

**UNIVERSIDADE FEDERAL DE OURO PRETO**  
**INSTITUTO DE CIÊNCIAS SOCIAIS APLICADAS**  
**DEPARTAMENTO DE CIÊNCIAS ADMINISTRATIVAS**



**APLICAÇÕES DA DEEP LEARNING NA ANÁLISE DE DADOS EMPRESARIAIS:**  
**UM PANORAMA DE ESTUDOS DE 2021 A 2023**

**JERDDY MAYCON LEITE**

**MARIANA**

**2024**

**JERDDY MAYCON LEITE**

**APLICAÇÕES DA DEEP LEARNING NA ANÁLISE DE DADOS EMPRESARIAIS:  
UM PANORAMA DE ESTUDOS DE 2021 A 2023**

Monografia apresentada ao Curso de Administração da Universidade Federal de Ouro Preto como requisito para obtenção do título Bacharel em Administração.

**Orientadora: Profa. Dra. Héliida Mara Gomes Norato Duarte**

**MARIANA**

**2024**

## SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

L533a Leite, Jerddy Maycon.  
Aplicações da Deep Learning na análise de dados empresariais  
[manuscrito]: um panorama de estudos de 2021 a 2023. / Jerddy Maycon  
Leite. - 2024.  
54 f.: il.: color., tab.. + Quadros.

Orientadora: Profa. Dra. Héli da Mara Gomes Norato Duarte.  
Monografia (Bacharelado). Universidade Federal de Ouro Preto.  
Instituto de Ciências Sociais Aplicadas. Graduação em Administração .

1. Análise de envoltória de dados. 2. Aprendizado do computador. 3.  
Negócios. 4. Previsão de negócios. I. Duarte, Héli da Mara Gomes Norato.  
II. Universidade Federal de Ouro Preto. III. Título.

CDU 330.33.01

Bibliotecário(a) Responsável: Essevalter De Sousa - Bibliotecário Coordenador  
CBICSA/SISBIN/UFOP-CRB6a1407



## FOLHA DE APROVAÇÃO

**Jerddy Maycon Leite**

### **Aplicações da Deep Learning na análise de dados empresariais: um panorama de estudos de 2021 a 2023**

Monografia apresentada ao Curso de Administração da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Administração

Aprovada em 26 de fevereiro de 2024

#### Membros da banca

[Doutora] - Héliida Mara Gomes Norato Duarte - Orientador(a) (Universidade Federal de Ouro Preto - DECAD)

[Doutor] - Fábio Viana de Moura - (Universidade Federal de Ouro Preto - DECAD)

[Doutora] - Fernanda Maria Felício Macedo Boava - (Universidade Federal de Ouro Preto - DECAD)

[Héliida Mara Gomes Norato Duarte], orientadora do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 27/02/2024.



Documento assinado eletronicamente por **Helida Mara Gomes Norato Duarte, PROFESSOR DE MAGISTERIO SUPERIOR**, em 27/02/2024, às 15:54, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0674750** e o código CRC **1B3D51E5**.

## RESUMO

Os dados são fatores decisivos para o desempenho das organizações, e analisá-los adequadamente permite com que as empresas extraiam informações importantes que podem beneficiar o processo de negócio tornando-os eficientes. Nessa tarefa a *Deep Learning* (DL) traz contribuições importantes em um contexto na qual os dados são ativos estratégicos e a atividade de analisar dados é uma necessidade cada vez mais latente na atualidade. Entretanto, pesquisas quanto à aplicação da DL na análise de dados gerados pelas atividades dos negócios ainda demandam novas perspectivas de análises, pois algumas avaliam faces específicas das empresas, o que impossibilita uma visão mais abrangente do real estado da aplicação da DL na análise de dados empresariais. Para investigar essa possível lacuna, o presente estudo de natureza qualitativa, buscou realizar um mapeamento das aplicações da DL na análise de dados empresariais por meio de uma revisão sistemática de literatura nos últimos 3 anos (2021 - 2023). Com base nos resultados obtidos, foi possível identificar as principais aplicações da DL na análise de dados empresariais, o desempenho da DL frente a outras abordagens, as principais tecnologias DL utilizadas e a identificação de lacunas que representam oportunidades de pesquisas.

**Palavras-chave:** *Deep Learning*; Análise de dados; Negócios; Revisão Sistemática.

## ABSTRACT

Data is a decisive factor in the performance of organizations, and analyzing it properly allows companies to extract important information that can benefit the business process, making it efficient. In this task, Deep Learning (DL) makes important contributions in a context in which data are strategic assets and the activity of analyzing data is an increasingly latent need today. However, research on the application of DL in the analysis of data generated by business activities still requires new analytical perspectives, as some evaluate specific aspects of companies, which makes it impossible to have a more comprehensive view of the real state of the application of DL in data analysis business. To investigate this possible gap, this qualitative study sought to map the applications of DL in business data analysis through a systematic literature review over the last 3 years (2021 - 2023). Based on the results obtained, it was possible to identify the main applications of DL in business data analysis, the performance of DL compared to other approaches, the main DL technologies used and the identification of gaps that represent research opportunities.

**Keywords:** *Deep Learning*; Data analysis; Business; Systematic review.

## **LISTA DE ABREVIATURAS**

DL - Deep Learning / Aprendizagem Profunda

CNN - Convolutional Neural Network / Rede Neural Convolucional

RNN - Recurrent Neural Network / Rede Neural Recorrente

DNN - Deep Neural Network / Rede Neural Profunda

BERT - Bidirectional Encoder Representations from Transformers for Language Understanding / Representações de Codificador Bidirecional de Transformers para Compreensão de Linguagem

LSTM - Long Short-Term Memory / Memória de Longo Prazo a Curto Prazo

GRU - Gated Recurrent Unit / Unidade Recorrente Fechada

GANs - Generative Adversarial Networks / Redes Adversariais Generativas

## LISTA DE QUADROS

Quadro 1: Termos-chave definidos e aplicados nas bases de dados.....	22
Quadro 2: Filtros definidos para a revisão.....	23
Quadro 3: Testes de Relevância aplicados.....	28
Quadro 4: Agrupamento dos estudos identificados na 11 <sup>a</sup> etapa.....	29
Quadro 5: Aplicações da Deep Learning na análise de dados empresariais.....	32
Quadro 6: Desempenho da DL frente a outras abordagens.....	33
Quadro 7: Abordagens DL utilizadas nos estudos.....	34
Quadro 8: Modalidade dos estudos.....	34
Quadro 9: Oportunidades de pesquisa para preencher lacunas.....	35
Quadro 10: Apresentação dos Resultados.....	36
Quadro 11: Comparativo entre Referencial teórico e a Revisão Sistemática de Literatura.....	36



## **LISTA DE TABELAS**

Tabela 1: Número de resultados encontrados em cada termo-chave aplicado.....	25
Tabela 2: Etapas para o desenvolvimento do estudo.....	26

## LISTA DE FIGURAS

Figura 1: Passos para uma RSL.....	21
------------------------------------	----

## SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>12</b>
<b>2. REFERENCIAL TEÓRICO.....</b>	<b>14</b>
<b>2.1 Sociedade dos Dados: A perspectiva atual das empresas.....</b>	<b>14</b>
<b>2.2 Gestão da Informação na Sociedade dos dados.....</b>	<b>15</b>
<b>2.3 Deep learning: Uma alternativa para a Gestão da Informação.....</b>	<b>15</b>
<b>2.3.1 Tipologias da Deep Learning.....</b>	<b>16</b>
<b>2.3.2 Modelo de atividades de Contador (2001).....</b>	<b>17</b>
<b>2.3.3 Aplicações e implicações do uso da Deep Learning na análise de dados.....</b>	<b>18</b>
<b>3. METODOLOGIA.....</b>	<b>20</b>
<b>4. REVISÃO SISTEMÁTICA DA LITERATURA.....</b>	<b>21</b>
<b>4.1 Apresentação da Revisão Sistemática da Literatura (RSL).....</b>	<b>21</b>
<b>4.2 Análise dos resultados.....</b>	<b>31</b>
<b>4.2.1 Principais aplicações da Deep Learning na análise de dados empresariais. 32</b>	<b>32</b>
<b>4.2.2 Principais abordagens Deep Learning na análise de dados empresariais.... 34</b>	<b>34</b>
<b>4.2.3 Modalidades dos estudos selecionados..... 34</b>	<b>34</b>
<b>4.2.4 Lacunas e oportunidades de estudo no campo da aplicação da DL na análise de dados empresariais..... 35</b>	<b>35</b>
<b>5. CONSIDERAÇÕES FINAIS.....</b>	<b>39</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>40</b>

## 1. INTRODUÇÃO

O século XXI impacta de diferentes maneiras como as empresas operam em seus mercados, sendo um processo ligado em parte pelo aumento da disponibilidade de dados. De acordo com Rautenberg e Carmo (2019) há uma produção volumosa de dados em diversos contextos. Diante disso, Canedo (2021) destaca que a realidade das empresas atualmente é ligada a geração de dados promovida pela Transformação Digital (TD) em toda sociedade, na qual destaca-se o papel desafiador e fundamental da Gestão da Informação (GI) em tempos de TD (CORONEOS, 2020).

Segundo Andrade e Roseira (2018) a GI envolve a captação, o armazenamento de informações, a análise e o compartilhamento da informação obtida dentro das organizações, entretanto, devido à grande disponibilidade dos dados é exigido das pessoas e empresas competências para utilizar tais informações (GAMA *et al.* 2016). Nesse limiar, Najafabadi (2015) destaca as aplicações da *Deep Learning* (DL) na análise de grandes volumes de dados, na qual segundo Ganaie (2022) é uma tecnologia que sobressai em relação às tecnologias de análise tradicionais.

Segundo Hosaki e Ribeiro (2021), a DL pode ser entendida como um conjunto de algoritmos de aprendizagem de máquina profunda que atuam por meio de diferentes graus e subjetividades no processamento de informação, gerando no final do processo significado e valor para os dados.

Segundo Inomata *et al.* (2015) todas as atividades de uma empresa criam dados que quando processados podem gerar informações importantes, na qual segundo Contator (2001) são atividades ligadas ao apoio, planejamento, produção e atendimento de clientes pelas empresas. Diante disso, as redes de algoritmos baseadas em DL atualmente representam parte do desejo de organizações e pessoas (FRANÇA, 2022). Essa relevância observada é notada em pesquisas que mostram os impactos positivos da DL. Segundo Santos (2020) destacam-se os benefícios de resposta e previsão da DL em contextos complexos na indústria química. Na gestão de estoque a DL se destaca na previsão de demandas (PUNIA *et al.*, 2020). No Marketing a DL tem Aplicações em análises de sentimento de compra e uso de produtos por clientes (CARMO NETO, 2022). De modo geral, Schmitt (2023), pontua que o uso da DL tornará padrão no dia a dia das indústrias, sendo parte do processo de tomada de decisão.

Em relação aos estudos de Revisão Sistemática de Literatura (RSL) sobre aplicação de DL na realidade organizacional devem ser feitas algumas ressalvas. Neu, Lahann e Fettke (2022) realizaram uma RSL para identificar os métodos DL usados na previsão de processos

de negócios, onde 32 artigos foram identificados, entretanto, não buscaram destacar as aplicações da DL na análise de dados empresariais. A RSL desenvolvida por Adak, Pradhan e Shukla (2022) revisou métodos DL aplicados na análise de sentimentos de clientes em 97 artigos selecionados em uma janela de tempo entre 2001 e 2022, entretanto, a RSL por objetivar apenas uma faceta (análise de sentimentos) impossibilita compreender o real estado da DL na análise de dados empresariais em sua totalidade. A RSL realizada por Shavaki e Ghahnavih (2023) buscou construir uma visão sobre as aplicações de DL orientadas ao contexto da cadeia de suprimentos ao analisar 43 artigos, entretanto, o estudo por descrever apenas o uso da tecnologia sob a ótica da cadeia de abastecimento, impossibilita compreender as implicações da DL em contextos empresariais que não envolvem cadeia de abastecimento.

Nota-se que as RSL sobre a temática buscam apresentar um enfoque maior em contextos específicos buscando destacar as principais metodologias DL implementadas, entretanto, não exploram uma perspectiva global das aplicações da DL, não exploram as análises comparativas da DL frente a outras abordagens e não apontam, por buscarem contextos específicos, uma visão conclusiva sobre o estado da arte do uso da DL na análise de dados empresariais. Além disso, de acordo com Schmitt (2023) o uso da DL na análise dos negócios é relativamente baixa, representando, portanto, uma oportunidade a ser explorada por meio de RSL que identifique possíveis lacunas e oportunidades que norteia novos estudos sobre a aplicação da DL na análise de atividades e dados dos negócios.

Segundo Kaufman (2018) a DL apresenta grande influência no século XXI, sendo assim, este estudo irá expor uma Revisão Sistemática de Literatura (RSL) por meio do levantamento de estudos dos últimos 3 anos (2021-2023) em relação às aplicações da DL na análise de dados empresariais gerados por atividades associadas ao contexto empresarial, desta forma, o presente estudo buscará responder à questão: “Como têm sido as aplicações da *Deep Learning* na análise de dados empresariais em estudos publicados entre 2021 e 2023?” O presente estudo tem como objetivo geral mapear as aplicações da *Deep Learning* na análise de dados empresariais entre 2021 e 2023, tendo como objetivos específicos: i) Identificar as principais aplicações da DL na análise de dados e os respectivos desempenhos obtidos; ii) Identificar dentre as principais abordagens *Deep Learning* aquelas mais utilizadas na análise de dados empresariais e iii) Propor uma agenda de pesquisa visando orientar futuros estudos sobre a aplicação de DL na análise de dados empresariais, destacando as lacunas no conhecimento sobre a prática e possibilidades de pesquisa.

Após esta introdução, encontra-se o referencial teórico que norteou o presente estudo, em seguida é apresentada a metodologia que possibilitou o desenvolvimento do presente

estudo, em sequência são apresentadas as análises dos resultados conquistados por meio da RSL, e por fim, são expostas as considerações finais.

## **2. REFERENCIAL TEÓRICO**

### **2.1 Sociedade dos Dados: A perspectiva atual das empresas**

Segundo Rautenberg e Carmo (2019, p. 56) "atualmente, produz-se volumosas bases de dados para os mais variados domínios, devido à evolução e ao uso massivo das Tecnologias de Informação e Comunicação". Diante disso, Souza, Almeida e Souza (2018, p. 5) afirmam que "os dados são considerados o novo petróleo na era digital, possuindo um valor altamente estratégico".

Segundo os autores Pereira (2015), Silva, Ferreira e Borges (2017) e Vale Júnior (2021), a realidade das empresas atualmente é ligada ao aumento dos dados. Diante disso, segundo Vieira (2016) os dados são uma oportunidade para que os negócios obtenham informações importantes, na qual segundo Souza e Buzo (2021, p. 2), destacam que "os avanços da tecnologia da informação e o aumento de dados digitais em todas as áreas da sociedade dão a oportunidade de se obter essas informações e realizar análises profundas", o que destaca o papel desafiador, mas importante da Gestão da Informação (GI) em tempos de Transformação Digital (TD) (CORONEOS, 2020).

A mudança é uma variável constante a ser observada pelas empresas, sendo a mudança digital, reforçada pela Internet, Big Data, ferramentas de nuvem e surgimento de várias plataformas voltadas à geração de conteúdo, a necessidade atual de ajuste das empresas (PINÇON, 2017).

Segundo Canedo (2021), a modernidade apresenta às empresas um novo momento a partir dos dados trazidos pela TD em toda a sociedade. Diante disso, Massruhá *et al.* (2020, p. 23) apontam que a TD e o uso de Tecnologias da Informação e Comunicação (TIC) resultaria em benefícios na "performance e o alcance das empresas por meio da mudança na maneira como os negócios são feitos", mas enfatizam aspectos importantes na TD como a ciência de dados, o Big Data, a Inteligência Artificial e a aprendizagem de máquina.

Em suma, diante do cenário que envolve os dados, Brynjolfsson, Hitt e Kim (2011) apontam que o alinhamento de uma organização à realidade dos dados possibilita a ela o aumento de seu desempenho.

## 2.2 Gestão da Informação na Sociedade dos dados

De acordo com Gama *et al.* (2016) a sociedade se encontra na era da informação e do conhecimento associado a uma grande disponibilidade de informações, entretanto, para os autores esse limiar atual exige das pessoas e empresas capacidades para empregar tais informações em prol da organização.

Segundo Braga (2000) a Gestão da Informação (GI) tem como objetivo atender os interesses das empresas, apoiando a comunicação, a tomada de decisão e a evolução do negócio. Andrade e Roseira (2018) expandem e estabilizam o conceito ao destacar que a GI envolve a captação, o armazenamento de informações, a análise e o compartilhamento da informação obtida dentro das organizações. Para os autores, nos conceitos apresentados a GI, é necessário destacar que em todos os conceitos se tem o uso da informação visando beneficiar a organização.

Em contrapartida, outras pesquisas mostraram que o aumento de dados representa novos desafios para a realização da GI. Pimenta (2013, p. 11) afirma que o aumento de dados representa “um desafio jamais visto no tocante à gestão da informação”. Melo e Rockembach (2019, p. 26) afirmam que “está cada vez mais latente a necessidade de encontrar soluções que auxiliarão na recuperação das informações” devido ao volume, a variedade e a velocidade da produção dos dados, segundo os pesquisadores. Silva *et al.* (2020) afirmam que os dados não-estruturados, entendido por Feliciano (2018) como dados sem uma organização prévia, são o maior desafio relacionado ao grande volume de dados. Perfetto, Reis e Paletta (2023) afirmam que as informações digitais carregam desafios relacionados à armazenagem, processamento e legislação.

Em resumo, destaca-se o papel estratégico que a GI tem no uso dos dados pelas empresas, entretanto, a TD e o aumento de dados trazem novos desafios impondo dificuldades nunca vistas antes relacionadas aos dados e informações digitais.

## 2.3 *Deep learning*: Uma alternativa para a Gestão da Informação

De acordo com Pimenta (2013), Melo e Rockembach (2019) e Silva *et al.* (2020) a conjuntura atual que envolve os dados traz novas barreiras à sua manipulação. Nesse cenário, Najafabadi (2015) e Tomar, Tomar e kaur (2019) destacam o protagonismo que a *Deep Learning* (DL) traz para a análise de dados, na qual segundo Ganaie (2022), a DL demonstra desempenho superior em comparação com metodologias tradicionais de análise.

A *Deep Learning* ou Aprendizagem Profunda ganhou atenção na primeira década dos anos 2000 logo após Geoffrey Hinton e Ruslan Salakhutdinov explicarem como uma rede neural artificial de vários graus (camadas) poderiam ser feitas (CHAGAS, 2019). O conceito proposto por Hosaki e Ribeiro (2021) define a DL como um conjunto de algoritmos de aprendizagem de máquina profunda que atuam por meio de diferentes graus e subjetividades em prol do processamento de informação gerando no final do processo valor aos dados. Segundo Damaceno (2018) o conceito de DL foi trazido da *Machine Learning* (ML), na qual segundo o pesquisador, a ML é uma estratégia de aprendizagem de máquina feita por meio de dados disponibilizados a máquina e gerando por meio deles valor para atender um contexto específico.

Segundo Chen e Lin (2014) a DL é um dos principais direcionamentos do mundo digital, na qual em vários campos está trazendo melhorias para o processo de tomada de decisão (AHMED *et al.*, 2023). Diante disso, Bártolo (2018) afirma que a DL desperta interesse empresarial na atualidade, e sendo um campo em evolução (YANG *et al.*, 2022).

### **2.3.1 Tipologias da *Deep Learning***

De acordo com Yan e Hu (2023) existem 4 vertentes principais de redes neurais baseadas em aprendizagem profunda, sendo elas: Redes Neurais Convolucionais (CNN); Redes Neurais Recorrentes (RNN); Transformadores e Redes de Convolução em Grafo (GCN).

Conforme define Abu-Alsaad (2023), a CNN é uma arquitetura aplicada em dados sensoriais, como imagens, enquanto que a RNN segundo Forke e Tropmann-Frick (2021) é indicada para modelagem de dados sequenciais, como dados em séries temporais. Em relação aos Transformadores, de acordo com Peters (2022), essas arquiteturas apresentam a capacidade de processar dados em forma de textos. Em relação a GCN, segundo Pereira e Murai (2021) as redes GCN são estruturas que processam dados amplos e que obtêm sucesso na identificação de padrões. Segundo Zhao, Du e Tan (2023) a GCN é um instrumento indicado para análises de dados que carregam complexidade nas quais modelos tradicionais não conseguem modelar adequadamente.

Segundo Li (2017) as redes neurais DL têm sido aplicadas com sucesso em tarefas que envolvem Processamento de Linguagem Natural (PNL). De acordo com Agarwal e Saxena (2019) a PNL é uma metodologia que permite que máquinas compreendam a linguagem humana.



De acordo com Azar *et al.* (2021), a DL tem sido utilizada no aprendizado por reforço profundo, um subcampo da *Machine Learning*, segundo o pesquisador. Para Boute *et al.* (2022) o aprendizado por reforço profundo tem demonstrado potencial em processos de tomada de decisão, como em gestão de estoques.

Conforme Chai *et al.* (2021) a DL tem tido sucesso na área da visão computacional, na qual segundo Jin, Tan e Jiang (2020) é um dos principais pontos de estudo da DL. A visão computacional segundo Matsuzaka e Yashiro (2023) é o campo que permite com que máquinas absorvam informações em dados visuais, como em vídeos ou imagens, e a partir das informações geradas produzir sugestões.

### **2.3.2 Modelo de atividades de Contador (2001)**

De acordo com Contador (2001) todas as atividades de uma empresa, sendo elas de bens ou serviços, podem ser centradas em 4 polos, sendo atividades que podem ter o objetivo de apoiar, planejar, produzir ou atender clientes. Para o autor as atividades que visam apoiar são aquelas ligadas às ações administrativas como: compra de recursos e análise de fornecedores; Recursos Humanos; finanças e contabilidade; projeção do sistema de informação; apoio jurídico e relacionamento governamental.

Em relação às atividades que visam planejar, Contador (2001) afirma que são atividades ligadas às estratégias organizacionais que antecedem as atividades de apoiar, produzir e atender, sendo relacionadas às estratégias globais de gestão de informação, conhecimento e sistemas de informação e Planejamento & Desenvolvimento de novos produtos, serviços ou processos a serem implementados.

Em relação às atividades que visam produzir, o autor afirma que são as atividades inerentes a produção de mercadorias e serviços, planejamento e controle da operação produtiva, controle de qualidade, logística dentro e fora das empresas, projeção do produto e serviço a serem produzidos, assistência técnica e confecção de ferramentas necessárias.

As atividades que visam atender, Contador (2001) afirma que são atividades realizadas com o envolvimento físico ou remoto de clientes em atividades relacionadas ao front office, e-commerce, call center, marketing e vendas.

Diante do modelo proposto por Contador (2001), todas as atividades inerentes à realidade organizacional segundo Inomata *et al.* (2015) criam dados que quando processados podem gerar informações importantes. Diante disso, segundo Balakrishnan, Pelusi e Ganesan (2020) os dados são cada vez mais importantes para que empresas alcancem sua

sustentabilidade, na qual segundo Howard (2013) a DL tem extensas implicações para as empresas que necessitam do processo de análise de dados.

### **2.3.3 Aplicações e implicações do uso da *Deep Learning* na análise de dados**

No âmbito da análise de dados, Kraus, Feuerriegel e Oztekin (2020) destacam que a DL supera modelos tradicionais em se tratando de análise e que segundo Fombellida *et al.* (2020) o uso da DL deve ser considerado para a *Business Intelligence* (BI), uma vez que para Schmitt (2023), o uso da DL tornará padrão no dia a dia das indústrias, sendo parte do processo de tomada de decisão.

De acordo com Hu, Zhao e Khushi (2021) atualmente o uso da DL se apresenta como tendência na modelagem financeira. Diante disso, Lado-Sestayo e Vivel-Búa (2020), com base na DL modelada e introduzida por meio da análise de dados de lucratividades de um hotel, foi capaz de gerar alta capacidade de previsão sobre a lucratividade. Conforme Gao (2021), o sistema em DL desenvolvido pelo pesquisador visando a prevenção contra riscos, foi eficiente ao avaliar riscos financeiros em empresas. De acordo com Nikou, Mansourfar e Bagherzadeh (2019) foi indicado que o método baseado em DL apresentou melhor previsão do preço de ações em comparação com outros modelos com base nos dados diários dos preços de ações de empresas. Segundo Lekkala (2023) os modelos de aprendizagem de máquina profunda como a CNN e a RNN apresentam maior capacidade de identificação de fraudes em dados da indústria da saúde em comparação com modelos tradicionais contribuindo na redução de perdas financeiras. De acordo com Wujec (2021), análises de textos financeiros são fontes importantes de informações e a DL desenvolvida pelo pesquisador apresentou capacidade de identificar sentimentos em textos financeiros e os resultados obtidos podem ser utilizados para confecção de estratégias sobre o mercado.

Em relação à atividade produtiva, Abdullayeva e Imamverdiyev (2019) a aplicação da DL no âmbito da gestão e controle da produção gera eficiência na produção de petróleo. Saprónova (2016) utilizou a DL como ferramenta na previsão da produção de energia eólica ao usar dados históricos da produção. De acordo com Martínez-Arellano, Terrazas e Ratchev (2019) foi desenvolvido um modelo com DL para identificar desgaste em ferramentas a partir de imagens, sendo segundo os autores, um modelo capaz de gerar alto valor preditivo em contexto de usinagem e produção. No âmbito da gestão agrícola, de acordo com Koul (2021), a DL levou o setor agrícola para um novo patamar. Diante disso, Ahmad *et al.* (2021) demonstrou que a DL têm aplicações de alta predição para analisar e identificar em dados

visuais as ervas daninhas em plantações. Takkar *et al.* (2021) sugeriu um modelo DL para identificar doenças em plantas por meio de dados visuais para evitar perdas de produção e investimento.

No âmbito da logística, Bhattacharjee (2023) aponta que a DL trouxe melhorias para os processos logísticos ao explorar o uso da DL na roteirização do transporte. Diante disso, Shavaki e Ghahnavieh (2023) destacam que a DL em cadeias de abastecimento tem gerado um crescente interesse, na qual de acordo com Jayaprakash *et al.* (2023), o modelo DL desenvolvido pelos pesquisadores obteve maior previsão sobre movimentação de cargas de contêineres em portos. Segundo Vats e Anastasiu (2023) o modelo DL desenvolvido pelos pesquisadores é capaz de rastrear produtos com eficiência e Isman, Amin e Wardley (2023) buscaram aprimorar o processo de seleção de fornecedores e alocação de pedidos utilizando DL, na qual o modelo reduz os erros na previsão.

No Marketing, com o fenômeno do aumento de dados, Liu (2023) afirma que o aumento de dados está estimulando o uso da DL. Segundo Abdalla e Özyurt (2021) utilizaram modelos DL visando analisar dados de opiniões, pois segundo eles, analisar opiniões ajudam as empresas a melhorar os produtos oferecidos. Segundo Soni (2021) foi utilizado DL associado à visão computacional para avaliar sentimentos dos clientes no ambiente do varejo. Han *et al.* (2023) desenvolveram um modelo a base de DL voltado à análise de dados de usuários com preservação de dados pessoais para campanhas de Marketing. De acordo com Lee, Kim e Shim (2021) no e-commerce a classificação eficiência de produtos conforme suas especificações é fundamental, com base nessa perspectiva, os pesquisadores desenvolveram um modelo eficiente na classificação de produtos com base na DL. Em relação à previsão de demanda, Mezzogori e Zammori (2019), modelaram e implementaram uma DL em contexto de uma empresa de moda capaz de prever a demanda a partir de dados de vendas históricas de 9 anos. Em relação a Segmentação de clientes, Wang (2022) propôs um modelo com DL capaz de analisar os dados de clientes e promover as suas classificações, sendo um modelo segundo o autor, capaz de melhorar a lucratividade. Segundo Wang (2022), para realizar vendas ao cliente ideal é importante segmentar os clientes e mapear seus comportamentos.

Por fim, no âmbito dos Recursos Humanos, a DL segundo Shi e Li (2021) gera resultados positivos na eficiência e eficácia da aplicação dos Recursos Humanos ao realizar recomendações avaliando o grau de correspondência entre dados da mão de obra e cargos. Segundo Gopal, Subhash e Anil (2022) a DL estruturada com CNN e introduzida por eles tem implicações no monitoramento do trabalho dos colaboradores.

### 3. METODOLOGIA

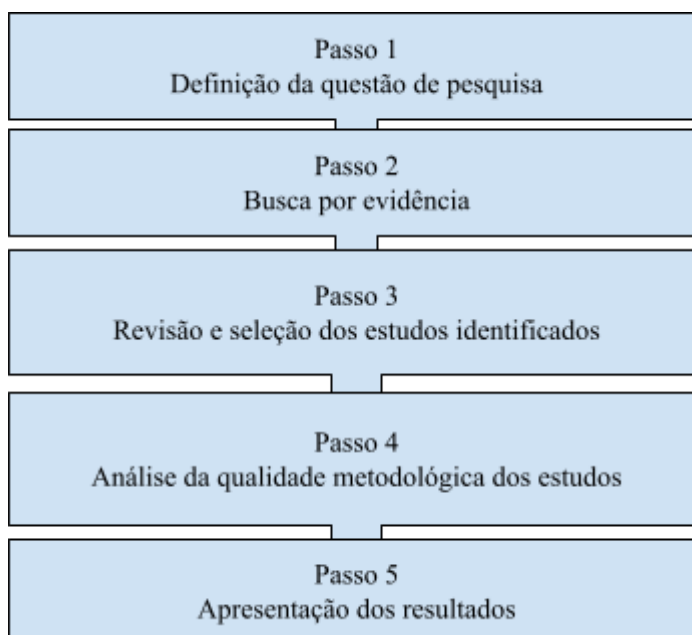
A metodologia adotada para o presente estudo baseou-se na realização de uma Revisão Sistemática de Literatura (RSL). Para Galvão e Ricarte (2019, p. 58) a RSL "segue protocolos específicos, e que busca entender e dar alguma logicidade a um grande corpus documental, especialmente, verificando o que funciona e o que não funciona num dado contexto".

A análise dos dados será abordada de forma qualitativa por meio da análise de conteúdo. A análise qualitativa segundo Brito, Oliveira e Silva (2021, p. 5), os autores retratam que "os estudos qualitativos se caracterizam principalmente como aqueles que buscam compreender determinado fenômeno no seu ambiente natural, ou seja, onde eles efetivamente acontecem". A análise de conteúdo visa gerar novos saberes sobre determinado tema ao analisar dados como textos (PAIVA; OLIVEIRA; HILLESHEIM, 2021).

O motivo da escolha da estrutura é norteado pelo papel que os dados e a informação têm como fator agregador da vantagem competitiva no século XXI e o protagonismo apontado por Najafabadi (2015) e Tomar, Tomar e kaur (2019) tem o uso da DL em relação à crescente produção de dados. Portanto, a estrutura permitiu alcançar os objetivos geral e específicos ao compreender a temática da DL na vida empresarial possibilitando identificar as aplicações e o desempenho da prática da DL, apontar as principais metodologias DL usadas e as lacunas e oportunidades de pesquisa, possibilitando assim fazer com que a ciência possa entender melhor a temática no âmbito das empresas.

Em relação a realização da RSL, foi utilizado o modelo de RSL desenvolvido por Sampaio e Mancini (2007) que é estruturado pelos passos definidos na figura 1.

Figura 1: Passos para uma RSL



Fonte: Adaptado de Sampaio e Mancini (2007)

Em conformidade com o modelo de RSL definido por Sampaio e Mancini (2007), o primeiro passo (passo 1) envolve a escolha da questão de pesquisa de forma clara para guiar a inclusão de estudos durante o processo de revisão. No passo 2, como abordam os autores, é realizada a busca por evidências por meio de buscas em bases de dados através de termos-chave utilizando operadores booleanos (a RSL utilizou o operador “E”) somados a bases de dados e filtros definidos para a pesquisa a ser feita. No passo 3, em conformidade com os autores, é aplicado critérios de inclusão e exclusão no processo de revisão e seleção visando validar os estudos resultantes da revisão realizada. O passo 4, segundo os autores, representa o processo onde os dados encontrados são compilados para a construção de conclusões. Por fim, no passo 5 do modelo de RSL estabelecido por Sampaio e Mancini (2007), é realizada a composição dos resultados obtidos por meio da RSL à luz da questão pesquisada e definida no passo 1.

## 4. REVISÃO SISTEMÁTICA DA LITERATURA

### 4.1 Apresentação da Revisão Sistemática da Literatura (RSL)

Em sintonia com o passo a passo para a execução de uma RSL definido por Sampaio e Mancini (2007) demonstrado pela figura 1, foi escolhido para a revisão o protocolo (passo 1) por meio da questão de pesquisa que norteará o processo de inclusão de estudos, sendo a

questão: “Como têm sido as aplicações da *Deep Learning* na análise de dados empresariais em estudos publicados entre 2021 e 2023?”. Os objetivos específicos também foram utilizados como base para o protocolo de revisão, sendo os objetivos específicos: i) Identificar as principais aplicações da DL na análise de dados e os respectivos desempenhos obtidos; ii) Identificar, dentre as principais abordagens *Deep Learning*, aquelas mais utilizadas na análise de dados empresariais; iii) Propor uma agenda de pesquisa visando orientar futuros estudos sobre a aplicação de DL na análise de dados empresariais, destacando as lacunas no conhecimento sobre a prática e oportunidades de pesquisa.

Em seguida, logo após definir o protocolo de revisão (passo 1), foi efetuada a busca por evidências por meio de termos-chave em inglês, como recomenda o manual de acesso do CAPES (2019) em bases de dados definidos (passo 2). A busca por evidências foi norteada por 25 (vinte e cinco) termos-chave (Quadro 1) aplicados em bases de dados acessadas por meio do Portal de Periódicos do CAPES e por filtros definidos conforme demonstrado no Quadro 2.

Quadro 1: Termos-chave definidos e aplicados nas bases de dados.

Pesquisas via Portal de Periódicos CAPES	
Termos-chave em português	Termos-chave em inglês
1. <i>Deep Learning</i> E análise de dados E negócios E compra de recursos;	1. Deep Learning E Data Analysis E Business E Resource Purchasing;
2. <i>Deep Learning</i> E análise de dados E negócios E análise de fornecedores;	2. Deep Learning E Data Analysis E Business E Supplier Analysis;
3. <i>Deep Learning</i> E Análise de Dados E Negócios E Recursos Humanos;	3. Deep Learning E Data Analysis E Business E Human Resources;
4. <i>Deep Learning</i> E Análise de Dados E Negócios E Finanças e Contabilidade;	4. Deep Learning E Data Analysis E Business E Finance and Accounting;
5. <i>Deep Learning</i> E Análise de Dados E Negócios E Suporte Jurídico;	5. Deep Learning E Data Analysis E Business E Legal Support;
6. <i>Deep Learning</i> E Análise de Dados E Negócios E Relações Governamentais;	6. Deep Learning E Data Analysis E Business E Government Relations;
7. <i>Deep Learning</i> E Análise de dados E Negócios E Atividades administrativas;	7. Deep Learning E Data Analysis E Business E administrative activities;
8. <i>Deep Learning</i> E Análise de Dados E Negócios E Planejamento Organizacional;	8. Deep Learning E Data Analysis E Business E Organizational Planning;
9. <i>Deep Learning</i> E Análise de Dados E Negócios E Suporte ao Desenvolvimento de Produtos;	9. Deep Learning E Data Analysis E Business E Product Development Support;
10. <i>Deep Learning</i> E Análise de dados E Business E suporte ao desenvolvimento de serviços;	10. Deep Learning E Data Analysis E Business E service development support;
11. <i>Deep Learning</i> E Análise de Dados E Negócios E Inteligência Organizacional;	11. Deep Learning E Data Analysis E Business E Organizational Intelligence;
12. <i>Deep Learning</i> E Análise de dados E Business E suporte ao desenvolvimento de processos;	12. Deep Learning E Data Analysis E Business E process development support;
13. <i>Deep Learning</i> E Análise de dados E Negócios E Produção de bens;	13. Deep Learning E Data Analysis E Business E production of goods;

(continuação)

Pesquisas via Portal de Periódicos CAPES	
Termos-chave em português	Termos-chave em inglês
14. <i>Deep Learning</i> E Análise de dados E Negócios E Produção de serviços;	14. Deep Learning E Data Analysis E Business E service production;
15. <i>Deep Learning</i> E Análise de dados E Negócios E Controle de qualidade da produção;	15. Deep Learning E Data Analysis E Business E production quality control
16. <i>Deep Learning</i> E Análise de Dados E Negócios E Logística;	16. Deep Learning E Data Analysis E Business E Logistics
17. <i>Deep Learning</i> E Análise de Dados E Negócios E Planejamento de Produção;	17. Deep Learning E Data Analysis E Business E Production Planning
18. <i>Deep Learning</i> E Análise de Dados E Negócios E Manutenção de Produção;	18. Deep Learning E Data Analysis E Business E Production Maintenance
19. <i>Deep Learning</i> E Análise de Dados E Negócios E Monitoramento de Produção;	19. Deep Learning E Data Analysis E Business E Production Monitoring
20. <i>Deep Learning</i> E Análise de Dados E Negócios E Gestão de Estoque;	20. Deep Learning E Data Analysis E Business E Inventory Management
21. <i>Deep Learning</i> E Análise de Dados E Negócios E Front office;	21. Deep Learning E Data Analysis E Business E Front office.
22. <i>Deep Learning</i> E Análise de Dados E Negócios E E-commerce;	22. Deep Learning E Data Analysis E Business E E-commerce
23. <i>Deep Learning</i> E Análise de Dados E Negócios E call center;	23. Deep Learning E Data Analysis E Business E call center
24. <i>Deep Learning</i> E Análise de Dados E Negócios E Marketing;	24. Deep Learning E Data Analysis E Business E Marketing
25. <i>Deep Learning</i> E Análise de Dados E Negócios E Vendas.	25. Deep Learning E Data Analysis E Business E Sales

Fonte: Elaboração própria.

Quadro 2: Filtros definidos para a revisão.

Pesquisas via Portal de Periódicos CAPES
Filtros selecionados
<ol style="list-style-type: none"> <li>1. Periódicos revisados por pares;</li> <li>2. Janela de tempo delimitada: 2021 – 2023;</li> <li>3. Bases de dados utilizadas na RSL: <ul style="list-style-type: none"> <li>ACS_美国化学学会过刊 (与NSTL共建)</li> <li>American Chemical Society Journals</li> <li>American Chemical Society (ACS) Legacy Archive</li> <li>American Society of Civil Engineers ASCE Journals</li> <li>Arts &amp; Humanities Citation Index (Web of Science)</li> <li>AUC Wiley Frozen Package in 2012</li> <li>arXiv.org</li> <li>BMJ Open Access Journals</li> <li>De Gruyter journals</li> <li>DOAJ Directory of Open Access Journals</li> <li>Education Resources Information Center (ERIC)</li> <li>Emerald Backfiles</li> <li>Emerald Complete Journals</li> <li>Emerald Insight database</li> <li>Emerald Journals</li> </ul> </li> </ol>

(continuação)

Pesquisas via Portal de Periódicos CAPES
Filtros selecionados
Emerald Open Access Free E- Journals HighWire Press (Free Journals) IEEE Electronic Library (IEL) Journals IEEE Open Access Journals IEEE Xplore Open Access Journals Institute of Physics IOP Science Extra Institute of Physics Journals Institute of Physics Open Access Journal Titles J-STAGE (Free - Japanese) Journals@Ovid Complete Nature Free Nature Journals Online Nature Publishing Group website Oxford Journals Current Collection PubMed PubMed Central Sage Premier Journal Collection SciELO Chile SciELO Peru Science Citation Index Expanded (Web of Science) ScienceDirect SpringerLink SpringerNature Complete Journals Taylor & Francis Journals Complete Taylor & Francis Open Access Wiley Journals Open Access Wiley Online Library All Journals Wiley Online Library Journals Frontfile Complete Wiley-Blackwell Full Collection Wiley-Blackwell Open Access Collection

Fonte: Elaboração própria.

Para a execução de uma RSL é necessário definir as bases para pesquisa e a janela de tempo a ser delineada. O presente trabalho foi executado no Portal de Periódicos da CAPES. De acordo com Costa (p. 58, 2021) o CAPES é “utilizado por inúmeros pesquisadores e instituições de ensino do país, reunindo diferentes conteúdos de pesquisa de qualidade”. No Portal do CAPES foram efetuadas buscas nas bases destacadas no Quadro 2. Optou-se em utilizar todos os repositórios disponíveis ao aplicar os termos-chave para angariar o máximo de resultados visando promover maior qualidade e alcance da RSL.

Em relação aos filtros aplicados, a presente pesquisa utilizou os filtros: Periódicos revisados por pares e período de publicação de 2021 a 2023. A escolha desse período é norteada, como afirma Oliveira (2021), pelo fato das tecnologias mudarem a todo momento e a *Deep Learning*, segundo Yang *et al.* (2022), ser uma tecnologia em evolução, logo, o



período de 2021 a 2023 permitiu buscar resultados próximos do estado atual da tecnologia *Deep Learning*.

Em relação aos termos-chave (Quadro 1) foram escolhidos respeitando o delineamento na qual o termo “*Deep Learning*” se refere a tecnologia pesquisada, o termo “*Data Analysis*” delimita a aplicação da DL a análise de dados e o termo “*Business*” define o contexto (empresarial) onde a DL está sendo aplicada. O quarto termo aborda atividades destacadas pelo modelo geral de atividades de empresas proposto por Contador (2001), uma vez que para Inomata *et al.* (2015) todas as atividades de uma empresa criam dados que quando processados podem gerar informações importantes. Desta forma, a utilização conjunta (Tabela 1) possibilitou a base para a revisão sobre a aplicação da *Deep Learning* na análise de dados empresariais.

O número total de resultados encontrados após a finalização de buscas por meio dos termos-chave foi de 1261 trabalhos, sendo representados pela Tabela 1 uma síntese por termo-chave.

Tabela 1: Número de resultados encontrados em cada termo-chave aplicado.

<b>Termos-chave</b>	<b>Nº de Resultados</b>
Deep Learning E Data Analysis E Business E Resource Purchasing	1
Deep Learning E Data Analysis E Business E Supplier Analysis	6
Deep Learning E Data Analysis E Business E Human Resources	148
Deep Learning E Data Analysis E Business E Finance and Accounting	38
Deep Learning E Data Analysis E Business E Legal Support	5
Deep Learning E Data Analysis E Business E Government Relations	16
Deep Learning E Data Analysis E Business E administrative activities	3
Deep Learning E Data Analysis E Business E Organizational Planning	6
Deep Learning E Data Analysis E Business E Product Development Support	41
Deep Learning E Data Analysis E Business E service development support	74
Deep Learning E Data Analysis E Business E Organizational Intelligence	23
Deep Learning E Data Analysis E Business E process development support	107
Deep Learning E Data Analysis E Business E production of goods	41
Deep Learning E Data Analysis E Business E service production	38
Deep Learning E Data Analysis E Business E production quality control	45

(continuação)

<b>Termos-chave</b>	<b>Nº de Resultados</b>
Deep Learning E Data Analysis E Business E Logistics	218
Deep Learning E Data Analysis E Business E Production Planning	35
Deep Learning E Data Analysis E Business E Production Maintenance	10
Deep Learning E Data Analysis E Business E Production Monitoring	63
Deep Learning E Data Analysis E Business E Inventory Management	57
Deep Learning E Data Analysis E Business E Front office.	2
Deep Learning E Data Analysis E Business E E-commerce	85
Deep Learning E Data Analysis E Business E call center	11
Deep Learning E Data Analysis E Business E Marketing	123
Deep Learning E Data Analysis E Business E Sales	65

Fonte: Elaboração própria.

A condução do segundo e terceiro passos da RSL foram realizadas ao longo de 14 etapas que são expostas na Tabela 2 de forma resumida.

Tabela 2: Etapas para o desenvolvimento do estudo

<b>Etapas</b>	<b>Descrição das Etapas realizadas</b>	<b>Estudos Excluídos</b>	<b>Estudos Restantes</b>
1	Definição dos termos-chave e filtros incluindo a base de dados e período de tempo utilizados e aplicados na realização da busca por evidências.	-	1261
2	Mapeamento por meio de tabelas de todos os trabalhos identificados para cada um dos 25 termos-chave aplicados.	-	-
3	Identificação de trabalhos repetidos pela RSL.	-	-
4	Exclusão dos trabalhos repetidos encontrados.	227	1033
5	Realização da leitura do título e resumo dos trabalhos que restaram após a exclusão de trabalhos repetidos.	-	1033
6	Exclusão de trabalhos encontrados após a realização da leitura do título e resumo.	655	378
7	Realização da leitura da introdução e conclusão dos trabalhos que restaram após a exclusão anterior.	-	378
8	Exclusão dos trabalhos encontrados após a realização da leitura da introdução e conclusão.	240	138
9	Realização da leitura completa dos trabalhos que restaram.	-	138

(continuação)

<b>Etapas</b>	<b>Descrição das Etapas realizadas</b>	<b>Estudos Excluídos</b>	<b>Estudos Restantes</b>
10	Exclusão dos trabalhos após a leitura completa dos trabalhos que restaram.	113	25
11	Compilamento dos trabalhos que restaram em tabelas.	-	25
12	Realização do fichamento de cada estudo restante contendo trechos considerados importantes para a pesquisa.	-	-
13	Classificação dos trabalhos restantes com base nas aplicações e no desempenho da DL frente a outras abordagens distintas da DL na análise de dados empresariais, metodologias DL utilizadas e modalidade de cada estudo (se são empíricos ou teóricos).	-	-
14	Análise dos resultados obtidos	-	-

Fonte: Elaboração própria.

Em síntese, com a aplicação dos termos-chave e filtros definidos no Periódico do CAPES (1ª etapa) foram obtidos 1261 (mil e duzentos e sessenta e um) trabalhos, que na etapa 2 foram mapeados para a classificação de trabalhos repetidos e removidos em sequência (3ª etapa e 4ª etapa respectivamente) restando 1033 (mil e trinta e três) trabalhos. Com a leitura dos títulos e resumos (5ª etapa) dos trabalhos restantes, aplicando-se critérios de inclusão e exclusão (6ª etapa), foram selecionados para a próxima etapa (7ª etapa) 378 (trezentos e setenta e oito) trabalhos. Com a leitura da introdução e conclusão (7ª etapa) dos trabalhos e ao aplicar critérios de inclusão e exclusão definidos, foram selecionados (8ª etapa) 138 (cento e trinta e oito) trabalhos. Na etapa seguinte realizou-se a leitura completa dos trabalhos restantes (9ª etapa), e identificou-se 25 trabalhos (10ª etapa), que foram compilados em uma tabela (11ª etapa), em seguida ocorreu o fichamento dos trabalhos restantes contendo trechos importantes para a pesquisa realizada (12ª etapa), permitindo classificar os trabalhos com base nas aplicações da DL abordadas e o desempenho da DL frente a outras abordagens distintas da DL na análise de dados empresariais, identificação das metodologias DL utilizadas no processo de análise de dados empresariais e modalidades de cada estudo selecionado (se são teóricos ou empíricos) (13ª etapa), por fim foi realizado a análise dos resultados encontrados pela pesquisa como etapa final (14ª etapa) da RSL realizada.

Em sequência ao passo 2 da RSL, conforme Sampaio e Mancini (2007) que está relacionado à etapa 1 representada na Tabela 2, o processo de revisão e seleção dos trabalhos encontrados (passo 3) ocorreu a partir da etapa 2. No decorrer das etapas foram aplicados quatro Testes de Relevância representados pelas etapas 4, 6, 8 e 10 por meio de critérios de

inclusão e exclusão dos trabalhos encontrados pela RSL. De acordo com Segura-Muñoz *et al.* (2002) o Teste de Relevância é o mecanismo que define o tipo de estudo que vai agregar a RSL, desta forma, os Testes de Relevância utilizados são expressos no Quadro 3.

Quadro 3: Testes de Relevância aplicados

Testes de Relevância	
Critérios para Inclusão	Critérios para exclusão
<ol style="list-style-type: none"> <li>1. Estudos resultantes dos 25 termos-chave (Quadro 1);</li> <li>2. Estudos resultantes das bases de dados definidas (Quadro 2);</li> <li>3. Janela de tempo delimitada entre 2021-2023;</li> <li>4. Periódicos revisados por pares;</li> <li>5. Artigos de livre acesso.</li> </ol>	<ol style="list-style-type: none"> <li>6. Trabalhos repetidos;</li> <li>7. Artigos que aparentemente não expressam o uso da <i>Deep Learning</i> associado ao contexto empresarial;</li> <li>8. Artigos que aparentemente não expressam implicações práticas do uso da <i>Deep Learning</i> na análise de dados empresariais;</li> <li>9. Artigos que aparentemente não expressam análises comparativas frente a outros modelos distintos do campo da <i>Deep Learning</i>;</li> <li>10. Artigos que não são transparentes em relação às limitações dos modelos DL desenvolvidos.</li> </ol>

Fonte: Elaboração própria.

A respeito do Quadro 3, os critérios 1, 2, 3 e 6 buscam delimitar a RSL, enquanto que os critérios 4, 5, 7, 8, 9 e 10 buscam agregar valor à RSL. O critério 4 buscou garantir a qualidade, confiabilidade e validade das informações dos estudos devido a avaliação por pares. O critério 5 permite ampliar o acesso à informação, facilitando a replicabilidade dos estudos selecionados. Este filtro garante que todos e quaisquer indivíduos possam ter acesso aos resultados. O critério 7 visa manter o foco no tema da análise de dados empresariais ao excluir artigos que não estejam associados ao contexto empresarial e a temática. O critério 8 possibilitou a exclusão de artigos sem perspectiva prática e que não contribuem para a solução da questão de pesquisa “Como têm sido as aplicações da *Deep Learning* na análise de dados empresariais em estudos publicados entre 2021 e 2023?”. Em relação ao critério 9, a comparação com outros modelos possibilita avaliar a eficácia das aplicações da DL em termos de desempenho na análise de dados empresariais, possibilitando responder à questão de pesquisa frente a outras abordagens utilizadas em análise de dados empresariais. E por fim, o critério 10 permite que outros pesquisadores interessados pelos resultados possam compreender as restrições e desafios enfrentados, influenciando o desenvolvimento futuro de novos modelos e abordagens que possam sanar tais limitações e a ciência possa progredir.

Após a aplicação de todos os testes de relevância definidos, restaram 25 trabalhos, apresentados no Quadro 4.

Quadro 4: Agrupamento dos estudos identificados na 11ª etapa

Trabalhos Selecionados		
Nº	Referência (ABNT)	Objetivo/contexto
1	BAS, J.; CIRILLO, C.; CHERCHI, E. Classification of potential electric vehicle buyers: a machine learning approach. <b>Technological Forecasting and Social Change</b> , v. 168, p. 120759, 2021. Disponível em: <a href="https://doi.org/10.1016/j.techfore.2021.120759">https://doi.org/10.1016/j.techfore.2021.120759</a> . Acesso em: 27 jan. 2024.	Testou modelos, dentre eles a DL, para prever a demanda por veículos elétricos e trouxe contribuições para a indústria automotiva, entretanto, a DL não superou outros modelos.
2	CHANG, Y.; KU, C.; NGUYEN, D. L. Aspect-based sentiment prediction using deep learning and information visualization: The impact of COVID-19 on the airline industry. <b>Information and Management</b> , v. 59, n. 2, p. 103587, 2022. Disponível em: <a href="https://doi.org/10.1016/j.im.2021.103587">https://doi.org/10.1016/j.im.2021.103587</a> . Acesso em: 15 jan. 2024	Implementou a PLN com DL para analisar sentimentos em avaliações de companhias aéreas no TripAdvisor superando outros modelos.
3	DESHAI, N.; BHASKARA RAO, B. Unmasking deception: An adaptive CNN and PSO approach to detect fake online reviews. <b>Soft Computing</b> , vol. 27, p. 11357–11378, 2023.	Implementou a CNN para identificar sentimentos falsos de clientes visando manter a credibilidade das avaliações online e superou outros modelos.
4	HO, T. T.; BUI, H. M.; PHUNG K. A hybrid model for sentiment analysis based on aspects of customer feedback: research on the mobile commerce sector in Vietnam. <b>International Journal of Advances in Intelligent Computing</b> , v. 2, p. 273-285, 2023.	Testou modelos, dentre eles a DL, na análise de opiniões de clientes em plataformas de comércio online do Vietnã. A DL superou outros modelos.
5	OZYEGEN, O. <i>et al.</i> Classification of multi-level product categories using dynamic masks and transformer models. <b>J. of Data, Inf. and Management</b> , vol. 4, n. 4, p. 71-85, 2022.	Implementou a DL para classificar e categorizar produtos online, superando outros modelos e sendo capaz de apoiar os varejistas.
6	CUI, J. <i>et al.</i> Regional Collaborative Freight Yield Forecast in Circum-Bohai-Sea Region of China Based on LSTM Model. <b>Computational Intelligence and Neuroscience</b> , v. 2022, p. 1-13, 2022.	Implementou a DL para prever a movimentação de cargas portuárias, sendo capaz de superar outros modelos e reduzir custos operacionais.
7	TALAAT, F. M., <i>et al.</i> A Mathematical Model for Customer Segmentation Leveraging Deep Learning, Explainable AI, and RFM Analysis in Targeted Marketing. <b>Mathematics</b> , vol. 11, n. 18, p. 3930, 2023. Disponível em: <a href="https://doi.org/10.3390/math11183930">https://doi.org/10.3390/math11183930</a> . Acesso em: 01 fev. 2024.	Implementou a DL para analisar e segmentar clientes. O modelo superou outros modelos, além de possibilitar com que empresas tomem decisões embasadas em dados.
8	ACHAMRAH, F. E. <i>et al.</i> An artificial immune system-based algorithm enhanced with deep reinforcement learning to solve returnable shipping item problems. <b>Sustainability</b> , vol. 14, p. 5805, 2022. Disponível em: <a href="https://doi.org/10.3390/su14105805">https://doi.org/10.3390/su14105805</a> . Acesso em: 3 fev. 2024.	Implementou um sistema acoplado com aprendizado por reforço profundo para otimizar o fluxo de itens de transporte retornáveis em cadeia de suprimentos, possibilitando economias e redução de custos.
9	SEDAI, A.; <i>et al.</i> Performance analysis of statistical, machine learning and deep learning models in long-term forecasting of solar energy production. <b>Forecast</b> , vol. 5, p. 256-284, 2023.	Implementou a DL na previsão da produção de energia. O modelo não superou os demais.

(continuação)

Trabalhos Selecionados		
Nº	Referência (ABNT)	Objetivo/contexto
10	ABDOLMALEKI, M.; CONSENSO, M.; ESMAEILI, K. Discrimination of ore residues using supervised and unsupervised classification of hyperspectral images. <b>Remote Sensor</b> , vol. 14, p. 6386, 2022. Disponível em: <a href="https://doi.org/10.3390/rs14246386">https://doi.org/10.3390/rs14246386</a> . Acesso em: 03 fev. 2024.	Implementou a DL para identificar resíduos em minério de ferro para otimizar as operações de mineração. O modelo superou os demais.
11	PATALAS-MALISZEWSKA, J.; HALIKOWSKI, D.; DAMAŠEVIČIUS, R., J. An Automated Recognition of Work Activity in Industrial Manufacturing Using Convolutional Neural Networks. <b>Electronics</b> , vol. 10, n. 23, p. 2946, 2021. Disponível em: <a href="https://doi.org/10.3390/electronics10232946">https://doi.org/10.3390/electronics10232946</a> . Acesso em: 5 fev. 2024.	Implementou a DL e visão computacional para analisar e avaliar o trabalho dos colaboradores em uma fábrica, sendo um sistema que pode ser integrado a empresas da indústria 4.0.
12	JIANG, Y.; LEI, Y. Implementation of Trusted Traceability Query Using Blockchain and Deep Reinforcement Learning in Resource Management. <b>Computational Intelligence and Neuroscience</b> , vol. 2022, p. 1-20, 2022	Implementou aprendizado por reforço profundo em questões de agendamento de tarefas no rastreamento de produtos.
13	NABRAWI, E.; ALANAZI, A. Fraud Detection in Healthcare Insurance Claims Using Machine Learning. <b>Risks</b> , vol. 11, n. 9, p. 160, 2023. Disponível em: <a href="https://doi.org/10.3390/risks11090160">https://doi.org/10.3390/risks11090160</a> . Acesso em: 5 fev. 2024.	Implementou modelos, dentre eles a DL, visando identificar fraudes no setor de saúde. Os modelos trazem implicações práticas e econômicas para esse setor.
14	QIN, J. <i>et al.</i> Optimal droplet transfer mode maintenance for wire+arc additive manufacturing (WAAM) based on deep learning. <b>J Intell Manuf</b> , vol. 33, p. 2179-2191, 2022.	Implementou a DL para controlar e estabilizar o processo de produção WAAM e obteve maior precisão entre os modelos comparados.
15	XU, J.; HSU., Y. Analysis of agricultural exports based on deep learning and text mining. <b>J Supercomputer</b> , v. 78, p. 10876-10892, 2022.	Implementou a DL visando prever exportações agrícolas para subsidiar operadores no agronegócio.
16	YU, L.; <i>et al.</i> A Resource Scheduling Method for Reliable and Trusted Distributed Composite Services in Cloud Environment Based on Deep Reinforcement Learning. <b>Frontiers in Genetics</b> , vol. 13, p. 964784, 2022. Disponível em: <a href="https://doi.org/10.3389/fgene.2022.964784">10.3389/fgene.2022.964784</a> . Acesso em: 7 fev. 2024.	Implementou o aprendizado por reforço profundo na tomada de decisão de agendamento de serviços de nuvem para subsidiar a indústria biomédica.
17	ZHANG, F.; FLEYEH, H.; BALES, C. A hybrid model based on bidirectional long short-term memory neural network and Catboost for short-term electricity spot price forecasting. <b>The Journal of the Operational Research Society</b> , v. 73, n. 2, p. 301-325, 2022.	Implementou a DL para prever o preço da eletricidade no curto prazo para maximizar lucros e superando outros modelos.
18	SAMARGHANDI, H., ASKARANY, D; DEHKORDI, B. B. A hybrid method to predict the human action of actors in the accounting information system. <b>Journal of Risk and Financial Management</b> , vol. 16, n. 1, p. 1-37, 2023.	Implementou uma DL capaz de melhorar a seleção e emprego dos recursos humanos por gestores em sistemas contábeis.

(continuação)

Trabalhos Seleccionados		
Nº	Referência (ABNT)	Objetivo/contexto
19	GHOLAMI, S. <i>et al.</i> Using deep learning to improve business intelligence in organizational management. <b>Data Science in Finance and Economics</b> , v. 3, n. 4, p. 337-353, 2023.	Implementou a DL em contexto de <i>Business Intelligence</i> para melhorar o gerenciamento organizacional, superando modelos tradicionais de BI na análise de feedback de clientes.
20	SUDU, B. <i>et al.</i> Retrieving SPAD values of summer corn using UAV hyperspectral data based on multiple machine learning algorithm. <b>Remote Sensor</b> , v. 14, n. 21, p. 5407, 2022. Disponível em: <a href="https://doi.org/10.3390/rs14215407">https://doi.org/10.3390/rs14215407</a> . Acesso em: 10 fev. 2024.	Implementou a DL para prever a clorofila na produção do milho. O modelo desenvolvido apresenta referência técnica para o processo de análise.
21	YAN, W.; SONG, Y. Intelligent Evaluation and Early Warning of Liquidity Risk of Commercial Banks Based on RNN. <b>Computational Intelligence and Neuroscience</b> , vol. 2022, p. 7325798, 2022. Disponível em: <a href="https://doi.org/10.1155/2022/7325798">https://doi.org/10.1155/2022/7325798</a> . Acesso em: 1 fev. 2024.	Implementou a DL para prever o risco de liquidez e oferecer suporte aos bancos comerciais.
22	ANAND, P.; LEE, C. Using Deep Learning to Overcome Privacy and Scalability Issues in Customer Data Transfer. <b>Marketing Science</b> , vol. 42, n. 1, 2023, p. 189-207, 2023.	Implementou a DL para gerar um modelo que realize análises de clientes sem comprometer a privacidade. O modelo desenvolvido soluciona problemas de Marketing relacionados a dados e suas regulamentações.
23	BARIK, K. <i>et al.</i> LSTM-DGWO based sentiment analysis framework for analyzing online customer reviews. <b>Computational Intelligence and Neuroscience</b> , vol. 2023, p. 1-19, 2023.	Implementou um modelo integrado com DL para analisar sentimentos em comentários de clientes. O modelo superou os modelos convencionais.
24	ALBATTAH, W. <i>et al.</i> A Novel Deep Learning Method for Detection and Classification of Plant Diseases. <b>Complex &amp; Intelligent Systems</b> , vol. 8, n. 1, p. 507-524, 2022.	Implementou a DL para identificar doenças de plantas em plantações visando manter a taxa de produção agrícola.
25	CHOW, B.; REYES-ALDASORO, C. Automatic Gemstone Classification Using Computer Vision. <b>Minerals</b> , vol. 12, n. 1, p. 60, 2022. Disponível em: <a href="https://doi.org/10.3390/min12010060">https://doi.org/10.3390/min12010060</a> . Acesso em: 07 fev. 2024	Implementou a DL e visão computacional para inspecionar jóias aplicável ao comércio de jóias, entretanto, obteve desempenho inferior.

Fonte: Elaboração própria.

#### 4.2 Análise dos resultados

Por meio da leitura dos 25 trabalhos identificados, foi realizado o fichamento em conformidade ao passo 4 que retrata a análise da qualidade metodológica segundo Sampaio e Mancini (2007). Com base na realização e análise do fichamento, foi possível classificar os

trabalhos com base nas aplicações da DL abordadas e o desempenho da DL frente a outras abordagens distintas da DL na análise de dados empresariais, abordagens DL utilizadas no processo de análise de dados empresariais e a metodologia de cada estudo selecionado (se são teóricos ou empíricos).

#### 4.2.1 Principais aplicações da *Deep Learning* na análise de dados empresariais

As aplicações predominantes da DL no processo de análise de dados empresariais, em pesquisas publicadas no Periódico do CAPES nos últimos três anos, exibem que a Transformação Digital em cenário organizacional, sobretudo provocada pela DL, podem refletir no desempenho e alcance das empresas, corroborando o que Massruhá *et al.* (2020) havia evidenciado. Esse reflexo é observado nos trabalhos destacados no Quadro 5 que abordam o potencial do uso da DL ao trazer implicações que agregam valor às organizações, como foi apontado por Howard (2013). Conforme o Quadro 5, os pesquisadores da DL empenharam maior interesse em desenvolver modelos DL para analisar dados de clientes buscando gerar reflexões a respeito de seus sentimentos, uma vez que a aplicação da DL possibilita com que empresas possam desempenhar uma visão analítica sobre os clientes, corroborando com o crescente interesse do Marketing pela DL em contexto de aumento de dados como apontado por Liu (2023).

Segundo Bártolo (2018) o meio empresarial denota interesse sobre a DL cujo interesses podem ser justificados pelas pesquisas do Quadro 5. Além das aplicações em Marketing, o uso da DL na análise de dados empresariais revelou um setor de interesse específico pelos pesquisadores, o setor do agronegócio. Sob a ótica de Contador (2001) os pesquisadores da tecnologia nesse setor abordaram exclusivamente a atividade de produzir, em especial a atividade de controle da produção.

Quadro 5: Aplicações da *Deep Learning* na análise de dados empresariais.

Aplicações da <i>Deep Learning</i> (DL) nos trabalhos selecionados	Nº dos Estudos
Desenvolveu um modelo com DL para analisar dados de sentimentos de clientes.	2, 3, 4 e 23.
Desenvolveu um modelo com DL para analisar dados para prever possíveis clientes.	1
Desenvolveu um modelo com DL que promove análise de dados e privacidade do cliente.	22
Desenvolveu um modelo com DL que analisa dados de produtos para classificá-los.	5
Desenvolveu um modelo com DL que analisa dados de clientes para segmentá-los.	7



(continuação)

<b>Aplicações da <i>Deep Learning</i> (DL) nos trabalhos selecionados</b>	<b>Nº dos Estudos</b>
Desenvolveu um modelo com DL para analisar e prever as movimentações de carga.	6
Desenvolveu um modelo com DL para analisar e otimizar a cadeia de suprimentos.	8
Desenvolveu um modelo com DL que analisa dados e otimiza o rastreio de produtos	12
Desenvolveu um modelo com DL que analisa dados para identificar fraudes.	13
Desenvolveu um modelo com DL que analisa dados para prever o risco de liquidez.	21
Desenvolveu um modelo com DL aplicável a Business Intelligence de negócios.	19
Desenvolveu um modelo com DL que analisa dados para prever o preço da eletricidade.	17
Desenvolveu um modelo com DL que analisa dados aplicável no suporte ao agronegócio.	15, 20 e 24
Desenvolveu um modelo com DL que analisa dados para prever a produção de energia.	9
Desenvolveu um modelo com DL que analisa dados para gerar controle de resíduos em mineração.	10
Desenvolveu um modelo com DL que analisa dados e possibilita o controle da produção.	14
Desenvolveu um modelo com DL que analisa jóias aplicável ao comércio de jóias.	25
Desenvolveu um modelo com DL que analisa dados para controle de agendamento de serviços.	16
Desenvolveu um modelo com DL para analisar dados e prever o comportamento do empregado.	18
Desenvolveu um modelo com DL para analisar dados para monitorar o trabalho do colaborador.	11

Fonte: Elaboração própria.

Associando o Quadro 5 ao modelo geral de atividades proposto por Contador (2001), o uso notável das aplicações da DL na análise de dados empresariais são associadas à análise de sentimento de clientes e suporte ao agronegócio, revelando o interesse maior dos pesquisadores da tecnologia DL em atividades que visam atender e produzir.

Associando o Quadro 6 ao protagonismo da DL frente às outras abordagens destacadas por Kraus, Feuerriegel e Oztekin (2020), os resultados confirmam o protagonismo da DL em se tratando de análise de dados empresariais frente a outras abordagens distintas, portanto, corroborando com a perspectiva dos pesquisadores.

Quadro 6: Desempenho da DL frente a outras abordagens.

<b>Desempenho da DL frente a outros modelos distintos de <i>Deep Learning</i></b>	
Aplicações apoiadas com Deep Learning obtiveram desempenho superior nos estudos:	2, 3, 4, 5, 6, 7, 8, 10, 11, 12, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23 e 24.
Aplicações apoiadas com Deep Learning obtiveram desempenho inferior nos estudos:	1, 9, 13 e 25

Fonte: Elaboração própria.

#### 4.2.2 Principais abordagens *Deep Learning* na análise de dados empresariais

Em relação às principais tipologias DL que foram destacadas por Yan e Hu (2023), o uso da DL por pesquisadores revelou que a CNN e a RNN obtiveram maior atenção em estudos relativos à análise de dados empresariais, em especial um tipo de RNN conhecida como *Long Short-Term Memory* (LSTM) conforme aponta o Quadro 7.

Quadro 7: Abordagens DL utilizadas nos estudos.

Abordagens <i>Deep Learning</i> utilizadas nos estudos	Artigos Seleccionados (Numerados conforme Quadro 4)
DNN (DL)	1, 7, 13, 18 e 20.
Processamento de linguagem natural + BERT (Transformadores)	2.
BERT (Transformadores)	3, 5 e 19.
CNN	2, 3, 10, 11, 19, 23, 24 e 25.
LSTM (RNN)	3, 4, 5, 6, 9, 11, 14, 15, 17 e 23.
Aprendizado por reforço profundo	8, 12 e 16.
GRU (RNN)	9 e 17.
GANs (DL)	22.
RNN	6, 11 e 21.

Fonte: Elaboração própria.

#### 4.2.3 Modalidades dos estudos seleccionados

Em relação a Modalidade dos 25 trabalhos seleccionados, o Quadro 8 destaca que os pesquisadores apresentaram interesse no desenvolvimento de trabalhos empíricos por meio do desenvolvimento de modelos DL e validados por meio de análises comparativas.

Quadro 8: Modalidade dos estudos.

Modalidades dos Artigos Seleccionados	Trabalhos Seleccionados (numerados conforme Quadro 4)
Empíricos	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24 e 25.
Teóricos	0 (Zero)

Fonte: Elaboração própria.

#### 4.2.4 Lacunas e oportunidades de estudo no campo da aplicação da DL na análise de dados empresariais

Com base nos resultados da RSL foi possível elaborar uma agenda de pesquisas para futuros estudos. O Quadro 9 lista as oportunidades de estudos que representam lacunas no conhecimento que não foram exploradas por nenhum estudo analisado na presente pesquisa.

Quadro 9: Oportunidades de pesquisa para preencher lacunas.

Oportunidade de pesquisa	Questão de pesquisa	Metodologia Indicada
Aplicação da <i>Deep Learning</i> para identificar <i>Burnout</i> .	Como a <i>Deep Learning</i> pode auxiliar os Recursos Humanos na prevenção de <i>Burnout</i> ?	Desenvolver por meio da Deep Learning um sistema de visão computacional para identificar indicadores visuais de <i>burnout</i> utilizando redes neurais convolucionais (CNN) para análise de expressões faciais e comportamentais dos colaboradores.
Aplicação da <i>Deep Learning</i> no acompanhamento de fornecedores.	Como a <i>Deep Learning</i> pode melhorar a análise de desempenho de fornecedores?	Desenvolver um sistema de análise de desempenho de fornecedores com base em redes neurais recorrentes (RNN), para prever tendências e padrões temporais no desempenho dos fornecedores.
Aplicação da <i>Deep Learning</i> no suporte de empresas em questões de Direito Empresarial	Como a <i>Deep Learning</i> pode auxiliar empresas em questões de Direito Empresarial?	Desenvolver uma rede neural recorrente (RNN) e utilizar como suporte ao direito empresarial por meio da coleta e análise avançada de dados legais da jurisprudência empresarial, possibilitando a identificação de padrões e insights relevantes para a tomada de decisões estratégicas.
Aplicação da <i>Deep Learning</i> para aprimorar as ações estratégicas de empresas em relação às informações sobre cenário político conturbado.	Como a <i>Deep Learning</i> pode auxiliar empresas a serem mais estratégicas em um cenário político conturbado?	Desenvolver um sistema integrado para analisar sentimentos da população e notícias sobre o governo por meio de Processamento de Linguagem Natural, para entender a linguagem das pessoas e notícias, somado aos Transformadores, para processar dados textuais e rede neural convolucional para identificar características emocionais importantes.
Aplicação da <i>Deep Learning</i> em contexto de micro e pequenas empresas.	Como as microempresas podem aplicar a DL na análise de dados empresariais?	Realização de um RSL que aborda contexto de micro e pequenas empresas. A RSL pode buscar listar modelos DL simplificados orientados para esse contexto.
Aplicação da <i>Deep Learning</i> na análise da satisfação do cliente no <i>front office</i> .	Como a DL pode contribuir para analisar sentimentos de clientes no <i>front office</i> ?	Desenvolver um modelo de visão computacional com CNN para avaliar expressão e comportamentos dos clientes no <i>front office</i> .

Fonte: Elaboração própria.

Em conformidade com o último e quinto passo para a RSL segundo Sampaio e Mancini (2007), consiste na demonstração dos resultados identificados e na análise dos mesmos com o intuito

de verificar se a questão de pesquisa delimitada no passo 1 foi respondida pela RSL. A relação entre os objetivos específicos e resultados conquistados são apresentados através do Quadro 10.

Quadro 10: Apresentação dos Resultados.

Apresentação dos Resultados	
Objetivos específicos	Resultados observados
Identificar as principais aplicações da DL na análise de dados e os respectivos desempenhos obtidos.	De acordo com o Quadro 5 é possível identificar que as principais aplicações da DL na análise de dados empresariais estão relacionadas à análise de sentimentos de clientes e suporte ao agronegócio. Com base no Quadro 6 é possível identificar que a aplicação da DL tem demonstrado desempenho superior na análise de dados empresariais em comparação com metodologias distintas.
Identificar dentre as principais abordagens Deep Learning aquelas mais utilizadas na análise de dados empresariais.	De acordo com o Quadro 7 é possível verificar que as metodologias DL mais utilizadas para analisar dados empresariais são a <i>Long Short-Term Memory</i> (LSTM), uma variante da RNN, e as redes neurais CNN.
Propor uma agenda de pesquisa visando orientar futuros estudos sobre a aplicação de DL na análise de dados empresariais, destacando as lacunas no conhecimento sobre a prática e possibilidades de pesquisa em campos atuais.	Em conformidade com o Quadro 8 é possível identificar oportunidades de pesquisas resultantes da RSL. São propostas que envolvem perspectiva de Recursos Humanos, desempenho de fornecedores, Direito Empresarial, cenário político na qual as empresas estão inseridas, contexto de microempresas e Marketing. Em suma, são temáticas que não foram identificadas pela RSL.

Fonte: Elaboração própria.

Após a realização da RSL e da análise dos resultados identificados, foi possível estabelecer um comparativo entre as informações destacadas no referencial teórico sobre o uso da *Deep Learning* na análise de dados empresariais conforme apresentado no Quadro 11.

Quadro 11: Comparativo entre Referencial teórico e a Revisão Sistemática de Literatura

Comparativo entre o Referencial Teórico e a Revisão Sistemática da Literatura		
Trechos do Referencial Teórico	Questões	Trabalhos da RSL (Nº dos estudos)
Segundo Fombellida <i>et al.</i> (2020) o uso da DL deve ser considerado para a Business Intelligence (BI).	Algum artigo considera o uso da DL em BI?	Apenas o trabalho n.º 19.
Para Schmitt (2023), o uso da DL tornará padrão no dia a dia das indústrias, sendo parte do processo de tomada de decisão.	Algum artigo menciona DL em tomada de decisão?	Apenas o trabalho n.º 16.
Conforme Gao (2021), o sistema em DL desenvolvido pelo pesquisador visando a prevenção contra riscos, foi capaz de avaliar riscos financeiros em empresas.	Algum artigo menciona DL na análise de dados para prever riscos financeiros em empresas?	Apenas trabalho n.º 21.

(continuação)

<b>Comparativo entre o Referencial Teórico e a Revisão Sistemática da Literatura</b>		
<b>Trechos do Referencial Teórico</b>	<b>Questões</b>	<b>Trabalhos da RSL (Nº dos estudos)</b>
De acordo com Nikou, Mansourfar e Bagherzadeh (2019) foi indicado que o método baseado em DL apresentou melhor previsão do preço de ações em comparação com outros modelos com base nos dados diários dos preços de ações de empresas.	Algum artigo menciona o uso da DL na análise de dados para prever preços?	Trabalho 17 (preço da eletricidade).
Em relação à atividade produtiva, Abdullayeva e Imamverdiyev (2019) a aplicação da DL no âmbito da gestão e controle da produção gera eficiência na produção de petróleo.	Algum artigo menciona o uso da DL na análise de dados em contexto de gestão e controle da produção?	Trabalhos nº 10 (controle de resíduos na Mineração); 14 (estabilidade da produção WAAM) e 15, 20 e 24 (agronegócio)
No âmbito da gestão agrícola, de acordo com Koul (2021), a DL levou o setor agrícola para um novo patamar.	Algum artigo menciona DL na análise de dados empresariais em contexto agrícola?	Trabalhos 15, 20 e 24.
Takkar <i>et al.</i> (2021) desenvolveu um modelo DL para identificar doenças em plantas por meio de dados visuais.	Algum artigo menciona DL na análise de dados para identificar doenças em plantas?	Apenas o trabalho nº 24.
Segundo Shavaki e Ghahnavieh (2023) a DL em cadeias de abastecimento tem gerado um crescente interesse.	Algum artigo menciona DL em cadeia de abastecimento?	Apenas o trabalho nº 8.
Dito isso, de acordo com Jayaprakash et al. (2023), o modelo DL desenvolvido pelos pesquisadores obteve maior previsão sobre movimentação de cargas de contêineres em portos.	Algum artigo menciona DL na análise de dados para prever a movimentação de cargas?	Apenas o trabalho nº 6.
Segundo Vats e Anastasiu (2023) o modelo DL desenvolvido pelos pesquisadores é capaz de rastrear produtos com eficiência.	Algum artigo menciona o uso da DL em rastreamento de produtos?	Apenas o trabalho nº 12.
No âmbito dos Recursos Humanos, a DL segundo Shi e Li (2021) gera resultados positivos na eficiência e eficácia da aplicação dos Recursos Humanos ao realizar recomendações avaliando o grau de correspondência entre dados da mão de obra e cargos.	Algum estudo menciona o uso da DL na análise da correspondência entre mão de obra e cargos?	Apenas o trabalho nº 18.

(continuação)

<b>Comparativo entre o Referencial Teórico e a Revisão Sistemática da Literatura</b>		
<b>Trechos do Referencial Teórico</b>	<b>Questões</b>	<b>Trabalhos da RSL (Nº dos estudos)</b>
Abdalla e Özyurt (2021) utilizaram modelos DL visando analisar opiniões, pois segundo eles, analisar opiniões ajuda as empresas a melhorar os produtos oferecidos.	Algum artigo menciona DL na análise de dados de sentimentos?	Trabalhos 2, 3, 4 e 23.
Han et al. (2023) desenvolveram um modelo a base de DL voltado à análise de usuários com preservação de dados pessoais para campanhas de Marketing.	Algum artigo menciona DL em análise de dados de clientes e preservação da privacidade?	Apenas o trabalho n ° 22.
De acordo com Lee, Kim e Shim (2021) no e-commerce a classificação eficiência de produtos conforme suas especificações é fundamental, com base nessa perspectiva, os pesquisadores desenvolveram um modelo eficiente na classificação de produtos por meio de suas especificações e com base na DL.	Algum artigo menciona DL na análise de dados para promover a classificação de produtos?	Apenas o trabalho n ° 5
Em relação a Segmentação de clientes, Wang (2022) propôs um modelo com DL capaz de analisar os dados de clientes e promover as suas classificações, sendo um modelo segundo o autor, capaz de melhorar a lucratividade.	Algum artigo menciona DL em análise de dados para a segmentação de clientes?	Apenas o trabalho n ° 7.
De acordo com Wujec (2021), análises de textos financeiros são fontes importantes de informações e a DL desenvolvida pelo pesquisador apresentou capacidade de identificar sentimentos em textos financeiros e os resultados obtidos podem ser utilizados para confecção de estratégias sobre o mercado.	Algum artigo menciona o uso da DL na análise de dados textuais financeiros?	Não.
Segundo Gopal, Subhash e Anil (2022) a DL estruturada com CNN e introduzida por eles tem implicações no monitoramento do trabalho dos colaboradores.	Algum artigo menciona DL no monitoramento de colaboradores?	Apenas o trabalho n ° 11.
Lado-Sestayo e Vivel-Búa (2020), com base na DL modelada e introduzida por meio da análise de dados de lucratividades de um hotel, foi capaz de gerar alta capacidade de previsão sobre a lucratividade.	Algum artigo menciona o uso da DL na análise de dados da lucratividade para prever a lucratividade?	Não.

Fonte: Elaboração própria.

Com a apresentação da análise desenvolvida por meio da RSL, é possível realizar a análise dos resultados e verificar se respondem à questão de pesquisa definida inicialmente (passo 1), sendo: “Como têm sido as aplicações da *Deep Learning* na análise de dados empresariais em estudos publicados entre 2021 e 2023?”. Portanto, a resposta para a questão de pesquisa pode ser dada da seguinte maneira: A partir dos resultados obtidos por meio da

RSL, foi possível observar que as aplicações da DL na análise de dados empresariais têm sido realizadas com maior ênfase na análise de sentimentos de clientes e no suporte ao agronegócio. Além disso, as aplicações da DL na análise de dados empresariais têm sido direcionadas majoritariamente a duas vertentes da DL, a CNN e a RNN. Por fim, as aplicações da DL têm sido promissoras em termos de desempenho no contexto que envolve a análise de dados empresariais, pois mostrou ser uma tecnologia que tem sido superior às outras metodologias de análise de dados nos três últimos anos (2021 - 2023).

## 5. CONSIDERAÇÕES FINAIS

A realização da revisão sistemática de literatura sobre estudos que abordam o uso da DL na análise de dados empresariais teve como objetivo elucidar quais as principais aplicações e desempenho da DL, bem como identificar as principais abordagens DL aplicadas pelos pesquisadores. Além disso, identificar possíveis lacunas que representam oportunidades de pesquisas

Conforme os estudos selecionados, foi possível identificar que a DL tem sido aplicada em atividades de atendimento e produção, representadas pelas aplicações na análise de sentimentos de clientes e suporte ao agronegócio, tendo como principais tecnologias DL utilizadas a CNN e a RNN. No que se refere ao desempenho apresentado, os modelos apoiados pela DL em comparação com outras abordagens distintas obtiveram na maioria dos estudos os melhores desempenhos.

Em relação às lacunas que representam oportunidades de pesquisas: i) nenhum artigo considerado nesta RSL retratou o uso da DL como uma tecnologia de apoio ao cuidado da saúde do funcionário ao analisar dados visuais dos colaboradores; ii) nenhum artigo considerado nesta RSL utilizou a aplicação da DL no suporte a decisões jurídicas ao analisar dados da jurisprudência; iii) nenhum artigo considerado nesta RSL utilizou a DL na análise de dados de sentimentos em contexto de cenário político instável para beneficiar as estratégias das empresas; iv) nenhum artigo considerado nesta RSL avaliou o uso da DL na análise de dados empresariais em contexto de microempresas; v) nenhum artigo considerado nesta RSL avaliou o uso da DL na análise de sentimentos de clientes no *front office*, e vi) nenhum artigo considerado nesta RSL utilizou a DL como uma tecnologia voltada para analisar desempenho dos fornecedores. Diante dessas lacunas é possível constatar que ainda há oportunidades de pesquisas para essa temática que necessitam de estudos e que podem ser direcionados por meio das metodologias indicadas no Quadro 9.

Em relação às implicações teóricas e práticas, o estudo realizado em termos teóricos reforça o uso da DL em contexto que envolve a análise de dados empresariais, uma vez que estudos da temática abordam faces e contextos específicos das empresas o que impossibilitava atribuir uma visão geral da tecnologia aplicada a análise de dados empresariais, e também, por explorar uma tecnologia com baixa aplicação, possibilita um melhor entendimento de sua atual prática. Em termos práticos, o estudo ao analisar o desempenho da tecnologia possibilita atestar para as empresas que a tecnologia tem fundamentos melhores do que metodologias tradicionais de análise de dados o que pode refletir de forma positiva no valor dos negócios caso seja estudada e implementada corretamente.

Por fim, apesar das etapas da RSL terem sido conduzidas de forma atenta e cuidadosa, o presente estudo apresentou limitação relacionado ao critério de inclusão de apenas artigos de livre acesso. O estudo por incluir apenas artigos de livre acesso, ou seja, artigos gratuitos, não considerou artigos pagos, o que implicou em descarte de artigos pagos que estavam relacionados à temática. Apesar da limitação, o estudo e os desenvolvimentos feitos possibilitaram a construção de uma visão geral da aplicação da DL na análise de dados empresariais, e a limitação em questão não afeta a importância do estudo realizado.

## REFERÊNCIAS BIBLIOGRÁFICAS

ABDALLA, G.; ÖZYURT, F. Sentiment analysis of fast food companies with deep learning models. **The Computer Journal**, v. 64, n. 3, p. 383-390, 2021.

ABDULLAYEVA, F.; IMAMVERDIYEV, Y. Development of Oil Production Forecasting Method based on Deep Learning. **Statistics, Optimization & Information Computing**, v. 7, n. 4, p. 826-839, 2019.

ABDOLMALEKI, M.; CONSENSO, M.; ESMAEILI, K. Discrimination of ore residues using supervised and unsupervised classification of hyperspectral images. **Remote Sensor**, vol. 14, p. 6386, 2022. Disponível em: <https://doi.org/10.3390/rs14246386>. Acesso em: 03 fev. 2024.

ABU-ALSAAD, H. A. CNN-Based Smart Parking System. **International Journal of Interactive Mobile Technologies (iJIM)**, v. 17, n. 11, p. 155–170, 2023.



ACHAMRAH, F. E, *et al.* An artificial immune system-based algorithm enhanced with deep reinforcement learning to solve returnable shipping item problems. **Sustainability**, vol. 14, p. 5805, 2022. Disponível em: <https://doi.org/10.3390/su14105805>. Acesso em: 3 fev. 2024.

ADAK, A.; PRADHAN, B.; SHUKLA, N. Sentiment Analysis of Customer Reviews of Food Delivery Services Using Deep Learning and Explainable Artificial Intelligence: Systematic Review. **Foods**, v. 11, n. 10, p. 1-21, 2022.

AGARWAL, M.; SAXENA, A. An overview of natural language processing. **International Journal for Research in Applied Science and Engineering Technology (IJRASET)**, v. 7, n. 5, p. 2811-2813, 2019.

AHMAD, A. *et al.* Performance of deep learning models for classification and detection of common plants in corn and soybean production systems. **Computers and Electronics in Agriculture**, v. 184, p. 106081, 2021. Disponível em: <https://doi.org/10.1016/j.compag.2021.106081>. Acesso em: 28 jan. 2024.

AHMED, S. F. *et al.* Deep learning modeling techniques: current progress, applications, advantages, and challenges. **Artificial Intelligence Review**, [s. l.], v. 56, p. 1-97, 2023.

ALBATTAH, W; *et al.* A Novel Deep Learning Method for Detection and Classification of Plant Diseases. **Complex & Intelligent Systems**, vol. 8, n. 1, p. 507-524, 2022.

ANAND, P.; LEE, C. Using Deep Learning to Overcome Privacy and Scalability Issues in Customer Data Transfer. **Marketing Science**, vol. 42, n. 1, 2023, p. 189-207, 2023.

ANDRADE, A. R.; ROSEIRA, C. A informação como elemento de integração entre propósito, processos e pessoas em instituições brasileiras e portuguesas 1. **REAd. Revista Eletrônica de Administração**, Porto Alegre, v. 23, p. 292-316, 2017.

AZAR, A. T. *et al.* Drone Deep Reinforcement Learning: A Review. **Electronics**, v. 10, n. 9, p. 999, 2021. Disponível em: <https://doi.org/10.3390/electronics10090999>. Acesso em: 28 jan. 2024

BALAKRISHNAN, N.; PELUSI, D.; GANESAN, S. Special issue on “Big Data Analytics and Deep Learning for E-Business Outcomes”. **Inf Syst E-Bus Manage**, v. 18, p. 281–282, 2020.

BARIK, K. *et al.* LSTM-DGWO based sentiment analysis framework for analyzing online customer reviews. **Computational Intelligence and Neuroscience**, vol. 2023, p. 1-19, 2023.

BAS, J.; CIRILLO, C.; CHERCHI, E. Classification of potential electric vehicle buyers: a machine learning approach. **Technological Forecasting and Social Change**, v. 168, p. 120759, 2021. Disponível em: <https://doi.org/10.1016/j.techfore.2021.120759>. Acesso em: 27 jan. 2024

BHATTACHARJEE, S. Optimization Techniques in Logistics Management Using Deep Learning Algorithms. **IUP Journal of Operations Management**, vol. 22, ed. 3, p. 23-30, 2023.

BOUTE, R. N. *et al.* Deep reinforcement learning for inventory control: A roadmap. **European Journal of Operational Research**, vol. 298, n. 2, p. 401-412, 2022.

BRAGA, A. A Gestão da Informação. **Revista Millenium**, Viseu, v. 1, n. 19, p.1-10, 2000.

BRAGA, R. M. **Impacto da gestão da informação e inovação tecnológica no empreendedorismo digital**. 2021. 66 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Produção) - Escola de Engenharia de Petrópolis, Universidade Federal Fluminense, Petrópolis, 2021.

BRITO, Ana Paula Gonçalves; DE OLIVEIRA, Guilherme Saramago; DA SILVA, Brunna Alves. A importância da pesquisa bibliográfica no desenvolvimento de pesquisas qualitativas na área de educação. **Cadernos da FUCAMP**, v. 20, n. 44, p. 1-15, 2021.

BRYNJOLFSSON, E.; HITT, L.; KIM, H. Strength in Numbers: How Does Data-Driven Decisionmaking Affect Firm Performance? 22 de abril de 2011. **SSRN Electronic Journal** 1, [s. l.], v. 1, p. 1-28, 2011.

CANEDO, F. L. O. **Privacidade e ética na sociedade de dados: Uma reflexão filosófica sobre a Lei Geral de Proteção de Dados brasileira**. 2021. 125 f. Dissertação (Mestrado em Direito) - Pontifícia Universidade Católica de São Paulo, São Paulo, 2021.

CAPES. Coordenação de Aperfeiçoamento de Pessoal de Nível Superior. **Guia de acesso ao Portal de Periódicos da CAPES**. Brasília: CAPES, 2019. 144 p.

CARMO NETO, F. V. **Análise de sentimentos de reviews de produtos em e-commerces brasileiros**. 2022. 33 f. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) - Universidade Federal de Alagoas, UFAL, Campus Arapiraca, Unidade Educacional Arapiraca, 2022.

CHAGAS, E. T. de O. Deep Learning e suas aplicações na atualidade. **Revista Científica Multidisciplinar Núcleo do Conhecimento**. [s. l.], v. 4, ed. 5, p. 5-26, 2019.

CHAI, J. *et al.* Deep learning in computer vision: A critical review of emerging techniques and application scenarios. **Machine Learning with Applications**, v. 6, p. 1-13, 2021.

CHANG, Y.; KU, C.; NGUYEN, D. L. Aspect-based sentiment prediction using deep learning and information visualization: The impact of COVID-19 on the airline industry. **Information and Management**, v. 59, n. 2, p. 103587, 2022. Disponível em: <https://doi.org/10.1016/j.im.2021.103587>. Acesso em: 15 jan. 2024.

CHEN, X.; LIN, X. Big data deep learning: desafios e perspectivas. Big data deep learning: challenges and perspectives. **IEEE access**, [s. l.], v. 2, p. 514-525, 2014.

CHOW, B.; REYES-ALDASORO, C. Automatic Gemstone Classification Using Computer Vision. **Minerals**, vol. 12, n. 1, p. 60, 2022. Disponível em: <https://doi.org/10.3390/min12010060>. Acesso em: 07 fev. 2024

CONTADOR, J. C. Modelo geral das atividades da empresa. **Gestão & Produção**, v. 8, p. 219-236, 2001.

CORONEOS, J. A. C. A Transformação Digital como agente transformadora na Gestão do Conhecimento em Ciência da Informação. *In*: CARVALHO, F. C. A de. **Ensaio sobre a Transformação Digital e Gestão do Conhecimento**. São Paulo: SBGC, p. 16-19, 2020.

COSTA, S. D. M. Engajamento no trabalho: estudo bibliométrico da produção científica nacional nas plataformas Capes e Spell (2010-2019). **Revista Gestão & Conexões**, v. 10, n. 2, p. 53-70, 2021.

CUI, J. *et al.* Regional Collaborative Freight Yield Forecast in Circum-Bohai-Sea Region of China Based on LSTM Model. **Computational Intelligence and Neuroscience**, v. 2022, p. 1-13, 2022.

DAMACENO, S. S. *et al.* Inteligência artificial: uma breve abordagem sobre seu conceito real e o conhecimento popular. **Caderno de Graduação-Ciências Exatas e Tecnológicas-UNIT-SERGIPE**, [s. l.], v. 5, n. 1, p. 11-11, 2018.

DESHAI, N.; BHASKARA RAO, B. Unmasking deception: An adaptive CNN and PSO approach to detect fake online reviews. **Soft Computing**, vol. 27, p. 11357–11378, 2023.

FELICIANO, M. B. D. **Classificação e Predição de Preços de Imóveis a Partir de Dados Estruturados e Não Estruturados**. 2018. 33 f. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) - Universidade Federal de Pernambuco, Pernambuco, 2018.

FOMBELLIDA, J. *et al.* Enfrentando a inteligência de negócios com aprendizado profundo bioinspirado. **Computação Neural e Aplicações**, v. 32, p. 13195-13202, 2020.

FRANÇA, I. O. de. **Deep Learning: A relação entre inteligência artificial e organização da informação**. 2022. 51 f. Trabalho de Conclusão de Curso (Bacharelado em Biblioteconomia e Gestão de Unidades de informação.) - Faculdade de Administração e Ciências Contábeis, Rio de Janeiro, 2022.

FORKE, C.; TROPMANN-FRICK, M. Técnicas de engenharia de recursos e processamento de dados espaço-temporais. **Datenbank-Spektrum**, v. 21, p. 237-244, 2021.

GALVÃO, M. C. B.; RICARTE, I. L. M. Revisão sistemática da literatura: conceituação, produção e publicação. **Logeion: Filosofia da informação**, [s. l.], v. 6, n. 1, p. 57-73, 2019.

GAMA, M. X. B. *et al.* A Liderança na Era da Informação e do Conhecimento nas empresas. **Research, Society and Development**, v. 3, n. 1, p. 2-18, 2016.

GANAIE, M.A. *et al.* Ensemble deep learning: A review. **Artificial Intelligence Engineering Applications**, v. 115, p. 1-18, 2022.

GAO, B. O uso de aprendizado de máquina aliado à tecnologia de mineração de dados na prevenção de riscos financeiros. **Economia Computacional**, v. 59, n. 4, p. 1385-1405, 2022.

GHOLAMI, S. *et al.* Using deep learning to improve business intelligence in organizational management. **Data Science in Finance and Economics**, v. 3, n. 4, p. 337-353, 2023.

GOPAL, P. G.; SUBHASH, N. S.; ANIL, R. A. Analysis of Employee Surveillance System using Deep Learning Models. In: 2022 - 6th International Conference On Computing, Communication, Control And Automation (ICCUBEA). **Proceedings[...]** Proce Pune, Índia: IEEE, 2022, p. 1-6.

HAN, Q. *et al.* Towards privacy-preserving digital marketing: an integrated framework for user modeling using deep learning on a data monetization platform. **Electronic Commerce Research**, v. 23, p. 1701-1730, 2023.

HOSAKI, G. Y.; RIBEIRO, D. F. Deep learning: ensinando a aprender. **RGE - Revista de Gestão e Estratégia**. Assis, v.1, n.3, p. 36-50, 2021.

HO, T.T.; BUI, H.M.; PHUNG K. A hybrid model for sentiment analysis based on aspects of customer feedback: research on the mobile commerce sector in Vietnam. **International Journal of Advances in Intelligent Computing**, v. 2, p. 273-285, 2023.

HOWARD, J. The business impact of deep learning. *In*: Proceedings of the 19th ACM SIGKDD international conference on knowledge discovery and data mining (KDD '13). New

York, USA. **Proceedings [...]**, New York: Association for Computing Machinery, 2013. p. 1135.

HU, Z.; ZHAO, Y.; KHUSHI, M. A survey of stock and forex price prediction using deep learning. **Applied Systems Innovation**, v. 4, no. 1, p. 1-34, 2021.

INOMATA, D. O. *et al.* Análise da produção científica brasileira sobre fluxos de informação. **Biblios**, n. 59, p. 1-17, 2015.

ISLAM, S.; AMIN, S. H.; WARDLEY, L. J. A supplier selection & order allocation planning framework by integrating deep learning, principal component analysis, and optimization techniques. **Expert Systems with Applications**, Vol. 235, p. 121121, 2024. Disponível em: <http://dx.doi.org/10.1016/j.eswa.2023.121121>. Acesso em: 10 fev. 2024.

JAYAPRAKASH, P. O. *et al.* Artificial Bee Colony Optimized Recurrent Neural Network-Based Port Container Throughput Forecast. **International Journal of Intelligent Systems and Applications in Engineering**, v. 11, n. 1, p. 12-17, 2023.

JIANG, Y.; LEI, Y. Implementation of Trusted Traceability Query Using Blockchain and Deep Reinforcement Learning in Resource Management. **Computational Intelligence and Neuroscience**, vol. 2022, p. 1-20, 2022

JIN, L.; TAN, F.; JIANG, S. Generative Adversarial Network Technologies and Applications in Computer Vision. **Computational Intelligence and Neuroscience**, vol. 2020, p. 1-17, 2020.

KAUFMAN, D. Dossiê: Deep learning: a Inteligência Artificial que domina a vida do século XXI. **TECCOG - Revista Digital de Tecnologias Cognitivas**, São Paulo, n. 17, p. 17-30, 2018.

KIM, Y.; LEE, H. J.; SHIM, J. Developing data-conscious deep learning models for product classification. **Applied Sciences**, v. 11, n. 12, p. 5694, 2021. Disponível em: <https://doi.org/10.3390/app11125694>. Acesso em: 28 jan 2024.

KOUL, S. Machine learning and deep learning in agriculture. *in: PATEL, G. S. et al. Smart Farming: Emerging Pedagogies of Deep Learning. Machine Learning, and the Internet of Things*. Boca Raton: CRC Press, 2021, ed. 1, p. 1-19.

KRAUS, M.; FEUERRIEGEL, S.; OZTETKIN, A. Aprendizado profundo em análise de negócios e pesquisa operacional: modelos, aplicações e implicações gerenciais. **European Journal of Operational Research**, v. 281, n. 3, p. 628-641, 2020.

LADO-SESTAYO, R.; VIVEL-BÚA, M. Rentabilidade hoteleira: uma abordagem de rede neural multicamadas. **Revista de Tecnologia em Hotelaria e Turismo**, v. 1, p. 35-48, 2020.

LEKKALA, L. R. Importância dos modelos de aprendizado de máquina na detecção de fraudes em saúde. **Voz do Editor**, v. 9, n. 4, p. 207-215, 2023.

LI, H. Deep Learning for Natural Language Processing: Advantages and Challenges. **National Scientific Review**, v. 1, p. 24-26, 2017.

LIU, X. Aprendizado profundo em marketing: uma agenda de revisão e pesquisa. **Inteligência Artificial em Marketing**, v. 20, p. 239-271, 2023.

MARTÍNEZ-ARELLANO, G.; TERRAZAS, G.; RATCHEV, S. Classificação de desgaste de ferramentas usando imagens de séries temporais e aprendizado profundo. **O Jornal Internacional de Tecnologia de Fabricação Avançada**, v. 104, p. 3647-3662, 2019.

MASSRUHÁ, S. M. F. S. *et al.* A transformação digital no campo rumo à agricultura sustentável e inteligente. *In: MASSRUHÁ, S. M. F. S. et al. Agricultura Digital: Pesquisa, desenvolvimento e inovação nas cadeias produtivas*. Brasília, DF: Embrapa, 1. ed., cap. 1, p. 20-45, 2020.

MATSUZAKA, Y.; YASHIRO, R. Técnicas de visão computacional baseadas em IA e sistemas especialistas. **AI**, vol. 4, n. 1, p. 289-302, 2023.

MELO, J. F.; ROCKEMBACH, M. Arquivologia e Ciência da Informação na era do Big Data: perspectivas de pesquisa e atuação profissional em arquivos digitais. **Prisma.com**, Porto, Portugal, n. 39, p. 14-28, 2019.

MEZZOGORI, D.; ZAMMORI, F. An entity embeddings deep learning approach for demand forecast of highly differentiated products. **Procedia Manufacturing**, v. 39, p. 1793-1800, 2019.

NABRAWI, E.; ALANAZI, A. Fraud Detection in Healthcare Insurance Claims Using Machine Learning. **Risks**, vol. 11, n. 9, p. 160, 2023. Disponível em: <https://doi.org/10.3390/risks11090160>. Acesso em: 5 fev. 2024.

NAJAFABADI, M. M. *et al.* Aplicações de aprendizagem profunda e desafios na análise de big data. **Revista de big data**, v. 1, pág. 1-21, 2015.

NEU, D. A.; LAHANN, J.; FETTKE, P. Uma revisão sistemática da literatura sobre métodos de aprendizagem profunda de última geração para previsão de processos. **Artificial Intelligence Review**, vol. 55, n. 5, p. 801-827. 2022.

NIKOU, M.; MANSOURFAR, G.; BAGHERZADEH, J. Previsão de preços de ações usando algoritmo de aprendizado DEEP e sua comparação com algoritmos de aprendizado de máquina. **Sistemas Inteligentes em Contabilidade, Finanças e Gestão**, v. 26, n. 4, p. 164-174, 2019.

OLIVEIRA, G. A. P. *et al.* A importância das redes sociais nas decisões organizacionais: Um estudo sobre a fidelização de clientes. **Brazilian Business Law Journal/Administração de Empresas em Revista**, v. 14, n. 15, p. 1-17, 2015.

OZYEGEN, O. *et al.* Classification of multi-level product categories using dynamic masks and transformer models. **J. of Data, Inf. and Management**, vol. 4, n. 4, p. 71-85, 2022.

PAIVA, A. B.; OLIVEIRA, G. S.; HILLESHEIM, M. C. P. Análise de conteúdo: uma técnica de pesquisa qualitativa. **Revista Prisma**, v. 2, n. 1, p. 16-33, 2021.

PATALAS-MALISZEWSKA, J.; HALIKOWSKI, D.; DAMAŠEVIČIUS, R. J. An Automated Recognition of Work Activity in Industrial Manufacturing Using Convolutional Neural Networks. **Electronics**, vol. 10, n. 23, p. 2946, 2021. Disponível em: <https://doi.org/10.3390/electronics10232946>. Acesso em: 5 fev. 2024.



PEREIRA, M. C. **Análise de soluções “Big Data” para monitorização de consumos de água**. 2015. 110 f. Dissertação (Mestrado em Sistemas de Informação) - Universidade de Aveiro, Aveiro, Portugal, 2015.

PEREIRA, R. D. R.; MURAI, F. Quão efetivas são Redes Neurais baseadas em Grafos na Detecção de Fraude para Dados em Rede? *In: BRAZILIAN WORKSHOP ON SOCIAL NETWORK ANALYSIS AND MINING (BRASNAM)*, vol. 10., 2021, Evento Online. **Anais [...]**. Porto Alegre: Sociedade Brasileira de Computação, 2021, p. 205-210.

PINÇON, A. C. M. **A Transformação Digital das Empresas no Brasil**. Trabalho de Conclusão de Curso (Especialização MBA em Tecnologia da Informação-Executivo), Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2017.

PIMENTA, R. M. Big data e controle da informação na era digital: tecnogênese de uma memória a serviço do mercado e do estado. **Tendências da Pesquisa Brasileira em Ciência da Informação**, [s. l.], v. 6, n. 2, p. 1-15 2013.

PUNIA, S. *et al.* Deep learning with long short-term memory network and random forest for demand forecasting in multi-channel retail. **International Journal of Production Research**, [s. l.], v. 58, n° 16, p. 4964-4979, 2020.

QIN, J. *et al.* Optimal droplet transfer mode maintenance for wire+arc additive manufacturing (WAAM) based on deep learning. **J Intell Manuf**, vol. 33, p. 2179-2191, 2022.

RAUTENBERG, S.; CARMO, P. R. V. Big data e ciência de dados: complementariedade conceitual no processo de tomada de decisão. **Brazilian Journal of Information Science: research trends**, [s. l.], v. 13, n. 1, p. 56–67, 2019. DOI: 10.36311/1981-1640.2019

SAMARGHANDI, H., ASKARANY, D; DEHKORDI, B. B. A hybrid method to predict the human action of actors in the accounting information system. **Journal of Risk and Financial Management**, vol. 16, n. 1, p. 1-37, 2023.

SAMPAIO, R. F.; MANCINI, M. C. Estudos de Revisão Sistemática: um guia para síntese

critérioria da evidéncia científica. **Revista Brasileira de Fisioterapia**, v. 11, n. 1., p. 83-89, 2007.

SANTOS, A. T. **Desenvolvimento de estratégia para projeto de controlador preditivo baseada em deep learning**. 2023. 45 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Química) - Universidade Federal de Alagoas, Maceió, 2020.

SAPRONOVA, A. *et al.* Deep learning for wind energy production forecasting. *In: Norwegian Big Data Symposium, Proceedings [...]*. Trondheim, Noruega: CEUR, 2016, v. 1818, p. 28-33.

SCHMITT, M. Deep learning in business analytics: A clash of expectations and reality. **International Journal of Information Management Data Insights**, [s. l.], v. 3, n. 1, p. 100146, 2023. Disponível em: <https://doi.org/10.1016/j.jjime.2022.100146>. Acesso em: 17 nov. 2023.

SEDAI, A.; *et al.* Performance analysis of statistical, machine learning and deep learning models in long-term forecasting of solar energy production. **Forecast**, vol. 5, p. 256-284, 2023.

SEGURA-MUÑOZ, S. I. *et al.* Revisão sistemática da literatura e metanálise: noções básicas sobre seu desenho, interpretação e aplicação na área de saúde. *In: Anais do 8º Simpósio Brasileiro de Comunicação em Enfermagem. Anais [...]* Ribeirão Preto: Escola de Enfermagem de Ribeirão Preto, Universidade de São Paulo, 2002. Disponível em: <http://www.proceedings.scielo.br>. Acesso em: 18 fev. 2024.

SHAVAKI, F. H.; GHANAVIEH, A. E. Applications of deep learning into supply chain management: a systematic literature review and a framework for future research. **Artificial Intelligence Review**, v. 56, n. 5, p. 4447-4489, 2023.

SHI, W.; LI, Q. Human resources balanced allocation method based on deep learning algorithm. **Scientific Programming**, v. 2021, p. 1-9, 2021.

SILVA, A. M. *et al.* **Coletânea Luso-Brasileira XI: Gestão da informação, cultura organizacional e literacia**. 11<sup>a</sup>: Porto, Portugal: FLUP – U. PORTO, 2020, p. 231.

SILVA, F. H. B; FERREIRA, M. F.; BORGES, A. M. Abordagens Estratégicas sobre as Vantagens e Desafios na Implantação dos Sistemas ERP. **Revista Agroveterinária, Negócios e Tecnologias**, [s. l.] v. 2, n. 1, p. 103-113, 2017.

SONI, V. Deep Learning and Computer Vision-Based Retail Analytics for Customer Interaction and Response Monitoring. **Eigenpub Review of Science and Technology**, v. 5, n. 1, p. 1-15, 2021.

SOUZA, E. R.; BUZO, L. J. **A importância das ferramentas de análise de dados na gestão da pandemia de Covid-19: a utilização do Power Bi**. 2021. Trabalho de Conclusão de Curso (Bacharelado em Tecnologia em Sistemas para Internet) - Faculdade de Tecnologia Prof. José Camargo - Fatec Jales, São Paulo, 2021.

SOUZA, M.; ALMEIDA, F. G.; SOUZA, R. R. O termo Big Data: quebra de paradigma dos n-V's?. In: II Workshop de Informação, Dados e Tecnologia (WIDaT 2018), 2018, João Pessoa. **Anais [...]** João Pessoa: Editora UFPB, 2018. p. 246-253.

SUDU, B. *et al.* Retrieving SPAD values of summer corn using UAV hyperspectral data based on multiple machine learning algorithm. **Remote Sensor**, v. 14, n. 21, p. 5407, 2022. Disponível em: <https://doi.org/10.3390/rs14215407>. Acesso em: 10 fev. 2024.

TAKKAR, S. *et al.* Reconhecimento de doenças foliares de plantas baseadas em imagens usando modelos de classificação de aprendizagem profunda. **Natureza, Meio Ambiente e Tecnologia de Poluição**, v. 20, n. 5, p. 2137-2147, 2021.

TALAAT, F. M., *et al.* A Mathematical Model for Customer Segmentation Leveraging Deep Learning, Explainable AI, and RFM Analysis in Targeted Marketing. **Mathematics**, vol. 11, n. 18, p. 3930, 2023. Disponível em: <https://doi.org/10.3390/math11183930>. Acesso em: 01 fev. 2024.

TOMAR, D.; TOMAR, P.; KAUR, G. Aprendizado profundo em Big Data e Internet das Coisas. In: Tecnologia de Informação, Comunicação e Computação: Terceira Conferência Internacional, ICICCT 2018. **Proceedings [...]** Nova Delhi, Índia, 12 de maio de 2018, Artigos Seleccionados Revisados 3 . Springer Singapura, 2019. p. 70-81.

VALE JÚNIOR, C. P. **Desenvolvimento de um aplicativo para monitoramento de banco de dados**. 2020. 79 f. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) - Pontifícia Universidade Católica, Goiânia, 2020.

VATS, A.; ANASTASIU, D. C. Enhancing Retail Checkout Through Video Inpainting, YOLOv8 Detection, and DeepSort Tracking. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. **Proceedings [...]** Vancouver, Canadá: IEEE Xplore, 2023, p. 5529-5536.

VIEIRA, V. F. G. **Auditoria em tempos de Big Data & Analytics. Requisitos mínimos de controlo**. 2016. 95 f. Dissertação (Mestrado em Auditoria Empresarial e Pública). Instituto Superior de Contabilidade e Administração de Coimbra - Instituto Politécnico de Coimbra, Coimbra, Portugal, 2016.

WANG, C. Efficient customer segmentation in digital marketing using deep learning with swarm intelligence approach. **Information Processing & Management**, v. 59, n. 6, p. 103085, 2022. Disponível em: <https://doi.org/10.1016/j.ipm.2022.103085>. Acesso em: 15 fev. 2024.

WUJEC, M. Analysis of the Financial Information Contained in the Texts of Current Reports: A Deep Learning Approach. **Journal of Risk and Financial Management**, v. 14, n. 12, p. 582, 2021. Disponível em: <https://doi.org/10.3390/jrfm14120582>. Acesso em: 17 fev. 2024.

XU, J.; HSU., Y. Analysis of agricultural exports based on deep learning and text mining. **J Supercomputer**, v. 78, p. 10876-10892, 2022.

YANG, Z. *et al.* A systematic literature review of methods and datasets for anomaly-based network intrusion detection. **Computers & Security**, v. 116, p. 102675, 2022. Disponível em: <https://doi.org/10.1016/j.cose.2022.102675>. Acesso em: 7 fev. 2024..

YAN, W.; SONG, Y. Intelligent Evaluation and Early Warning of Liquidity Risk of Commercial Banks Based on RNN. **Computational Intelligence and Neuroscience**, vol. 2022, p. 7325798, 2022. Disponível em: <https://doi.org/10.1155/2022/7325798>. Acesso em: 1 fev. 2024.

YAN, Y.; HU, Y. Um método de adaptação de domínio não supervisionado baseado em transformador para reconhecimento de comportamento de esqueleto. **IEEE Access**, v. 8, p. 51689-51700, 2023.

YU, L.; *et al.* A Resource Scheduling Method for Reliable and Trusted Distributed Composite Services in Cloud Environment Based on Deep Reinforcement Learning. **Frontiers in Genetics**, vol. 13, p. 964784, 2022. Disponível em: [10.3389/fgene.2022.964784](https://doi.org/10.3389/fgene.2022.964784). Acesso em: 7 fev. 2024.

ZHANG, F.; FLEYEH, H.; BALES, C. A hybrid model based on bidirectional long short-term memory neural network and Catboost for short-term electricity spot price forecasting. **The Journal of the Operational Research Society**, v. 73, n. 2, p. 301-325, 2022.

ZHAO, K.; DU, C.; TAN, G. Improving basketball game outcome prediction via fused graph convolutional networks and expected forest algorithm. **Entropy**, v. 25, n. 5, p. 765, 2023. Disponível em: <https://doi.org/10.3390/e25050765>. Acesso em: 24 jan. 2024.