

**ESTUDOS SOBRE *DATA SCIENCE*: UM ENFOQUE EM
STORYTELLING*****DATA SCIENCE STUDIES: A FOCUS ON STORYTELLING***

Liriane Soares de Araújo– lirianearaujo@hotmail.com

Faculdade de Tecnologia de Catanduva – Catanduva – São Paulo - Brasil

Lucas Da Cunha Ramos – lucas.ramos@fatec.sp.gov.br

Faculdade de Tecnologia de Catanduva – Catanduva – São Paulo - Brasil

Rita de Cassia Chimello Marino – rita.marino@fatec.sp.gov.br

Faculdade de Tecnologia de Catanduva – Catanduva – São Paulo - Brasil

RESUMO

Este trabalho aborda a área de Ciência de Dados, utilizando a análise descritiva, exploratória e de levantamento por meio de entrevistas a um especialista da área com o objetivo de apresentar casos de sucesso e de insucesso para auxiliar empresas na compreensão e utilização de princípios da Ciência de Dados. Os relatos desses casos são conhecidos como Storytelling, que segundo a literatura envolve experiências contadas a fim de serem analisadas, revelando padrões, tendências e desafios, bem como envolve uma prática que possibilita insights e conhecimento para tomada de decisão. Espera-se mostrar benefícios, desafios e impactos que a Ciência de Dados pode causar nas empresas por meio de relatos de casos a fim de melhor compreender e escolher a implantação de tal conceito.

Palavras-chave: Ciência de Dados. Storytelling. Tratamento de Dados. Descrição de experiências.

ABSTRACT

This work addresses the area of Data Science through descriptive and exploratory analysis, and through interviews with a specialist in the area with the objective of presenting successful and unsuccessful cases to help companies understand and use the principles of Data Science of Data. The reporting of these cases is known as Storytelling, which according to the literature involves experiences told in order to be analyzed, revealing patterns, trends and

challenges, as well as involving a practice that enables insights and knowledge for decision making. It is expected to show benefits, challenges and impacts that Data Science can cause in companies through case reports in order to better understand and choose the implementation of such a concept.

Keywords: *Data Science. Storytelling. Data Processing. Description of Experiences.*

1 INTRODUÇÃO

Atualmente, as empresas estão enfrentando um aumento constante na quantidade de informações vindas de diversas origens. Possuir uma base de dados robusta não é suficiente para garantir a sobrevivência do negócio, é crucial reunir, agrupar e organizar esses dados de maneira lógica, além de analisá-los para embasar as decisões. Ignorar esses dados não é uma opção viável, uma vez que eles podem trazer muitos benefícios ao aprimorar a qualidade da produção, serviços, reduzir o consumo energético e aprimorar a eficiência de todo o processo, até mesmo ampliar as vendas. Sendo assim, as empresas têm buscado cada vez mais ferramentas que auxiliem a competitividade como consequência da pressão competitiva, além da necessidade de decisões mais assertivas.

Na busca de melhorias, a empresa precisa conhecer cada um de seus processos, para reconhecer as necessidades de melhorias, conseguindo decidir iniciativas para desenvolver as implantações tecnológicas.

Considerando esse contexto, destaca-se a importância da área de Ciência de Dados, também conhecida em inglês como *Data Science* (DS), que se utiliza de processos científicos e computacionais para extrair conhecimento, padrões, tendências e percepções a partir de conjuntos de dados em vários formatos, estruturados ou não-estruturados (BELL, 2009). Uma organização pode implantar as mais modernas tecnologias para obter, armazenar e analisar dados, mas quem efetivamente tomará as decisões reais que impactarão no negócio são as pessoas que compõem a organização. Para analisar essas grandes quantidades de dados, novas ferramentas técnicas e novas habilidades são necessárias. Um novo perfil profissional é necessário (cientistas de dados) que deve ser treinado para dominar as habilidades fundamentais para fazer descobertas a partir de grandes conjuntos de dados (DAVENPORT e PATIL, 2012).

Sendo assim, este trabalho possui como objetivo apresentar desafios, benefícios,

funcionamento, princípios de *Data Science*, enfocando a prática de *Storytellings*, abrangendo experiências de empresas de diferentes portes, em que visa identificar casos de sucesso e de insucesso a fim de contribuir com outras empresas no processo de análise de dados.

Contar histórias vai além de apoiar a marca, também fortalecendo a cultura empresarial. Em períodos de mudança, cria um terreno comum, promove confiança interna e quebra barreiras de isolamento mental (FOG *et al.*, 2001).

A metodologia de pesquisa consiste em análise bibliográfica descritiva e na realização de entrevistas com um especialista da área a fim de coletar e relatar as histórias (*Storytelling*) com o intuito de aumentar a compreensão sobre os resultados, desafios e funcionamento do DS nas empresas.

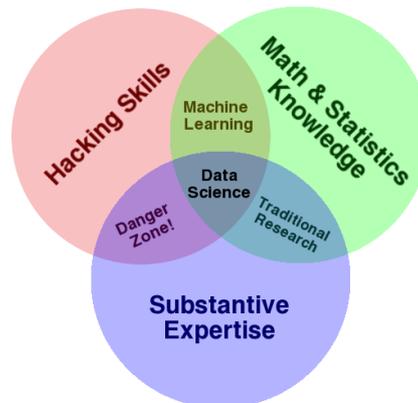
1 DATA SCIENCE

Esta seção apresenta conceitos e características de *Data Science*, e princípios importantes para embasar esta pesquisa.

1.1 Conceitos e Características do *Data Science*

Data Science é uma área relativamente nova, que surgiu devido a convergência de diversos campos, como a estatística, a ciência da computação e a análise de dados. De acordo com Amaral (2016), o termo “*Data Science*”, teve origem nos anos 1960, porém a Ciência de Dados é considerada uma ciência nova. Esse mesmo autor (2016) afirma que a Ciência de dados é um campo interdisciplinar de investigação da origem das informações utilizadas para resolver problemas reais de negócios, com o uso de métodos científicos e técnicas avançadas de análise de dados. A Figura 1 demonstra a união de três competências básicas, nas quais são responsáveis por gerir muitas informações da indústria, essas informações, quando aplicadas, proporcionam um resultado positivo da utilização do Data Science (VANDERPLAS, 2016).

Figura 1 – O Diagrama de Venn de Data Science



Fonte: Conway, 2010 apud Vanderplas, 2016.

Para obter um resultado satisfatório com o *Data Science* é fundamental a união de três competências básicas: conhecimento computacional (*Computer Science* ou *Hacking Skills*), conhecimento exato (*Math Statistics and Knowledge*) e conhecimento de especialista (*Subject Matter Expertise*). De acordo com Vanderplas (2016), *Data Science* é “o conjunto de habilidade interdisciplinares que se tornam cada vez mais importantes em diversas aplicações em toda indústria e academia”. *Data Science* é um campo multidisciplinar que envolve a extração de conhecimento e insights de grandes volumes de dados estruturados e não estruturados. Ele combina técnicas de estatística, matemática, programação e conhecimento de domínio para coletar, organizar, analisar e interpretar dados com o objetivo de tomar decisões e previsões informadas. DS é amplamente aplicada em vários setores, incluindo negócios, saúde, finanças, marketing e pesquisa científica. Envolve o uso de ferramentas e metodologias como mineração de dados, aprendizado de máquina e visualização de dados para descobrir padrões, tendências e correlações nos dados. Para Netto e Maciel (2021) é um termo mais apropriado ao uso de dados com a finalidade de prever comportamentos, realizando análises exploratórias para fornecer recomendações baseadas em modelos identificados por dados presentes e passados.

Não tem como falar em *Data Science* se não falar em ciclo de vida do dado, que se refere ao processo completo que os dados percorrem desde a sua criação ou coleta até o seu descarte. É uma sequência de fases que inclui a geração, aquisição, armazenamento, processamento, análise, interpretação e, finalmente, o descarte ou arquivamento dos dados. O ciclo de vida dos dados abrange seis etapas: produção, armazenamento, transformação, armazenamento analítico, análise e descarte, dependendo da natureza e finalidade dos dados, com variações de tempo de retenção de imediato a décadas, de acordo com normas e

regulamentos (AMARAL, 2016). Além desses princípios e conceitos, algumas tecnologias que são utilizadas no *Data Science* estão descritas a seguir.

1.2 Tecnologias Relacionadas

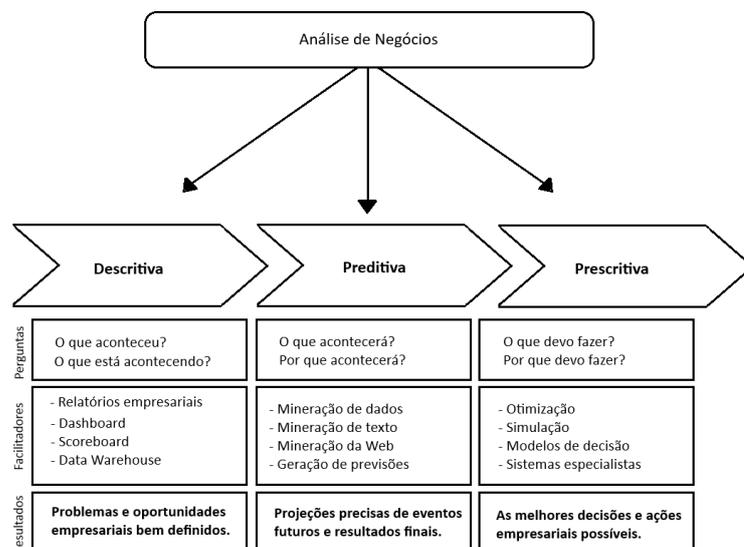
A seguir são apresentadas tecnologias importantes para a utilização do *Data Science*.

- **Inteligência Artificial:** é a capacidade de computadores executarem tarefas que normalmente requerem inteligência humana, como raciocinar, resolver problemas, aprender, perceber visualmente e linguisticamente, reconhecer padrões e tomar decisões. Segundo Akerkar (2019) a inteligência é uma das capacidades para comparar o mundo objetivo e aplicar conhecimento para resolver problemas.
- **Machine Learning:** é uma subárea da IA que envolve o desenvolvimento de algoritmos que permitem aos sistemas aprenderem padrões a partir de dados, melhorando sua performance com o tempo. Isso inclui aprendizado supervisionado, não supervisionado e por reforço. Com o *Machine Learning*, computadores processam, aprendem e extraem informações úteis do vasto volume de dados, desde supercomputadores usados pelo Google até smartphones comuns, confiamos no aprendizado de máquina para impulsionar nosso mundo, frequentemente sem perceber (RASCHKA, 2015).
 - **Aprendizagem supervisionada:** envolve treinar um algoritmo com um conjunto de dados rotulados, onde respostas corretas são fornecidas. Isso permite que o algoritmo aprenda a mapear entradas para saídas corretas, facilitando previsões precisas em novos dados não vistos com base no treinamento anterior. Segundo Netto e Maciel (2021) Os algoritmos de aprendizagem supervisionada são aqueles em que os dados têm atributos relacionados e nos quais se deseja prever quais atributos influenciam a variável independente. Esses algoritmos usam dados que já foram previamente separados em atributos.
 - **Aprendizagem não supervisionada:** envolve algoritmos treinados com dados não rotulados, descobrindo padrões e agrupamentos internos. Ao contrário da abordagem supervisionada, que usa exemplos rotulados para previsões, a aprendizagem não supervisionada explora automaticamente estruturas nos dados, como agrupamentos e anomalias. Segundo Netto e Maciel (2021) Os algoritmos de aprendizagem não supervisionada não têm variável independente e nem uma classificação de atributos prévia. O objetivo desses algoritmos é descobrir relacionamentos entre os dados,

agrupamentos entre estes ou a distribuição dos dados entre si.

- **Mineração de Dados:** é o processo de extrair padrões, insights e conhecimento valiosos de grandes conjuntos de dados. Envolve a aplicação de técnicas estatísticas e de aprendizado de máquina para identificar padrões ocultos, correlações e tendências nos dados. A mineração de dados é usada para tomar decisões informadas, melhorar as estratégias de negócios e descobrir informações valiosas que podem não ser prontamente aparentes. A Mineração de dados é um termo usado para descrever a descoberta ou a “mineração” de conhecimento junto a grandes quantidades de dados (SHARDA *et al.*, 2019).
- **Big Data:** refere-se a conjuntos de dados extremamente grandes e complexos que excedem a capacidade de processamento e análise dos sistemas tradicionais de gerenciamento de dados. "Big data" abrange situações em que o armazenamento, processamento e análise de dados excedem as capacidades tradicionais das organizações (DEAN, 2014).
- **Análise de dados:** é usada para identificar tendências, padrões e percepções dos dados, incluindo técnicas como mineração de dados, análise estatística e análise de tendências. Segundo Sharda (2019) a análise de dados pode ser vista como o processo de desenvolvimento de decisões ou recomendações práticas para ações baseadas em vislumbres gerados por dados históricos. A análise de dados é composta por três níveis: descritiva, preditiva e prescritiva (representado na Figura 2).

Figura 2 – Representação da análise de dados



Fonte: Adaptado SHARDA *et al.*; 2019.

Esta representação visual indica que esses níveis podem ser considerados como estágios em grande parte independentes, com uma aplicação de análise de dados conduzindo naturalmente ao próximo. Além disso, sugere que há uma certa sobreposição entre esses tipos de análise de dados, evidenciando a natureza interconectada das várias abordagens de análise de dados (SHARDA *et al.*, 2019).

- **Análise descritiva:** A análise de dados descritiva enfoca resumir e interpretar dados para compreender padrões, tendências e medidas resumidas. Ela proporciona uma visão geral dos dados, permitindo extrair insights iniciais e compreender o contexto dos conjuntos de dados, bem como busca entender eventos e tendências organizacionais por meio da consolidação de dados relevantes em *Data Warehouses*, permitindo a criação de relatórios e visualizações claras das operações com o uso de ferramentas modernas (SHARDA *et al.*, 2019).
- **Análise preditiva:** A análise de dados preditiva prevê eventos futuros ao identificar padrões nos dados históricos. Ao contrário da análise descritiva, que descreve o passado, ela usa esses padrões para fazer previsões informadas sobre o futuro, usando técnicas estatísticas e de mineração para prever eventos futuros com base em padrões de dados históricos, envolvendo algoritmos como regressão logística, árvores de decisão e análise de associação para identificar comportamentos (SHARDA *et al.*, 2019).
- **Análise prescritiva:** Essa análise vai além da previsão (análise preditiva), recomendando ações específicas para otimizar resultados desejados. Em outras palavras, não apenas prevê o que pode acontecer no futuro, mas também sugere o que deve ser feito para alcançar um determinado objetivo. Ela visa otimizar o desempenho reconhecendo eventos presentes e futuros, levando a decisões específicas para alcançar resultados ideais como escolhas binárias, valores quantificados ou planos de produção. (SHARDA *et al.*, 2019).
- **Algoritmos de regressão:** modelam relações entre variáveis dependentes e independentes, usando estatísticas e aprendizado de máquina. Eles são usados para previsões e inferências, buscando entender impactos e padrões. Diferentes tipos de algoritmos de regressão se adaptam a diversos cenários e dados. Segundo Netto e Maciel (2021) Regressão é utilizada se um ou mais atributos são variáveis contínuas(reais) e dependentes. Ou seja, a mudança em uma variável implica a mudança da outra.
- **Algoritmos de classificação:** aplicam padrões identificados em dados para rotulá-los,

automatizando a categorização de novos dados conforme características semelhantes a exemplos de treinamento. Esses algoritmos são usados para classificar em categorias binárias ou multiclasse. Segundo Netto e Maciel (2021) eles tratam de problemas em que os dados têm uma classificação prévia e se deseja prever a qual categoria um dado não classificado pertence.

Além dessas tecnologias, algumas ferramentas importantes para a implantação do *Data Science* são:

- **Python:** Python é uma linguagem de programação de alto nível, versátil e amplamente utilizada, conhecida por sua sintaxe legível e intuitiva. Python é projetada para ser fácil de aprender e usar, tornando-a uma escolha popular tanto para iniciantes em programação quanto para desenvolvedores experientes (PYTHON, 2023).
- **Linguagem R:** Segundo Silva *et al.* (2016) O R é uma linguagem de programação e um ambiente para desenvolvimento de ferramentas computacionais que envolvam conceitos de estatística e apresentação de resultados na forma de gráficos.

Esta sessão demonstrou a fundamentação teórica com os principais conceitos e características do *Data Science*, que é um campo interdisciplinar que combina estatística, ciência da computação e análise de dados para extrair *insights* de grandes volumes de dados, envolvendo ainda três competências fundamentais: conhecimento computacional, conhecimento exato e conhecimento de especialista. *Data Science* lida com a IA e o *Machine Learning*, incluindo aprendizado supervisionado e não supervisionado, e utiliza técnicas como mineração de dados e análise de dados. Também aborda o ciclo de vida dos dados, desde a coleta até o descarte, e compreende três níveis de análise de dados: descritiva, preditiva e prescritiva, além de envolver o uso de algoritmos de regressão e classificação, podendo ainda afirmar que Python e R são ferramentas essenciais para a implantação do *Data Science*.

3 PROCEDIMENTOS METODOLÓGICOS

A metodologia de pesquisa consiste em análise bibliográfica e documental descritiva de abordagem qualitativa de natureza aplicada, bem como na realização de entrevistas com um especialista da área a fim de coletar e relatar as histórias, conhecidas na área de *Storytelling*. Segundo Severino (2007), a análise bibliográfica é uma síntese ou comentário

dos livros publicados feito em revistas especializadas das várias áreas da ciência, das artes e da filosofia. Para Leite e Possa (2013), a abordagem qualitativa trabalha com interpretações, comparações e resultados que não podem ser mensuráveis numericamente.

Vale comentar que *storytelling* são histórias relatadas e foram realizadas quatro reuniões de uma média de duas horas cada *online* no software Discord com um profissional Cientista de Dados, Matheus Bertuci, além das reuniões também foi utilizado um grupo criado no Whatsapp para solucionar dúvidas que ficaram, foram adicionadas nove histórias dentre vinte histórias que foram contadas.

4 STORTELLINGS APRESENTADAS

Nesta seção são apresentadas as informações que foram colhidas com as entrevistas e os resultados obtidos.

A primeira história conta a análise para uma **cadeia de lojas**. Neste relato, aborda-se uma cadeia de lojas do ramo de farmácia, em que se acreditava que as maiores lojas vendiam mais, porém quando foram criadas as hipóteses e colocados os dados em si, percebeu-se que havia três tipos de lojas: pequena, média e grande, e descobriram que as lojas médias vendiam mais. Já as lojas pequenas tinham faturamento, proporcionalmente, maior que as lojas grandes e que as lojas que ficavam perto das concorrentes vendiam mais. Assim, restou evidência que não havia necessidade de lojas de grande porte, o que foi valioso para a diversificação dos investimentos e para logística (localização, investimento, tamanho), e isso só foi possível devido a criação, análise e seleção das variáveis, nesse caso específico: faturamento, tamanho das lojas, promoções, sortimento de produtos, tratamento de dados faltantes, criação e validação adequada das hipóteses, estressando ao máximo os dados, analisando se os vieses utilizados estão corretos, escalonagem de dados.

O segundo relato abrange uma análise para uma **companhia aérea**, que utiliza o porão de seus aviões para transportar cargas e otimizar o lucro da empresa com as cargas. O responsável pelo setor procurou o DS para criar uma solução para resolver este problema, pois a carga precisa ser otimizada para obter o máximo lucro possível em uma viagem. Nesse caso, deve-se levar em consideração alguns fatores, como: cargas vivas são as mais caras para transportar, depois vêm produtos perigosos e depois eletrônicos, e também é cobrado por tamanho e peso. Então é preciso levar em conta o tamanho e o preço, pois ao invés de um pedido com apenas um item poderia ser um pedido com 10 menores, o que financeiramente,

seria mais interessante para a empresa. Para resolver este problema foram utilizados algoritmos genéticos para criar uma solução, usando dados como: id, peso, preço, valor e volume. No processamento, foram utilizados quanto de peso e volume ainda estão disponíveis no plano para colocar as cargas e então foi escolhido o número de iterações para o algoritmo trazer o resultado. Depois de escolher todas as opções e clicar em processar, o aplicativo de DS mostrava quais cargas devem ser enviadas.

Outro relato interessante foi sobre **imagens de satélite**. Hoje existem vários satélites que passam no Brasil, pode se acessar satélites gratuitos ou pagos. Um exemplo interessante é o CBERS, um satélite, totalmente, desenvolvido pelo INPE que faz coleta de dados e imagens que são utilizadas para diversos setores como agricultura, meio ambiente, recursos hidrológicos e oceânicos, florestas, geologia etc., que tem revisitação a cada 15 dias. Em caso de muitas nuvens usa-se imagens de satélite por radar, que consegue atravessar as nuvens, exceto as nuvens *cumulonimbus* que contém cristais de gelo. Na agricultura pode-se determinar num hectare onde tem mais ou menos água na planta, quando deve ser feita a colheita, maior probabilidade infestação de pragas, vegetação saudável.

Na mineração pode-se localizar garimpos ilegais e para onde estão crescendo, lavras e cavas, assim toda a vez que o satélite passar pelo local o algoritmo baixa as imagens, passa pela visão computacional, pelas redes neurais criadas e identificar e quantificar se houve aumento. Ainda estimar decomposição de rejeitos, identificação de materiais pela reflexão da luz.

Nas prefeituras pode-se identificar temporais, na ajuda com desastres naturais, cálculo de ITBI e IPTU, entendimento de mancha urbana, realizar plano diretor das cidades, localizar pessoas em casos de desastres naturais.

Na manutenção dos negócios, com a utilização do *churning*, que é uma métrica utilizada pode-se mostrar o número de clientes que cancelaram um serviço em um determinado período, a criação de modelos estáticos e matemáticos que identificam onde a empresa deve atuar para conseguir um cliente com os dados disponíveis, escolha do canal de atuação, horário e tipo de publicação, testes no site de estática e probabilidade, onde devem ficar os botões, que cor devem ser, pensando em toda a cadeia do cliente desde quando é lead até a permanência, em todo processo de cliente.

No mercado financeiro é possível fazer a previsão, classificação, testes estáticos de valores, análise de sentimento para identificar se o mercado está positivo ou negativo, estável, análise de eventos sazonais para maiores assertividades futuras, através de séries temporais

que são modelos estatísticos onde são criados modelos de redes neurais,

Foi relatado ainda a utilização na área de recursos humanos através de *web crawler* que é um algoritmo que faz a pesquisa e extração de grande volume de dados em tempo real, pode ser utilizado dentro do LinkedIn, onde é informado as características que estão sendo procuradas e ele faz uma varredura de todos os perfis que se adequem.

Outra possibilidade é a previsão de *turn over* dos colaboradores, que é um problema principalmente para as empresas de tecnologia, ajudando o departamento a identificar esses colaboradores e realizar um tratamento caso a caso, inclusive tentando reverter uma provável saída ou agilizar a dispensa para novas contratações, diminuindo os custos para a empresa.

Resumindo, tais histórias apresentam soluções, identificação de indicadores importantes pois os dados quantificáveis nas variáveis das *Storytellings* auxiliaram em relação a aplicação estatística para geração de conhecimento, entretanto faz-se necessário esclarecer que pode haver algum viés nas aplicações apresentadas no trabalho, o que não ocorreu no estudo apresentado.

5 CONSIDERAÇÕES FINAIS

Os resultados obtidos demonstram a importância do DS em diversas áreas, desde negócios até utilidade pública e a importância da narrativa e comunicação desses resultados para que não se percam e possam ser utilizados para melhorias futuras. A utilização de uma narrativa simples e coesa sobre os dados é fundamental para transmitir as mensagens de maneira eficaz, através histórias reais. Durante o processo de elaboração da narrativa das histórias encontram-se desafios, como a escolha das histórias e de técnicas de narrativa, bem como a ética na confidencialidade dos dados. O trabalho realizado pode influenciar diversos profissionais, uma vez que transformou dados em narrativas em diferentes situações e áreas.

É importante ressaltar que o campo do DS está em constante evolução, sendo recomendável para futuras pesquisas, explorar novas técnicas, fontes de dados e áreas de aplicação. O aprendizado contínuo é fundamental. Enfim, esse estudo apresentou a *Storytelling* para transmissão de conhecimento e propagação de fatos positivos e/ou negativos na DS, podendo assim transformar a compreensão e a interação com o mundo ao redor, principalmente por trazer histórias de empresas reais que demonstram como aplicar na prática o que existe na literatura.

REFERÊNCIAS

- AMARAL, F. **Introdução a ciência de dados: mineração de dados e Big Data**. Rio de Janeiro: Alta Books, 2016.
- ANKERKAR, R. **Artificial Intelligence for Business**. Cham - Suíça: Springer, 2019.
- BELL, G. Foreword. **The fourth paradigm: data-intensive scientific discovery**. In: HEY, T.; TANSLEY, S.; TOLLE, K. M. Redmond, WA: Microsoft Research, p. 11-14, 2009.
- DAVENPORT, T. H.; PATIL, D. J. Data Scientist: The Sexiest Job of the 21st Century. **Harvard Business Review**, v. 90, n. 10, p. 70-128, 2012. Disponível em: https://www.researchgate.net/publication/232279315_Data_Scientist_The_Sexiest_Job_of_the_21st_Century. Acesso em: 30 ago. 2023.
- DEAN, J. **Big data, data mining, and machine learning: value creation for business leaders and practitioners**. New Jersey – Estados Unidos: Wiley, 2014.
- FOG *et al.* **Storytelling: Branding in Practice**. Berlin: Springer, 2010.
- LEITE, F.; POSSA, A. **Metodologia da Pesquisa Científica**. 2. ed. Florianópolis: IFSC, 2013.
- NETTO, A; MACIEL, F. **Python para Data Science**. Rio de Janeiro: Alta Books, 2021.
- PYTHON, Python. About. **Python.org**, 2023. Disponível em: <https://www.python.org/about/>. Acesso em: 30 ago. 2023.
- SEVERINO, A. **Metodologia da Pesquisa Científica**. 23. ed. São Paulo: Cortez, 2007.
- SHARDA *et al.* **Business Intelligence e Análise de Dados para gestão do negócio**. Porto Alegre: Bookman, 2019.
- SILVA *et al.* **Introdução à mineração de dados: Com aplicações em R**. Rio de Janeiro: Elsevier, 2016.
- RASCHKA, S. **Python Machine Learning**. Birmingham – Reino Unido: Packt, 2015.
- VANDERPLAS, J. **Python Data Science Handbook**. 1. ed. Sebastopol – Estados Unidos: Editora O'Reilly Media, 2016.