A., & Krejcar, O. (2018). Consequences of industry 4.0 in business and economics. *Economies*, 6(3), 46.
- Maskuriy, R., Selamat, A., Ali, K. N., Maresova, P., & Krejcar, O. (2019). Industry 4.0 for the construction industry—how ready is the industry?. *Applied Sciences*, 9(14), 2819.
- Mettler, T., & Rohner, P. (2009). Situational maturity models as instrumental artifacts for organizational design. In *Proceedings of the 4th international conference on design science research in information systems and technology* (pp. 1-9).

- Min-Hooi, C., & Kee-Luen, W. (2011). A review of business intelligence and its maturity models. *African journal of business management*, 5(9), 3424-3428. <https://doi.org/10.5897/AJBM10.1564>
- Montoya-Weiss, M. M., & Calantone, R. (1994). Determinants of new product performance: A review and meta-analysis. *Journal of product innovation management*, 11(5), 397-417.
- Muller, L., & Hart, M. (2016). Updating business intelligence and analytics maturity models for new developments. In *International Conference on Decision Support System Technology* (pp. 137-151). Springer, Cham.
- Nam, D., Lee, J., & Lee, H. (2019). Business analytics adoption process: An innovation diffusion perspective. *International Journal of Information Management*, 49, 411-423.
- Negash, S., & Gray, P. (2008). Business intelligence. In *Handbook on decision support systems 2* (pp. 175-193). Springer, Berlin, Heidelberg.
- Nolan, R. L. (1973). Managing the computer resource: a stage hypothesis. *Communications of the ACM*, 16(7), 399-405.
- Oesterreich, T. D., & Teuteberg, F. (2016). Understanding the implications of digitisation and automation in the context of Industry 4.0: A triangulation approach and elements of a research agenda for the construction industry. *Computers in industry*, 83, 121-139.
- Pan, Y., & Zhang, L. (2021). Roles of artificial intelligence in construction engineering and management: A critical review and future trends. *Automation in Construction*, 122, 103517.
- Paulk, M. C., Curtis, B., Chrissis, M. B., & Weber, C. V. (1993). *Capability maturity model for software, version 1.1*. Software Engineering Institute, Carnegie Mellon University.
- Pirola, F., Cimini, C., & Pinto, R. (2019). Digital readiness assessment of Italian SMEs: a case-study research. *Journal of Manufacturing Technology Management*.
- Pivka, M. (1996). *Kakovost v programskem inženirstvu*, Desk.
- Posada, J., Toro, C., Barandiaran, I., Oyarzun, D., Stricker, D., De Amicis, R., ... & Vallarino, I. (2015). Visual computing as a key enabling technology for industrie 4.0 and industrial internet. *IEEE computer graphics and applications*, 35(2), 26-40.
- Rajaraman, A. (2013). *More Data Usually Beats Better Algorithms*. <http://anand.typepad.com/datawocky/2008/03/moredata-usual.html>
- Rajterič, I. H. (2010). Overview of business intelligence maturity models. *Management: journal of contemporary management issues*, 15(1), 47-67.
- Ramamurthy, K. R., Sen, A., & Sinha, A. P. (2008). An empirical investigation of the key determinants of data warehouse adoption. *Decision support systems*, 44(4), 817-841.
- Reffat, R. M., Gero, J. S., & Peng, W. (2004). Using data mining to improve building life cycle.
- Salehi, H., & Burgueño, R. (2018). Emerging artificial intelligence methods in structural engineering. *Engineering structures*, 171, 170-189.

- Schmidt, R., Möhring, M., Härtling, R. C., Reichstein, C., Neumaier, P., & Jozinović, P. (2015, June). Industry 4.0-potentials for creating smart products: empirical research results. In *International Conference on Business Information Systems* (pp. 16-27). Springer, Cham.
- Seddon, P. B., Constantinidis, D., Tamm, T., & Dod, H. (2017). How does business analytics contribute to business value?. *Information Systems Journal*, 27(3), 237-269.
- Simpson, J.A., Weiner, E.S.C. (1989). *The Oxford English Dictionary*. Oxford University Press: Oxford 21989, 65.
- Soibelman, L., & Kim, H. (2002). Data preparation process for construction knowledge generation through knowledge discovery in databases. *Journal of Computing in Civil Engineering*, 16(1), 39-48.
- Stawiarska, E., Szwajca, D., Matusek, M., & Wolniak, R. (2021). Diagnosis of the maturity level of implementing industry 4.0 solutions in selected functional areas of management of automotive companies in Poland. *Sustainability*, 13(9), 4867.
- Team, C.P. (2006). *CMMI for Development, v.1.2., Technical Report*, CMU/SEI-2006-TR-008, Carnegie Mellon Software Engineering Institute, Pittsburgh.
- Tserng, H. P., Liao, H. H., Jaselskis, E. J., Tsai, L. K., & Chen, P. C. (2012). Predicting construction contractor default with barrier option model. *Journal of Construction Engineering and Management*, 138(5), 621-630.
- Watson, H. J., & Wixom, B. H. (2007). The current state of business intelligence. *Computer*, 40(9), 96-99.
- Xue, X., Wang, Y., Shen, Q., & Yu, X. (2007). Coordination mechanisms for construction supply chain management in the Internet environment. *International Journal of project management*, 25(2), 150-157.
- Yan, H., Yang, N., Peng, Y., & Ren, Y. (2020). Data mining in the construction industry: Present status, opportunities, and future trends. *Automation in Construction*, 119, 103331.
- Yang, B.M. (2017). *Changing Construction: the Power of BIM*. China Architecture & Building Press, (ISBN: 978-7-112-20135-8).
- You, Z., Fu, H., & Shi, J. (2018). Design-by-analogy: A characteristic tree method for geotechnical engineering. *Automation in Construction*, 87, 13-21.
- You, Z., & Wu, C. (2019). A framework for data-driven informatization of the construction company. *Advanced Engineering Informatics*, 39, 269-277.
- Zou, Y., Kiviniemi, A., & Jones, S. W. (2017). A review of risk management through BIM and BIM-related technologies. *Safety science*, 97, 88-98.
- Zhang, G., Pan, Y., Zhang, L., & Tiong, R. L. K. (2020). Cross-scale generative adversarial network for crowd density estimation from images. *Engineering Applications of Artificial Intelligence*, 94, 103777.



## Anexo A

### Anexo A.1 Questões cujas pontuações foram alteradas

Código	Questão	Grupo
O4	A gestão da mudança é uma parte importante da estratégia analítica/de dados na empresa.	Organização
O11	Há uma base ética forte na empresa, que se estende a Analytics.	Organização
D6	A sua organização utiliza a seguinte tecnologia para a gestão de dados:	Infraestrutura de dados
D8	A sua organização tem um arquiteto de dados para toda a empresa, focado em <i>Analytics</i> e que consegue lidar com a democratização dos dados.	Infraestrutura de Dados
R10	A sua organização é literada em dados. Os utilizadores de negócio, bem como os analistas de negócios, podem usar dados para obter insights.	Recursos
R11	A sua organização investe em formação para <i>Analytics</i> .	Recursos
A7	As vossas soluções de análise são direcionadas para fornecer a melhor interface de utilizador para a pessoa certa (por exemplo, analistas de negócios, utilizadores de negócios, cientistas de dados...	Analytics
A9	A sua organização utiliza tecnologias de código aberto para <i>Analytics</i> .	Analytics

### ANEXO A.2 Pontuação de cada grupo de questões

Grupo	Pontuação
Organização	20
Infraestrutura de Dados	20
Recursos	20
Analytics	22
Governance	18
Total	100

## **Anexo B**

### **Anexo B.1      Frequência de respostas “Não compreendi esta questão” por pergunta**

% de N da coluna  
Contagem da camada

O1	0	0,00%
O2	0	0,00%
O3	0	0,00%
O4	0	0,00%
O5	0	0,00%
O6	0	0,00%
O7	0	0,00%
O8	0	0,00%
O9	0	0,00%
O10	0	0,00%
O11	0	0,00%
D1	4	13,30%
D2	5	16,70%
D3	6	20,00%
D4	0	0,00%
D5	0	0,00%
D6	0	0,00%
D7	6	20,00%
D8	9	30,00%
D9	1	3,30%
D10	1	3,30%
D11	1	3,30%
R1	1	3,30%
R2	1	3,30%
R3	6	20,00%
R4	6	20,00%
R5	1	3,30%
R6	1	3,30%
R7	1	3,30%
R8	1	3,30%
R9	5	16,70%
R10	1	3,30%
R11	1	3,30%
A1	0	0,00%
A2	0	0,00%
A3	5	16,70%
A4	0	0,00%
A5	0	0,00%
A6	3	10,00%
A7	7	23,30%
A8	0	0,00%
A9	6	20,00%
A10	5	16,70%
A11	1	3,30%
A12	1	3,30%
G1	6	20,00%
G2	1	3,30%
G3	2	6,70%
G4	6	20,00%
G5	6	20,00%
G6	2	6,70%
G7	2	6,70%
G8	3	10,00%
G9	1	3,30%

**Anexo B.2**    **Frequência de respostas “Não compreendi esta questão” por grupo de questões**

Cluster	Contagem	%
Organização	0	0%
Infraestrutura de dados	33	10%
Recursos	25	7,58%
Analytics	28	7,78%
Governance	29	10,74%

**Anexo C**

**Anexo C.1**    **Teste para a associação entre “Maturidade Total” e “Departamento do respondente”**

Maturidade total vs Departamento do Respondente			
		Valor	Significância
	<b>F</b>	1,132	0,001
	<b>V de Cramer</b>	0,566	0,001
<b>Nº de casos</b>		30	

**Anexo C.2**    **Teste para a associação entre “Maturidade Total” e “Estudos do respondente”**

Maturidade total vs Estudos do Respondente			
		Valor	Significância
	<b>F</b>	0,736	0,180
	<b>V de Cramer</b>	0,425	0,180
<b>Nº de casos</b>		30	

**Anexo C.3**    **Teste para a associação entre “Maturidade Total” e “Cargo do respondente”**

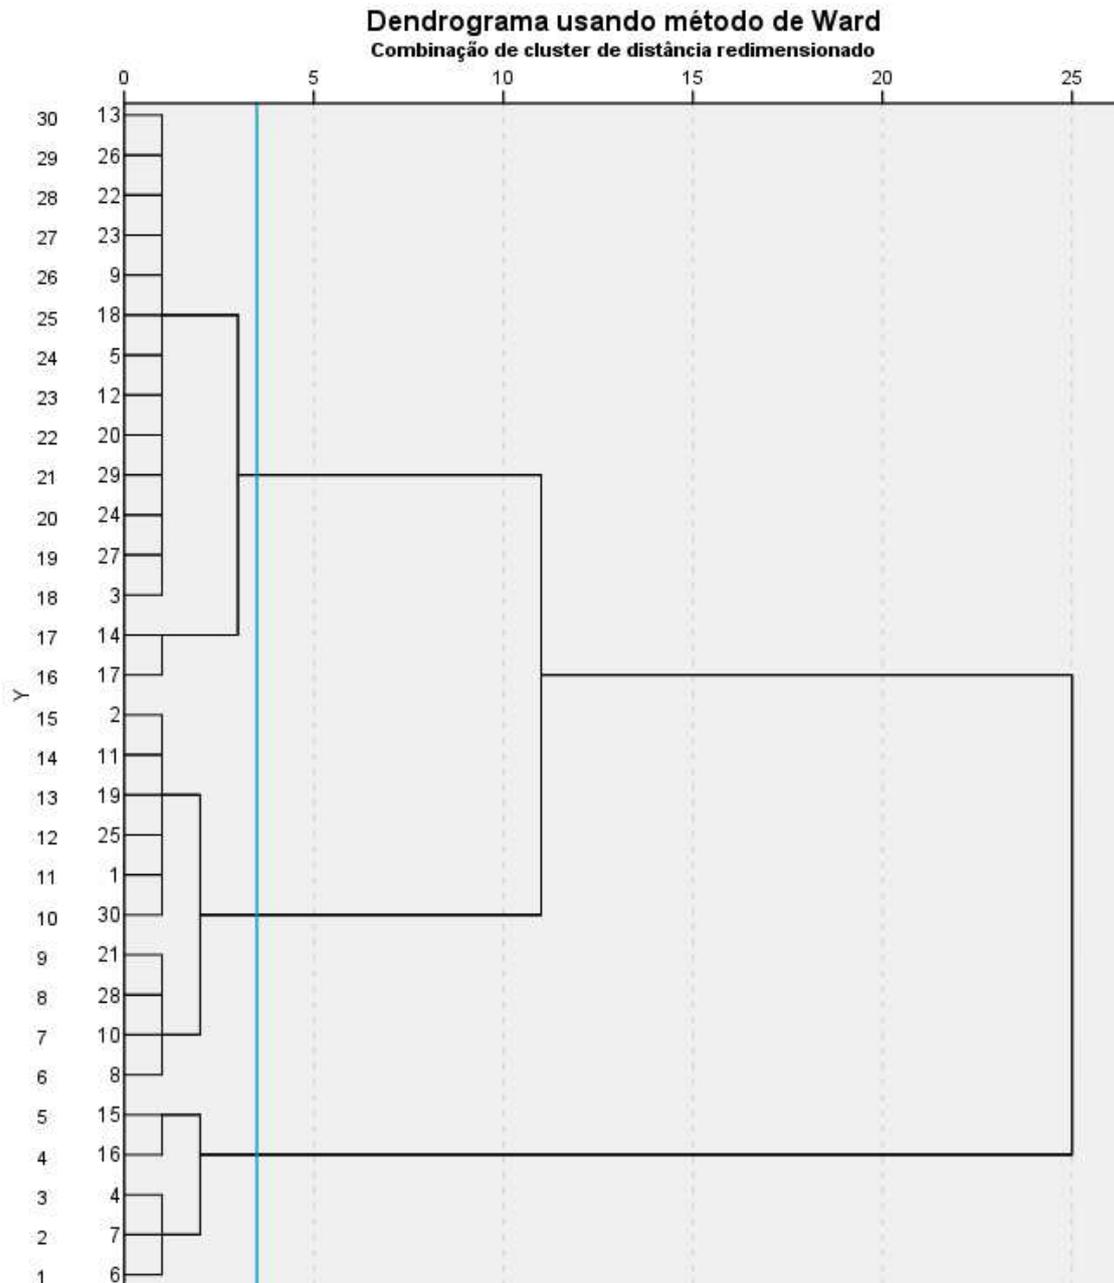
<b>Maturidade total vs Cargo do Respondente</b>			
		<b>Valor</b>	<b>Significância</b>
	<b>F</b>	0,753	0,030
	<b>V de Cramer</b>	0,532	0,030
<b>Nº de casos</b>		30	

**Anexo C.4      Teste para a associação entre “Maturidade Total” e “Nível de Faturação”**

<b>Maturidade total vs Nível de Faturação</b>			
		<b>Valor</b>	<b>Significância</b>
	<b>F</b>	1,269	0,002
	<b>V de Cramer</b>	0,635	0,002
<b>Nº de casos</b>		30	

**Anexo D**

**Anexo D.1      Dendrograma usando o método de Ward**



**Anexo D.2 Centros dos *clusters* finais pelo método “K-MEANS”**

	Cluster			
	1	2	3	4
<b>Organização</b>	7,72	11,48	15,48	16,86
<b>Infraestrutura de dados</b>	5,29	9,67	14,00	18,29
<b>Recursos</b>	4,53	9,33	10,06	18,42
<b>Analytics</b>	4,72	7,32	10,69	15,16
<b>Governance</b>	5,51	10,13	13,65	18,75

**Anexo D.3 Distâncias entre centros dos *clusters* pelo método “K-MEANS”**

Cluster				
	1	2	3	4
1	-			
2	9,194	-		
3	16,387	7,677	-	
4	27,016	17,932	11,671	-

**Anexo D.4 Tabela de ANOVA para as variáveis de construção dos *clusters* pelo método “K-MEANS”**

ANOVA						
	Cluster		Erro		Z	Sig.
	Quadrado médio	df	Quadrado Médio	df		
Organização	107,057	3	2,421	26	44,219	0,000
Infraestrutura de dados	187,444	3	2,578	26	72,721	0,000
Recursos	186,812	3	3,206	26	58,174	0,000
Analytics	115,752	3	4,360	26	26,546	0,000
Governance	186,510	3	3,422	26	54,506	0,000

## Anexo E

### Anexo E.1 Questionário disponibilizado aos respondentes

1. Os líderes da sua empresa apoiam e prescrevem Analytics em toda a organização. \*

- Não.
- Parecem um pouco ambíguos relativamente a Analytics e não prescrevem verdadeiramente.
- Apoiam as iniciativas de Analytics e começam a usá-las na organização. Isso inclui usar Analytics para a tomada de decisão.
- Apoiam firmemente as iniciativas de Analytics, usam-nas para a tomada de decisão em toda a empresa.

2. A sua organização possui um Chief Analytics Officer (CAO) que lidera as iniciativas de Analytics. \*

- Não temos ninguém responsável por Analytics na empresa.
- Analytics é responsabilidade do departamento de IT.
- Temos um ou mais VPs ou Diretores responsáveis por Analytics na empresa.
- Temos uma Chief Analytics Officer, ou alguém equivalente.

3. A sua empresa tem em curso uma estratégia sólida, para apoiar as iniciativas de dados e Analytics. \*

- Não, e não temos planos para o fazer.
- Não, mas temos planos para o começar no próximo ano.
- Sim, estamos a pôr uma estratégia em curso.
- Sim, temos em curso uma estratégia sólida para Analytics.

4. A gestão da mudança é uma parte importante da estratégia analítica/de dados na empresa. \*

- Discordo fortemente
- Discordo
- No limite
- Concordo
- Concordo fortemente

5. Que percentagem da sua empresa utiliza Analytics para a tomada de decisão do dia a dia? \*

- Menos de 25%
- Entre 26-40%
- Entre 41-55%
- Entre 55-70%
- Mais que 70%

6. A sua organização já mediu o impacto de Analytics? \*

- Não, ainda não assistimos a nenhum impacto significativo
- Não, ainda não medimos o impacto, mas acreditamos ter gerado valor
- Sim, já medimos alguns resultados

7. A sua organização utiliza Analytics para tomar ações \*

- Discordo fortemente
- Discordo
- Não concordo nem discordo
- Concordo
- Concordo fortemente

8. Há uma cultura de confiança em Analytics em toda a organização. \*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente

9. Há uma grande colaboração com Analytics na sua empresa. \*

- Não, não praticamos Analytics
- Não, não colaboramos com Analytics, que é competência de IT
- Ainda não, mas caminhamos nesse sentido
- Sim, as áreas de negócio e IT trabalham em conjunto quando há necessidade
- Sim, as áreas de negócio e IT colaboram porque procuram fazê-lo para gerar valor

10. Há uma cultura de inovação na empresa que se estende a Analytics \*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente

11. Há uma base ética forte na empresa, que se estende a Analytics. \*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente

## Infraestrutura de dados

Em 2006, o matemático britânico e mastermind do marketing da Tesco, Clive Humby afirmou, pela primeira vez, que os dados são o novo petróleo. Desde então, empresas como o Facebook, Google e Netflix têm baseado os seus modelos de negócio neste valioso bem.

Os dados são o combustível da disciplina de Analytics. Como tal, é fundamental que as empresas recolham, administrem e girem estes ativos fazendo uso das melhores práticas.

12. Que tipos de dados recolhe e gere a sua empresa, como parte dos esforços analíticos? \*

- Nenhum
- Dados estruturados de fontes internas apenas (e.g. folhas de cálculo)
- Dados estruturados e pelo menos um dos seguintes: dados semi-estruturados (e.g. JSON, XML), texto, dados gerados por máquina, dados geoespaciais, dados de eventos em tempo real, áudio, vídeo, weblogs, clickstreams.
- Dados estruturados e pelo menos TRÊS dos seguintes: dados gerados por máquina, dados geoespaciais, dados de eventos em tempo real, áudio, vídeo, clickstreams.
- Não compreendo esta questão

13. Os colaboradores podem aceder aos dados quando necessário, incluindo dados estruturados e não-estruturados, através de uma plataforma de acesso e processo de governance únicos. \*

- Não
- Só com a ajuda de IT
- Sim, business analysts e data scientists podem aceder e utilizar os dados, embora muitas vezes seja um desafio
- Sim, usamos tecnologias como opções de data sharing para ajudar a organizar e aceder a dados para um grande número de colaboradores.
- Não compreendo esta questão

14. A sua empresa tem um modelo de partilha de dados extenso, e um leque de fontes de dados grande, disponíveis para Analytics. \*

- O acesso a dados é limitado ao Enterprise Warehouse e partilha de folhas de Excel ad hoc
- Sim e os dados são partilhados entre departamentos através de um data lake
- Sim e os dados são recolhidos de parceiros externos através de serviços web e APIs e armazenados em Data Warehouses cloud ou equivalente.
- Não compreendo esta questão

15. A sua empresa frequentemente utiliza multiplas fontes de dados para Analytics. \*

- Não
- Sim, com dados estruturados
- Sim, com diferentes tipos de dados incluindo não-estruturados e outras fontes de dados não tradicionais
- Sim, com diferentes tipos de dados, e fazemos um bom trabalho na sua integração
- Sim, com todos os tipos de dados, internos ou externos - o importante para nós é termos a "full picture"
- Não compreendo esta questão

16. A sua empresa tem uma política de qualidade de dados para Analytics. \*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente
- Não compreendo esta questão

17. A sua organização utiliza a seguinte tecnologia para a gestão de dados: \*

- Utilizamos arquivos de ficheiros simples ou folhas de cálculo
- Temos um data warehouse ou um data mart
- Usamos um data warehouse e um data lake, mas estão isolados
- Usamos um conjunto de tecnologias incluindo o nosso data warehouse, data lake, cloud, ou outro tipo, e estamos a desenhá-los para formarem um ecossistema
- Utilizamos um grande número de abordagens, que se encontram integradas num bom sistema de fácil acesso
- Não compreendo esta questão

18. A sua empresa consegue orquestrar e monitorizar múltiplos pipelines de dados. \*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente
- Não compreendo esta questão

19. A sua organização tem um arquiteto de dados para toda a empresa, focado em Analytics e que consegue lidar com a democratização dos dados. \*

- Os dados estão isolados, com apenas o nosso business analyst a utilizar folhas de cálculo e o data warehouse
- Os nossos analistas e data scientists conseguem usar ferramentas analíticas diferentes com a mesma fonte de dados
- Temos uma arquitetura unificada, self-service de acesso a dados e preparação para um catálogo de bens para utilizadores não-IT
- Não compreendo esta questão

20. A sua organização desenhou a sua arquitetura para integrar, aceder e analisar dados diversos vindos de fontes diferentes. \*

- Ainda não
- Usamos diversas fontes, mas integramos em dados estruturados
- Sim, e integramos dados estruturados e semiestruturados porque são todos os que necessitamos para nos dar uma visão mais completa e tomar as melhores decisões ou automatizar os melhores processos
- Não compreendo esta questão

21. A nossa arquitetura de dados foi desenhada para poder crescer conforme a necessidade. \*

- Não
- Ainda não, mas estamos a mudar para uma arquitetura mais flexível e escalável
- Sim, estamos confiantes na capacidade da empresa de escalar dependendo do caso de uso, incluindo flutuações sazonais
- Não compreendo esta questão

22. A arquitetura da sua empresa é projetada para escalar conforme a procura, para atender às necessidades do utilizador.

- Não
- Não, mas vemos-lo como uma falha
- Sim, estamos a caminhar nessa direção
- Sim, mas apenas para alguns momentos
- Sim
- Não compreendo esta questão

## Recursos

23. A sua organização tem um processo de financiamento bem estabelecido para tecnologia e Analytics. É orientado tanto para negócios quanto para IT. \*

- Discordo totalmente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente
- Não compreendo esta questão

24. A estratégia de análise da sua organização inclui um componente organizacional que permite que sua empresa execute Analytics. Isso pode incluir o financiamento de um centro de excelência, equipas de capacitação de data literacy e similares.

- Não
- Ainda não, mas é importante e algumas pessoas pretendem-no
- Sim, estamos a tentar executá-lo
- Sim, temos grupos/equipas ativas e procuramos extendê-las
- Sim, temos um investimento significativo neste tipo de coisa que inclui treino e suporte para iniciativas de analytics
- Não compreendo esta questão

25. A sua empresa investe em iniciativas de gestão de mudanças

- Não, e não temos planos
- Não, mas procuramos fazê-lo no próximo ano
- Sim, estamos a pô-lo em prática
- Sim, temos treinos de change management, mas apenas para executivos
- Sim, pusemo-lo em prática em toda a empresa
- Não compreendo esta questão

26. A sua equipa está a lutar para manter a sua infraestrutura de dados para dar suporte à análise.

- Sim, é um desafio: há poucos recursos
- Estamos a procurar trabalhar de forma mais inteligente e utilizar tecnologia, assim como recrutar mais pessoas
- Estamos a trabalhar de forma mais inteligente e temos os recursos que precisamos
- Não compreendo esta questão

27. A sua empresa contratou cientistas de dados ou capacitou funcionários existentes para se tornarem cientistas de dados como parte de seus esforços de Analytics. \*

- Não, e não temos planos para o fazer
- Não, mas vamos fazê-lo no próximo ano
- Sim, contratámos alguns data scientists
- Sim, os nossos data scientists são parte da equipa de analytics
- Sim, os nossos data scientists são parte da equipa de analytics e colaboram com as áreas de negócio
- Não compreendo esta questão

28. Além dos cientistas de dados, a sua organização emprega uma variedade de funcionários para lidar com diferentes aspectos do ciclo de vida de Analytics. Isso inclui engenheiros de dados e equipas de operações (como MLOps), por exemplo, para lidar com modelos em produção. \*

- Não, e não tenho certeza se estamos a pensar contratar engenheiros de dados ou operações
- Não, mas percebemos que isso é importante e estamos a tentar trabalhar nisso de maneira ad hoc com a equipa existente
- Estamos a contratar um grupo/equipa dedicado para isso
- Sim, temos um grupo dedicado, com um mandato e skills específicas
- Não compreendo esta questão

29. A sua organização tem uma equipa com competências para executar a gestão de dados para Analytics

\*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente
- Não compreendo esta questão

30. A sua organização tem uma equipa com competências para executar Analytics \*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente
- Não compreendo esta questão

31. A sua organização tem uma equipa de Dev/Ops a bordo para criar aplicativos internos ou externos que usam Analytics. \*

- Não
- Não, mas planeamos fazê-lo
- Sim, a nossa equipa DevOps constrói aplicações como embeded dashboards
- Sim, a nossa equipa DevoOps constrói aplicações mais complexas como visualização de dados e machine learning
- Sim, temos construído aplicações e rentabilizamo-las
- Não compreendo esta questão

32. A sua organização é literada em dados. Os utilizadores de negócio, bem como os analistas de negócios, podem usar dados para obter insights. \*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente
- Não compreendo esta questão

33. A sua organização investe em formação para Analytics. \*

- Não
- Não, mas sugerimos aos colaboradores que o façam
- Sim, financiamos training interno
- Sim, financiamos programas regulares, e garantimos que os colaboradores estão a aprender
- Não compreendo esta questão

## Analytics

Mais do que um conjunto de ferramentas e conhecimentos, Analytics é uma disciplina. As próximas questões permitem perceber como é que a sua empresa transforma a estratégia em ações, atividades e processos concretos.

34. Qual das seguintes tecnologias a sua organização usa para analisar dados? \*

- Folhas de cálculo
- Usamos folhas de cálculo juntamente com relatórios, dashboards e descoberta visual
- Usamos o acima junto com a descoberta de dados self-service; também estamos a começar a usar análises preditivas
- Usamos o acima junto com análise preditiva/machine learning contra vários tipos de dados
- Usamos o acima junto com outras técnicas, como NLP, deep learning e outras facetas da IA
- Não compreendo esta questão

35. Sua organização gere grandes volumes de dados para análise (por exemplo, mais de 10 TB) \*

- Não
- Ainda não, mas caminhamos nessa direção
- Sim, utilizamos Analytics em grandes quantidades de dados
- Não compreendo esta questão

36. Quantos modelos de análise preditiva/machine learning a sua empresa possui em produção? \*

- Nenhum
- 1
- 2-10
- Dezenas
- Centenas
- Não compreendo esta questão

37. Que percentagem de pessoas na sua empresa tem acesso a Analytics? \*

- Menos que 25%
- 26-40%
- 41-55%
- 56-70%
- Mais de 70%
- Não compreendo esta questão

38. A sua organização é bem-sucedida na articulação de problemas de negócios que exigem análise. Sabe em que casos usar técnicas específicas para resolver diferentes problemas. \*

- Não somos nada bem sucedidos nisso
- Não somos muito bem sucedidos nisso
- Não somos nem bem-sucedidos nem mal sucedidos nisso
- Nós somos bem sucedidos nisso
- Nós somos muito bem sucedidos nisso
- Não compreendo esta questão

39. Analytics é usada por equipas em toda a organização, quando necessário. \*

- Não, é usada principalmente em finanças, operações ou IT
- Atualmente não, mas cada vez mais departamentos estão a interessar-se nisso
- Sim, usamos em toda a organização
- Não compreendo esta questão

40. As vossas soluções de análise são direcionadas para fornecer a melhor interface de utilizador para a pessoa certa (por exemplo, analistas de negócios, utilizadores de negócios, cientistas de dados, engenheiros de dados etc.). Por exemplo, os cientistas de dados podem usar notebooks para ciência de dados, enquanto os analistas de negócios podem preferir drag&drop e detalhar GUIs, e os usuários de negócios em geral podem querer apenas consumir painéis e relatórios ou utilizar mecanismos automatizados sugeridos pelos seus modelos.

\*

- Não, só temos uma ferramenta e toda a gente reclama, pois não serve para ninguém
- Estamos a pensar ou planear instalar ferramentas que podem ser usadas por diferentes personas
- Sim, utilizamos várias ferramentas para que cada uma de nossas personas tenha o ambiente adequado
- Sim, usamos uma plataforma de dados para que cada persona tenha um ambiente que maximize a eficiência e haja processos claros para impulsionar o trabalho entre eles
- Igual a (4) e por outro lado a nossa plataforma torna a partilha de dados entre ambientes o mais simples possível
- Não compreendo esta questão

41. A sua organização utiliza Analytics automatizada (por exemplo, sistemas que sugerem insights ou modelos de construção) \*

- Não
- Não, mas estamos a explorar essas soluções
- Sim, nós usamos para democratizar a análise e aumentar a produtividade
- Sim, usamos uma plataforma de dados para ajudar a aumentar a produtividade e colocamos controlos em torno dessas ferramentas para garantir que elas funcionam corretamente
- Não compreendo esta questão

42. A sua organização utiliza tecnologias de código aberto para Analytics. \*

- Sim, só usamos open source
- Sim, usamos open source em conjunto com produtos comerciais: o que quer que cubra as necessidades dos nossos analistas
- Não: usamos apenas produtos comerciais
- Não compreendo esta questão

43. Analytics é operacionalizada/implementada num(s) sistema(s) de negócios ou numa(s) aplicação(ões) na sua organização. \*

- Não, não temos planos para o fazer
- Não, mas temos planos para o fazer no próximo ano
- Sim, estamos a fazê-lo em dashboards
- Sim, fazemos por rotina em dashboards
- Sim, operacionalizamos por rotina as nossas análises, incluindo dashboards e modelos preditivos em produção
- Não compreendo esta questão

44. Os outputs de modelos construídos usando inteligência aumentada tem funcionalidades explicativas para aumentar a transparência para especialistas e não especialistas.

\*

- Não aplicável, não usamos essas ferramentas
- Não
- Sim, usamos apenas pacotes que possuem esses recursos
- Não compreendo esta questão

45. A sua organização monitoriza modelos de análise preditiva/machine learning quanto à deterioração. \*

- Não aplicável, não temos modelos em produção
- Não, e não temos planos para o fazer
- Ainda não, mas planeamos fazê-lo
- Sim, estamos a fazer isso agora
- Sim, fazemos isso regularmente
- Sim, fazemos isso rotineiramente com verificações automatizadas e alocamos o tempo necessário para que a nossa equipa resolva
- Não compreendo esta questão

## Governance

Governance refere o sistema sob o qual as organizações são administradas, que rege as regras, condutas e éticas necessárias ao normal funcionamento.

46. Os dados são confiáveis e governados em todas as plataformas da sua organização \*

- Não, temos muitos silos de dados que não são governado
- Confiamos nos dados que usamos para relatórios provenientes de nosso DW, mas não muito mais
- Iniciámos o processo de implementação para data governance além do DW ou de outras fontes de dados que precisam estar em conformidade (por exemplo, HIPAA) para que possamos confiar em outras fontes de dados importantes
- Temos um plano de data governance sólido que descreve as principais políticas e processos; estes são seguidos na organização
- Não compreendo esta questão

47. A sua organização entende de onde os dados são originados e tem as políticas corretas em vigor para lidar com diferentes tipos de dados (por exemplo, estruturados, semiestruturados ou não estruturados) \*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente
- Não compreendo esta questão

48. Os utilizadores aceitam e aderem às políticas de data governance. \*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente
- Não compreendo esta questão

49. A sua organização usa ferramentas como catálogos de dados para ajudar os usuários a acessar a dados confiáveis. \*

- Não, e não temos planos de instalar um catálogo de dados
- Não, mas estamos a planejar isso
- Estamos neste momento a selecionar um fornecedor de catálogo agora
- Sim, temos um catálogo de dados, mas nem todos o utilizam
- Sim, temos um catálogo de dados e as pessoas estão a usá-lo
- Não compreendo esta questão

50. Os processos de implementação de modelos estão em vigor na sua organização. Por exemplo, os modelos devem ser validados para não serem incorretos ou antiéticos (por exemplo, ter preconceito racial) antes de serem colocados em produção. \*

- Não aplicável, não temos modelos em produção na minha empresa
- Temos modelos implantados, mas não verificamos se estão corretos. Confiamos em nossos cientistas de dados
- Estamos em processo de implementação de controles sobre modelos em produção
- Temos um forte processo de controle de modelos
- Não compreendo esta questão

51. As políticas de gestão de modelo estão em vigor em sua organização. Os modelos devem ser controlados por versão e os metadados capturados para cada modelo colocado em produção. \*

- Não aplicável -- não temos modelos em produção
- Temos apenas alguns modelos, então nossos cientistas de dados lidam com eles
- Temos uma abordagem de sistema de arquivos para acompanhar os modelos e lidar com o controle de versão
- Estamos a começar a usar registros de modelos e outras tecnologias para capturar metadados sobre modelo
- Usamos ferramentas e tecnologias para gerir os nossos modelos. Os modelos são versionados e rastreados
- Não compreendo esta questão

52. A sua empresa tem uma equipa de data governance e analytics com representantes de toda a empresa, incluindo os principais interessados nos negócios. As funções e responsabilidades são claramente definidas.

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente
- Não compreendo esta questão

53. A função do(s) administrador(es) de dados está em vigor e as funções e responsabilidades dessa pessoa (ou equipa) são claramente identificadas. \*

- Não
- Estamos no processo de identificação de administradores de dados
- Os administradores de dados estão em vigor na minha empresa
- Não compreendo esta questão

54. Políticas de segurança e privacidade são estabelecidas e aplicadas para todas as formas de dados na sua empresa. \*

- Discordo fortemente
- Discordo
- Nem concordo nem discordo
- Concordo
- Concordo fortemente
- Não compreendo esta questão

## Caracterização da empresa

Para finalizar, por favor responda às seguintes perguntas:

55. Qual é a dimensão da sua empresa (em número de funcionários)? \*

- Menos de 20
- Entre 20 e 50
- Entre 50 e 100
- Entre 100 e 250
- Entre 250 e 500
- Entre 500 e 1000
- Mais de 1000

56. Qual é a dimensão da sua empresa (em faturação anual)? \*

- Até 1 000 000€
- Entre 1 e 2 milhões de euros
- Entre 2 e 5 milhões de euros
- Entre 5 e 20 milhões de euros
- Entre 20 e 50 milhões de euros
- Entre 50 e 200 milhões de euros
- Mais de 200 milhões de euros

57. Qual a idade da sua empresa? \*

58. Nome da empresa (esta questão é opcional, porém está garantido o sigilo da sua resposta )

59. Quantas pessoas foram necessárias para responder a este questionário? \*

60. Cargo da pessoa que respondeu ao questionário \*

61. Departamento da pessoa que respondeu ao questionário \*

62. Habilitações da pessoa que respondeu ao questionário \*

- Até ao 12º ano
- Licenciatura/Bacharelato
- Mestrado ou superior

63. Área de estudo da pessoa que respondeu ao questionário \*

64. Idade da pessoa que respondeu ao questionário \*

65. Por favor insira um endereço de email para receber os resultados deste questionário. \*