

**Victor Barbosa Gonçalves**

**Utilização de Inteligência Artificial na  
Metodologia de OKRs: Um Framework Teórico**

**Uberlândia, MG**

**2022**

**Victor Barbosa Gonçalves**

**Utilização de Inteligência Artificial na Metodologia de  
OKRs: Um Framework Teórico**

Trabalho de Conclusão de Curso da Engenharia de Engenharia Elétrica da Universidade Federal de Uberlândia - UFU - Campus Santa Mônica, como requisito para a obtenção do título de Graduação em Engenharia Elétrica.

Universidade Federal de Uberlândia - UFU  
Faculdade de Engenharia Elétrica - FEELT

Orientador Prof. Dr. Alexandre Cardoso

Uberlândia, MG

2022

Dedico a esse trabalho à minha família, Ester,  
Gervásio, Matheus, Cleide e Rosa, que sempre  
foram meu alicerce de incentivos

# Agradecimentos

Gostaria de agradecer primeiramente às oportunidades que tive para concluir essa etapa da minha vida, sei que foram privilegiadas e por isso gostaria de agradecer à todos que contribuíram para essa jornada.

Sou extremamente grato aos meus pais, pelo amor, paciência, investimento e confiança que depositaram em mim. Agradeço também, ao meu irmão Matheus que sempre me apoiou em todas as circunstâncias.

Agradeço também, a minha namorada Isabela que sempre me apoia, inspira e me faz crescer a cada dia. Sou extremamente feliz por ter você na minha vida.

Sou imensamente grato também ao professores Alexandre Cardoso e Edgard Lamou-nier, os quais me deram a minha primeira oportunidade de me desenvolver academicamente. Agradeço também, à todos os integrantes do Grupo de Realidade Virtual e Aumentada (GRVA) que também contribuíram para o meu desenvolvimento durante a graduação.

Expresso também, o meu muito obrigado a toda a equipe do Brain, onde tive a oportunidade de me desenvolver profissionalmente e pessoalmente. Em especial, agradeço minha equipe de governança, que sempre me deu muita oportunidade e apoio.

Gostaria de agradecer também aos meus amigos Eduardo e Victor que imensamente contribuíram para o meu desenvolvimento pessoal e científico. De fato, grande parte do meu sucesso é devido à vocês.

Não tenho palavras para agradecer também à todos os meus colegas que fizeram parte da minha caminhada durante a graduação. Em especial, gostaria de agradecer aos meus queridos amigos, Leonardo, Isabela e Jota. Além de fazerem minha caminhada durante a faculdade ser especial, levo essas amizades para a vida, vocês são muito especiais para mim.

Por fim, gostaria de agradecer aos meus amigos que sempre foram pontos de apoio nos momentos de alegria e tristeza, em especial às minhas amigas Eduarda e Vitória.

# Resumo

A transição ágil das empresas, de fato, é algo complexo para ser realizado. Para conseguir uma organização ágil, que gere valor e esteja em linha com a estratégia da companhia, o uso de metodologias e ferramentas pode se tornar necessário. Neste cenário, a metodologia de *Objectives and Key Results* (OKRs) e a tecnologia de Inteligência Artificial (IA) podem auxiliar na estruturação da empresa, tendo em vista que sua combinação emerge como uma oportunidade para ampliar, ainda mais, a geração de valor e contribuir para alinhamento de estratégia. Para aumentar o potencial da metodologia de OKRs através da orientação de dados, este trabalho propõe um *framework* teórico da aplicação da tecnologia de IA na metodologia de OKRs. Através do *framework* proposto, é construída uma fundamentação para apoiar o desenvolvimento de trabalhos futuros relacionados ao tema do estudo. É expectável que a tecnologia de IA amplifique os resultados de alinhamento de estratégia da metodologia de OKRs com a orientação a dados. Com isso, espera-se que lacunas da metodologia de OKRs sejam supridas, como escalabilidade e aumento da geração de mais percepções sobre problemas de engajamento e motivação. Dessa forma, potencializando os benefícios da metodologia de OKRs.

**Palavras-chaves:** Inteligência Artificial; OKRs; Aprendizado de Máquina; Orientação a Dados; Framework Teórico.

# Abstract

The agile transition of companies is something complex to accomplish. The use of methodologies and resources may be necessary to achieve an agile organization that generates value and is aligned with the company's strategy. In this context, the Objectives and Key Results (OKRs) methodology and Artificial Intelligence (AI) technology may help in the structuring of the company, considering that their combination emerges as an opportunity to enhance value generation further and contribute to strategy alignment. To enhance the potential of the OKRs methodology through data-driven guidance, this paper proposes a theoretical framework of AI technology applied in the OKRs methodology. Through the proposed framework, a groundwork is built to support the development of future work related to the theme of the investigation. AI technology is expected to amplify the strategy alignment outcomes of the OKRs methodology with data-driven orientation. As a result, it is expected that shortcomings of the OKRs methodology will be addressed, such as scalability and increased generation of more insights into engagement and motivational problems, thus, enhancing the benefits of the OKRs methodology.

**Key-words:** Artificial Intelligence; OKRs; Machine Learning; Data-Driven; Theoretical Framework.

# Lista de ilustrações

Figura 1 – Representação do ciclo de vida do Processo de Ciência de Dados de Equipe. . . . .	14
Figura 2 – Desdobramento da estratégia em objetivos através da metodologia de OKRs. . . . .	17
Figura 3 – Ciclo de OKRs. . . . .	18
Figura 4 – Etapas do processo de construção do <i>framework</i> teórico. . . . .	21
Figura 5 – Proposta de <i>Framework</i> do Ciclo de OKRs com a utilização de IA . . . . .	28

# Lista de tabelas

Tabela 1 – Termos utilizados na busca sistemática de acordo com as bases de dados.	23
Tabela 2 – Artigos identificados na busca sistemática da literatura. . . . .	24



# Lista de abreviaturas e siglas

AM	Aprendizado de Máquina
IA	Inteligência Artificial
OKRs	<i>Objectives and Key Results</i>
TDSP	<i>Team Data Science Process</i>

# Sumário

1	<b>INTRODUÇÃO</b>	11
1.1	Motivação	11
1.2	Objetivos	12
1.2.1	Objetivo Geral	12
1.2.2	Objetivos Específicos	12
1.3	Justificativa	12
1.4	Organização do Texto	13
2	<b>REFERENCIAIS TEÓRICOS</b>	14
2.1	Ciclo de Vida dos Dados	14
2.1.1	Entendimento do Negócio	15
2.1.2	Aquisição e Entendimento dos Dados	15
2.1.3	Modelagem	15
2.1.4	Implantação	16
2.2	Ciclo de OKRs	17
2.2.1	Estratégia e Periodicidade dos Objetivos	18
2.2.2	Construção e Planejamento	18
2.2.3	Alinhamento	19
2.2.4	Check-ins	19
2.2.5	Reviews e Retrospectivas	19
3	<b>METODOLOGIA</b>	21
3.1	Busca Sistemática na Literatura	21
3.2	Análise de Artigos Correlatos	21
3.3	Construção do <i>Framework</i> Teórico	22
4	<b>BUSCA SISTEMÁTICA NA LITERATURA</b>	23
4.1	Identificação de Artigos	23
4.2	Análise dos Artigos Identificados	25
4.2.1	Motivação dos Times	25
4.2.2	Alinhamento de Estratégia e Orientação a Dados	25
4.2.3	IA e seu Potencial para Análise de Dados	25
4.2.4	Demais Artigos	26
5	<b>PROPOSTA DE FRAMEWORK TEÓRICO</b>	27
5.1	Entendimento do Negócio	27

5.2	Aquisição e Entendimento de Dados . . . . .	28
5.3	Modelagem . . . . .	29
5.4	Implantação e Aceitação do Cliente . . . . .	29
6	CONCLUSÃO . . . . .	31
	REFERÊNCIAS BIBLIOGRÁFICAS . . . . .	32

# 1 Introdução

## 1.1 Motivação

A utilização de metodologias ágeis em empresas é uma tendência que tem aumentado. Uma pesquisa mostra que 90% dos gestores modernos querem implementar a agilidade em suas organizações (COSTA, 2022). Para consolidar uma empresa ágil são necessárias equipes proativas, dinâmicas, versáteis e com autonomia.

Um estudo realizado pela McKinsey<sup>1</sup> mostrou que apenas um pequeno grupo de organizações consegue realizar transformações ágeis bem sucedidas (AGHINA et al., 2021). Através de entrevistas feitas com essas organizações, identificou-se que tais empresas estavam adotando agilidade em escala para criar e capturar valor, ao invés de tratar a metodologia ágil como experimentos limitados a equipes em departamentos discretos.

Uma transformação ágil bem sucedida requer um alinhamento de valor e estratégia nas equipes. A “*Objectives and Key Results*” (OKRs) é uma metodologia considerada efetiva para alinhamento de estratégia e foco em resultado. Este conceito, criado por Andy Grove, define a criação de objetivos mensurados por resultados para atingir um propósito ambicioso e desafiador (DOERR, 2018).

Tal metodologia, atualmente difundida entre empresas, proporciona diversos benefícios considerados essenciais, tanto para criar e capturar valor quanto para tornar uma empresa ágil; são alguns dos benefícios: foco, alinhamento, comprometimento, rastreamento e flexibilidade (DOERR; PANCHADSARAM; SHUFRO, 2020).

A utilização da tecnologia de Inteligência Artificial (IA) nas empresas é também uma tendência que se tem feito presente como uma ferramenta para criação e captura de valor. A IA, em conjunto com Aprendizado de Máquina (AM), pode ser usada para desenvolver novas ideias, descobrir novos padrões e estabelecer interações com os dados (CHUI; KAMALNATH; MCCARTHY, 2020).

Dados textuais provenientes do acompanhamento da metodologia de OKRs são complexos de serem analisados — além de demandarem leitura e interpretação de texto —, o que pode gerar uma alta demanda de tempo e trabalho. Neste contexto, a IA pode ser utilizada para análise de texto e processamento de linguagem natural, visto que possibilita a extração de texto — extração de frases ou palavras relevantes ou essenciais a partir de dados sem estruturação — e a classificação de texto — classificação automática de frases ou palavras com etiquetas pré-definidas (ESULI; SEBASTIANI, 2009).

---

<sup>1</sup> McKinsey & Company é uma das mais conceituadas empresas de consultoria empresarial, que aconselha empresas, governos e outras organizações em consultoria estratégica.

O conceito de orientação de dados por meio das tecnologias de IA e AM tem sido bastante difundido (AZIZ; DOWLING, 2019). Esse conceito já é utilizado por diversas áreas para ganho de valor e auxílio nas tomadas de decisões das empresas (SCHNEIDER et al., 2022; KAR; KUSHWAHA, 2021). Um exemplo disso é a sua aplicação na área de recursos humanos, auxiliando nas deliberações para retenção de talentos (SHRIVASTAVA; NAGDEV; RAJESH, 2018; KHAN; MILLNER, 2020).

A transição ágil das empresas, de fato, é algo complexo de ser realizado (AGHINA et al., 2021). Para conseguir uma organização ágil, que gere valor e esteja em linha com a estratégia da companhia, o uso de metodologias e ferramentas pode se tornar necessário. Neste cenário, a metodologia de OKRs e a tecnologia de IA podem auxiliar na estruturação da empresa, tendo em vista que essa combinação emerge como uma oportunidade para aumentar, ainda mais, a geração de valor e contribuir para alinhamento de estratégia.

## 1.2 Objetivos

### 1.2.1 Objetivo Geral

Considerando o alinhamento de estratégia proporcionado pelos OKRs e o potencial de sintetização de dados através da IA para gerar orientação e embasamento nas tomadas de decisões, o objetivo geral desse estudo é propor um *framework* teórico de utilização da tecnologia de IA na metodologia de OKRs.

### 1.2.2 Objetivos Específicos

- Conhecer teorias relevantes do ciclo de vida dos dados e da metodologia de OKRs, através de fundamentação teórica;
- Conduzir uma busca sistemática na literatura com a finalidade de identificar estudos que correlacionem a tecnologia de IA com a metodologia de OKRs;
- Identificar possíveis oportunidades de aplicação de IA na metodologia de OKRs por meio da análise de trabalhos correlatos;
- Propor *framework* teórico da aplicação da tecnologia de IA na metodologia de OKRs.

## 1.3 Justificativa

A metodologia de OKRs tem mostrado o seu potencial para alinhamento de estratégia. Através do envolvimento dos colaboradores na definição dos objetivos da companhia, as prioridades para atingir as aspirações da empresa são constituídas em conjunto e o engajamento dos colaboradores tende a ser estimulado. No entanto, em

empresas com grande capilaridade, pode ser um desafio considerar ideias e opiniões de todos os colaboradores. Dessa forma, supõe-se que utilizar a tecnologia de IA — que possui o poder de sintetização e estruturação de dados — para auxiliar nas tomadas de decisões durante o ciclo de OKRs pode ampliar os benefícios da metodologia e, portanto, apoiar na consolidação de empresas ágeis. Por conseguinte, especula-se que as prioridades da empresa se tornem nítidas e sejam seguidas mais naturalmente de forma que aprimore o alinhamento estratégico dos colaboradores, convergindo o foco das ações da empresa para o aumento da geração de valor.

## 1.4 Organização do Texto

Esse trabalho está organizado em seis capítulos. No primeiro capítulo é apresentado uma breve contextualização ao tema de pesquisa e a motivação e objetivos do trabalho.

No segundo capítulo é apresentado o referencial teórico utilizado para fundamentação do trabalho, sendo abordado o ciclo de vida dos dados e a metodologia de OKRs.

No capítulo 3 é apresentada a metodologia utilizada para estruturar o *framework* teórico proposto neste estudo.

No capítulo 4 são apresentados os trabalhos correlatos, os quais foram identificados a partir de uma busca sistemática na literatura. Ademais, são apresentadas as contribuições de tais trabalhos que suportam o presente estudo.

No capítulo 5 é apresentada a proposta de *framework* teórico, identificando como pode ser combinado a metodologia de OKRs com a tecnologia de IA.

Por fim, no capítulo 6 o trabalho é sumarizado e as considerações finais e próximos passos dessa pesquisa são apresentados.

## 2 Referenciais Teóricos

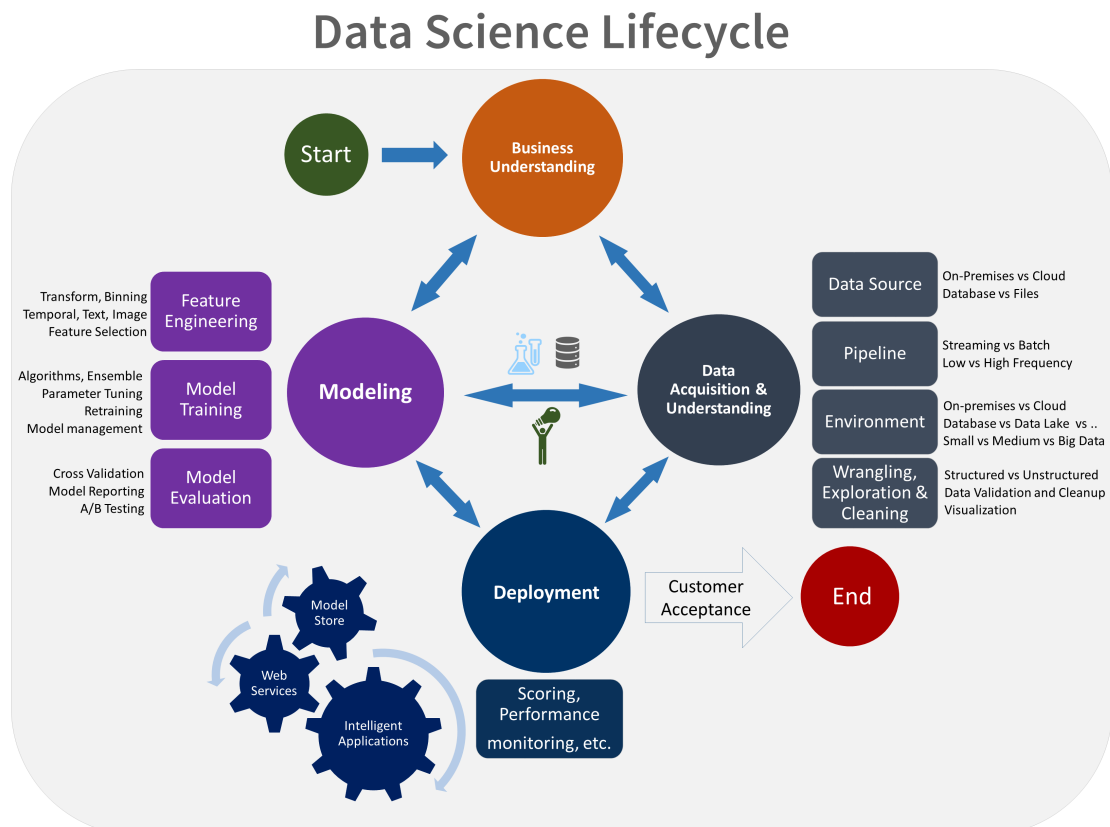
### 2.1 Ciclo de Vida dos Dados

A IA tem o potencial de se tornar cada vez mais importante para as organizações no auxílio das tomadas de decisões e na construção de valor. No entanto, ainda existem dúvidas em relação à implementação e a manutenção dessa tecnologia (MENZIES, 2020).

Há processos que recomendam um ciclo de vida para estruturar os projetos de ciência de dados, como o *Team Data Science Process* (TDSP) (MICROSOFT, 2020) — Processo de Ciência de Dados da Equipe, em português. Esses *frameworks* têm o objetivo de guiar a implantação da IA, mas cada projeto se beneficia desse processo de maneira adaptável, ou seja, algumas etapas no processo podem não ser necessárias.

De forma geral, conforme disposto na Figura 1, o ciclo de vida do TDSP é composto por cinco principais estágios executados de forma iterativa, quais sejam: “Entendimento do negócio”, “Aquisição de dados e entendimento”, “Modelagem”, “Implantação” e “Aceitação do cliente” (MICROSOFT, 2020).

Figura 1 – Representação do ciclo de vida do Processo de Ciência de Dados de Equipe.



Fonte: Microsoft (2020).

Já que a ciência de dados é um exercício de pesquisa e descoberta, a capacidade de comunicar tarefas para equipe e clientes, se padronizados, ajudam a evitar confusões. Dessa forma, a meta desse ciclo de vida é fornecer direcionamentos para um objetivo: concluir um projeto de ciência de dados com êxito.

### 2.1.1 Entendimento do Negócio

O passo inicial desse processo é o entendimento do negócio, que consiste na definição do problema e objetivos do projeto em conjunto com *stakeholders*. Além disso, é necessário verificar se o projeto tem os requerimentos necessários para possibilitar a aplicação de AM, por exemplo, dados rastreáveis, interpretáveis e explicáveis (ARPTEG et al., 2018; AHMED et al., 2019). Com isso, é possível identificar que modelos de IA precisam ser ajustados conforme cada caso.

### 2.1.2 Aquisição e Entendimento dos Dados

A segunda etapa consiste no processo de aquisição de dados e entendimento. Essa é considerada como a etapa que exige mais tempo do projeto de AM e a mais importante para o sucesso do projeto (DAMIANI; FRATI, 2018; AMERSHI et al., 2019).

Realizar a aquisição de dados é considerado na literatura uma atividade desafiadora (ARPTEG et al., 2018; HAAKMAN et al., 2021). Este impedimento é comum nos casos de uso porque os dados a serem trabalhados são sensíveis, o que demanda uma requisição formal de acesso. Após a captura dos dados, é necessário realizar uma limpeza; dados do mundo real apresentam ruído — valores ausentes ou com discrepância considerável.

É importante auditar a qualidade dos dados e verificar se eles estão prontos para modelagem. Esse processo costuma ser iterativo e pode envolver etapas como lidar com valores ausentes, normalizar os dados, diferenciar os dados e limpar os dados textuais (HAN; PEI; KAMBER, 2011). Após a limpeza de dados, é necessário configurar o *pipeline* de dados e atualizá-los regularmente como parte de um processo de aprendizado contínuo<sup>1</sup>.

### 2.1.3 Modelagem

O próximo estágio é o de modelagem, que consiste na criação de modelos de AM a partir de modelos informativos. Os modelos informativos servem de parâmetros para o AM, a fim de que seja possível a realização do seu treinamento.

Nesse sentido, ressalta-se a importância de dividir os parâmetros em dois grupos: um conjunto de dados para treinamento e, um outro, para testes do modelo. Dessa forma,

---

<sup>1</sup> Apesar de ser um tópico importante para o projeto, o presente trabalho não irá entrar nos detalhes do desenvolvimento desse tópico, haja vista a grande variação de sistemas e estruturação dos bancos de dados entre as empresas.



com um conjunto de dados para testes, é possível determinar se o modelo é adequado para a produção.

Quanto ao conjunto de dados, deve-se dividir os conjuntos aleatoriamente para que a amostragem selecionada no treinamento não seja tendenciosa e, assim, o modelo possa ser devidamente treinado e testado.

Existem três tipos distintos de AM: aprendizado supervisionado, aprendizado não supervisionado e aprendizado de reforço (CHINNAMGARI, 2019). No aprendizado supervisionado, os dados são rotulados ou associados a uma categoria de interesse. Dessa forma, é conhecido *a priori* em quais categorias os dados precisam ser classificados e busca-se identificar como o conjunto de dados tem relação com o resultado. Já no aprendizado não supervisionado, as categorias de dados são desconhecidas. Nesse tipo de AM, a meta é organizar os dados de alguma forma ou descrever a sua estrutura. Por fim, o aprendizado de reforço é uma abordagem híbrida entre o aprendizado supervisionado e não supervisionado.

É importante lembrar que o treinamento do modelo é um processo iterativo e, portanto, é possível criar um modelo base simplificado para avaliar o resultado de outros modelos mais complexos (CRUZ; ABREU, 2019) — sendo cabível a utilização de diversas ferramentas. No entanto, para lidar com dados sensíveis, os cientistas de dados são limitados a recursos e plataformas disponíveis na organização (HAAKMAN et al., 2021).

Cada um desses modelos criados precisam ser documentados (AKKIRAJU et al., 2020), uma vez que essa ação permite a criação de uma trilha auditável de versões e decisões; sendo possível, então, acessar o modelo através de uma perspectiva regulatória (CRUZ; ABREU, 2019). Além disso, a documentação auxilia na transferência de conhecimento, por exemplo, para novos membros do time e usuários finais, os quais muitas vezes não são especialistas em AM (FASICK, 1977).

#### 2.1.4 Implantação

Após a construção dos modelos, a próxima etapa é a de implantação, na qual, o principal objetivo é colocar o modelo construído e o *pipeline* de dados em um ambiente de produção. Destaca-se que existem diversas interfaces que permitem o consumo do modelo pelo usuário, tais como planilhas, painéis, aplicativos de linhas de negócios e aplicativos de *back-end*, devendo a empresa escolher a melhor opção disponível.

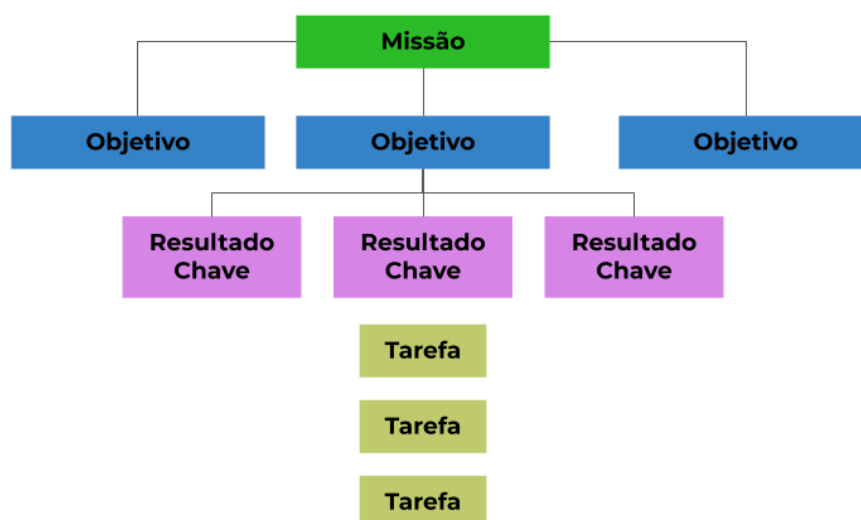
Como último passo, é necessária a aceitação do cliente, sendo importante verificar se o modelo e a implantação em um ambiente de produção atendem os seus objetivos. Dessarte, o cliente deve validar se o projeto atende às suas necessidades e se ele responde às perguntas com uma precisão aceitável para implantar o projeto. Importante salientar que toda documentação referente ao projeto deverá ser repassada nessa etapa para a finalização do ciclo de dados e aceite do projeto de AM.

## 2.2 Ciclo de OKRs

A metodologia de OKRs, que significa “Objetivos e Resultados Chave”, foi criada por Andy Grove e tem como objetivo criar alinhamento e foco em resultados nas empresas (DOERR, 2018).

Essa metodologia prevê a criação de resultados chaves mensuráveis para atingir cada objetivo proposto. Assim, as ações dos times de colaboradores das empresas são direcionadas e alinhadas para atingir uma missão ou um resultado ambicioso e desafiador a longo prazo. A Figura 2 mostra como é o desdobramento da estratégia para a criação dos OKRs.

Figura 2 – Desdobramento da estratégia em objetivos através da metodologia de OKRs.

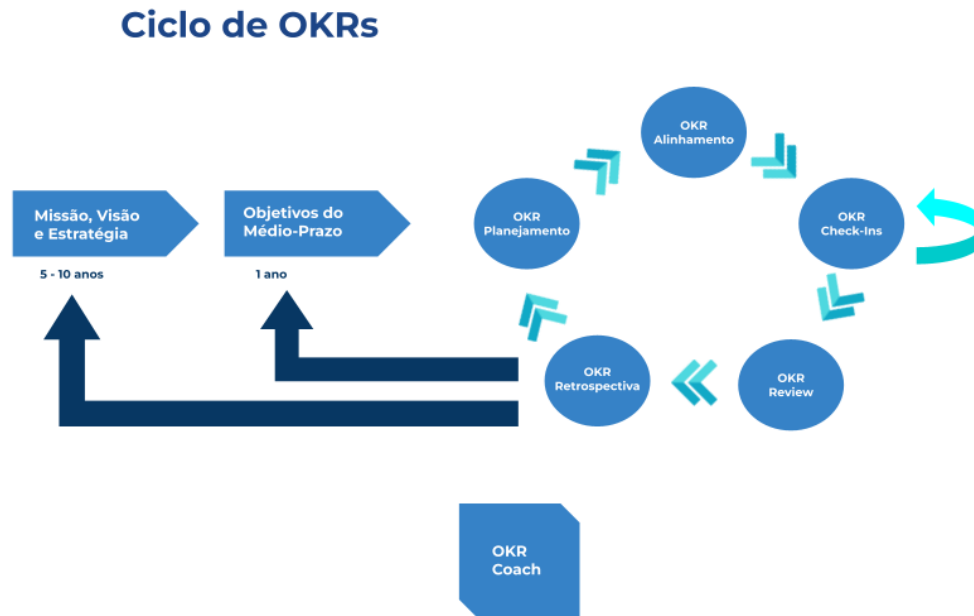


Fonte: Autoria própria (2022). Baseado em Doerr (2018).

Para o desenvolvimento desse subcapítulo, utilizou-se como referência o livro “*Measure What Matters*” (DOERR, 2018) e o site “*What Matters*” (DOERR; PANCHAD-SARAM; SHUFRO, 2020), os quais compilam a teoria da metodologia, seus benefícios e melhores práticas.

Prévia a etapa de construção dos OKRs, é necessário que a empresa defina sua missão, visão e estratégia. Após essas definições, é possível elaborar objetivos de longo prazo e estabelecer a periodicidade. Deste modo, as etapas subsequentes da metodologia de OKRs podem ser executadas e, assim, inicia-se o ciclo de OKRs, como é apresentado na Figura 3.

Figura 3 – Ciclo de OKRs.



Fonte: Autoria própria (2022). Baseado em [Doerr \(2018\)](#).

### 2.2.1 Estratégia e Periodicidade dos Objetivos

Inicialmente, antes de definir os objetivos, é importante que a empresa tenha, de forma clara, sua estratégia e missão definidas, a fim de que os objetivos sejam traçados de maneira coerente com estratégia para o longo prazo. Para tanto, são definidos objetivos alcançáveis em períodos menores, dando cadência nas entregas.

A partir disso, torna-se possível, então, definir objetivos a médio prazo, geralmente de periodicidade anual, que guiam o planejamento dos OKRs trimestrais. Importa ressaltar que a periodicidade pode variar de empresa para empresa, uma vez que a cadência e necessidade são parâmetros variáveis e individuais.

### 2.2.2 Construção e Planejamento

Para auxiliar na construção e padronização dos OKRs, além de treinar as lideranças e os times sobre a metodologia de OKR, existe a figura do *OKR Coach*. Esse indivíduo assegura o alinhamento com os times, pois os colaboradores devem saber como eles contribuem para os objetivos e, além disso, é importante para as lideranças terem a percepção se sua equipe acredita que os objetivos aspiracionais são de fato exequíveis.

Para realizar esse alinhamento, o *OKR Coach* e as lideranças são responsáveis por trazer as percepções dos times ainda na etapa de planejamento dos OKRs, na qual são definidos os objetivos que a empresa tem a pretensão de alcançar.

### 2.2.3 Alinhamento

Após a construção e planejamento dos OKRs, realiza-se a etapa de alinhamento, a qual consiste na orientação dos OKRs construídos com os times contribuintes de cada objetivo. Apesar da existência de participação dos times na construção dos OKRs, é necessário certificar que toda a empresa esteja consciente com os objetivos definidos anteriormente. Dessa forma, tanto a orientação sobre os OKRs quanto o direcionamento dos times e a certificação do entendimento são objetivos da etapa de alinhamento, para que, assim, haja adesão e engajamento da empresa com os OKRs construídos na etapa de planejamento.

### 2.2.4 Check-ins

Em sequência, ocorrem os *check-ins* dos objetivos, que consistem na atualização do andamento dos OKRs — construídos pelos próprios contribuintes dos objetivos; estes, devem ser realizados de forma frequente e contínua durante todo o ciclo de OKRs. Nessa etapa, requer-se transparência de toda a equipe, incluindo as lideranças e o OKR *Coach*, já que os objetivos correlacionados são dependentes. Por isso, é necessário que os times apontem, além do cumprimento dos objetivos, quaisquer impedimentos e adversidades que possam ocorrer.

Assim, tanto o OKR *Coach* pode analisar os resultados e identificar se a estratégia está sendo seguida, quanto os colaboradores podem informar qualquer percalço que possa ocorrer. Dessa forma, caso seja necessário, o OKR *Coach* pode conduzir o processo de mudança de prioridades, tendo em vista que a metodologia de OKRs prevê a possibilidade de mudanças dos objetivos para representar as atuais prioridades e necessidades da empresa (CASEY, 2020).

### 2.2.5 Reviews e Retrospectivas

Para verificar o cumprimento dos objetivos e os *check-ins* são realizados fóruns de acompanhamento. Em tais reuniões, ocorrem as revisões (*reviews*) e retrospectivas dos OKRs para, além de acompanhar os *check-ins*, discutir novas iniciativas e impedimentos. Esses acompanhamentos podem ser realizados por cada equipe, assim como, pela empresa em conjunto, para um acompanhamento geral dos OKRs da organização.

A periodicidade dessas reuniões varia com a necessidade de acompanhamento dos objetivos, mas, em regra, as *reviews* acontecem com uma periodicidade maior, sendo realizadas durante o ciclo de OKRs; enquanto isso, as retrospectivas ocorrem apenas ao fim de cada ciclo. Desse modo, é possível, por exemplo, realizar as *reviews* quinzenalmente e as retrospectivas a cada fim de ciclo trimestral.

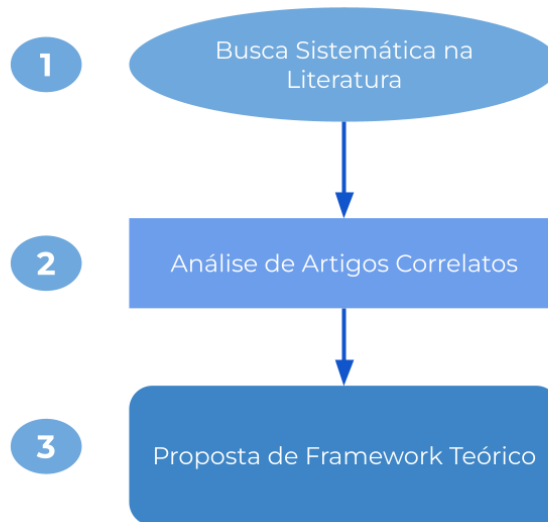
Necessário salientar que as *reviews*, por serem mais constantes, fazem parte da rotina das equipes e, portanto, possibilitam o entendimento de suas contribuições para o panorama geral da empresa, bem como o acompanhamento das atualizações de objetivos com co-dependência. Lado outro, as agendas de retrospectivas são destinadas para a análise do ciclo de OKRs que se encerrou e para o planejamento do próximo e, portanto, é primordial o compartilhamento das lições aprendidas e a celebração dos OKRs cumpridos para a motivação dos times.

É relevante mencionar, também, que para ambos os fóruns — *review* e retrospectiva —, a orientação à dados favorece a tomada de decisões. Dessa forma, é possível identificar fraquezas e pontos fortes e, assim, ter um início sólido do próximo ciclo. Assim, é reiniciado o ciclo.

## 3 Metodologia

O percurso metodológico utilizado neste trabalho consistiu em três etapas: (1) busca sistemática na literatura, para identificar estudos que correlacionam a tecnologia de IA com a metodologia de OKRs; (2) análise de artigos correlatos, para identificar possíveis oportunidades de aplicação de IA na metodologia de OKRs; e (3) construção de *framework* teórico, a partir de oportunidades de aplicação, identificadas na etapa anterior. A [Figura 4](#) apresenta as etapas realizadas no processo de construção do *framework* teórico.

Figura 4 – Etapas do processo de construção do *framework* teórico.



Fonte: Autoria própria (2022).

### 3.1 Busca Sistemática na Literatura

Identificar trabalhos correlatos é uma etapa essencial para contextualizar a proposta de uma pesquisa em relação ao estado da arte. Além disso, ideias fundamentadas em trabalhos relacionados podem sustentar decisões em uma pesquisa.

Neste sentido, esta etapa foi uma estratégia utilizada para encontrar trabalhos na literatura que correlacionassem direta ou indiretamente a metodologia de OKRs e a tecnologia de IA.

### 3.2 Análise de Artigos Correlatos

O próximo passo foi realizar a leitura dos textos identificados na busca sistemática para investigar possíveis benefícios da utilização da tecnologia de IA na metodologia de

OKRs. Assim, buscou-se identificar os benefícios que a metodologia de OKRs associada com a tecnologia de IA pode proporcionar para o alinhamento de estratégia das empresas.

Considerando a possibilidade de não serem encontrados artigos que apresentassem uma correlação direta, buscou-se, na análise dos trabalhos, indicações de lacunas ou oportunidades de melhorias para a metodologia de OKRs através do potencial de transformação da tecnologia de IA.

Dessa forma, investigou-se os benefícios que a metodologia de OKRs propicia para o alinhamento de estratégia e como a tecnologia de IA melhora as tomadas de decisão através da orientação a dados.

### 3.3 Construção do *Framework* Teórico

O *framework* teórico é uma estrutura que sumariza conceitos e teorias, sendo considerado um passo importante para identificar o propósito e significância de uma pesquisa (SWANSON; CHERMACK, 2013). A partir da explicação de teorias relevantes que suportam o trabalho, pode ser demonstrado que a pesquisa se fundamenta em ideias estabelecidas (KIVUNJA, 2018).

Como o presente estudo apresenta uma abstração acerca de um tema, o *framework* teórico pode estruturar a especulação proposta, fornecendo uma sustentação para o desenvolvimento de trabalhos que, futuramente, podem vir a se apoiar neste. Para o desenvolvimento do presente estudo, foi utilizado como base um modelo de *framework* teórico construído por Vinz (2015). Esse modelo foi escolhido porque aborda etapas importantes, como identificação de conceitos chave e explicação de teorias relevantes, para a estruturação da fundamentação do *framework*.

A fim de sistematizar a identificação de estudos na literatura, foi adicionada uma etapa de busca sistemática, o que resultou em um ajuste no modelo de *framework* teórico proposto por Vinz (2015).

## 4 Busca Sistemática na Literatura

A busca sistemática foi uma estratégia utilizada para encontrar trabalhos na literatura que correlacionassem direta ou indiretamente a metodologia de OKRs e a tecnologia de IA. As descrições da busca sistemática, apresentadas neste capítulo, permitem a replicação da etapa de identificação de artigos.

### 4.1 Identificação de Artigos

No dia 13 de Abril de 2022, utilizou-se termos de busca para realizar buscas avançadas nas bases de dados, conforme apresentado na [Tabela 1](#).

Tabela 1 – Termos utilizados na busca sistemática de acordo com as bases de dados.

Base de Dados	Termo de Busca	Observações
Scopus	ALL(“Artificial Intelligence” AND “Objectives and Key Results”) AND (LIMIT-TO (DOCTYPE,“ar”) OR LIMIT-TO (DOCTYPE,“cp”) OR LIMIT-TO (DOCTYPE,“ch”) OR LIMIT-TO (DOCTYPE,“cr”) OR LIMIT-TO (DOCTYPE,“re”)) AND (LIMIT-TO (LANGUAGE,“English”))	Busca aplicada no título, resumo e palavras-chave dos artigos; limitada a artigos de revista (“ar” e “re”) e de conferência (“cp” e “cr”), capítulos de livro (“ch”) e publicações em inglês
Web of Science	((((ALL=(“Artificial Intelligence”)) AND ALL=(“Objectives and Key Results”)) AND LA=(English)) AND DT=(Article OR Proceedings Paper OR Book Chapter OR Review))	Busca aplicada no título, resumo e palavras-chave de artigos da coleção principal da Web of Science ( <i>Web of Science Core Collection</i> ); limitada a artigos de revista e de conferência, capítulos de livro e publicações em inglês
IEEE Xplore	(“Full Text & Metadata”:“Artificial Intelligence”) AND (“Full Text & Metadata”:“Objectives and Key Results”)	Como a busca aplicada nos metadados (incluindo título, resumo e palavras-chave) não retornou resultados, buscou-se também no texto completo dos artigos; além disso, essa base não possui a opção de filtrar — por língua e tipo de documento, no entanto, essa última opção surge como filtro posteriormente a busca
ACM Digital Library	[All: “artificial intelligence”] AND [All: “objectives and key results”]	Busca aplicada no texto completo, título, resumo e palavras-chave de artigos da coleção de textos completos da ACM ( <i>The ACM Full-text collection</i> ); além disso, essa base não possui a opção de filtrar — por meio do termo de busca — por língua e tipo de documento, no entanto, essa última opção surge como filtro posteriormente a busca
Science Direct	Find articles with these terms: “Artificial Intelligence” AND “Objectives and Key Results”	Busca aplicada no texto completo dos artigos (excluindo as referências); além disso, essa base não possui a opção de filtrar — por meio do termo de busca — por língua e tipo de documento, no entanto, essa última opção surge como filtro posteriormente a busca

Fonte: Autoria própria (2022).

Como pode ser observado na [Tabela 1](#), apesar de terem sido utilizadas as mesmas palavras-chave — “*Artificial Intelligence*” e “*Objectives and Key Results*” —, fez-se



necessário adaptar o termo de busca final em cada base de dados de acordo com suas particularidades. Apenas na Scopus e Web of Science foi possível filtrar por língua e tipo de documento por meio do termo de busca; as demais bases de dados possibilitaram refinar a busca filtrando o tipo de documento somente após a efetivação da busca avançada, mas não possibilitaram filtrar por língua em momento algum. Apesar disso, tal fato não afetou a identificação final de artigos, já que todos os identificados por essas bases de dados estavam escritos na língua inglesa.

Inicialmente, foram identificados 14 trabalhos. Como etapa de exclusão, foi realizada uma remoção de artigos duplicados; removeu-se apenas um trabalho. Os artigos mantidos para análise ( $n = 13$ ) podem ser consultados na [Tabela 2](#).

Tabela 2 – Artigos identificados na busca sistemática da literatura.

Base de Dados	Referência	Título	Tipo de Documento
ACM	<a href="#">Wong (2021)</a>	Tactics of Soft Resistance in User Experience Professionals' Values Work	Artigo de Revista
IEEE/Scopus	<a href="#">Erp et al. (2021)</a>	Management, Design, and Implementation of Innovation Projects: Towards a Framework for Improving the Level of Automation and Digitalization in Manufacturing Systems	Artigo de Conferência
IEEE	<a href="#">Birunda e Devi (2021)</a>	A Novel Score-Based Multi-Source Fake News Detection using Gradient Boosting Algorithm	Artigo de Conferência
Scopus	<a href="#">Scott et al. (2021)</a>	Enhancing agile software development in the banking sector—A comprehensive case study at LHV	Artigo de Revista
Scopus	<a href="#">Scott et al. (2021)</a>	Management, Design, and Implementation of Innovation Projects: Towards a Framework for Improving the Level of Automation and Digitalization in Manufacturing Systems	Artigo de Conferência
Scopus	<a href="#">Vedal et al. (2021)</a>	Managing Dependencies in Large-Scale Agile	Artigo de Conferência/ Capítulo de Livro
Science Direct	<a href="#">Merabet et al. (2021)</a>	Intelligent building control systems for thermal comfort and energy-efficiency: A systematic review of artificial intelligence-assisted techniques	Artigo de Revista/ Artigo de Revisão
Science Direct	<a href="#">Wilson Jahankhani (2021)</a>	A proposed OKR-based framework for cyber effective services in the GDPR era	Capítulo de Livro
IEEE	<a href="#">Cwik et al. (2020)</a>	Space Startup Accelerator Pilot	Artigo de Conferência
Science Direct	<a href="#">Camaréna (2020)</a>	Artificial intelligence in the design of the transitions to sustainable food systems	Artigo de Revista/ Artigo de Revisão
Scopus	<a href="#">Eißler, Schneider e Roling (2020)</a>	Product roadmap alignment – achieving the vision together: A grey literature review	Artigo de Conferência/ Capítulo de Livro/ Artigo de Revisão
Web of Science	<a href="#">Higgins e Madai (2020)</a>	From Bit to Bedside: A Practical Framework for Artificial Intelligence Product Development in Healthcare	Artigo de Revista
Scopus	<a href="#">Trinkenreich et al. (2019)</a>	Combining GQM+Strategies and OKR - Preliminary Results from a Participative Case Study in Industry	Artigo de Conferência/ Capítulo de Livro
Scopus	<a href="#">Kilu et al. (2019)</a>	Agile Software Process Improvement by Learning from Financial and Fintech Companies: LHV Bank Case Study	Artigo de Conferência/ Capítulo de Livro

Fonte: Aatoria própria (2022).

## 4.2 Análise dos Artigos Identificados

Após a leitura completa dos textos, constatou-se que nenhum dos artigos identificados abordou diretamente a utilização da tecnologia de IA na metodologia de OKRs. Apesar disso, discute-se, a seguir, contribuições dos trabalhos selecionados que suportam indiretamente o presente estudo; ou seja, indicações de lacunas e oportunidades para a metodologia de OKRs através do potencial de transformação da tecnologia de IA.

### 4.2.1 Motivação dos Times

O estudo de [Erp et al. \(2021\)](#) aborda a metodologia de OKRs para gerenciamento de processos de inovação da indústria 4.0 e 5.0, com o objetivo de alcançar o patamar de manufatura assistida por IA. No entanto, o artigo não aborda diretamente o uso da tecnologia de IA na metodologia de OKRs; entretanto, o trabalho aponta um obstáculo: a dificuldade de motivar os times.

A metodologia de OKRs por si, já prevê objetivos aspiracionais e a celebração de objetivos cumpridos, para motivação dos times. No entanto, no caso descrito no estudo, o uso exclusivo da metodologia não foi suficiente para resolver essa dor; portanto, supõe-se que a IA aplicada na metodologia de OKRs possa gerar percepções para a identificação dos problemas motivacionais dos times, através de dados.

### 4.2.2 Alinhamento de Estratégia e Orientação a Dados

Os autores [Kilu et al. \(2019\)](#) realizaram entrevistas para analisar percepções de bancos e *fintechs*, sobre como melhorar os processos ágeis. Através de uma das entrevistas realizadas, o artigo pontuou como a metodologia de OKRs aumenta a visibilidade dos objetivos da empresa, gerando alinhamento. O trabalho realizado por [Scott et al. \(2021\)](#) é uma continuação desse artigo. Nesse trabalho, foi realizado um estudo compreensivo de um caso de estudo dos métodos mencionados no trabalho de [Kilu et al. \(2019\)](#) em um banco de médio porte. Nessa nova análise, o estudo reafirma que a metodologia de OKRs prevê ganhos de alinhamento de estratégia. No entanto, o autor cita que, para o próximo nível de melhoria dos processos, é necessário abordagens orientadas a dados. Dessa forma, considera-se tal fato como outra relevante oportunidade de combinar a IA com a metodologia de OKRs.

### 4.2.3 IA e seu Potencial para Análise de Dados

Apesar de não mencionar o uso de OKRs, o estudo de [Birunda e Devi \(2021\)](#) mostra o potencial da IA para análise de dados textuais. Além disso, outros estudos mencionaram o potencial da IA para gerar orientação através de dados; no entanto, também não mencionaram o uso da metodologia de OKRs ([CAMARÉNA, 2020](#); [MERABET et al.](#),

2021; HIGGINS; MADAI, 2020). Apesar dos estudos mencionados não abordarem a associação investigada, é fundamental para a metodologia de OKRs tomadas de decisão conscientes e fundamentadas. Dessa forma, entende-se que, para atingir melhores resultados, a IA tem a capacidade de estruturar dados para fundamentar e aperfeiçoar as deliberações.

#### 4.2.4 Demais Artigos

Outros estudos apontaram o potencial da metodologia de OKRs para alinhamento dos times com a estratégia, mas não mencionaram lacunas da metodologia de OKRs que pudessem ser supridas pela tecnologia de IA (TRINKENREICH et al., 2019; EISSLER; SCHNEIDER; ROLING, 2020; VEDAL et al., 2021; WONG, 2021). Já o estudo de Cwik et al. (2020) não apresentou informações que pudessem ser consideradas relevantes para o escopo do presente trabalho.

## 5 Proposta de Framework Teórico

Dispostas as teorias relevantes, nesse capítulo é apresentado a proposta de *framework* teórico da utilização da tecnologia de IA com a metodologia de OKRs.

Como identificado no [Capítulo 2](#), há processos que recomendam um ciclo de vida para estruturar os projetos de ciência de dados, como o TDSP. Através da utilização deste processo para a implementação da IA, pode-se apontar sugestões de aplicação dos estágios do TDSP no contexto geral de estruturação dessa tecnologia dentro da metodologia de OKRs, sendo eles: “Entendimento do negócio”, “Aquisição de dados e entendimento”, “Modelagem”, “Implantação” e “Aceitação do cliente”.

A seguir é apresentada a contextualização da metodologia de OKRs aplicada à tecnologia de IA através do ciclo de vida do TDSP (ver [Figura 1](#)), a partir de especulações geradas por intermédio da fundamentação teórica disposta no [Capítulo 2](#) e no [Capítulo 4](#).

### 5.1 Entendimento do Negócio

O entendimento do negócio seria o primeiro passo do ciclo de vida de dados, que consiste na definição do problema e dos objetivos do projeto. É possível acreditar que esse passo já esteja resolvido, uma vez que o objetivo do projeto é implementar a ciência de dados na metodologia de OKRs. No entanto, seria necessária uma análise e ajustes de acordo com a realidade particular de cada empresa. Por exemplo, uma empresa poderia ter a metodologia de OKRs já implementada e seu objetivo seria apenas a implementação da tecnologia de IA. Por isso, o alinhamento com *stakeholders* da empresa seria necessário para possibilitar a identificação dos requerimentos necessários para implementar o *framework* e alinhar expectativas.

Ainda parte do entendimento do negócio, é importante expor como a IA poderia contribuir para a metodologia de OKRs e como ela seria aplicada. A etapa dos *check-ins* dos objetivos gera o alto volume de dados textuais que busca-se tratar com a tecnologia de IA. Considerando as demais etapas do ciclo de OKRs, a orientação a dados auxilia na tomada de decisões ([DOERR; PANCHADSARAM; SHUFRO, 2020](#)). Os dados tratados poderiam ser utilizados como insumo para apoiar e justificar as deliberações, como é esquematizado na figura [Figura 5](#).

Figura 5 – Proposta de *Framework* do Ciclo de OKRs com a utilização de IA

Fonte: Autoria própria (2022).

## 5.2 Aquisição e Entendimento de Dados

Para identificar se a empresa tem os requerimentos necessários para implementar o *framework*, divide-se o processo em duas categorias: (1) empresas que já possuem a metodologia de OKRs implementada e (2) empresas que não possuem. Essa divisão é feita, pois para implementar a metodologia de OKRs não há restrições; no entanto, para implementar a tecnologia de IA, a estrutura de dados pode limitar a aplicabilidade.

Para empresas que possuem a metodologia de OKRs implementada, seria necessário avaliar se a plataforma que faz a gestão da metodologia tem a possibilidade de rastrear os dados. Se possível realizar o rastreamento, seria indicado manter a plataforma atual; uma vez que, para alteração de plataforma, exigir-se-ia um trabalho extra de migração e sensibilização de uso da nova plataforma. Caso contrário, seria necessário realizar uma migração para uma nova plataforma que possibilitasse o rastreamento dos dados.

Ademais, existem dois requerimentos necessários, dados interpretáveis e dados explicáveis. Ambas as etapas seriam necessárias para as duas categorias de empresas, haja vista que os dados desse processo seriam textos extraídos de uma plataforma adequada. Para interpretar tais dados seria utilizado o processamento de linguagem natural, um campo da IA — este tópico será aprofundado na seção de modelagem.

É importante salientar que seria possível que empresas implementassem a metodologia de OKRs concomitantemente com tecnologia de IA. No entanto, sugere-se primeiramente a aplicação da metodologia; uma vez que, durante sua implementação, seria

necessário um trabalho de engajamento dos times. Além disso, a implementação posterior da IA aumentaria a base de dados para o desenvolvimento do algoritmo na etapa de modelagem de dados, o que poderia beneficiar a etapa de testes e possibilitar um algoritmo mais assertivo.

A figura do OKR *coach* seria importante para o último requisito: explicar os dados. Em posse dos dados obtidos e da estratégia dos OKRs, o OKR *coach* tem plenas condições de explicar a origem e raciocínio dos dados.

### 5.3 Modelagem

Na etapa de modelagem dos dados, seria importante pontuar que os dados analisados são os *check-ins* e os *reports* de entregas realizadas. Essa escolha é realizada, pois os dados de texto exigem um maior esforço humano para ser analisado, visto que estes dados nos OKRs são mais volumosos. Para efetuar o aprendizado supervisionado do modelo, seria utilizada a técnica de processamento de linguagem natural, a fim de que se realizasse a classificação dos textos extraídos utilizando etiquetas pré-definidas. Essas etiquetas poderiam sintetizar os textos dos *check-ins* e *reports* de entregas. Assim, com dados mais objetivos, o OKR *coach* poderia identificar se o objetivo estaria sendo seguido, se as atividades executadas estariam relacionadas com a estratégia proposta e quais colaboradores seriam contribuintes de cada objetivo, com mais facilidade.

Para a definição das etiquetas, seria importante o auxílio do OKR *coach*, para que ele pontuasse quais palavras chaves ou termos seriam referentes a quais objetivos e/ou estratégia; pois o OKR *coach* tem em posse a estratégia, e tem conhecimento sobre a metodologia. Além disso, é importante mencionar que o OKR *coach*, lideranças e tecnologia de IA seriam complementares, visto que dados sozinhos não realizam deliberações. Também, importa salientar que os dados atuariam como um apoio para as tomadas de decisões, sintetizando dados brutos, o que possibilitaria seu uso como embasamento para direcionamentos.

### 5.4 Implantação e Aceitação do Cliente

Como últimos passos da implantação de um projeto de ciência de dados, seria necessária, além da implantação do modelo, a aceitação do cliente. Portanto, seria necessário aplicar o modelo construído e o *pipeline* de dados em um ambiente de produção e, após isso, verificar se o projeto atenderia as necessidades do cliente. Nesses passos, seria importante reunir as documentações da etapa de modelagem e da arquitetura da solução final. Essas documentações seriam necessárias tanto para gestão do conhecimento quanto para transparência do modelo de dados.

Após a validação e aceite pelo cliente, ter-se-ia um *framework* de atuação da IA na metodologia de OKRs. Os *check-ins* realizados durante o ciclo de OKRs serviriam para fornecer os dados brutos para o modelo de IA. Após isso, a IA iria sintetizar os dados textuais, deixando-os mais claros e consumíveis. Os dados tratados pela IA, poderiam ser utilizados como *feedbacks* para as outras etapas do ciclo de OKRs. Dessa forma, as tomadas de decisões seriam, cada vez mais, apoiadas por dados. Assim, seria esperado que a metodologia de OKRs entregasse cada vez mais, para os colaboradores, foco e alinhamento com a estratégia da empresa.

Ressalta-se que tanto a tecnologia de IA quanto a metodologia de OKRs preveem evolução contínua, sendo possível evoluções concomitantes do modelo de dados e da aplicação dos OKRs.

## 6 Conclusão

A transformação ágil das empresas requer alinhamento dos times com a estratégia para ser bem sucedida. Para gerar esse alinhamento, metodologias são utilizadas e, assim, pode-se aumentar as chances de sucesso. Além disso, existem tecnologias emergentes que criam melhorias nos processos atuais.

Nesse contexto, este trabalho teve como objetivo propor um *framework* teórico de utilização da tecnologia de IA na metodologia de OKRs. O *framework* foi proposto considerando, principalmente, o alinhamento de estratégia que pode ser proporcionado pela metodologia de OKRs e o poder de sintetização de dados proporcionado pela tecnologia de IA, gerando orientação e embasamento nas tomadas de decisões.

Como apontado no referencial teórico ([Capítulo 2](#)), a tecnologia de IA é capaz de apoiar tomadas de decisões através do tratamento de dados; enquanto que, a metodologia de OKRs tem o potencial de alinhar os times com foco na estratégia.

Por meio da análise dos artigos identificados pela busca sistemática ([Capítulo 4](#)), observou-se oportunidades de aplicação da tecnologia de IA na metodologia de OKRs, quais sejam, gerar alinhamento estratégico nas empresas, identificar causas de problemas de motivação nos times e realizar melhorias nos resultados e escalabilidade da metodologia de OKRs. Dessa forma, potencializando os benefícios da metodologia de OKRs.

Em trabalhos futuros, para determinar com mais propriedade os ganhos que a combinação pode trazer para as organizações, pretende-se construir um algoritmo de IA apoiado na fundamentação do *framework* teórico proposto neste trabalho. Posteriormente, através de métricas pré-estabelecidas, será realizada uma prova de conceito com o *framework* teórico em conjunto com o modelo construído, para ser possível afirmar os benefícios e limitações da associação da metodologia de OKRs com a tecnologia de IA.



# Referências Bibliográficas

- AGHINA, W. et al. O impacto da agilidade: Como moldar sua organização para competir. 2021. Disponível em: <<https://www.mckinsey.com/business-functions/people-and-organizational-performance/our-insights/the-impact-of-agility-how-to-shape-your-organization-to-compete/pt-BR/>>. Acesso em: 26 de maio de 2022. Citado 2 vezes nas páginas 11 e 12.
- AHMED, Z. et al. Machine learning at microsoft with ml.net. In: *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York, NY, USA: Association for Computing Machinery, 2019. (KDD '19), p. 2448–2458. ISBN 9781450362016. Disponível em: <<https://doi.org/10.1145/3292500.3330667>>. Citado na página 15.
- AKKIRAJU, R. et al. Characterizing machine learning processes: A maturity framework. In: SPRINGER. *International Conference on Business Process Management*. [S.l.], 2020. p. 17–31. Citado na página 16.
- AMERSHI, S. et al. Software engineering for machine learning: A case study. In: IEEE. *2019 IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice (ICSE-SEIP)*. [S.l.], 2019. p. 291–300. Citado na página 15.
- ARPTEG, A. et al. Software engineering challenges of deep learning. In: *2018 44th Euromicro Conference on Software Engineering and Advanced Applications (SEAA)*. [S.l.: s.n.], 2018. p. 50–59. Citado na página 15.
- AZIZ, S.; DOWLING, M. Machine learning and ai for risk management. In: *Disrupting finance*. [S.l.]: Palgrave Pivot, Cham, 2019. p. 33–50. Citado na página 12.
- BIRUNDA, S. S.; DEVI, R. K. A novel score-based multi-source fake news detection using gradient boosting algorithm. In: IEEE. *2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS)*. [S.l.], 2021. p. 406–414. Citado 2 vezes nas páginas 24 e 25.
- CAMARÉNA, S. Artificial intelligence in the design of the transitions to sustainable food systems. *Journal of Cleaner Production*, Elsevier, v. 271, p. 122574, 2020. Citado 3 vezes nas páginas 24, 25 e 26.
- CASEY, B. Dear andy: Changing priorities with okrs. 2020. Disponível em: <<https://www.whatmatters.com/faqs/changing-okrs>>. Acesso em: 30 de maio de 2022. Citado na página 19.
- CHINNAMGARI, S. K. *R Machine Learning Projects: Implement supervised, unsupervised, and reinforcement learning techniques using R 3.5*. [S.l.]: Packt Publishing Ltd, 2019. Citado na página 16.
- CHUI, M.; KAMALNATH, V.; MCCARTHY, B. An executive's guide to ai. 2020. Disponível em: <<https://www.mckinsey.com/business-functions/quantumblack/our-insights/an-executives-guide-to-ai/>>. Acesso em: 28 de maio de 2022. Citado na página 11.

- COSTA, R. G. M. da. *Driven by Value: Estudo de caso: iniciando e finalizando um Value Management Office*. 1. ed. São Paulo: Ed. do Autor, 2022. ISBN 978-65-00-42794-3. Citado na página 11.
- CRUZ, L.; ABREU, R. Catalog of energy patterns for mobile applications. *Empirical Software Engineering*, Springer, v. 24, n. 4, p. 2209–2235, 2019. Citado na página 16.
- CWIK, T. et al. Space startup accelerator pilot. In: IEEE. *2020 IEEE Aerospace Conference*. [S.l.], 2020. p. 1–10. Citado 2 vezes nas páginas 24 e 26.
- DAMIANI, E.; FRATI, F. Towards conceptual models for machine learning computations. In: SPRINGER. *International Conference on Conceptual Modeling*. [S.l.], 2018. p. 3–9. Citado na página 15.
- DOERR, J. *Measure What Matters*. 1. ed. New York: Portfolio/Penguin, 2018. ISBN 9780525538349. Citado 3 vezes nas páginas 11, 17 e 18.
- DOERR, J.; PANCHADSARAM, R.; SHUFRO, L. What matters. 2020. Disponível em: <<https://www.whatmatters.com/>>. Acesso em: 26 de maio de 2022. Citado 3 vezes nas páginas 11, 17 e 27.
- EISSLER, P.; SCHNEIDER, J.; ROLING, B. Product roadmap alignment—achieving the vision together: a grey literature review. In: *Agile Processes in Software Engineering and Extreme Programming—Workshops*. [S.l.: s.n.], 2020. p. 50. Citado 2 vezes nas páginas 24 e 26.
- ERP, T. van et al. Management, design, and implementation of innovation projects: Towards a framework for improving the level of automation and digitalization in manufacturing systems. In: IEEE. *2021 9th International Conference on Control, Mechatronics and Automation (ICCMA)*. [S.l.], 2021. p. 211–217. Citado 2 vezes nas páginas 24 e 25.
- ESULI, A.; SEBASTIANI, F. Training data cleaning for text classification. In: AZZOPARDI, L. et al. (Ed.). *Advances in Information Retrieval Theory*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009. p. 29–41. ISBN 978-3-642-04417-5. Citado na página 11.
- FASICK, F. A. Some uses of untranscribed tape recordings in survey research. *The Public Opinion Quarterly*, JSTOR, v. 41, n. 4, p. 549–552, 1977. Citado na página 16.
- HAAKMAN, M. et al. Ai lifecycle models need to be revised. *Empirical Software Engineering*, Springer, v. 26, n. 5, p. 1–29, 2021. Citado 2 vezes nas páginas 15 e 16.
- HAN, J.; PEI, J.; KAMBER, M. *Data mining: concepts and techniques*. [S.l.]: Elsevier, 2011. Citado na página 15.
- HIGGINS, D.; MADAI, V. I. From bit to bedside: a practical framework for artificial intelligence product development in healthcare. *Advanced intelligent systems*, Wiley Online Library, v. 2, n. 10, p. 2000052, 2020. Citado 3 vezes nas páginas 24, 25 e 26.
- KAR, A. K.; KUSHWAHA, A. K. Facilitators and barriers of artificial intelligence adoption in business – insights from opinions using big data analytics. *Information Systems Frontiers*, Springer Nature, 2021. Disponível em: <<https://doi.org/10.1007/s10796-021-10219-4>>. Citado na página 12.

KHAN, N.; MILLNER, D. *Introduction to people analytics: A practical guide to data-driven HR*. [S.l.]: Kogan Page Publishers, 2020. Citado na página 12.

KILU, E. et al. Agile software process improvement by learning from financial and fintech companies: Lhv bank case study. In: SPRINGER. *International Conference on Software Quality*. [S.l.], 2019. p. 57–69. Citado 2 vezes nas páginas 24 e 25.

KIVUNJA, C. Distinguishing between theory, theoretical framework, and conceptual framework: A systematic review of lessons from the field. *International Journal of Higher Education*, ERIC, v. 7, n. 6, p. 44–53, 2018. Disponível em: <<https://doi.org/10.5430/ijhe.v7n6p44>>. Citado na página 22.

MENZIES, T. The five laws of se for ai. *IEEE Software*, v. 37, n. 1, p. 81–85, 2020. Citado na página 14.

MERABET, G. H. et al. Intelligent building control systems for thermal comfort and energy-efficiency: A systematic review of artificial intelligence-assisted techniques. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 144, p. 110969, 2021. Citado 3 vezes nas páginas 24, 25 e 26.

MICROSOFT. What is the team data science process? 2020. Disponível em: <<https://docs.microsoft.com/en-us/azure/architecture/data-science-process/overview>>. Acesso em: 30 de maio de 2022. Citado na página 14.

SCHNEIDER, J. et al. Artificial intelligence governance for businesses. *Information Systems Management*, Taylor & Francis, v. 0, n. 0, p. 1–21, 2022. Disponível em: <<https://doi.org/10.1080/10580530.2022.2085825>>. Citado na página 12.

SCOTT, E. et al. Enhancing agile software development in the banking sector—a comprehensive case study at lhv. *Journal of software: evolution and process*, Wiley Online Library, v. 33, n. 7, p. e2363, 2021. Citado 2 vezes nas páginas 24 e 25.

SHRIVASTAVA, S.; NAGDEV, K.; RAJESH, A. Redefining hr using people analytics: the case of google. *Human Resource Management International Digest*, Emerald Publishing Limited, 2018. Disponível em: <<https://doi.org/10.1108/HRMID-06-2017-0112>>. Citado na página 12.

SWANSON, R. A.; CHERMACK, T. J. *Theory building in applied disciplines*. 235 Montgomery Street, Suite 650: Berrett-Koehler Publishers, 2013. Citado na página 22.

TRINKENREICH, B. et al. Combining gqm+ strategies and okr-preliminary results from a participative case study in industry. In: SPRINGER. *International Conference on Product-Focused Software Process Improvement*. [S.l.], 2019. p. 103–111. Citado 2 vezes nas páginas 24 e 26.

VEDAL, H. et al. Managing dependencies in large-scale agile. In: SPRINGER, CHAM. *International Conference on Agile Software Development*. [S.l.], 2021. p. 52–61. Citado 2 vezes nas páginas 24 e 26.

VINZ, S. The theoretical framework of a thesis: what and how. *Retrieved February*, v. 11, p. 2017, 2015. Citado na página 22.

WILSON, D.; JAHANKHANI, H. A proposed okr-based framework for cyber effective services in the gdpr era. In: *Strategy, Leadership, and AI in the Cyber Ecosystem*. [S.l.]: Elsevier, 2021. p. 113–135. Citado na página 24.

WONG, R. Y. Tactics of soft resistance in user experience professionals' values work. *Proceedings of the ACM on Human-Computer Interaction*, ACM New York, NY, USA, v. 5, n. CSCW2, p. 1–28, 2021. Citado 2 vezes nas páginas 24 e 26.