



Rafael de Oliveira Vargas

Transformação digital na indústria de Defesa: análise da adoção da Inteligência Artificial na performance e resiliência da cadeia de suprimentos.

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Logística da PUC-Rio, do Departamento Industrial da PUC-Rio.

Orientador: Prof. Rodrigo Goyannes Gusmão Caiado

Coorientador: Prof. Adauto Farias Bueno

Rio de janeiro

26 de janeiro de 2024



Rafael de Oliveira Vargas

**Transformação digital na indústria de Defesa:
análise da adoção da Inteligência Artificial na
performance e resiliência da cadeia de
suprimentos.**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Logística da PUC-Rio. Aprovada pela comissão examinadora abaixo:

Prof. Rodrigo Goyannes Gusmão Caiado

Orientador

Departamento de Engenharia Industrial - PUC-Rio

Prof. Adauto Farias Bueno

Coorientador

Universidade do Estado do Mato Grosso

Prof. Renan Silva Santos

Departamento de Engenharia Industrial - PUC-Rio

Prof. Julio Vieira Neto

Universidade Federal Fluminense

Prof. Daniel Luiz de Mattos Nascimento

Universitat de Barcelona

Rio de Janeiro

26 de Janeiro de 2024.

Todos os direitos reservados. A reprodução, total ou parcial, do trabalho é proibida sem autorização do autor, do orientador e da universidade.

Rafael de Oliveira Vargas

Oficial intendente da Marinha do Brasil há 18 anos. Trabalhou por 5 anos na logística de abastecimento de navios e aeronaves na região amazônica. Atualmente, trabalha no Hospital Naval da Marinha onde desempenha tarefas relacionadas à logística de material de saúde. Mestrando em logística na Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio), possui Especialização em Gestão Pública pela Universidade Federal do Rio de Janeiro (UFRJ) e Bacharelado em Ciências Navais pela Escola Naval do Brasil.

Ficha Catalográfica

Vargas, Rafael de Oliveira

Transformação digital na indústria de defesa : análise da adoção da inteligência artificial na performance e resiliência da cadeia de suprimentos / Rafael de Oliveira Vargas ; orientador: Rodrigo Goyannes Gusmão Caiado ; coorientador: Adauto Farias Bueno – 2024.

89 f. : il. color. ; 30 cm

Dissertação (mestrado)—Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2024.

Inclui bibliografia

1. Engenharia Industrial – Teses. 2. Indústria 4.0. 3. Setor de defesa. 4. Inteligência artificial. 5. Cadeia de Suprimentos. I. Caiado, Rodrigo Goyannes Gusmão. II. Bueno, Adauto Farias. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. IV. Título.

CDD: 658.5

Agradecimentos

Em primeiro lugar, agradeço a Deus por ser a fonte de toda sabedoria e por guiar meus passos ao longo dessa jornada. Suas bênçãos foram a luz que iluminou meu caminho nos momentos desafiadores e a força que sustentou minha determinação.

À minha amada esposa, expresso minha eterna gratidão por seu apoio incondicional. Seu amor, paciência e compreensão foram pilares essenciais que me fortaleceram durante os períodos intensos de estudo e pesquisa. Juntos, compartilhamos as alegrias das conquistas e enfrentamos os desafios com união e resiliência.

Aos meus pais, cujos sacrifícios e dedicação foram cruciais para que eu pudesse seguir meus estudos, expresso meu profundo agradecimento. Seu apoio inabalável e valores fundamentaram minha jornada acadêmica, tornando esta conquista não apenas minha, mas também de nossa família.

À Marinha do Brasil, sou grato pela oportunidade de realizar este mestrado. A confiança depositada em mim é um privilégio que levarei comigo ao longo de toda minha carreira. Agradeço também aos meus superiores e colegas pela colaboração e incentivo, que foram essenciais para o sucesso deste empreendimento.

Aos meus orientador e coorientador, expresso minha sincera gratidão. Ao orientador, agradeço a paciência, orientação e dedicação incansável. Sua liderança e sabedoria foram fundamentais para moldar meu trabalho de pesquisa. Ao coorientador, agradeço a valiosa contribuição à minha dissertação, enriquecendo-a com perspectivas e insights essenciais.

A todos os professores do programa de mestrado profissional em Logística do departamento de Engenharia Industrial da PUC, agradeço pelos conhecimentos transmitidos. Suas aulas foram inspiradoras, desafiadoras e fundamentais para o desenvolvimento das competências necessárias para este feito.

Por fim, aos meus colegas de sala de aula, agradeço pelos momentos de mútua ajuda e companheirismo. Nossa jornada foi marcada por colaboração e aprendizado conjunto, e levo conosco as lembranças de uma verdadeira comunidade acadêmica.

Resumo

De Oliveira Vargas, Rafael; Goyannes Gusmão Caiado, Rodrigo; Farias Bueno, Aduino. **Transformação digital na indústria de Defesa: análise da adoção da Inteligência Artificial na performance e resiliência da cadeia de suprimentos.** Rio de Janeiro, 2023. 89p. Dissertação de Mestrado – Programa de Pós-Graduação em Logística, Pontifícia Universidade Católica do Rio de Janeiro.

A Indústria 4.0 (I4.0) está provocando mudanças significativas na dinâmica competitiva de diversos setores econômicos. Os avanços tecnológicos impulsionados pela I4.0 na gestão da cadeia de suprimentos (SCM) têm sido objeto de estudo abrangente tanto na academia quanto na indústria. A *SCM* desempenha um papel fundamental no aprimoramento da eficiência operacional, na promoção da satisfação do cliente, na redução de custos e na adaptação às mudanças de mercado. Ao trazer essas perspectivas para o contexto empresarial, a sigla VUCA (Volatilidade; Incerteza; Complexidade; e Ambiguidade), que descreve um mundo volátil, incerto, complexo e ambíguo, ganha relevância considerável. Adicionalmente, eventos altamente improváveis e imprevisíveis, denominados *Black Swan*, como a COVID-19 e a guerra entre Rússia e Ucrânia, deixam o cenário ainda mais inconstante. Ao concentrar-se no setor de defesa, surgem desafios adicionais, dadas as circunstâncias singulares associadas à defesa de um país. Nesse cenário desafiador, entre as tecnologias introduzidas pela I4.0 com aplicação na *SCM*, a Inteligência Artificial (IA) destaca-se pela diferenciação estratégica que proporciona aos que a adotam. A IA desempenha um papel central no processo de transformação digital de qualquer organização. Assim, o objetivo desta pesquisa é identificar e avaliar a adoção de IA na performance e resiliência da cadeia de suprimentos do setor de defesa nacional. Para tal, utilizou-se uma metodologia mista de pesquisa, iniciando-se por uma revisão de escopo que identificou o estado da arte e tendências futuras da I4.0 na *SCM* do setor de defesa, culminando na elaboração de uma agenda de pesquisa composta por 4 clusters. Em seguida, realizou-se uma revisão sistemática da literatura de modo a identificar e analisar os fatores que afetam a adoção da IA no setor de defesa a partir dos achados da revisão de escopo e de artigos de grande relevância sobre o tema pesquisado, resultando na formulação de constructos e variáveis relacionados aos fatores que influenciam a adoção de IA e como essa tecnologia impacta a cadeia de suprimentos. Como terceiro método de pesquisa, conduziu-se um *survey* aplicado no setor de defesa com o propósito de se identificar e avaliar empiricamente a adoção de IA no desempenho e resiliência da cadeia de suprimentos. Foram feitas análises descritivas e fatorial exploratória dos dados, chegando-se a 6 fatores latentes compostos pelas variáveis com maiores cargas fatoriais e permitindo a formulação de novos constructos e variáveis que agora aguardam uma análise confirmatória por meio de pesquisas futuras. Por fim, a pesquisa propõe um *roadmap* para fortalecer e melhorar o desempenho da cadeia de suprimentos na indústria de Defesa, usando IA. Este novo artefato foi desenvolvido por meio de uma abordagem que combina diferentes métodos, como análise bibliométrica, revisão sistemática e questionários, para entender e explorar os desafios. Para demonstrar sua aplicação prática, o plano foi adaptado para a Marinha do Brasil, destacando como a IA pode ser usada no planejamento e execução de metas para aumentar a robustez, resiliência e responsividade (Triple-R) da cadeia de suprimentos, considerando-se tanto os aspectos técnicos quanto sociais do contexto institucional. Além disso, a pesquisa teórica resultou em uma agenda de futuras pesquisas sobre transformação digital na indústria de defesa, delineando um caminho para o desenvolvimento de soluções inovadoras orientadas pela adoção de IA.

Palavra-chave: Indústria 4.0; Setor de defesa; Inteligência Artificial; Cadeia de Suprimentos.

Abstract

De Oliveira Vargas, Rafael; Goyannes Gusmão Caiado, Rodrigo; Farias Bueno, Aduino. **Digital Transformation in the Defense Industry: Analysis of the Adoption of Artificial Intelligence on the Performance and Resilience of the Supply Chain.** Rio de Janeiro, 2023. 89p. Master's Dissertation - Graduate Program in Logistics, Pontifical Catholic University of Rio de Janeiro.

Industry 4.0 (I4.0) is causing significant changes in the competitive dynamics of various economic sectors. Technological advances driven by I4.0 in supply chain management (SCM) have been the subject of comprehensive study both in academia and in industry. SCM plays a fundamental role in enhancing operational efficiency, promoting customer satisfaction, reducing costs, and adapting to market changes. Bringing these perspectives into the business context, the acronym VUCA (Volatility; Uncertainty; Complexity; and Ambiguity), which describes a volatile, uncertain, complex, and ambiguous world, becomes considerably relevant. Additionally, highly improbable and unpredictable events, known as Black Swans, such as COVID-19 and the war between Russia and Ukraine, further exacerbate the uncertain scenario. Focusing on the defense sector presents additional challenges, given the unique circumstances associated with defending a country. In this challenging scenario, among the technologies introduced by I4.0 with application in SCM, Artificial Intelligence (AI) stands out for the strategic differentiation it provides to adopters. AI plays a central role in the digital transformation process of any organization. Thus, the objective of this research is to identify and evaluate the adoption of AI in the performance and resilience of the national defense supply chain. To this end, a mixed research methodology was used, starting with a scoping review that identified the state of the art and future trends of I4.0 in the defense sector SCM, culminating in the development of a research agenda composed of 4 clusters. Next, a systematic literature review was conducted to identify and analyze the factors affecting the adoption of AI in the defense sector based on the findings of the scoping review and highly relevant articles on the researched theme, resulting in the formulation of constructs and variables related to the factors influencing AI adoption and how this technology impacts the supply chain. As a third research method, a survey was conducted in the defense sector with the purpose of identifying and empirically evaluating the adoption of AI in the performance and resilience of the supply chain. Descriptive and exploratory factor analyses of the data were performed, resulting in 6 latent factors composed of variables with higher factor loadings and allowing for the formulation of new constructs and variables that now await confirmatory analysis through future research. Finally, the research proposes a roadmap to strengthen and improve the performance of the Defense industry supply chain using AI. This new artifact was developed through an approach that combines different methods, such as bibliometric analysis, systematic review, and questionnaires, to understand and explore the challenges. To demonstrate its practical application, the plan was adapted for the Brazilian Navy, highlighting how AI can be used in planning and goal execution to increase the robustness, resilience, and responsiveness (Triple-R) of the supply chain, considering both the technical and social aspects of the institutional context. Furthermore, the theoretical research resulted in a future research agenda on digital transformation in the defense industry, outlining a path for the development of innovative solutions guided by the adoption of AI.

Keyword: Industry 4.0; Defense Sector; Artificial Intelligence; Supply Chain.

Lista de figuras

Figura 1. Estrutura metodológica	29
Figura 2. Fluxograma metodológico para revisão de escopo.....	30
Figura 3. Search string – Revisão de Escopo.....	31
Figura 4. Estágios da SLR.....	34
Figura 5. Search string – Revisão Sistemática.....	35
Figura 6. Estágio II – Fases 3 a 5.....	37
Figura 7. Processo para survey.....	39
Figura 8. Frequência da Produtividade Científica.....	44
Figura 9. Dez artigos mais citados por ano.....	44
Figura 10. Nuvem com as palavras chaves com mais aparições.....	45
Figura 11. Tópicos de tendência.....	45
Figura 12. Three-Fields plot.....	46
Figura 13. Clusterização.....	47
Figura 14. Número de trabalhos de cada constructo.....	55
Figura 15. Fatores sociais.....	58
Figura 16. Fatores Técnicos.....	59
Figura 17. Avaliação da Variável “perform”.....	59
Figura 18. Avaliação da Variável “use”.....	60
Figura 19. Comparação entre as variáveis “resil” e “use”.....	61
Figura 20. Comparação entre as variáveis "rrrperf", "robust" e "respon".....	63
Figura 21. Correlação de Spearman entre as variáveis.....	64

Figura 22. Gráfico de Escarpa	65
Figura 23. Agrupamento das variáveis	67
Figura 24. Distribuição das variáveis.....	67
Figura 25. Roadmap para transformação digital.....	73
Figura 26. Roadmap para transformação digital na MB.....	78

Lista de quadros

Quadro 1. Fatores que afetam a adoção de IA.....	50
Quadro 2. Impacto da adoção de IA no desempenho.....	51
Quadro 3. Impacto da adoção de IA no <i>Triple-R</i>	52
Quadro 4. Impacto do <i>Triple-R</i> no desempenho.....	53

Lista de tabelas

Tabela 1. Feedback do questionário piloto.....	41
Tabela 2. Agenda de pesquisa.....	48
Tabela 3. Faixa de Confiabilidade.....	55
Tabela 4. Confiabilidade dos constructos.....	55
Tabela 5. Perfil demográfico da amostra	56
Tabela 6. Fatores sociais.....	57
Tabela 7. Fatores Técnicos.....	58
Tabela 8. Impacto da adoção de IA no desempenho.....	59
Tabela 9. Impacto da Adoção de IA no Triple-R.....	61
Tabela 10. Impacto do Triple-R no desempenho.....	62
Tabela 11. Dez primeiros autovalores.....	65
Tabela 12. Correspondência entre variáveis e fatores.....	66

Lista de siglas

I4.0 – Indústria 4.0

AFE - Análise Fatorial Exploratória

AOP - Algoritmo de Otimização Probabilística

EUA – Estados Unidos da América

GAI - *Generative Artificial Intelligence*

GPT - *General Purpose Technology*

IA - Inteligência Artificial

IoT - *Internet of Things*

KMO - Kaiser-Meyer-Olkin

LDs - Lógicas de Descrição

MI - Manufatura Inteligente

PDCA - Plan, Do, Check and Act

P&D - Pesquisa e Desenvolvimento

RSL - Revisão Sistemática da Literatura

SCM - *Supply Chain Management*

SCV - *Supply Chain Viability*

SLR - *Systematic Literature Review*

Triple-R - *Responsiveness, Resilience, and Robustness*

VUCA - *Volatility; Uncertainty; Complexity; e Ambiguity*

WoS - *Web of Science*

SUMÁRIO

1. Introdução	14
1.1 Lacunas e questões de pesquisa	17
1.2 Objetivos geral e específico	19
1.2.1 Objetivo geral	19
1.2.2 Objetivos específicos	19
1.3 Contribuições da pesquisa	19
2. Fundamentação teórica	21
2.1 Indústria 4.0 e transformação digital	21
2.2 Transformação digital na indústria de defesa: Defesa 4.0	22
2.3 Fatores que afetam a adoção de Inteligência Artificial em <i>SCM</i> ..	22
2.4 Adoção da Inteligência Artificial na <i>SCM</i>	25
2.5 <i>Triple-R</i> na cadeia de suprimentos	26
2.6 Desempenho da <i>SCM</i>	27
3. Metodologia da pesquisa	28
3.1 Etapas da pesquisa	29
3.2 Revisão de escopo	29
3.3 Revisão sistemática	33
3.4 Survey	37
4. Resultados e discussões	43
4.1 Resultados teóricos	43
4.1.1 Resultado da Revisão de escopo	43

4.1.2 Resultados da <i>SLR</i>	49
4.2 Resultados empíricos	54
4.2.1 Análise descritiva do <i>Survey</i>	54
4.2.1.1 Perfil demográfico	55
4.2.1.2 Investigação dos constructos	56
4.2.2 Análise Fatorial Exploratória	63
4.3. Discussão de resultados	68
4.3.1 Discussões Gerais	68
4.3.2 Aplicação na Marinha do Brasil	77
5. Conclusões e sugestões para trabalhos futuros	80
Bibliografia	83

1

Introdução

A Indústria 4.0 (I4.0) está provocando uma transformação significativa no cenário competitivo em vários setores econômicos. Os progressos tecnológicos na gestão da cadeia de suprimentos, impulsionados pela I4.0, têm sido objeto de estudo tanto no âmbito acadêmico quanto na indústria. Isso se deve à transformação radical na concepção da logística que esses avanços trouxeram, bem como ao reconhecimento da sua capacidade de representar um ponto estratégico de vantagem competitiva (Masood & Sonntag, 2020). No entanto, é importante ressaltar que a transformação digital vai além da simples implementação de novas tecnologias de forma isolada. Ela exige a análise cuidadosa dos benefícios e desafios decorrentes dessa implementação, adaptando-a a realidade específica da empresa, levando em consideração tanto a sua estrutura quanto a sua finalidade de negócio (Zeller et al., 2018).

Para o entendimento mais profundo da complexidade da utilização das tecnologias da I4.0 na gestão da cadeia de suprimentos (*Supply Chain Management - SCM*) é importante a conceituação dessa que, de acordo com Lambert (2014), pode ser descrita como a administração dos vínculos entre diversas organizações em uma rede, englobando os principais processos de negócios, que vão desde os fornecedores até os clientes finais, com o objetivo de criar valor tanto para os clientes quanto para os *stakeholders*.

Além disso, é essencial reconhecer o papel crítico da *SCM* no contexto competitivo de qualquer empresa, como enfatizado por Chandra & Kumar (2000). A *SCM* desempenha um papel vital na melhoria da eficiência operacional, na promoção da satisfação do cliente, na redução de custos e na capacidade de adaptação a mudanças no mercado (Khan, 2014).

Ao trazer essas perspectivas para o ambiente de negócio, a sigla VUCA (*Volatility; Uncertainty; Complexity; e Ambiguity*), cunhada pelo exército dos EUA para descrever um mundo que é volátil, incerto, complexo e ambíguo (Casey, 2014), ganha grande relevância nos dias atuais, pois trata-se de uma abordagem que busca encontrar solução para desafios de previsão corporativa e disrupção tecnológica global, e envolve agilidade, gestão de informação e conhecimento, reestruturação e experimentação (Kaivo-oja & Lauraeus, 2018). Os gestores precisam reconhecer e responder às diferentes circunstâncias colocadas por cada uma das quatro situações da sigla (James & Bennett, 2014).

Para a *SCM*, *VUCA* tem grande significância porque, segundo Mr (2020), ela se amolda à imprevisibilidade da *SCM* o que obriga as organizações a estarem preparadas para as mudanças no mercado. O ambiente *VUCA* exacerba a possibilidade de perturbação da cadeia de suprimentos, tornando importante construir uma cadeia resiliente para melhor responder aos riscos de interferência. Essa resiliência pode gerar vantagens competitivas para as empresas que a dominam (Gao et al., 2021).

Além disso, ainda existem interferências causadas por eventos altamente improváveis e imprevisíveis, alcunhados de *Black Swan*, cuja ocorrência traz repercussões significativas, como a COVID-19, por exemplo, que de acordo com Weber-Snyman (2021), trouxe perturbações externas e internas nas cadeias de suprimentos, destacando a importância de ser ágil e de tomar decisões estratégicas a fim de restaurar o estado normal de operação, bem como a guerra entre Rússia e Ucrânia que afetou sobremaneira o abastecimento alimentar global, com impactos duradouros na produção, disponibilidade e acessibilidade de alimentos, sendo a inovação tecnológica, uma ferramenta para mitigar a proporção dos efeitos indesejados (Jagtap et al., 2022).

De fato, as incertezas dos tempos atuais impõem a necessidade de uma abordagem que supere a maioria das teorias tradicionais que adota uma visão estática da *SCM* e que a considere como um sistema social-ecológico adaptativo mais eficaz para o desempenho de uma organização (Wieland, 2021). Desta forma, não basta apenas se valer da resiliência no sentido tradicional da palavra, como a capacidade de um sistema de se recuperar após um evento iminente, mas sim de se adaptar a ele e se transformar a fim de manter sua performance (Wieland & Durach, 2021).

Focando a atenção no setor de defesa, acrescenta-se complexidade ainda maior à temática, pois trata-se de um segmento que depende de maneira crucial de avanços tecnológicos, investimentos em pesquisa e desenvolvimento (P&D), sólidas práticas de engenharia e uma força de trabalho devidamente treinada e qualificada para enfrentar os desafios relacionados à defesa do país (Zimmerman et al., 2019). Esses desafios originam-se de diversas fontes, incluindo a urgente necessidade de se adaptar rapidamente a um ambiente operacional em constante evolução, ameaças em mutação, restrições orçamentárias, cronogramas rigorosos e uma cultura organizacional que tende a evitar riscos (Zimmerman et al., 2019).

Os problemas relacionados à defesa e à segurança nos dias de hoje são

consideravelmente mais complexos do que em épocas passadas, devido ao seu impacto global e às oportunidades oferecidas pelas novas tecnologias digitais, bem como pelo uso de armamento "inteligente" (Fernandez-Villacanas Marin, 2020). Dvir & Tishler (2000) reforçam a importância crucial da indústria de defesa no desenvolvimento industrial e tecnológico, destacando sua relevância para a sobrevivência de um país, especialmente em um cenário onde fusões transfronteiriças e consolidações se tornam cada vez mais comuns.

Diante deste cenário, dentre as tecnologias trazidas pela I4.0, com aplicação na *SCM*, a Inteligência Artificial (IA) ganha notoriedade pela diferenciação estratégica que proporciona àqueles que a utilizam, como previsão de demanda, otimização de rotas e logística, redução de custos, tomada de decisão estratégica, melhoria na visibilidade da cadeia de suprimentos, gestão de inventário eficiente, detecção de anomalias e fraudes, aprimoramento da experiência do cliente, adaptação a mudanças rápidas, dentre outras (AL-MAdhrai et al., 2022; Pournader et al., 2021; Wang & Pan, 2022). Em meio a esse arranjo dinâmico e complexo, a *General Purpose Technology (GPT)* ganha protagonismo justamente por constituir-se em uma classe de Inteligência Artificial que têm a capacidade de afetar profundamente e de maneira ampla diversos setores da economia e da sociedade (Bresnahan, 2010). Sua proposta é ter aplicabilidade em múltiplos contextos e ser uma base fundamental para a inovação em várias áreas (Bekar et al, 2018).

Assim, considerou-se IA, para este trabalho, como a aplicação de análise avançada e técnicas baseadas em lógica, incluindo aprendizado de máquina, para interpretar eventos, apoiar e automatizar decisões e realizar ações (Jan et al., 2023).

A IA desempenha um papel central nesse processo de transformação digital, conforme destacado por Peres et al. (2020) e Jagatheesaperumal et al. (2022). De acordo com Chudasama (2022), empresas que efetivamente adotam e utilizam essa tecnologia têm uma vantagem competitiva substancial em um ambiente de negócios cada vez mais digitalizado e automatizado.

A inclusão das empresas de defesa nessa revolução tecnológica é de extrema importância para o desenvolvimento nacional, haja vista que ela pode aprimorar as capacidades militares, fortalecer a segurança nacional e impulsionar o crescimento econômico (Saputro, 2022). Suwarno (2020) complementa essa ideia, enfatizando que os programas de defesa podem gerar benefícios multiplicadores para a sociedade, impulsionando a economia como um todo.

Pelo exposto, é de grande relevância identificar e avaliar a adoção de IA na performance e resiliência da cadeia de suprimentos do setor de defesa nacional por meio, primeiramente, da identificação do estado da arte e de tendências futuras da I4.0 na *SCM* do setor de defesa, depois da identificação e análise dos fatores que afetam a adoção da IA no setor de defesa e, finalmente, da identificação e avaliação empírica da adoção de IA no desempenho e resiliência da cadeia de suprimentos da indústria de defesa.

1.1

Lacunas e questões de pesquisa

Em que pese o conceito sobre a I4.0 venha sendo estudado desde a sua criação, em 2011, por uma iniciativa do governo alemão a fim de alavancar a competitividade de suas indústrias (Yong Yin & Li, 2018), bem como por outras iniciativas, como “Smart Manufacturing” nos EUA, “Made in China 2025” e “Future of Manufacturing”, no Reino Unido, com concepções bem semelhantes à introduzida na Alemanha (Liao et al., 2017), o assunto ainda carece de ser explorado no setor de defesa.

O estudo de Anand & Nagendra (2019) examina o estado da indústria de defesa da Índia, abrangendo a Organização de Pesquisa e Desenvolvimento de Defesa, Fábricas de Artilharia, Empresas do Setor Público de Defesa e Indústria Privada, incluindo as micro, pequenas e médias empresas controladas pelo Estado, sob a perspectiva das tecnologias da I4.0. No entanto, essa abordagem é altamente específica, o que dificulta a sua aplicabilidade em contextos de defesa de outros países.

Já na pesquisa de Kuo et al. (2019), foi realizada uma análise comparativa da política de inovação no contexto da revitalização industrial da I4.0 entre China, Alemanha e EUA. Tal estudo se concentrou na diferenciação de instrumentos políticos específicos anunciados por esses governos, destacando um foco mais direcionado para a política nacional desses países do que para os impactos da I4.0 no setor de defesa.

No caso da pesquisa de Bibby & Dehe, (2018), ela se concentrou na análise de uma empresa específica, o que torna difícil generalizar suas descobertas ao tentar entender de maneira mais abrangente a consistência da I4.0.

Uma vez evidenciada essa lacuna, conduziu-se uma revisão de escopo acerca do tema a qual gerou como resultado, como se pode observar na seção 4 deste estudo, uma agenda de

pesquisa. Dentre os temas sugeridos para pesquisas futuras, encontrou-se: avaliar e analisar a adoção de IA no setor de defesa.

Corroborando com tais achados, o estudo de Svenmarck et al. (2018) afirma que a utilização de IA no setor de defesa carece de estudos mais robustos e confiáveis de maneira a avaliar se os benefícios compensam as vulnerabilidades trazidas pela tecnologia.

Já para Chedrawi & Atallah (2021), que avaliou os desafios enfrentados pelas Forças Armadas Libanesas para a implementação de IA, a área demanda estudos mais aprofundados a fim de evitar isomorfismo institucional.

O estudo de Lahmann & Geiss (2022), inclusive, aponta para a necessidade de trazer para a pauta de debate aspectos éticos, enfatizando a criticidade de cada aplicação específica da IA.

Tal lacuna motivou a condução de uma Revisão Sistemática da Literatura (RSL) a qual sugeriu que fatores sociais e técnicos interferem na adoção de IA e que a adoção de IA afeta a performance e a resiliência da cadeia de suprimentos.

Neste sentido, percebe-se que a adoção da IA é influenciada por diversos fatores interligados, incluindo a confiança nas tecnologias de IA, que desempenha um papel crucial ao impactar a disposição para adotar a IA. A resistência dos profissionais, muitas vezes relacionada ao conhecimento técnico insuficiente, também representa um obstáculo significativo. Além disso, a cultura organizacional da instituição em questão é um fator determinante, podendo favorecer ou dificultar a integração da IA (Devi K et al., 2021; Müller, 2019; Vogelsang et al., 2019).

Em contrapartida, sua adoção pode proporcionar ganhos significativos no desempenho e na resiliência da cadeia de suprimentos, como a criação de novos modelos de negócios, melhoria da qualidade dos serviços prestados/produtos produzidos e a resposta rápida a interrupções inesperadas, restaurando rapidamente o fluxo normal das atividades (Belhadi et al., 2021; AL-MAdhrai et al., 2022; Dey et al., 2023).

Outro ponto que merece ser investigado é a relação entre os constructos resiliência e desempenho, haja vista que aquele impacta nesse, pois, conforme propõe Dmitry (2023), as empresas que desejam performar de maneira a se manter competitiva no mercado, precisam desenvolver uma cadeia de suprimentos resiliente capaz de retornar ao seu estado natural após um evento disruptivo.

Além disso, uma cadeia de suprimentos resiliente permite rápida adaptação às mudanças de mercado, reduzindo custos e superando gargalos na produção. Favorece também, uma personalização em massa, minimizando a padronização de processos e incentivando a inovação (Pranesh, 2023; Kristianto, 2017).

Desta forma, é fundamental testar e validar os conceitos teórico sugeridos pela RSL (Os fatores sociais afetam a implementação da IA na SCM; Os fatores técnicos afetam a implementação da IA na SCM; A utilização da IA afeta o desempenho operacional nos diversos níveis da cadeia de suprimentos; e A utilização da IA afeta a resiliência da cadeia de suprimentos), bem como aquela (A resiliência da cadeia de suprimentos afeta o desempenho operacional) proposta pela análise de quatro artigos que relacionam resiliência e desempenho da SCM, por meio da coleta de dados reais, contribuindo para a robustez e credibilidade das conclusões.

1.2

Objetivos geral e específico

1.2.1 Geral

- Identificar e avaliar a adoção de IA na performance e resiliência da cadeia de suprimentos do setor de defesa nacional (OG).

1.2.2 Específicos

- Identificar o estado da arte e tendências futuras da I4.0 na *SCM* do setor de defesa (OE_1);
- Identificar e analisar os fatores que afetam a adoção da IA no setor de defesa (OE_2);
- Identificar e avaliar empiricamente a adoção de IA no desempenho e resiliência da cadeia de suprimentos (OE_3).

1.3

Contribuições da pesquisa

Este trabalho traz três contribuições importantes: uma teórica, outra metodológica e, por fim, de aplicação prática.

A contribuição teórica deste estudo preenche lacunas acadêmicas ao fornecer uma visão abrangente do campo de pesquisa. Ele destaca os principais estudos, autores, universidades e conceitos relacionados à adoção de IA na indústria de defesa. Além disso, explora os fatores sociotécnicos que afetam essa adoção e as contribuições para o

desempenho e resiliência da cadeia de suprimentos em situações adversas.

Metodologicamente, este trabalho é robusto e reproduzível, concentrando múltiplas fontes de dados e combinando métodos complementares para a pesquisa científica, como revisão de escopo, revisão sistemática da literatura e *survey*, contribuindo para o avanço do conhecimento nesta temática e servindo como referência para futuras pesquisas.

Quanto à contribuição prática, os achados da pesquisa servem como um direcionamento no processo de transição para a digitalização da cadeia de suprimentos da área de defesa, permitindo uma avaliação das implicações acarretadas com a adoção de IA na sua *SCM*.

Além disso, tais resultados podem contribuir para a indústria de defesa e para líderes e gerentes da cadeia de suprimentos na adoção de IA para aumentar a performance e resiliência das seguintes formas:

- **Compreensão dos fatores que afetam a adoção de IA:** auxílio na identificação de áreas específicas para aplicação da IA na indústria de defesa e na cadeia de suprimentos, abrangendo a otimização de processos, previsão de demanda, automação de tarefas, detecção de ameaças e outras oportunidades. Além disso, ela revela desafios e obstáculos a serem superados para uma adoção bem-sucedida da IA.
- **Melhoria da Tomada de Decisões:** A IA aprimora a tomada de decisões em tempo real, fornecendo análises e insights dinâmicos baseados em dados. Assim, a pesquisa contribui para o desenvolvimento de algoritmos e modelos de IA personalizados para atender às necessidades da indústria de defesa e da cadeia de suprimentos, resultando em decisões mais eficazes e informadas.
- **Aumento da Resiliência:** A IA pode ajudar a melhorar a resiliência da cadeia de suprimentos ao antecipar e responder rapidamente a interrupções e perturbações. A pesquisa pode explorar como a IA pode ser usada para desenvolver estratégias de resiliência, como identificação de riscos, alocação eficiente de recursos e planos de contingência.
- **Eficiência Operacional:** A IA pode otimizar operações em toda a cadeia de suprimentos, economizando tempo e recursos. A pesquisa pode investigar como a automação de processos, roteamento eficiente e gestão de estoque podem ser melhorados com a IA, resultando em maior eficiência.

- **Inovação Tecnológica:** A pesquisa pode impulsionar a inovação tecnológica na indústria de defesa e na cadeia de suprimentos, promovendo o desenvolvimento de soluções de IA de ponta. Isso pode envolver a criação de novas aplicações e tecnologias adaptadas às necessidades específicas desses setores.
- **Compreensão de Questões Éticas e de Segurança:** A pesquisa também pode abordar questões éticas e de segurança relacionadas à IA na indústria de defesa. Isso envolve a garantia de que a IA seja usada de maneira ética e segura, cumprindo regulamentações e diretrizes aplicáveis.

2

Fundamentação teórica

2.1

Indústria 4.0 e transformação digital

A Indústria 4.0 é definida como uma "quarta revolução industrial" que está sendo impulsionada pela convergência de tecnologias digitais, físicas e biológicas. A transformação digital trazida pela I4.0 está transformando a forma como as indústrias operam, com impactos significativos na produtividade, eficiência e competitividade (Schwab K., 2016).

Piccarozzi et al. (2018) caracteriza essa revolução industrial como a era dos "sistemas ciberfísicos". Estes sistemas representam a integração de computação, redes e processos físicos e englobam uma ampla gama de tecnologias, que incluem dispositivos móveis, *Internet of Things (IoT)*, inteligência artificial (IA), robótica, segurança cibernética e impressão 3D.

A expectativa é que a implementação das tecnologias facilitadoras da I4.0 leve a melhorias substanciais no desempenho da *SCM*. Isso será possível por meio de uma abordagem abrangente, alcançada pela integração extensiva da cadeia, compartilhamento de informações e transparência em todos os seus estágios (Fatorachian & Kazemi, 2020).

À medida que as organizações avançam na transformação digital de seus processos da cadeia de suprimentos, elas se deparam com desafios que surgem ao adotar novas tecnologias e com as pressões decorrentes das rápidas mudanças no cenário da tecnologia digital (Hartley e Sawaya, 2019).

2.2

Transformação digital na indústria de defesa: Defesa 4.0

A transformação digital das indústrias de defesa é um processo complexo que necessita vencer diversas barreiras para alcançar sucesso, conforme aponta a pesquisa de Anand e Nagendra (2019) que aborda a adoção de Manufatura Inteligente (MI) nas indústrias de defesa da Índia, incluindo custos, segurança cibernética, habilidades, regulamentações e infraestrutura. Eles entendem que a MI pode melhorar a qualidade e produtividade, porém exige requalificação da força de trabalho.

Para Marín (2020), a logística 4.0 é uma oportunidade para o setor de defesa e segurança melhorar sua eficiência, produtividade e flexibilidade, mas isso requer uma mudança significativa na cultura e nos processos. Ele propõe uma estratégia de cooperação público-privada com base na colaboração, envolvimento de todas as partes interessadas e foco em resultados. Essa estratégia é essencial para a transformação do setor e pode ajudá-lo a se tornar mais competitivo globalmente.

A sensibilidade do setor de defesa, dada a sua importância para a soberania de um país, torna ainda mais complexo esse processo, impondo a análise de até que proporção a digitalização deve ser incorporada à doutrina de planejamento militar. Duas áreas principais de preocupação são identificadas: a extensão da digitalização, incluindo preocupações com riscos e o momento de escolha de soluções digitais específicas, e os limites da digitalização em relação às noções militares sobre o papel e identidade dos líderes. A digitalização pode afetar profundamente os papéis e identidades profissionais, e os desenvolvedores de gerenciamento de conhecimento estratégico precisam estar cientes disso (Heltberg, 2022).

Diante disto, a transformação digital trazida pelas tecnologias da I4.0 tem grande potencial de transformar o setor de defesa. No entanto, é importante que essas organizações avaliem a sua maturidade quanto ao nível de digitalização que possuem para identificar áreas onde precisam melhorar (Bibby e Dehe, 2018).

2.3

Fatores que afetam a adoção de Inteligência Artificial em SCM

Inteligência Artificial (IA) pode ser descrita como a aplicação de métodos avançados de análise e técnicas fundamentadas em lógica, que incluem aprendizado de máquina, para interpretar eventos, fornecer suporte e automatizar decisões, além de executar ações. Essa

definição está alinhada com as atuais e emergentes tecnologias e recursos de IA (Thayyib et al., 2023).

Segundo Alenizi et al. (2023) a IA traz mudanças profundas nas indústrias, impactando manutenção, controle, monitoramento de processos, otimização de produção e gerenciamento de serviços, considerando-a essencial para alcançar os objetivos da I4.0, contribuindo para uma maior eficiência, qualidade, segurança e sustentabilidade na fabricação inteligente e em aplicações industriais.

Raciocínio probabilístico; lógica computacional; técnicas de otimização; processamento de linguagem natural; representação de conhecimento, aprendizado e busca; e computação baseada em agentes são tipos de técnicas de IA que podem ser utilizadas para resolver problemas do mundo real de várias maneiras. Por exemplo, a programação probabilística permite a modelagem de fenômenos estocásticos complexos e o uso de números aleatórios para representar a incerteza (Shuyang D., 2023).

Algoritmos de otimização, como o Algoritmo de Otimização Probabilística (AOP), utilizam representações probabilísticas para explorar simultaneamente todo o espaço de busca, combinando processos de busca locais e globais (Hong, Y. et al., 2019).

A lógica computacional, especificamente o uso de Lógicas de Descrição (LDs) e algoritmos de raciocínio, pode ajudar a modelar domínios do mundo real e lidar com não determinismo e informações incertas (Najaran & Tootouchi, 2020).

Por fim, a *Generative Artificial Intelligence (GAI)* vem ganhando grande visibilidade, pois abrange vários tipos de modelos de IA capazes de gerar autonomamente novo conteúdo, como texto, imagens, áudio e vídeo. Esses modelos têm sido aplicados em diferentes campos e setores. Por exemplo, o StableDiffusion e o GPT-3 são modelos de IA generativa que foram usados para gerar imagens e texto, respectivamente (Oermann & Kondziolka, 2023).

Na gestão da cadeia de suprimentos, sua aplicação é ampla e contribui para aprimorar a tomada de decisões e otimizar processos. Ao analisar dados de diversas fontes, como dados históricos de transações e informações de mercado externo, a IA generativa pode identificar potenciais riscos e sugerir estratégias para gerenciá-los (Rajagopal et al., 2023). Ela também pode auxiliar na detecção de fraudes, analisando grandes volumes de dados em tempo real e identificando desvios da norma que podem indicar atividades fraudulentas (Adobor et al., 2023; Mendonça & Junior, 2023).

As mudanças trazidas pela IA estão provocando transformações significativas na *SCM* (Masood & Sonntag, 2020). No entanto, muitas empresas com uma cultura organizacional rígida podem resistir a essas mudanças, o que se torna um obstáculo para a implementação da IA, uma tecnologia relativamente nova (Pournader et al., 2021).

A adoção de novos modelos de negócios digitais pode ser um desafio complexo, pois requer uma compreensão profunda das mudanças necessárias e da capacidade de implementá-las de forma eficiente. Um dos desafios é a falta de compreensão adequada sobre o que envolve a transformação digital, o que pode levar alguns profissionais a temerem a dependência tecnológica (Kutnjak & Pihir, 2019).

Muitas organizações estão temerosas de não conseguirem se adaptar à IA e, por isso, optam por esperar pelos resultados de outras empresas antes de tomar uma decisão (Gupta et al., 2021).

Além disso, a falta de estudos empíricos sobre as implementações da Indústria 4.0 e o impacto da IA pode limitar o conhecimento sobre os fatores críticos de sucesso e as melhorias resultantes para as empresas (Jain & Ajmera, 2018).

A integração de diferentes tecnologias, a atualização de infraestruturas existentes e a adaptação dos processos de negócios podem apresentar dificuldades técnicas e organizacionais, afetando a adoção e o uso generalizado da IA (Davies et al., 2017).

Adicionalmente, a implementação das tecnologias Indústria 4.0, incluindo a IA, geralmente requer um investimento significativo em termos de tecnologia, equipamentos, infraestrutura e treinamento (Horváth & Szabó, 2019).

A falta de profissionais qualificados nesse campo também pode ser uma limitação para algumas empresas, já que a contratação ou desenvolvimento de talentos nessa área pode ser desafiador e exigir investimento adicional em capacitação e treinamento (Pozzi et al., 2021).

É importante ressaltar que a implementação de novas tecnologias frequentemente envolve riscos relacionados à segurança de TI e proteção de dados. Isso pode levar as organizações a relutarem em aceitar esses riscos e os custos associados devido ao receio em relação ao excesso de transparência dos dados (Tsiavos & Kitsios, 2022).

Diante do exposto, a literatura traz, à evidência, que os fatores sociais e técnicos afetam a adoção de IA na *SCM*, tornando fundamental a sua compreensão para garantir a

aceitação dos colaboradores, otimizar a integração tecnológica e promover uma implementação bem-sucedida

2.4

Adoção da Inteligência Artificial na *SCM*

A adoção da IA traz inúmeros impactos na *SCM*, como apontado pela literatura. Pournader et al. (2021) destacam que a IA tem a capacidade de prever a demanda por produtos e serviços, otimizar o planejamento de produção, gerenciar estoques e roteirizar veículos, além de automatizar tarefas operacionais, liberando recursos para atividades estratégicas. Adicionalmente, a IA pode identificar e reduzir desperdícios na cadeia de suprimentos, aprimorar a experiência do cliente e fornecer recomendações personalizadas de produtos.

Ribeiro et al. (2021) ressaltam que a IA capacita máquinas a executar tarefas complexas, otimiza processos, personaliza produtos e possibilita a análise eficiente de grandes volumes de dados em tempo real.

Além disso, Modgil et al. (2022) ressaltam que a IA desempenha um papel crucial na otimização de processos industriais e na aprimorada comunicação entre os membros da cadeia de suprimentos. Isso resulta em maior visibilidade e transparência, estimulando a inovação colaborativa e a personalização de produtos.

Wamba & Queiroz (2022) complementam, destacando que a IA melhora a eficiência operacional nas cadeias de suprimentos, auxilia na tomada de decisões embasadas em dados valiosos e fomenta a colaboração entre os diversos atores da cadeia. Essa abordagem resolve problemas comuns, como a falta de visibilidade e questões relacionadas à transparência e responsabilidade.

No contexto da Indústria 4.0, AL-MAdhrai et al. (2022) salientam que a IA contribui para uma tomada de decisão mais informada, impactando positivamente áreas como o desempenho financeiro e o marketing, enquanto melhora a compreensão das necessidades dos clientes e otimiza os aspectos de custos na cadeia de suprimentos.

Jauhar et al. (2023) observam que a IA desempenha um papel fundamental na redução das distorções de estoque e na melhoria da visibilidade e automação nas operações da cadeia de suprimentos, tornando-a mais ágil e precisa.

Dey et al. (2023) adicionam que o uso de técnicas de aprendizado de máquina facilita a previsão de riscos, aprimora a tomada de decisões baseadas em dados e auxilia na identificação de gargalos nas operações e no planejamento da *SCM*.

No contexto da adaptação a eventos disruptivos e inesperados, Belhadi et al. (2021) enfatizam que a IA confere maior resiliência à cadeia de suprimentos, permitindo o desenvolvimento de produtos sob medida, a identificação de pontos fracos na *SCM* e facilitando o *design thinking* em sistemas de negócios.

Portanto, a IA desempenha um papel fundamental na transformação e melhoria das operações da cadeia de suprimentos, proporcionando eficiência, inovação e automação em diversos aspectos.

2.5

***Triple-R* na cadeia de suprimentos**

Segundo Kristianto et al. (2017), uma cadeia de suprimentos flexível é aquela que possui a capacidade de se adaptar rapidamente a mudanças no mercado ou na demanda do cliente, demonstrando resiliência, robustez e responsividade (*Triple-R*). Isso implica na habilidade de se recuperar de perturbações (resiliência), na capacidade de funcionar sem falhas (robustez) e na aptidão de responder de forma eficaz a mudanças no ambiente (responsividade). Os autores complementam ainda que, além disso, a flexibilidade da cadeia de suprimentos também inclui a consideração do tempo como parte fundamental, a fim de garantir a customização em massa e a coordenação eficiente de oferta e demanda.

Neste mesmo sentido, (Pranesh Saisridhar & Avittathur, 2023) considera que uma cadeia de suprimentos flexível é aquela que possui a capacidade de desenvolver simultaneamente responsividade, resiliência e robustez (*Triple-R*) para se proteger contra interrupções e riscos, ao mesmo tempo em que se mantém competitiva. Acrescentam ainda, que isso implica a necessidade de tomar decisões de investimento cuidadosas para criar um portfólio de estratégias que possam enfrentar diferentes tipos de interrupções.

Sharma (2023) afirma que a resiliência é crucial, especialmente em momentos de crise como a segunda onda da COVID-19 na Índia. A pandemia destacou as deficiências do sistema de saúde do país e a lacuna entre a demanda e o fornecimento de recursos médicos. A pesquisa enfatiza a importância da gestão eficaz das cadeias de suprimentos durante crises, propondo o uso da IA para melhorar a coordenação entre oferta e demanda. Além disso, o

estudo destaca a necessidade de cadeias de suprimentos mais resilientes e equilibradas para enfrentar situações similares futuras.

Desta forma, percebe-se que a importância de uma cadeia de suprimentos flexível reside na capacidade de se adaptar rapidamente a mudanças, interrupções e a demandas do mercado, garantindo a resiliência, robustez e responsividade necessárias para manter a eficiência e a competitividade das organizações (kristianto et al 2017).

Diante das informações apresentadas, a literatura destaca claramente que a utilização da IA afeta a resiliência da cadeia de suprimentos, sendo crucial sua compreensão para garantir a eficiência e competitividade no ambiente empresarial em constante evolução.

2.6

Desempenho da *SCM*

De acordo com Ivanov et al. (2023), o desempenho da cadeia de suprimentos é de extrema importância, especialmente à luz das vulnerabilidades expostas pela pandemia COVID-19 nas cadeias globais. Para os autores, garantir o que chamam de Viabilidade da Cadeia de Suprimentos (*Supply Chain Viability - SCV*) eficaz, significa impor um olhar para além da eficiência e custos, incorporando resiliência, adaptabilidade, sustentabilidade e equidade. Isso envolve a construção de ecossistemas de cadeias de suprimentos caracterizados por colaboração, transparência, compartilhamento de riscos e benefícios, e inovação conjunta.

A pandemia de COVID-19 revelou a fragilidade das cadeias de suprimentos globais diante de perturbações significativas. Para aprimorar a resiliência e adaptabilidade das cadeias de suprimentos a eventos disruptivos, a IA se constitui em um instrumento poderoso, uma vez que é capaz de rastrear eventos disruptivos em tempo real, avaliar seu potencial impacto, elaborar planos de resposta e monitorar a eficácia das ações implementadas (Sharma, 2023).

Sob o foco do desempenho, Jauhar et al. (2023) afirma que a IA desempenha um papel crucial na otimização da cadeia de suprimentos. Ela não apenas ajuda a prever e minimizar distorções de estoque reduzindo, com isso, os custos, mas também aprimora a previsão de demanda, resultando em um atendimento mais eficiente às necessidades dos clientes. Os autores acrescentam que essa tecnologia emergente tem o potencial de transformar o gerenciamento de cadeias de suprimentos, oferecendo oportunidades significativas para melhorar o desempenho das empresas.

A IA executa um papel crucial na construção de uma cadeia de suprimentos integrada e eficiente. Ao proporcionar robustez, a IA minimiza falhas operacionais, ao mesmo tempo em que viabiliza a personalização em massa e fomenta a inovação. Além disso, contribui para a criação de uma cadeia responsiva, capaz de se ajustar rapidamente às mudanças de mercado. Esse ajuste ágil não apenas fortalece a adaptabilidade da cadeia, mas também resulta na redução de custos e na eliminação de gargalos nos processos produtivos (Kristianto et al., 2017).

A pesquisa de Wang & Pan (2022) revela que a adoção da IA nas cadeias de suprimentos impacta positivamente a sua performance em diversos aspectos cruciais, incluindo automatização de tarefas e prevenção de erros, resultando em economia de recursos. Outro ponto que os autores destacam é a capacidade que a IA possui de prover visibilidade à cadeia de suprimentos, acelerando a resposta a demandas e aumentando a sua flexibilidade operacional.

Portanto, o desempenho da cadeia de suprimentos é fundamental na era da fabricação global, especialmente no cenário dinâmico e imprevisível, onde a personalização de produtos é essencial para manter a fidelidade do cliente, evitar a comoditização e permitir a diferenciação competitiva (kristianto et al, 2017).

Considerando o exposto, a literatura destaca que a incorporação da IA afeta o desempenho operacional das organizações e que tal desempenho também é impactado por uma cadeia de suprimentos resiliente.

3

Metodologia da pesquisa

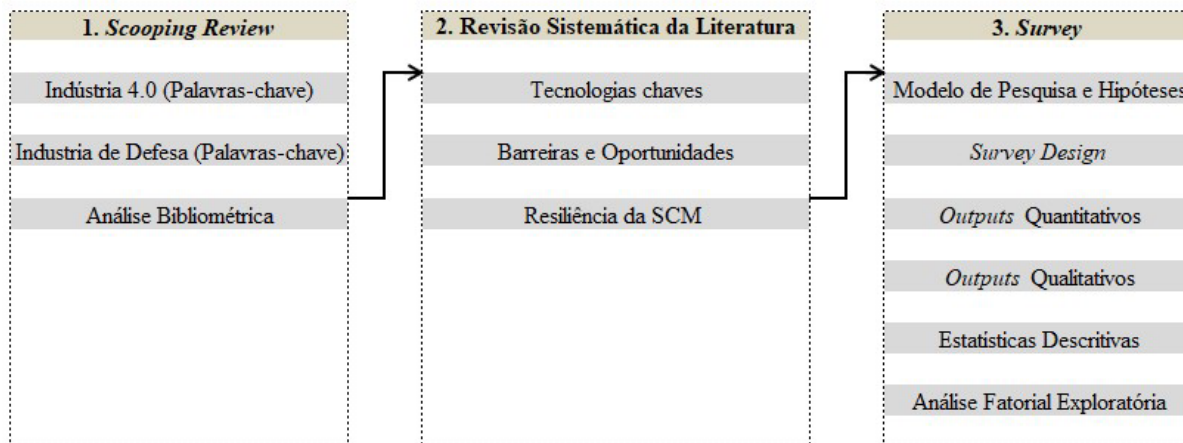
A metodologia desta pesquisa desenvolveu-se por meio de uma abordagem mista a fim de complementar a outra. A pesquisa mista é uma abordagem cada vez mais popular na pesquisa acadêmica, pois oferece uma maneira de obter uma visão mais completa e abrangente de um fenômeno, o que pode levar a resultados mais significativos e úteis (Stadtländer, 2009) e que, conforme Creswell (2012), envolvem a combinação de técnicas quantitativas e qualitativas na coleta, análise e interpretação de dados, caracterizando-se por uma abordagem interdisciplinar que aproveita os pontos fortes de cada método, resultando frequentemente em investigações de maior qualidade.

3.1

Etapas da pesquisa

A pesquisa foi metodologicamente conduzida, conforme figura 1.

Figura 1. Estrutura metodológica



Fonte: Elaborado pelo autor (2023).

Inicialmente, foi feita uma revisão de escopo para se entender o estado da arte acerca do tema. Em seguida, em decorrência dos achados da revisão de escopo, foi feita uma revisão sistemática da literatura para se estabelecer uma estrutura conceitual. Por fim, realizou-se uma pesquisa *survey* para proporcionar uma análise quantificável e mensurável.

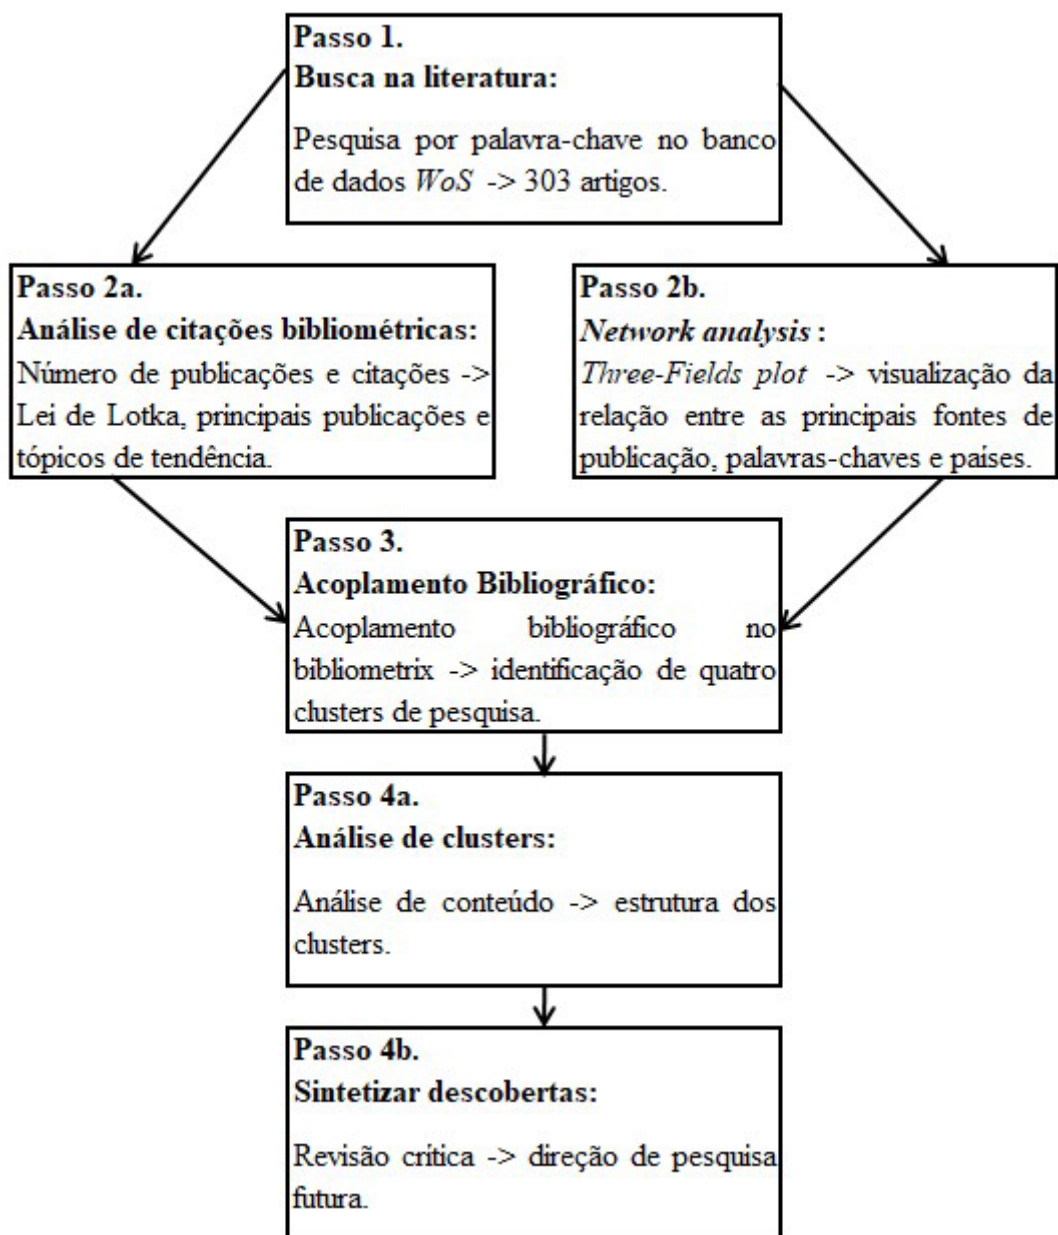
3.2

Revisão de escopo

Realizar uma pesquisa começando do macro para o micro, muitas vezes chamado de abordagem *top-down*, é uma estratégia comum na pesquisa científica e na investigação acadêmica quando se busca um panorama abrangente acerca de determinado assunto (Melsheimer & Walther, 2018).

Neste contexto, a revisão de escopo com o uso de técnicas bibliométricas é uma metodologia de pesquisa amplamente adotada pelos pesquisadores, pois desempenha um papel crucial ao aprofundar a literatura e criar um referencial teórico que conecta efetivamente dois ou mais temas de estudo (Munn et al., 2018). Essa abordagem utiliza ferramentas estatísticas para garantir uma análise qualitativa precisa e confiável (Brika et al., 2021). Para tal, foram seguidos 4 passos a partir de uma adaptação de Dushenko et al. (2020), conforme figura 2.

Figura 2. Fluxograma metodológico para revisão de escopo



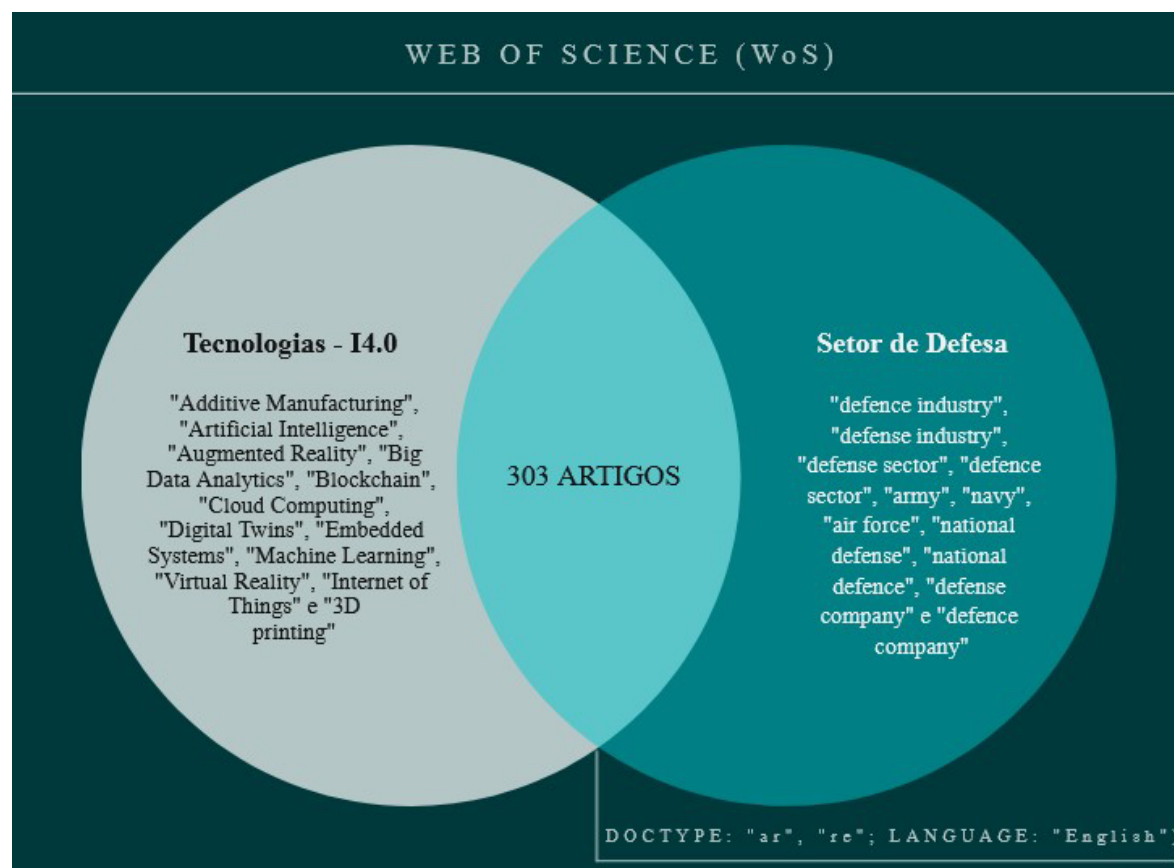
Fonte: adaptação de Dushenko et al. (2020)

Em uma busca na literatura (Passo 1), por meio do banco de dados da Web of Science (WoS) que, segundo Aria e Cuccurullo (2017), representa uma plataforma confiável, foram encontrados 303 artigos publicados em 227 fontes de publicação entre 1990 e 2022. Optou-se por utilizar apenas a WoS devido à melhor compatibilidade do pacote bibliometrix do “R Studio” com os dados provenientes dessa base. Ao tentar utilizar outras bases, é comum encontrar erros na análise.

Esses estudos foram escritos por um total de 1211 autores e apresentaram uma média de 10.06 citações por documento. Para essa busca, foram empregados dois conjuntos de

search string, conforme figura 3. O primeiro grupo incluiu "Additive Manufacturing", "Artificial Intelligence", "Augmented Reality", "Big Data Analytics", "Blockchain", "Cloud Computing", "Digital Twins", "Embedded Systems", "Machine Learning", "Virtual Reality", "Internet of Things" e "3D printing", todas conectadas pelo booleano "OR". Essas palavras foram escolhidas com base na definição de tecnologias relacionadas à Indústria 4.0, conforme apontado por Masood e Sonntag (2020). O segundo grupo de *search string* foi conectado ao primeiro por meio do operador "and" e incluiu termos como "defence industry", "defense industry", "defense sector", "defence sector", "army", "navy", "air force", "national defense", "national defence", "defense company" e "defence company", todas também conectadas pelo booleano "OR". Essas palavras foram selecionadas por serem sinônimas ou relacionadas entre si, abrangendo variações linguísticas entre o inglês britânico e o norte-americano.

Figura 3. *Search string* – Revisão de Escopo



Fonte: elaborado pelo autor (2023)

Os dados foram analisados usando a ferramenta bibliometrix (Passo 2a), que é uma ferramenta de código aberto programada em ambiente R. Essa ferramenta é recomendada para processar dados em várias etapas do estudo (Aria & Cuccurullo, 2017).

Foram extraídos os números de publicações e citações, por meio da Lei de Lotka, a qual avalia quantidade de autores em relação ao número de publicações utilizando os princípios da lei do quadrado inverso, na qual o número de autores que produzem "n" publicações em um campo científico específico é aproximadamente proporcional a $1/n^2$ daqueles que realizam apenas uma publicação, proporcionando uma compreensão mais profunda da estrutura e dinâmica da produção científica acerca do tema pesquisado.

Avaliou-se também os 10 estudos com maior número de citações por ano, por meio do *biblioshiny*, selecionando-se os parâmetros “palavras-chave” e “anual”, limitando a 10 estudos. Além disso, ainda no *biblioshiny*, foi gerada uma nuvem de palavras compostas pelas palavras-chave com mais ocorrências comparando-as com o ano das aparições de forma a identificar os tópicos de tendência.

Foi realizada também uma análise de rede, através do *Three-Fields plot* (Passo 2b.), em que se selecionam, no *biblioshiny*, os eixos que se quer avaliar, no caso deste estudo, foram as fontes de publicação, palavras-chaves e países, de maneira a permitir a visualização da interação entre esses eixos e, por conseguinte, a identificação de tendências e padrões na pesquisa.

Em seguida, os dados bibliográficos já importados para o R, usando o pacote *biblioshiny*, foram agrupados pelas palavras-chaves dos estudos pelo método de *clusterização* por centralidade e impacto (Passo 3), conforme o seguinte algoritmo: $J(C1,C2,C3,C4) = w1 \cdot (d(C1,C2) + d(C1,C3) + d(C1,C4) + d(C2,C3) + d(C2,C4) + d(C3,C4)) + w2 \cdot (I(C1,C2) + I(C1,C3) + I(C1,C4) + I(C2,C3) + I(C2,C4) + I(C3,C4))$.

Onde:

- $J(C1,C2,C3,C4)$ é a medida da distância entre os clusters C1, C2, C3 e C4.
- $d(Ci,Cj)$ é a distância euclidiana entre os centros de gravidade dos clusters C_i e C_j .
- $I(Ci,Cj)$ é a medida da interação entre os clusters C_i e C_j .
- $w1$ e $w2$ são pesos que controlam a importância da distância e da interação na medida da distância.

Esse método de clusterização é recomendado para identificar grupos de pontos de dados que estão recebendo muitas citações e downloads, indicando áreas de pesquisa que

estão crescendo e que são importantes para a comunidade científica. Para cada nó na rede, calcula-se sua centralidade e seu impacto, então os nós são ordenados de acordo com sua centralidade e impacto e, por fim, agrupados em *clusters*, começando pelos nós mais centrais e com maior impacto. De tal acoplamento, resultaram 4 *clusters*.

Por fim, procedeu-se a análise dos *clusters* (Passo 4a.) com a leitura completa de cada artigo, permitindo a interpretação e a compreensão do conteúdo, e a sintetização das descobertas (Passo 4.b), gerando uma planilha que apontou caminhos de pesquisas por *cluster* analisado.

3.3

Revisão sistemática

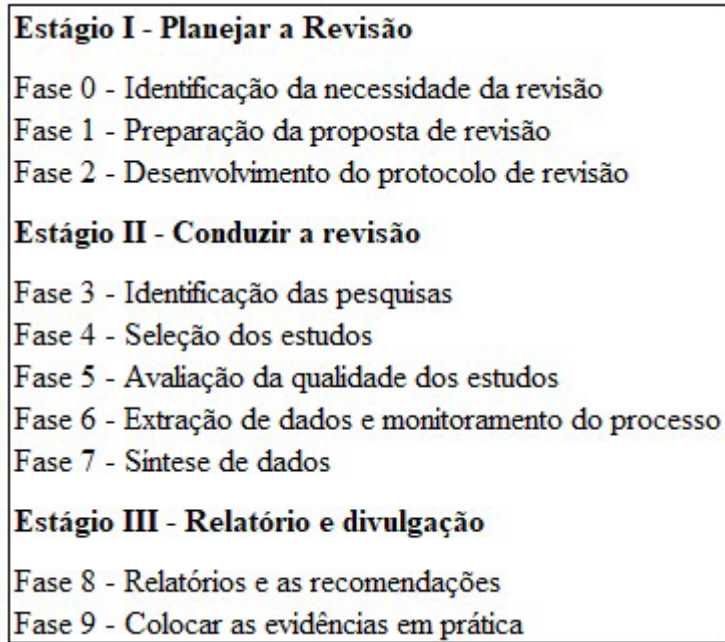
A revisão sistemática da literatura (*Systematic Literature Review - SLR*) é um método rigoroso e estruturado de pesquisa que tem o objetivo de identificar, analisar, avaliar e sintetizar todas as evidências disponíveis relacionadas a uma questão de pesquisa específica em um determinado campo ou tópico (Cooper, 1988).

A SLR não é apenas uma análise de trabalhos anteriores, mas sim uma pesquisa fundamental por conta própria. Ela se concentra em responder perguntas de pesquisa específicas e segue uma metodologia que envolve a identificação de estudos existentes, a seleção e avaliação de suas contribuições, a análise e síntese de dados relevantes, e a apresentação das evidências de uma maneira que possibilita a formulação de conclusões sólidas sobre o que é conhecido e o que permanece desconhecido (Denyer & Tranfield, 2009).

Segundo Munn et al. (2018), conduzir uma revisão sistemática a partir dos resultados de uma revisão de escopo revela-se como uma estratégia complementar essencial no processo de pesquisa, pois essa sequência proporciona uma abordagem progressiva e aprimorada para a investigação, permitindo uma análise mais aprofundada da evidência disponível, identificação precisa das lacunas críticas e contribuição para a construção de um corpo de conhecimento mais sólido

Desta forma, a fim de mapear os impactos com a adoção da IA no setor de defesa, caminho de pesquisa indicado pelo *cluster* 4, presentes na literatura, a *SLR* foi estruturada em 3 estágios conforme sugere Tranfield et al. (2003), assim visualizados na figura 4.

Figura 4. Estágios da SLR



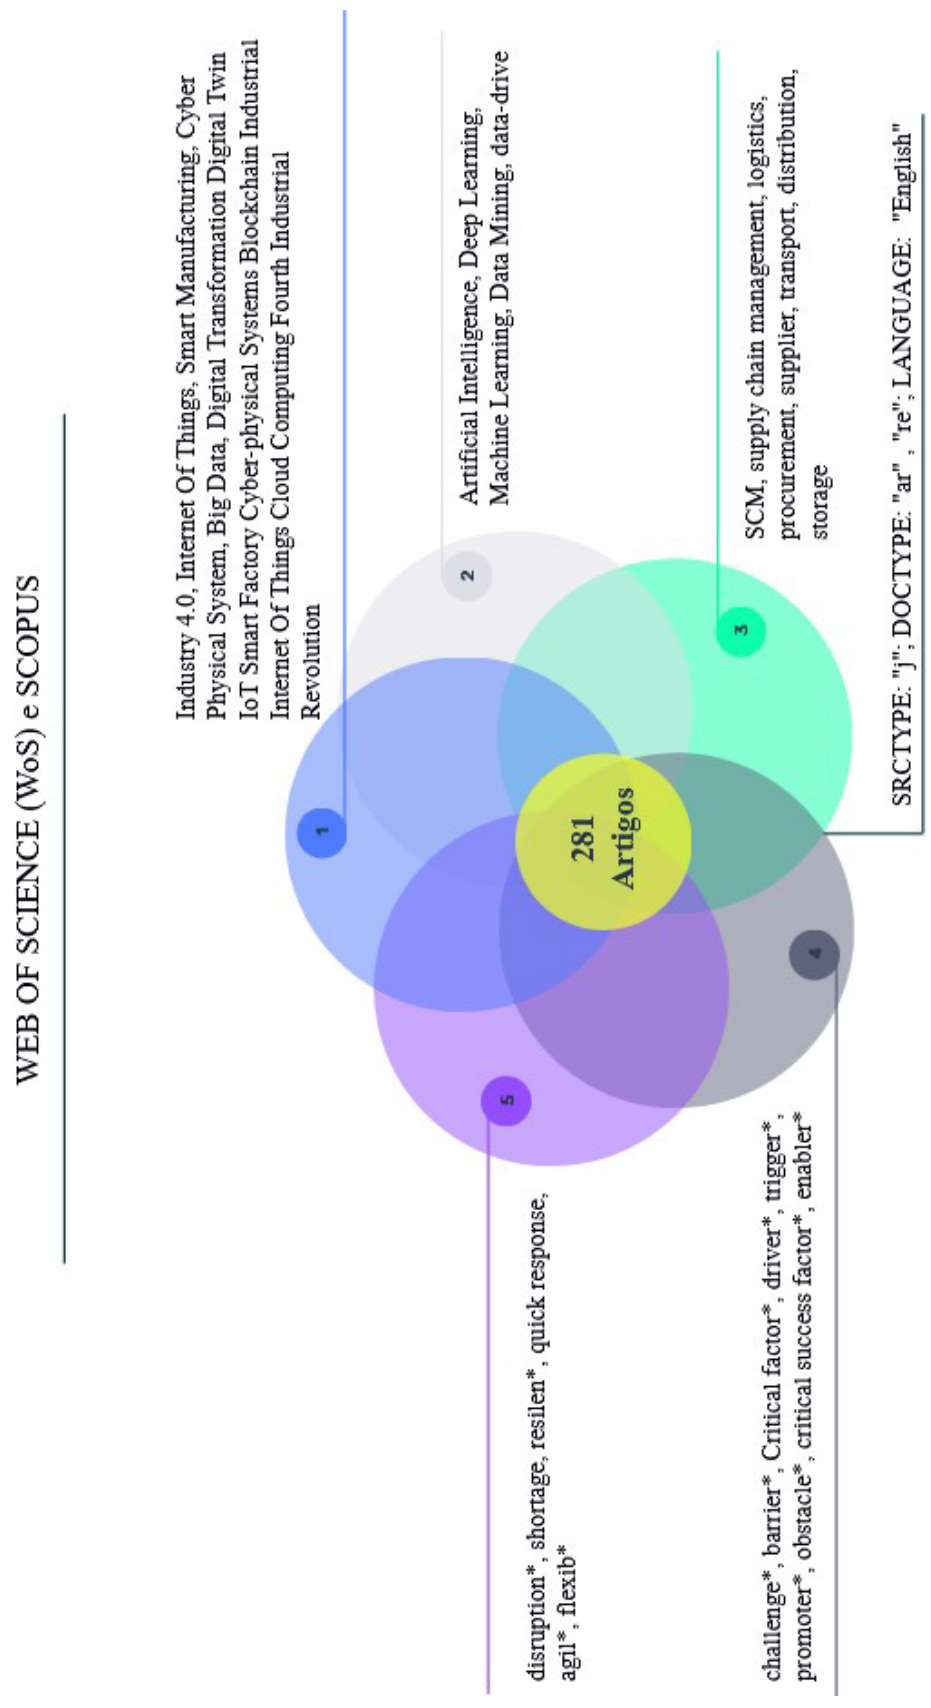
Fonte: Tranfield, D. (2003)

O planejamento da revisão (Estágio I), foi composto por 3 fases. Inicialmente, identificou-se a necessidade da revisão (fase 0), a partir dos achados da revisão de escopo e, por conseguinte, preparou-se a proposta de revisão (Fase 1), ambas decorrentes do *cluster* 4.

O desenvolvimento do protocolo (Fase 2) compreendeu a definição da *search string*, os critérios de inclusão e exclusão, bem como as bases de dados a serem utilizadas.

Para a definição da *search string*, optou-se por criar cinco eixos em que cada um compreendesse uma área de pesquisa específica que, quando conectadas pelo operador “AND”, atingisse o objetivo da SLR. Foram aplicados os filtros de *journal* e *articles*, pois geralmente passam por um rigoroso processo de revisão por pares, o que significa que os artigos publicados são submetidos a uma avaliação crítica por especialistas na área. Isso contribui para a credibilidade e confiabilidade dos resultados apresentados. Além disso, limitou-se também por trabalhos na língua inglesa porque contribui para a padronização e consistência na análise. A *search string* pode ser visualizada na figura 5.

Figura 5. *Search string* – Revisão Sistemática.



Fonte: elaborado pelo autor (2023)

Dentro de cada um dos grupos de palavras-chaves, essas foram conectadas pelo booleano “OR”, enquanto os grupos, pelo operador “AND”. Os critérios de inclusão/exclusão foram: identificação das duplicatas pelo gerenciador de referências bibliográficas gratuito Mendeley; leitura de título e resumo para identificar os estudos que se relacionavam ou não com o tema da pesquisa; e leitura completa para identificar daqueles que, embora relacionavam-se com o objeto estudado, possuíam características que não se amoldariam ao objetivo da pesquisa.

A bases de dados escolhidas foram Web of Science (WoS) e Scopus, pois, segundo Mongeon & Paul-Hus (2016) são abrangentes e de alta qualidade.

A condução da revisão (Estágio II) se deu em 19/04/2023, da qual resultaram 281 estudos, sendo 160 da WoS e 121 da Scopus (Fase 3). Dentre esses, 56 eram duplicatas, restando 225 para leitura de título e resumo. De tal leitura, resultou a exclusão de 181 por não se relacionarem diretamente com o tema pesquisado, permanecendo 44 para a leitura completa (Fase 4).

Após a leitura completa dos trabalhos, os estudos de Mhlanga (2021), Kraus et al. (2021) e Han et al. (2015) foram desconsiderados para fundamentar a fase empírica do trabalho (Fase 5).

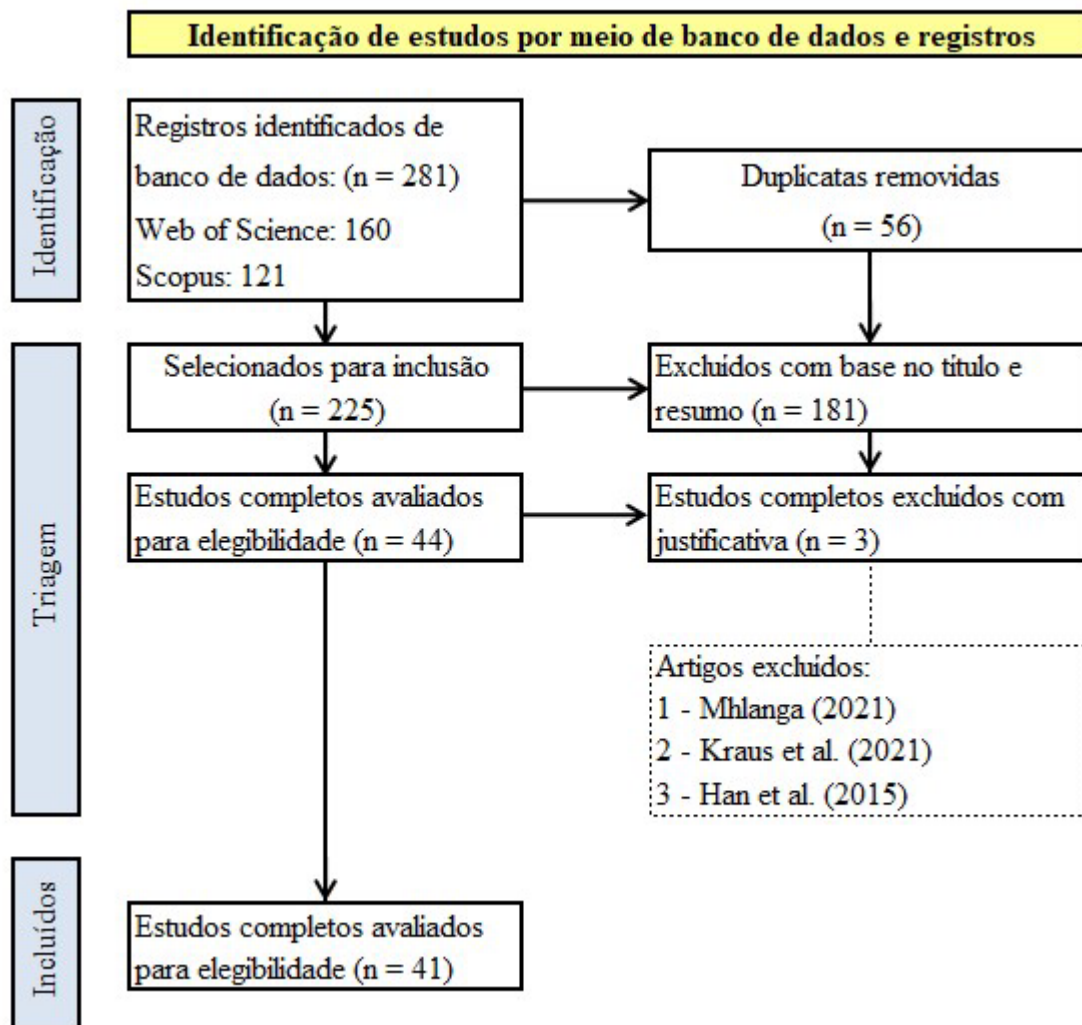
Embora Mhlanga (2021) traga a importância da IA para a produção agrícola, redução da pobreza e inclusão financeira, ele não fornece detalhes específicos sobre as tecnologias de IA utilizadas ou exemplos concretos de como esses impactos são alcançados.

A pesquisa de Kraus et al. (2021) traz informações sobre as implicações ambientais, sociais e institucionais das mudanças disruptivas decorrentes da transformação digital, porém não há menção as barreiras ou facilitadores para tal.

Já o trabalho de Han et al. (2015), aborda o surgimento de enormes conjuntos de dados em várias áreas, como sensoriamento remoto, medicina, internet e setores sociais, trazendo tanto oportunidades como desafios para cientistas e engenheiros, no entanto, o assunto não é tratado de forma objetiva de maneira a permitir que um paralelo fosse traçado com a adoção da IA.

O processo até a extração dos 41 estudos foi conduzido, conforme sugere Page et al. (2021), e pode ser observado na figura 6.

Figura 6. Estágio II – Fases 3 a 5



Fonte: Page et al. (2021)

Os dados dos 41 artigos foram analisados (Fase 6) sob a ótica dos impactos com a adoção da IA e as respectivas análises, planilhadas (Fase 7).

Os achados da *SLR* (Estágio III – Relatório e divulgação) foram planilhados (Fase 8) de maneira a correlacionar os constructos e com as assertivas a serem aplicadas no *survey* decorrente (Fase 9).

3.4

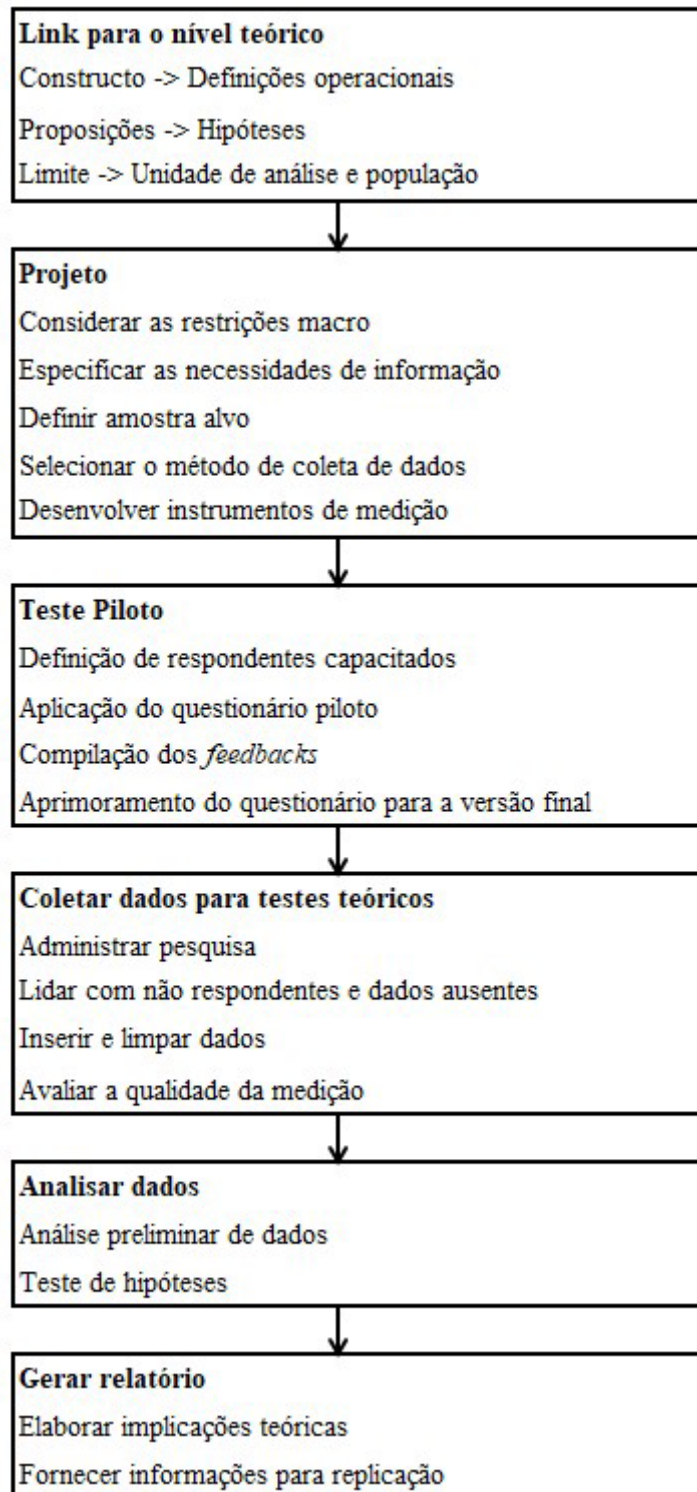
Survey

As pesquisas do tipo *survey* são uma valiosa ferramenta para a ampliação do conhecimento em uma área específica. Elas consistem na coleta de dados junto a uma

população definida por meio de questionários, entrevistas individuais realizadas pessoalmente no local do entrevistado ou por telefone. Essas entrevistas podem abordar tanto informações sobre o indivíduo em si quanto aspectos relacionados ao seu ambiente de trabalho (Forza, 2002).

O *survey* encontra total aderência para com o estudo que se está conduzindo, pois segundo Flynn et al. (1990), trata-se de um desenho de pesquisa indicado para questões que dependem de autorrelatos de dados factuais, bem como de opiniões de um grupo que seja homogêneo em relação a pelo menos uma característica, como a indústria ou o uso de uma determinada tecnologia.

O processo de condução do *survey* foi baseado em Forza (2002), conforme figura 7:

Figura 7. Processo para *survey*.

Fonte: adaptado de Forza (2002)

Chegou-se ao link para o nível teórico a partir dos resultados da *SLR* e de 4 artigos de grande relevância acerca de resiliência na *SCM*, servindo como fundamento teórico para a

definição dos constructos, variáveis e qual seria a população no qual o questionário seria aplicado.

A partir dessas considerações básicas, o projeto foi idealizado, levando em consideração os fatores amplos e externos que pudessem impactar a coleta e interpretação de dados da pesquisa (Restrições macro); quais informações seriam essenciais para atender aos objetivos da pesquisa (Necessidades de informação); qual o perfil adequado dos respondentes de modo a ter aderência com os objetivos do estudo e evitar possíveis vieses (Definição da amostra alvo); e as ferramentas a serem utilizadas para a aplicação do questionário (Método da coleta de dados e Instrumentos de medição), no caso concreto, *Google forms*.

O uso de questionários online em pesquisas do tipo *survey* tem se mostrado vantajoso em termos de custo, rapidez e conveniência (Hunter, 2012). No entanto, existem limitações na coleta de dados online, incluindo viés na amostra e taxas de resposta mais baixas (Lefever et al., 2007). Essas limitações podem ser mitigadas direcionando cuidadosamente os destinatários dos questionários e enfatizando o valor de sua contribuição (Hunter, 2012).

Para seguir as orientações de Hunter (2012), foi elaborado um e-mail enfatizando as contribuições da pesquisa para o setor de defesa nacional. Além disso, após a elaboração do questionário com os parâmetros básicos já estabelecidos, esse foi aplicado, no formato de entrevista, em 12 respondentes da Marinha do Brasil. Esses respondentes possuem notório saber na SCM em decorrência dos mais de 10 anos de experiência atuando na área, permitindo melhorar a qualidade do instrumento de pesquisa, aumentando sua validade, confiabilidade e aceitabilidade antes da aplicação em larga escala.

Dentre esses, 6 forneceram *feedbacks* de maneira a aprimorar o questionário piloto. Os *feedbacks*, tabela 1, foram avaliados e o questionário aprimorado para a versão final.

Tabela 1. Feedback do questionário piloto

Seção	Pergunta	Apontamentos	Ação Adotada
Perfil demográfico do respondente.	Qual é o seu cargo na Organização em que trabalha?	O profissional pode estar afastado temporariamente de suas funções (em curso) e se confundir se as perguntas devem ser respondidas pela sua experiência pregressa ou pelo cargo que exerce no presente momento.	Alterar a pergunta para "qual o(s) cargo(s) que você exerceu ou exerce, na Organização em que trabalha, afeto à cadeia de suprimentos?"
Perfil demográfico do respondente.	Com qual gênero você se identifica?	A palavra Masculino está sem o "s".	Correção para "Masculino"
Flexibilidade da cadeia de suprimentos.	Todas as perguntas	Podem ser que o respondente entenda que a sua Organização não utiliza IA e tenha dificuldades em responder as questões.	Acrescentar a frase "ou caso a sua Organização implantasse a IA"
Desempenho	Todas as perguntas	Podem ser que o respondente entenda que a sua Organização não utiliza IA e tenha dificuldades em responder as questões.	Acrescentar duas figuras com as principais definições de IA.
Desempenho	Como você vê o efeito do uso da IA na performance da sua organização?	Uma das opções começa com "r" minúsculo diferentemente das demais.	Corrigir para "Resulta"
Desempenho	Como você vê o efeito do uso da IA na performance da sua organização?	A frase "Resulta na aplicação razoável dos dados de máquina" está confusa.	Alterar para "Resulta no aprimoramento da interpretação dos dados gerados por máquinas ou equipamentos"

Fonte: elaborado pelo autor (2023)

Para aplicação do questionário final, foram selecionados 1973 respondentes entre militares da Marinha, Exército e Força Aérea e e-mails funcionais de 10 empresas pertencentes a Base Industrial de Defesa (BID), quais sejam: Empresa Gerencial de Projetos Navais; Amazônia Azul Tecnologias de Defesa S.A; Helibras; Taurus; Empresa Brasileira de Aeronáutica S/A; Avibras Indústria Aeroespacial S/A; Novonor; Companhia Brasileira de Cartuchos; Indústria de Material Bélico do Brasil; e NAV Brasil.

É comum em estudos de pesquisa que investigam fenômenos recentes a utilização de participantes selecionados de forma não aleatória, mas que atendem a critérios específicos, pois nos casos da familiaridade prévia dos autores com as empresas dos participantes é possível assegurar que os respondentes sejam adequados para o estudo, o que aumenta a credibilidade das opiniões dos participantes (Netland, 2016; Tortorella et al., 2022).

O perfil da amostra caracterizou-se por militares que fossem da área de intendência, a qual se relaciona diretamente com as atividades logísticas, ou de outras áreas que fossem, no mínimo, Oficiais Superiores, pois devido ao posto, haveria grande chance de terem atuado na SCM, bem como civis da área de defesa que atuassem como prestadores de serviços para as forças armadas.

Após 30 dias decorridos da disponibilização do questionário, obteve-se 247 respondentes. Desses, 32 não possuem experiência na área de logística.

Acerca da representatividade da amostra, Everitt (1975) considera que a partir de 5 respondentes por variável é um número adequado para garantir um nível de poder estatístico significativo, destacando que uma amostra menor de alta qualidade pode ser mais útil do que uma amostra maior de baixa qualidade. Neste mesmo sentido, Arrindell & Van Der Ende (1985) reconhecem que a escolha do tamanho ideal da amostra é uma decisão complexa que depende de vários fatores interligados, e que não existe uma fórmula mágica para determinar o tamanho ideal.

Os 215 respondentes válidos para a análise correspondem a 5,5 respondentes por variável, considerando o total de 39 variáveis analisadas, o que atende ao requisito mínimo de 5 respondentes por variável.

Considerando as avaliações feitas, esta pesquisa evidencia uma significância substancial, sendo pertinente para apresentar os resultados adquiridos no campo e avaliá-los com uma confiança estatística robusta.

Os dados obtidos foram extraídos para uma planilha do excel, tabulados e os *outliers* tratados. Foram identificados 32 outliers, pois foram os respondentes que afirmaram não terem experiência na área de logística e cadeia de suprimentos.

Iniciou-se a análise descritiva da amostra destacando perfil dos respondentes e das variáveis investigadas, utilizando medidas de frequência, como a frequência absoluta e relativa, bem como análise fatorial exploratória (AFE).

Para a AFE, inicialmente houve a preparação dos dados e verificação de adequação para AFE, por meio do cálculo do coeficiente Alpha de Cronbach. O coeficiente foi avaliado para cada um dos 7 constructos inicialmente definidos, segundo um intervalo de confiança de 95%. Em seguida, obteve-se a correlação entre as variáveis para inspecionar se há correlações acima de 0.3, limiar mínimo, por meio do teste de Spearman (Guttman, L., 1958).

Após isso, verificou-se a adequação dos dados à Análise Fatorial. Neste trabalho, essa etapa foi realizada por meio dos testes de KMO (Kaiser-Meyer-Olkin) e Bartlett os quais apontaram para a adequação dos dados para AFE conforme uma amostra acima de 100 (Fabrigar et al., 1999 & Hair et al., 2010). Então, procedeu-se a verificação do número de fatores latentes a partir da qual foram obtidas as cargas fatoriais de cada variável em cada um dos fatores. Por fim, agrupou-se as variáveis nos respectivos fatores para validação dos constructos teóricos.

4

Resultados e discussões

4.1

Resultados teóricos


4.1.1

Resultado da Revisão de escopo

É importante notar que a maioria dos autores (97.4%) colaborou em estudos com múltiplos autores (1180 autores), enquanto apenas 2.6% dos estudos foram de autoria única, envolvendo 31 autores.

Aplicando-se a Lei de Lotka (1926), percebe-se que 89.6% dos autores fizeram apenas uma publicação, 6.4% duas e 4.0% fizeram três ou mais publicações, reforçando a ideia de tratar-se de um domínio de pesquisa que, embora autônomo, é ainda pouco estudado e que conta com um alto grau de capilaridade de autoria (Figura 8).

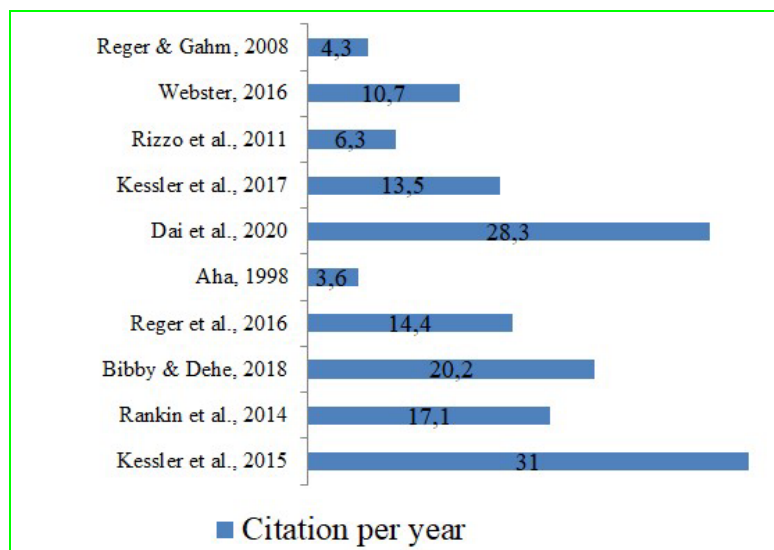
Figura 8. Frequência da Produtividade Científica



Fonte: elaborado pelo autor no *biblioshiny* (2023)

Ao analisar os estudos relevantes em termos de suas citações ao longo dos anos, conforme mostrado na figura 9, fica evidente mais uma vez que o tema abordado ainda recebe pouca atenção da academia.

Figura 9. Dez artigos mais citados por ano

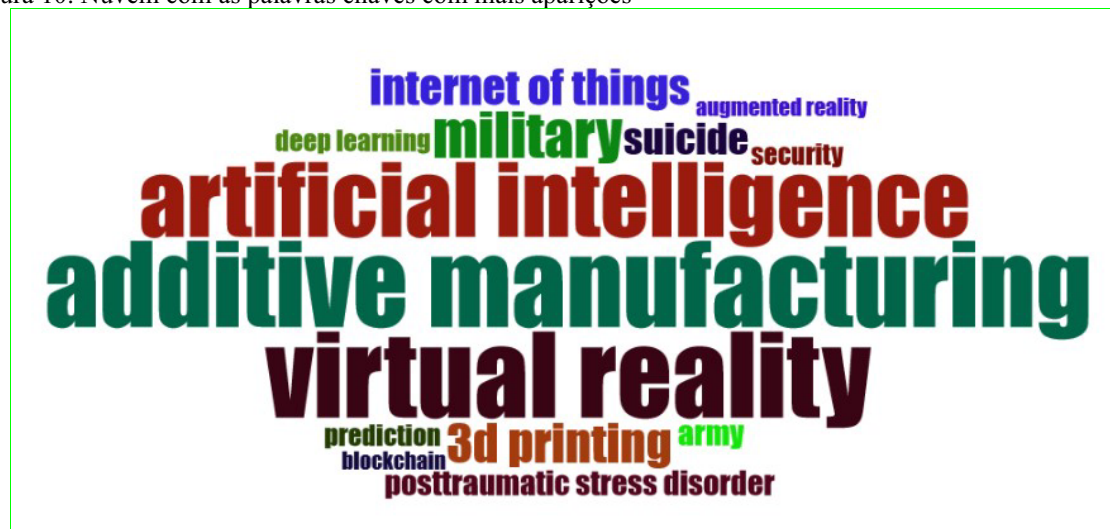


Fonte: elaborado pelo autor no *biblioshiny* (2023)

Após revisar os resumos e identificar estudos relacionados à Indústria 4.0 no setor de defesa, constatou-se que apenas o estudo de Bibby e Dehe (2018) está entre os 10 artigos mais citados por ano na base de dados que utilizamos.


De modo a mapear a tendência das palavras-chaves acerca do tema, comparou-se as figuras 10 e 11, essa demonstrando as ocorrências ao longo dos anos e aquela evidenciando as que mais apareceram nos estudos.

Figura 10. Nuvem com as palavras chaves com mais aparições



Fonte: elaborado pelo autor no *biblioshiny* (2023)

Figura 11. Tópicos de tendência



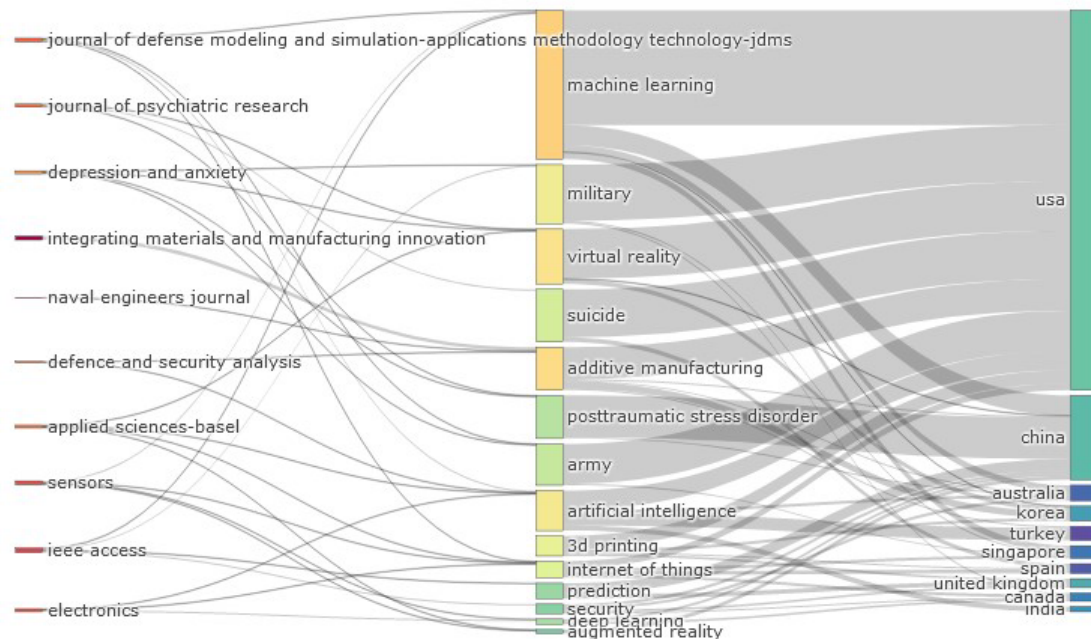
Fonte: elaborado pelo autor no *biblioshiny* (2023)

As palavras mais frequentes são lideradas por "machine learning," que aparece 45 vezes, seguido por "additive manufacturing" e "virtual reality," ambos com 24 ocorrências. Logo em seguida, com 21 aparições, temos "artificial intelligence." Além disso, "military," "3D printing," "Internet of Things," e "army" têm 13, 11, 10 e 7 ocorrências, respectivamente. Outras palavras, como "deep learning," "prediction," e "security," foram mencionadas 6 vezes cada, seguidas por "augmented reality" e "blockchain," com 5 ocorrências.

5 ocorrências.

Observando a Figura 11, fica evidente que as palavras mais frequentes, com exceção de "virtual reality," ganharam destaque a partir de 2018. Isso indica a contemporaneidade do tema e a lacuna existente no contexto do setor de defesa.

Quanto à interconexão entre periódicos, tópicos de pesquisa e países verifica-se, pela figura 12, que há uma diversificação dos principais veículos de publicação, porém uma concentração sob o tópico *machine learning* e que os Estados Unidos da América são os principais estudiosos sobre o tema.

Figura 12. *Three-Fields plot*

Fonte: elaborado pelo autor no *biblioshiny* (2023)

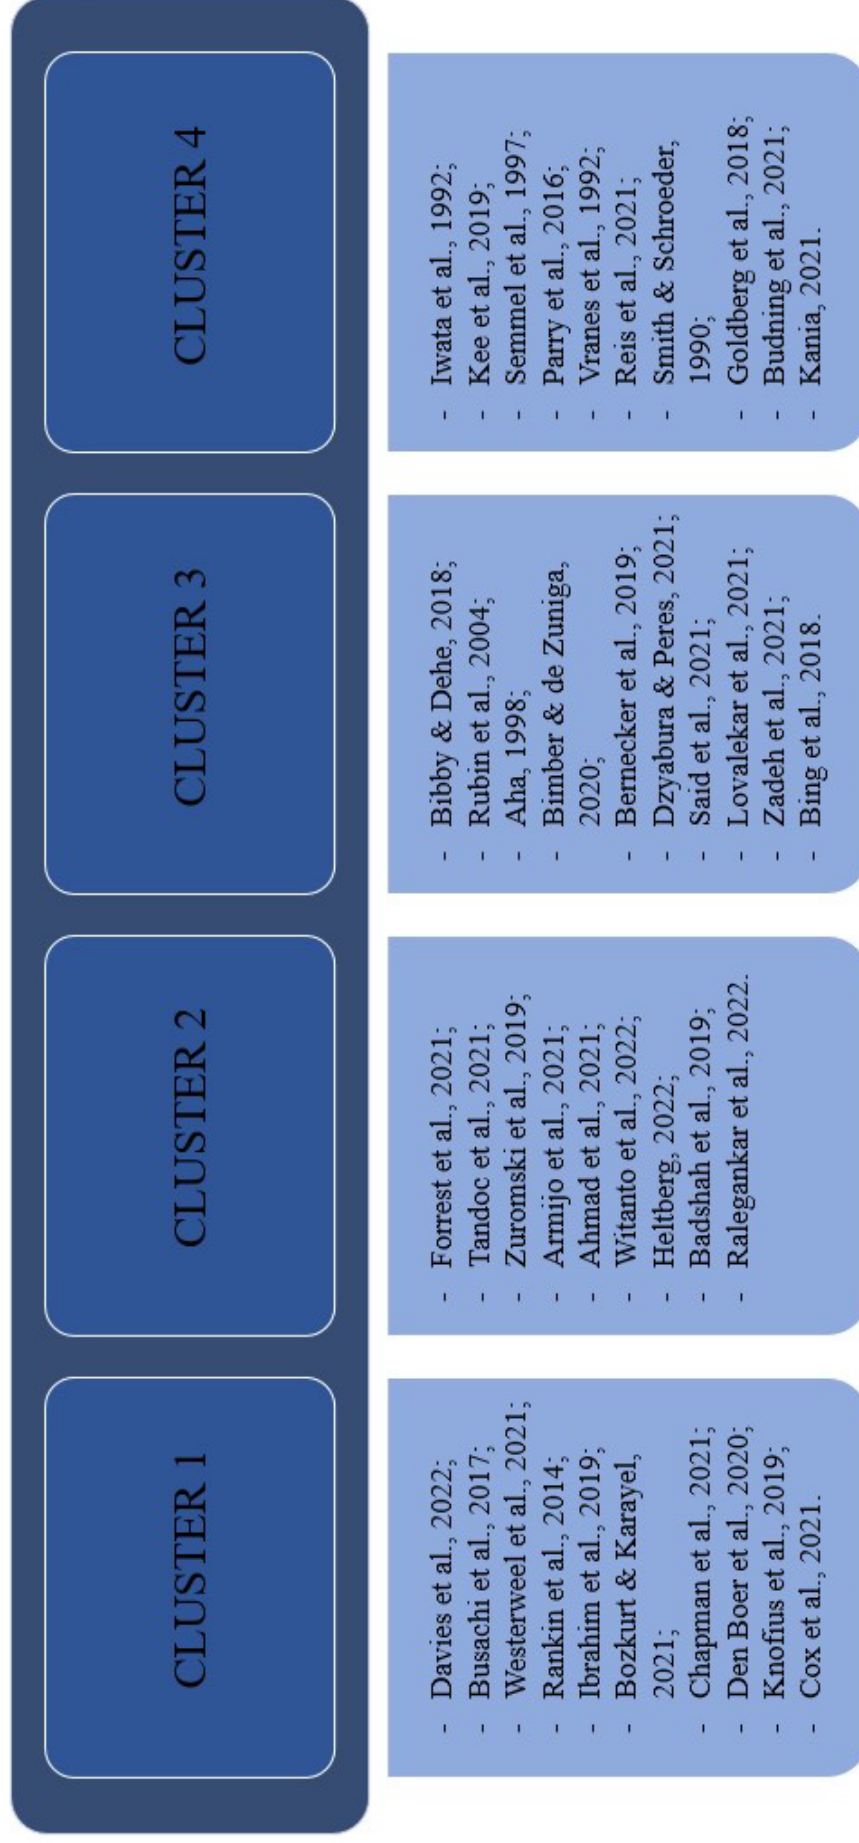
Por fim, a análise bibliométrica das palavras-chave, realizada com a ajuda do *bibliometrix*, resultou em quatro clusters distintos:

- Cluster 1: "additive manufacturing," "3d printing," "spare parts"
- Cluster 2: "internet of things," "deep learning," "military"
- Cluster 3: "machine learning," "suicide," "prediction"
- Cluster 4: "systems," "artificial intelligence," "expert system"

De certo, cumpre esclarecer que o termo “*suicide*” aparece em virtude de diversos estudos relacionando suicídios em decorrência de estresse pós-guerra e o uso de *machine learning* para evitar os incidentes.

Para mapear os conceitos da Indústria 4.0 no contexto do setor de defesa, foi conduzida uma análise crítica do conteúdo dos estudos associados a esses clusters, conforme apresentado na figura 13.

Figura 13. Clusterização



Fonte: elaborado pelo autor no *biblioshiny* (2023)

Ao comparar os clusters, fica evidente que todos eles incluem palavras relacionadas à I4.0. Isso sugere que esses clusters abordam tópicos de grande importância e atualidade, conforme indicado pelo seu alto grau de centralidade (Chen, 2005).

Realizou-se a leitura completa dos estudos relacionados para identificar aqueles que poderiam fornecer insights para a sugestão de futuros tópicos de pesquisa, categorizando-os por cluster. Essa análise resultou na agenda de pesquisa apresentada na tabela 2.

Tabela 2. Agenda de pesquisa

Tema de pesquisa	Cluster	Justificativa
Quais são as implicações práticas da impressão 3D na fabricação de produtos voltados para a indústria de defesa?	1	Os estudos presentes neste cluster evidenciam uma grande aplicabilidade da manufatura aditiva na concepção de produtos para os mais diversos setores. Conhecer as implicações da implementação desta tecnologia no setor de defesa atenderia expectativas de um setor dinâmico e avesso ao erro.
Como o blockchain pode ser utilizado para integrar as diversas indústrias que compõem o setor de defesa?	2	Os estudos presentes neste cluster demonstram que o blockchain tem a capacidade de otimizar processos e facilitar a coordenação entre diferentes empresas com alto nível de segurança. Tais características são fundamentais para o setor de defesa que, dada a natureza das transações que realiza, a integração dos agentes envolvidos no processo de forma segura é imprescindível.
Como os conceitos de Internet of things (IoT) e deep learning podem afetar as operações logísticas das indústrias de defesa?	2	A logística das indústrias de defesa necessita de uma rápida adaptabilidade e flexibilidade para atender a cenários não previstos característicos de um setor ligado a segurança de um país. Desta forma, os conceitos de IoT e deep learning, conforme abordado nos estudos deste cluster, são promissores para o setor.
Estudo de caso para se mapear o nível de maturidade da I4.0 nas indústrias de defesa.	3	Um conjunto de estudos permitirá que se tenha um panorama da I4.0 no setor de defesa e, por conseguinte, evidências empíricas sobre os impactos que as tecnologias inerentes a I4.0 gerem no desempenho operacional das empresas.
Impacto da implementação das tecnologias da I4.0 na <i>SCM</i> das indústrias de defesa.	4	De acordo com os estudos deste cluster, a implementação de inteligência artificial traz inúmeros impactos para as empresas. Um estudo específico sobre essa tecnologia poderia servir como um referencial para o setor de defesa em um possível processo de implantação.

Fonte: elaborado pelo autor (2023)

Em concordância com o cluster 4, Toorajipour et al. (2021) reforça o gap existente acerca do estudo da IA na *SCM* afirmando que mais pesquisas são essenciais para desvendar o potencial da IA e desenvolver soluções viáveis para o mundo real, uma vez que a

verdadeira implementação de soluções de IA na cadeia de suprimentos requer uma compreensão profunda dos desafios reais e dos potenciais benefícios.

Mohsen, B. (2023) reconhece que a IA tem o potencial de melhorar significativamente o desempenho da SCM em várias áreas, como eficiência, eficácia e resiliência. Isso é uma evidência do impacto positivo que a IA pode ter na otimização das operações de cadeia de suprimentos. No entanto, o autor afirma que o assunto ainda carece de ser explorado de maneira a estabelecer um arcabouço sólido para aqueles que desejam implementá-las.

Viswanath (2023), abordam o potencial das tecnologias de IA na gestão de cadeias de suprimentos e operações. Os autores propõem três direções de pesquisa para investigar a adoção e uso dessas tecnologias, que incluem estudos qualitativos e mistos para identificar recursos-chave, compreender os motivos de adoção ou não adoção, e remover obstáculos à adoção, visando obter benefícios significativos na área.

4.1.2

Resultados da SLR

Os 41 trabalhos oriundos da SLR, mais os artigos de Kristianto (2017), Ivanov et al. (2023), Pranesh Saisridhar & Avittathur (2023) e Sharma (2023), foram analisados e chegou-se à definição de cinco constructos: Fatores Sociais; Fatores Técnicos; Adoção de IA; Desempenho; e *Triple-R*.

Cada um deles, conforme aponta a literatura, é influenciado por variáveis específicas. Os fatores sociais e técnicos são constituídos por 3 variáveis (fact_1, fact_2 e fact_3) e (fact_4, fact_5 e fact_6), respectivamente. O constructo Adoção de IA é formado por 10 variáveis (use_1, use_2, use_3, use_4, use_5, use_6, use_7, use_8, use_9 e use_10), enquanto Desempenho por 14 (perform_1, perform_2, perform_3, perform_4, perform_5, perform_6, perform_7, perform_8, perform_9, perform_10, robust_1, robust_2, respon_1 e respon_2) e *Triple-R* por 9 (resil_1, resil_2, resil_3, resil_4, resil_5, rrrperf_1, rrrperf_2, rrrperf_3 e rrrperf_4). Essa relação pode ser visualizada nos quadros 1, 2, 3 e 4.

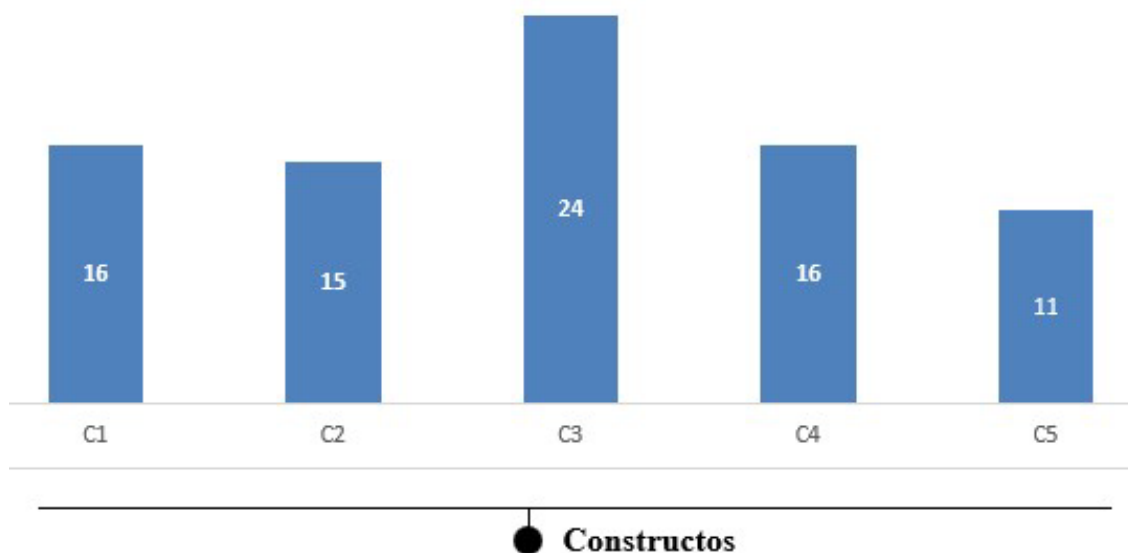
Quadro 4 - Impacto do Triple-R no desempenho

C o n s t r u c t o s	AUTOR		ANO	Variáveis	Assertivas	Min	Davies et al.	Krstianto	Horváth & Szabó	Pournader et al.	Toorajipour et al.	Noor et al.	Modgil et al.	Dey et al.	Ivanov et al.	Pranesh Saisridhar & Avitathur	Sharma				
T r i p l e - R	C ó d i g o s			A flexibilidade aumenta a capacidade de diversificação das fontes de fornecimento em resposta a interrupções	Aumenta a capacidade de diversificação das fontes de fornecimento em resposta a interrupções.									X			X				
				A flexibilidade na cadeia de suprimentos contribui para a redução de custos operacionais	Contribui para a redução de custos operacionais.			X									X				
				A flexibilidade da cadeia de suprimentos permite que ela se ajuste facilmente a mudanças nas condições do mercado	Permite que a cadeia de suprimentos se ajuste facilmente a mudanças nas condições do mercado.			X								X					X
				A flexibilidade na cadeia de suprimentos melhora a capacidade da empresa em atender a picos de demanda inesperados	Melhora a capacidade da empresa em atender a picos de demanda inesperados.											X					
D e s e m p e n h o				Uma cadeia de suprimentos robusta permite que ela opere sem apresentar falhas	Resulta em operações que minimizam falhas.								X								
				Uma cadeia de suprimentos robusta permite personalização em massa e estratégias que minimizam a padronização de processos e incentivam a inovação.	Resulta na personalização em massa e estratégias que minimizam a padronização de processos e incentivam a inovação.											X					
				Uma cadeia de suprimentos responsiva permite que ela responda rapidamente a mudanças no mercado	Resulta na capacidade de responder rapidamente a mudanças no mercado.			X								X					X
				Uma cadeia de suprimentos responsiva permite a redução de custos e gargalos dos processos de produção.	Uma cadeia de suprimentos responsiva resulta na redução de custos e gargalos dos processos de produção.												X				X

A literatura sustenta que os fatores sócio-técnicos afetam a adoção de IA, assim como endossa que a adoção de IA afeta o desempenho operacional e o *Triple-R* da cadeia de suprimentos. Da mesma forma sugere que o *Triple-R* interfere no desempenho operacional da cadeia de suprimentos.

Conforme evidenciado na figura 14, 16 dos artigos apontam para a influência de fatores sociais (C1) na adoção da IA, enquanto 15 indicam que fatores técnicos (C2) afetam essa adoção. Além disso, 24 dos estudos apontam que a implementação da IA na *SCM* resulta em melhorias no desempenho (C3), ao passo que 16 atribuem à IA a capacidade de conferir robustez, responsividade e resiliência (*Triple-R*) à *SCM* (C4), sendo o *Triple-R* também capaz de afetar o desempenho da Organização (C5) conforme sugeriu 11 dos trabalhos.

Figura 14. Número de trabalhos de cada constructo



Fonte: elaborado pelo autor (2023)

Após a identificação e análise dos fatores que afetam a adoção da IA no setor de defesa, resta a sua confirmação empírica por meio de um *survey* de maneira a garantir uma abordagem estruturada e quantificável.

4.2

Resultados empíricos

4.2.1

Análise descritiva do *Survey*

Nesta seção, será realizada a análise descritiva do perfil dos respondentes e das variáveis investigadas, utilizando medidas de frequência, como a frequência absoluta e relativa.

A amostra considerada foi de 215, após a exclusão de 32 respondentes que alegaram não possuir experiência em logística ou *SCM*. Em seguida, foi realizado o cálculo do coeficiente Alpha de Cronbach para avaliação da confiabilidade das respostas. O coeficiente foi avaliado para cada um dos constructos inicialmente definidos, considerando a faixa de confiabilidade apresentada na tabela 3, temos a avaliação conforme tabela 4.

Tabela 3. Faixa de Confiabilidade

Faixa	Classificação
$\alpha \leq 0.3$	Muito baixa
$0.3 < \alpha \leq 0.6$	Baixa
$0.6 < \alpha \leq 0.75$	Moderada
$0.75 < \alpha \leq 0.9$	Alta
$\alpha > 0.9$	Muito Alta

Fonte: elaborado pelo autor (2023)

Tabela 4. Confiabilidade dos constructos

	Coefficiente	Intervalo	Classificação
Fatores que afetam a adoção de IA	0.756	[0.702, 0.803]	Alta
Utilização das ferramentas de IA	0.965	[0.958, 0.972]	Muito Alta
Resiliência	0.948	[0.936, 0.958]	Muito Alta
Robustez	0.662	[0.558, 0.742]	Moderada
Responsividade	0.822	[0.767, 0.864]	Alta
Performance	0.955	[0.945, 0.963]	Muito Alta
Efeito dos 3R na performance	0.902	[0.878, 0.921]	Muito Alta
Geral	0.936	[0.923, 0.947]	Muito Alta

Fonte: elaborado pelo autor (2023)

Pode-se observar que para os constructos, bem como para a amostra como um todo, o coeficiente se encontra em uma faixa na qual o *survey* pode ter sua confiabilidade considerada como pelo menos moderada.

4.2.1.1

Perfil demográfico

A pesquisa conta com uma amostra 247 respondentes, e na tabela 5, é apresentada uma síntese do perfil demográfico desses profissionais por meio do uso de medidas de frequência. A categoria predominante, sob a ótica da experiência em logística ou *supply chain*, foi a com menos de 5 anos de experiência, representando 38,06% dos respondentes.

Em seguida, tem-se aqueles entre 5 e 10 anos de experiência, correspondendo a 23,89% dos respondentes. Em terceiro lugar, representando 16,6% dos profissionais, estão

aqueles entre 10 e 20 anos de experiência e, por último, 8,5% possuem mais de 20 anos de experiência.

Em grande parte, 91,5%, é formada por profissionais do sexo masculino que se encontram na faixa etária de 31 a 43 anos de idade, o que demonstra um perfil de transição entre a juventude e a maturidade. A maior parte desses profissionais que participaram da pesquisa tem mestrado (48,99%), demonstrando razoável grau de especialização.

Outro ponto de destaque é a presença maciça dos respondentes pertencentes a Marinha do Brasil (97,17%). Acredita-se que isso se deve ao fato da filiação do pesquisador a essa instituição. O pesquisador, como membro da Marinha, naturalmente estabelece uma conexão mais estreita com colegas e profissionais que compartilham o mesmo contexto militar.

Acerca da cultura organizacional, verificou-se que 82,59% dos respondentes a entendem como burocrática, 9,31% como inovadora, 4,45% como comunidade e 3,64% como competitiva.

Tabela 5. Perfil demográfico da amostra

Características	Tempo de Experiência												
	Sem experiência		Menos de 5 anos		Entre 5 e 10 anos		Entre 10 e 20 anos		Mais de 20 anos		Total		
	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	
Gênero	Feminino	5	2,02	10	4,05	6	2,43	0	0,00	0	0,00	21	8,50
	Masculino	27	10,93	84	34,01	53	21,46	41	16,60	21	8,50	226	91,50
	Total	32	12,96	94	38,06	59	23,89	41	16,60	21	8,50	247	100,00
Organização	Marinha	31	12,55	93	37,65	58	23,48	38	15,38	20	8,10	240	97,17
	Exército	0	0,00	0	0,00	0	0,00	1	0,40	2	0,81	3	1,21
	Força Aérea	0	0,00	0	0,00	0	0,00	2	0,81	0	0,00	2	0,81
	Outros	0	0,00	1	0,40	1	0,40	0	0,00	0	0,00	2	0,81
Escolaridade	Nível Médio	0	0,00	1	0,40	0	0,00	0	0,00	0	0,00	1	0,40
	Nível Superior	14	5,67	56	22,67	29	11,74	11	4,45	5	2,02	115	46,56
	Mestrado	16	6,48	34	13,77	27	10,93	28	11,34	16	6,48	121	48,99
	Doutorado	1	0,40	3	1,21	3	1,21	2	0,81	1	0,40	10	4,05
	Ph.D.	0	0	0	0	0	0	0	0	0	0	0	0,00
Idade	Entre 18 e 30 anos	3	1,21	22	8,91	5	2,02	0	0,00	0	0,00	30	12,15
	Entre 31 e 43 anos	18	7,29	46	18,62	36	14,57	19	7,69	4	1,62	123	49,80
	Entre 44 e 56 anos	10	4,05	25	10,12	18	7,29	22	8,91	18	7,29	93	37,65
	Entre 57 e 69 anos	0	0,00	1	0,40	0	0,00	0	0,00	0	0,00	1	0,40
	Mais de 69	0	0	0	0	0	0	0	0	0	0	0	0,00
Cultura organizacional	Inovadora	5	2,02	6	2,43	2	0,81	4	1,62	6	2,43	23	9,31
	Competitiva	1	0,40	3	1,21	0	0,00	5	2,02	0	0,00	9	3,64
	Burocrática	24	9,72	80	32,39	54	21,86	31	12,55	15	6,07	204	82,59
	Comunidade	1	0,40	5	2,02	3	1,21	1	0,40	1	0,40	11	4,45

Fonte: elaborado pelo autor (2023)

4.2.1.2

Investigação dos constructos

Uma visão geral das medidas de frequência, absoluta e relativa, e de tendência central, para cada constructo do modelo é apresentada a seguir. Salienta-se que os *outliers* foram retirados das análises.

Nota-se que na tabela 6 e figura 15, a maior parte dos respondentes (38,29%) concorda que os fatores sociais, em especial fact_3 - Resistência na aceitação de IA pelos

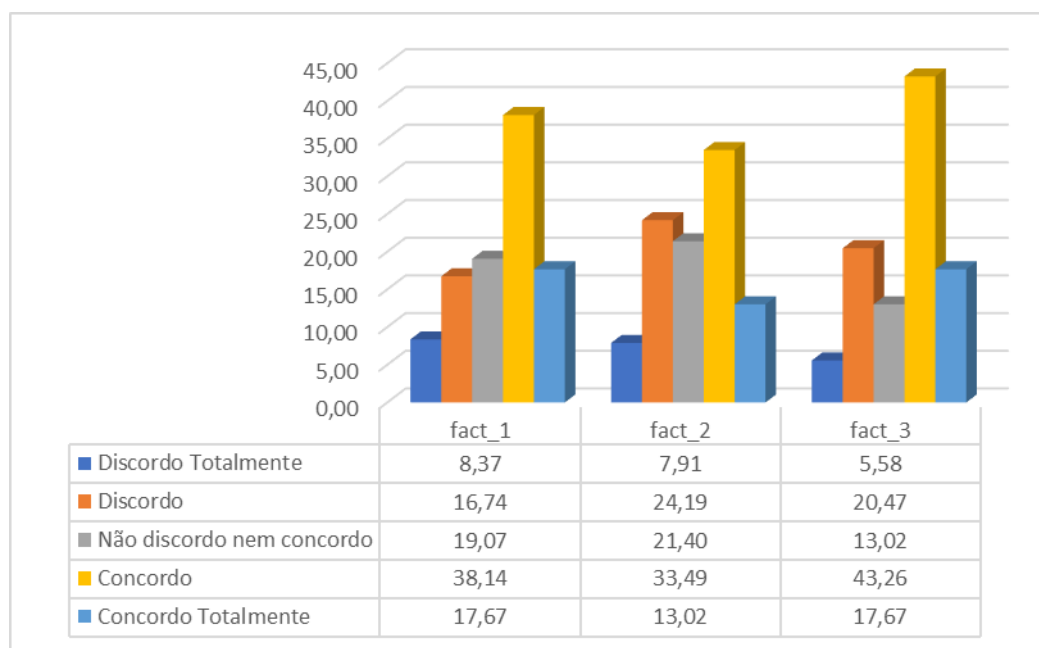
profissionais afeta a adoção de IA, influenciam na adoção de IA. A minoria (7,29%), discorda totalmente, 20,47% discordam, enquanto 16,12% concordam totalmente. 17,83% se mantiveram neutros, não concordando nem discordando.

Tabela 6. Fatores sociais

Variáveis	Escala Likert										Total
	Discordo Totalmente		Discordo		Não discordo nem concordo		Concordo		Concordo Totalmente		
	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	
fact_1	18	8,37	36	16,74	41	19,07	82	38,14	38	17,67	215
fact_2	17	7,91	52	24,19	46	21,40	72	33,49	28	13,02	215
fact_3	12	5,58	44	20,47	28	13,02	93	43,26	38	17,67	215
Total das Repostas	47	7,29	132	20,47	115	17,83	247	38,29	104	16,12	645

Fonte: elaborado pelo autor (2023)

Figura 15. Fatores sociais



Fonte: elaborado pelo autor (2023)


Para os fatores técnicos, verifica-se pela tabela 7 e figura 16, que a maioria maciça concorda (34,11%) ou concorda totalmente (37,36%) que os fatores técnicos afetam a adoção de IA. 15,04% não discordam nem concordam, 9,77% discordam, seguidos por 3,72% que discordam totalmente. Percebe-se que a maioria considera o conhecimento técnico e a cultura organizacional como os principais fatores técnicos a afetarem a adoção de IA.

Tabela 7. Fatores Técnicos

Variáveis	Escala Likert										Total
	Discordo Totalmente		Discordo		Não discordo nem concordo		Concordo		Concordo Totalmente		
	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	
fact_4	2	0,93	17	7,91	22	10,23	83	38,60	91	42,33	215
fact_5	16	7,44	36	16,74	54	25,12	62	28,84	47	21,86	215
fact_6	6	2,79	10	4,65	21	9,77	75	34,88	103	47,91	215
Total das Repostas	24	3,72	63	9,77	97	15,04	220	34,11	241	37,36	645

Fonte: elaborado pelo autor (2023)

Figura 16. Fatores Técnicos



Fonte: elaborado pelo autor (2023)

Investigando o impacto da adoção de IA no desempenho, fica demonstrado na tabela 8 que 41,37% concordam ou concordam totalmente que a adoção de IA impacta no desempenho operacional da organização, enquanto 12,20% discordam dessa opinião e 15,32% discordam totalmente. 31,11% se mantiveram neutros.

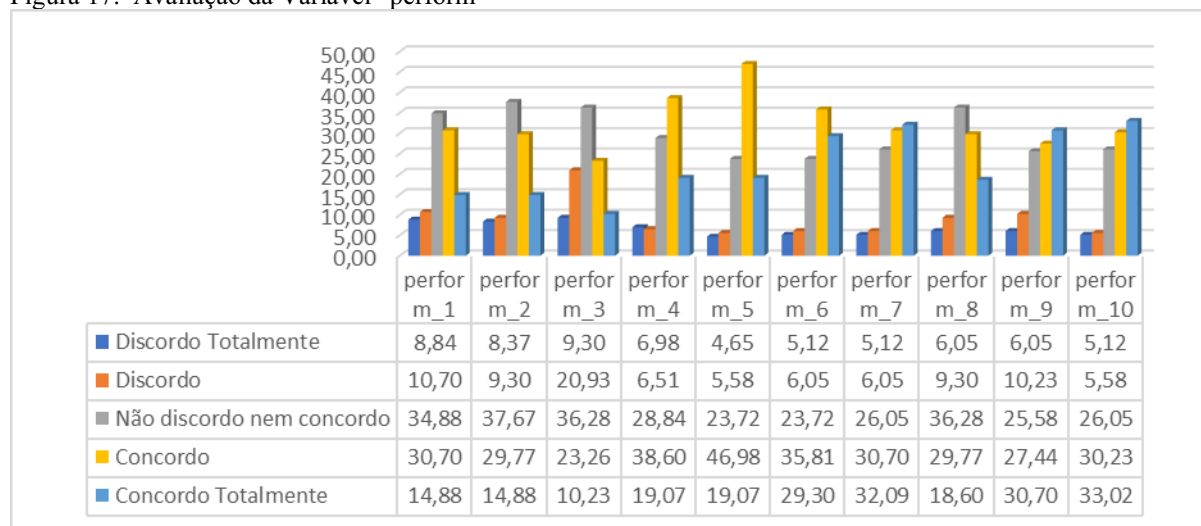
Tabela 8. Impacto da adoção de IA no desempenho

Variáveis	Escala Likert										Total
	Discordo Totalmente		Discordo		Não discordo nem concordo		Concordo		Concordo Totalmente		
	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	
perform_1	19	8,84	23	10,70	75	34,88	66	30,70	32	14,88	215
perform_2	18	8,37	20	9,30	81	37,67	64	29,77	32	14,88	215
perform_3	20	9,30	45	20,93	78	36,28	50	23,26	22	10,23	215
perform_4	15	6,98	14	6,51	62	28,84	83	38,60	41	19,07	215
perform_5	10	4,65	12	5,58	51	23,72	101	46,98	41	19,07	215
perform_6	11	5,12	13	6,05	51	23,72	77	35,81	63	29,30	215
perform_7	11	5,12	13	6,05	56	26,05	66	30,70	69	32,09	215
perform_8	13	6,05	20	9,30	78	36,28	64	29,77	40	18,60	215
perform_9	13	6,05	22	10,23	55	25,58	59	27,44	66	30,70	215
perform_10	11	5,12	12	5,58	56	26,05	65	30,23	71	33,02	215
use_1	60	27,91	38	17,67	69	32,09	34	15,81	14	6,51	215
use_2	66	30,70	39	18,14	72	33,49	31	14,42	7	3,26	215
use_3	57	26,51	34	15,81	73	33,95	33	15,35	18	8,37	215
use_4	54	25,12	31	14,42	66	30,70	42	19,53	22	10,23	215
use_5	61	28,37	36	16,74	74	34,42	28	13,02	16	7,44	215
use_6	57	26,51	30	13,95	64	29,77	44	20,47	20	9,30	215
use_7	64	29,77	44	20,47	76	35,35	21	9,77	10	4,65	215
Total das Respostas	560	15,32	446	12,20	1137	31,11	928	25,39	584	15,98	3655

Fonte: elaborado pelo autor (2023)

De forma específica, observa-se, na Figura 17, a representação gráfica da frequência de respostas relativas ao efeito do uso da IA no desempenho das organizações.

Figura 17. Avaliação da Variável “perform”




Fonte: elaborado pelo autor (2023)

Observa-se que parte considerável dos respondentes concorda que as variáveis perform_5 - Qualidade dos serviços prestados/produtos produzidos (46,98%) e perform_4 - Redução de custos através da interconexão (38,60%) são afetadas pelo uso de IA. Por outro lado, boa parte (20,93%) discorda que a variável perform_3 - Geração de soluções difíceis de imitar seja afetada pela adoção de IA.

Sob o prisma da utilização das ferramentas de IA na organização dos respondentes, têm-se os seguintes levantamentos, conforme figura 18:

Figura 18. Avaliação da Variável “use”



Fonte: elaborado pelo autor (2023)

Em todas as variáveis avaliadas, “não concordo nem discordo” foi a resposta da maioria dos respondentes. Essa resposta teve como média e desvio padrão, 33,21 e 1,69, respectivamente, denotando pouca dispersão em torno da média. Pode-se inferir a partir da neutralidade evidenciada, portanto, que a IA ainda é pouco utilizada nas organizações pesquisadas, tornando difícil para os respondentes avaliarem essas variáveis.

Ao consultar a tabela 9 para examinar o impacto da Adoção de IA no *Triple-R*, observa-se que 31,63% dos participantes concordam que a aplicação da inteligência artificial afeta a resiliência da cadeia de suprimentos. Enquanto isso, 26,74% mantêm uma posição neutra, não discordando nem concordando. Além disso, 16,16% expressam total concordância, 14,59% discordam integralmente, e 10,87% têm uma visão discordante sobre o assunto.


Tabela 9. Impacto da Adoção de IA no *Triple-R*

Variáveis	Escala Likert										Total
	Discordo Totalmente		Discordo		Não discordo nem concordo		Concordo		Concordo Totalmente		
	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	
use_8	71	33,02	46	21,40	73	33,95	16	7,44	9	4,19	215
use_9	76	35,35	42	19,53	73	33,95	15	6,98	9	4,19	215
use_10	70	32,56	39	18,14	74	34,42	19	8,84	13	6,05	215
resil_1	5	2,33	14	6,51	43	20,00	111	51,63	42	19,53	215
resil_2	8	3,72	11	5,12	43	20,00	101	46,98	52	24,19	215
resil_3	7	3,26	12	5,58	52	24,19	90	41,86	54	25,12	215
resil_4	7	3,26	12	5,58	52	24,19	100	46,51	44	20,47	215
resil_5	7	3,26	11	5,12	50	23,26	92	42,79	55	25,58	215
Total das Repostas	251	14,59	187	10,87	460	26,74	544	31,63	278	16,16	1720

Fonte: elaborado pelo autor (2023)

Ao comparar os dois tipos de variáveis observamos, na figura 19, que o impacto da adoção de IA no *Triple-R* é principalmente validada pelas variáveis "resil". Isso sugere, mais uma vez, que a inteligência artificial ainda é pouco utilizada nas organizações pesquisadas. Essa escassez de uso dificulta para os respondentes a avaliação das variáveis "use".

Figura 19. Comparação entre as variáveis "resil" e "use"



Fonte: elaborado pelo autor (2023)

Quanto ao impacto do *Triple-R* no desempenho, a análise da Tabela 10 revela que 42,56% dos participantes estão de acordo com essa afirmação. Enquanto isso, 24,59% mantêm uma posição neutra, sem concordar nem discordar. Adicionalmente, 17,97% expressam total concordância, 11,98% discordam e 2,91% discordam totalmente dessa ideia.

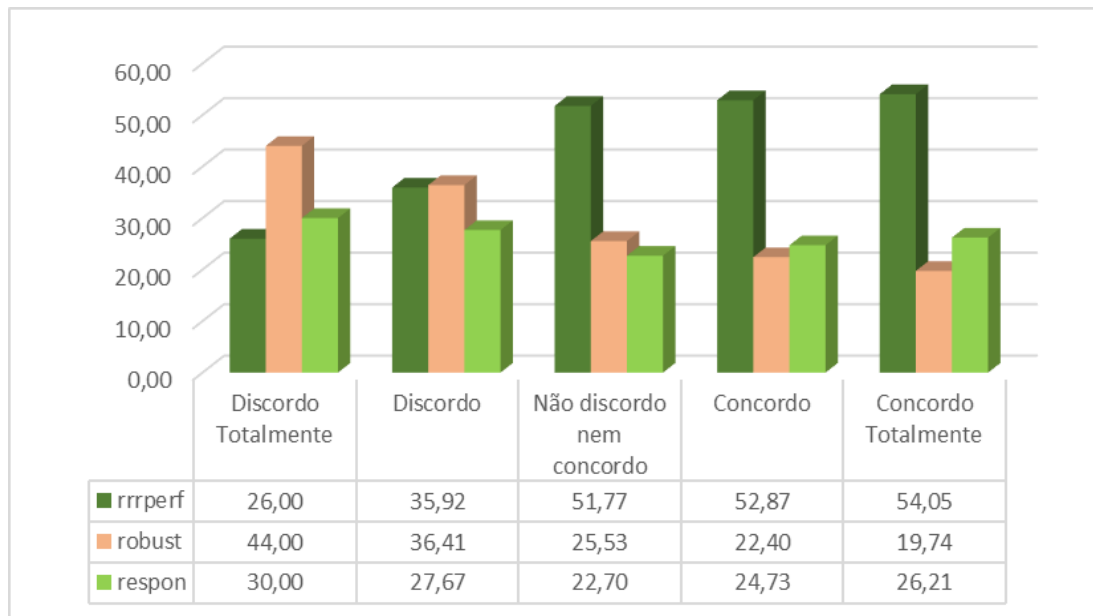
Tabela 10. Impacto do Triple-R no desempenho

Variáveis	Escala Likert										
	Discordo Totalmente		Discordo		Não discordo nem concordo		Concordo		Concordo Totalmente		Total
	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	F.Abs	F.Rel.(%)	
rrrperf_1	4	1,86	16	7,44	60	27,91	104	48,37	31	14,42	215
rrrperf_2	3	1,40	18	8,37	43	20,00	103	47,91	48	22,33	215
rrrperf_3	3	1,40	23	10,70	56	26,05	95	44,19	38	17,67	215
rrrperf_4	3	1,40	17	7,91	60	27,91	85	39,53	50	23,26	215
robust_1	6	2,79	32	14,88	42	19,53	95	44,19	40	18,60	215
robust_2	16	7,44	43	20,00	66	30,70	69	32,09	21	9,77	215
respon_1	7	3,26	29	13,49	53	24,65	85	39,53	41	19,07	215
respon_2	8	3,72	28	13,02	43	20,00	96	44,65	40	18,60	215
Total das Repostas	50	2,91	206	11,98	423	24,59	732	42,56	309	17,97	1720

Fonte: elaborado pelo autor (2023)

Ao contrastar os grupos de variáveis, conforme evidenciado na Figura 20, destaca-se que "rrrperf" é a variável principal que sustenta a afirmação de que o *Triple-R* na cadeia de suprimentos influencia seu desempenho operacional, abrangendo 52,87% dos que concordam e 54,05% dos que concordam totalmente. Em seguida, temos "respon" com 24,73% dos que concordam e 26,21% dos que concordam totalmente. Por fim, a variável "robust" é representativa com 22,40% dos que concordam e 19,74% dos que concordam plenamente. Vale ressaltar que, analisando individualmente por grupo de variável, "rrrperf_1" (48,37% concordam e 14,42% concordam totalmente), "robust_1" (44,19% concordam e 18,6% concordam totalmente) e "respon_2" (44,65% concordam e 18,60% concordam totalmente) se destacam como as que mais reforçam o impacto positivo do *Triple-R* no desempenho da cadeia de suprimentos.

Figura 20. Comparação entre as variáveis "rrrperf", "robust" e "respon"




Fonte: elaborado pelo autor (2023)

4.2.2

Análise Fatorial Exploratória

Para realização da análise fatorial exploratória, o primeiro passo é a obtenção da correlação entre as variáveis para inspecionar se há correlações acima de 0.3, limiar mínimo para realização da Análise Fatorial Exploratória. A figura 21, apresenta a correlação de Spearman.

Figura 21. Correlação de Spearman entre as variáveis




O passo seguinte é a verificação de adequação dos dados à Análise Fatorial. Neste trabalho, essa etapa foi realizada através dos testes de KMO (Kaiser-Meyer-Olkin) e de esfericidade de Bartlett, chegando-se ao valor de 0.9079 e de [Qui-quadrado: 7795,766; p-valor: 0], respectivamente. Desta forma, um p-valor de 0 para o teste de Bartlett e um valor de KMO acima de 0.7 confirmam a adequação dos dados à análise fatorial para uma amostra acima de 100 conforme concordam Fabrigar et al. (1999) e Hair et al. (2010).

Na sequência da análise fatorial exploratória, deve-se verificar o número de fatores latentes. Alguns critérios que podem ser utilizados nesse caso, são o gráfico de Escarpa e o

número de autovalores acima de 1. O gráfico de Escarpa para os dados analisados se encontra na figura 22 a seguir.

Figura 22. Gráfico de Escarpa



Os 10 primeiros autovalores encontram-se na tabela 11.

Tabela 11. Dez primeiros autovalores

ID	Autovalor
1	1.344.629
2	6.009.513
3	301.747
4	2.436.815
5	1.916.494
6	1.171.134
7	1.047.433
8	0.987303
9	0.760867
10	0.729866

Pode-se observar que, por ambos os critérios, o número de fatores latentes presentes é de 7. No entanto, prosseguiremos com 6 fatores, pois, ao tentar seguir com 7, um dos fatores não possuía nenhuma variável (isto é, a carga fatorial de todas as variáveis era menor neste fator do que nos outros), o que na prática corresponde à não-existência do fator.

A partir da definição do número de fatores, foram obtidas as cargas fatoriais de cada variável em cada um dos fatores. Estas cargas fatoriais foram então utilizadas para determinar quais variáveis correspondem a quais fatores, conforme tabela 12.

Tabela 12. Correspondência entre variáveis e fatores

Variáveis	Fatores					
	Factor 1	Factor 2	Factor 3	Factor 4	Factor 5	Factor 6
fact_1	0.183532	-0.07751	-0.09246	0.065633	0.67646	0.036102
fact_2	0.088932	-0.14465	-0.14051	0.05565	0.702293	0.017901
fact_3	-0.00536	-0.02491	-0.13479	0.017905	0.657596	0.094294
fact_4	-0.17362	0.038922	0.116871	0.039114	0.367255	-0.02683
fact_5	0.123817	-0.19667	0.086569	0.023074	0.587327	-0.06038
fact_6	-0.14964	0.063958	0.085431	-0.11353	0.499889	-0.01947
use_1	0.825373	0.138076	0.039095	0.170955	0.010002	-0.00381
use_2	0.850168	0.131805	-0.00641	0.013139	0.035775	0.082489
use_3	0.869076	0.140435	0.098569	0.076911	0.005735	-0.10991
use_4	0.830793	0.08713	0.119203	0.126214	0.030521	-0.13553
use_5	0.886521	0.091177	0.111105	0.049369	0.05123	-0.01882
use_6	0.889007	0.096224	0.0886	0.158577	-0.04406	-0.15019
use_7	0.757786	0.11322	0.083582	0.099663	-0.07256	0.050279
use_8	0.854466	0.136833	0.034499	0.031917	0.068141	0.260217
use_9	0.79917	0.136114	0.026376	0.049468	-0.00057	0.264873
use_10	0.858973	0.131342	0.0813	0.105915	-0.04769	0.157158
resil_1	0.095684	0.248375	0.847761	0.203826	-0.05419	-0.0083
resil_2	0.103969	0.230014	0.795032	0.170152	-0.04077	-0.00065
resil_3	0.079263	0.266746	0.802339	0.185809	-0.04575	0.06869
resil_4	0.037453	0.288918	0.830457	0.137682	0.015195	-0.00826
resil_5	0.099779	0.333595	0.798724	0.111741	-0.03199	0.01558
robust_1	0.146819	0.255823	0.308623	0.436854	0.079382	0.216089
robust_2	0.297232	0.260554	0.246684	0.277136	0.082904	0.344853
respon_1	0.163053	0.155338	0.427954	0.422659	0.117417	0.367698
respon_2	0.136713	0.209927	0.459678	0.428359	0.128503	0.243261
perform_1	0.160499	0.744002	0.08513	0.125711	-0.02378	0.278272
perform_2	0.154085	0.722398	0.130288	0.180404	-0.16267	0.248176
perform_3	0.154361	0.613627	0.038767	0.226784	-0.07211	0.375855
perform_4	0.19124	0.750188	0.138775	0.233075	-0.05151	0.096835
perform_5	0.115912	0.839582	0.258543	0.197383	-0.04804	-0.06076
perform_6	0.1394	0.818438	0.266578	0.168709	-0.00069	-0.07146
perform_7	0.107636	0.830424	0.269596	0.196782	-0.03722	-0.07343
perform_8	0.129855	0.715006	0.237752	0.122248	-0.03474	0.031056
perform_9	0.106441	0.781463	0.243266	0.209605	-0.07722	-0.08454
perform_10	0.096759	0.833815	0.309446	0.185789	-0.06076	-0.09147
rrrperf_1	0.149607	0.26819	0.142174	0.704201	-0.03785	0.049794
rrrperf_2	0.109203	0.365533	0.228457	0.709036	-0.02179	-0.09511
rrrperf_3	0.126643	0.238536	0.166409	0.802793	0.034427	-0.00817
rrrperf_4	0.10391	0.281123	0.166092	0.74884	0.024804	0.061382

Fonte: elaborado pelo autor (2023)

O agrupamento das variáveis nos respectivos fatores, com as cargas fatoriais, encontra-se na figura 23.


Figura 23. Agrupamento das variáveis

	Factor 1		Factor 2		Factor 3
use_1	0.825373	perform_1	0.744002	resil_1	0.847761
use_2	0.850168	perform_2	0.722398	resil_2	0.795032
use_3	0.869076	perform_3	0.613627	resil_3	0.802339
use_4	0.830793	perform_4	0.750188	resil_4	0.830457
use_5	0.886521	perform_5	0.839582	resil_5	0.798724
use_6	0.889007	perform_6	0.818438	respon_1	0.427954
use_7	0.757786	perform_7	0.830424	respon_2	0.459678
use_8	0.854466	perform_8	0.715006		
use_9	0.79917	perform_9	0.781463		
use_10	0.858973	perform_10	0.833815		
	Factor 4		Factor 5		Factor 6
robust_1	0.436854	fact_1	0.67646	robust_2	0.344853
rrrperf_1	0.704201	fact_2	0.702293		
rrrperf_2	0.709036	fact_3	0.657596		
rrrperf_3	0.802793	fact_4	0.367255		
rrrperf_4	0.74884	fact_5	0.587327		
		fact_6	0.499889		

Fonte: elaborado pelo autor (2023)

A distribuição das variáveis pelos fatores também pode ser visualizada na figura 24:

Figura 24. Distribuição das variáveis



Percebe-se que o Factor 1 é composto por variáveis que se relacionam com a adoção de IA, seja sobre o efeito que gera no desempenho das organizações pesquisadas, seja ao

impactar no *Triple-R*. Já o Factor 2, é constituído pelas variáveis que demonstram o efeito da IA no desempenho operacional.

O Factor 3 é formado por variáveis que indicam como a resiliência e a responsividade da cadeia de suprimentos é impactada pela adoção de IA, enquanto o 4 apresenta a flexibilidade ante a adoção de IA e a minimização de falhas atribuída a robustez de uma cadeia de suprimentos que utiliza IA.

No Factor 5 encontra-se o impacto dos fatores sociotécnicos no processo de implementação de IA nas organizações pesquisadas e, no Factor 6, verifica-se somente a variável que denota a personalização em massa e estratégias que minimizam a padronização de processos e incentivam a inovação diante da utilização de IA.

4.3

Discussão de resultados

4.3.1

Discussões Gerais

Constatou-se, portanto que o conceito da I4.0 nas indústrias de defesa representa um domínio de pesquisa distinto. Os principais periódicos, artigos, instituições e autores que atuam nesse domínio foram identificados e foi mapeada a rede de colaboração entre universidades e autores. Além disso, explorou-se a estrutura conceitual da I4.0 na indústria de defesa, identificando e investigando clusters de pesquisa relevantes.

Como resultado da revisão de escopo, propõe-se uma agenda de pesquisa que, embora não seja abrangente, servirá como um guia para uma análise mais aprofundada do tema, visando à construção de um referencial teórico consolidado.

Ficou evidente que este campo de pesquisa ainda é pouco explorado pelos acadêmicos, apesar da sua relevância, uma vez que as indústrias de defesa desempenham um papel fundamental na soberania nacional e na economia de um país. Portanto, é necessário direcionar mais atenção a essa área de estudo.

A partir do arcabouço teórico construído pela revisão de escopo, a *SLR* aprofundou o conhecimento teórico sobre a IA dentro do setor de defesa, formulando constructos e variáveis a partir dos conceitos trabalhados na literatura, além de identificar os principais estudos que tratam do tema.

Os resultados da pesquisa sobre os fatores que afetam a adoção da IA no setor de defesa são promissores e sugerem que a IA tem o potencial de melhorar significativamente o

desempenho das cadeias de suprimentos militares, corroborando com O'Connor e Pugh (2022), os quais consideram que a IA tem o potencial de trazer inovações significativas para a gestão da cadeia de suprimentos, melhorando a eficiência, a precisão e a capacidade de adaptação a um ambiente de negócios em constante mudança.

Os cinco constructos identificados na pesquisa - fatores sociais, fatores técnicos, adoção de IA, desempenho e Triple-R - fornecem uma estrutura conceitual útil para entender as relações entre esses fatores.

Os fatores sociais incluem fatores relacionados à cultura, à liderança e à gestão de pessoas. A pesquisa sugere que esses fatores podem ter um impacto significativo na adoção da IA. Por exemplo, uma cultura organizacional que valoriza a inovação e a experimentação pode ser mais propensa a adotar a IA. Da mesma forma, uma liderança forte e comprometida com a adoção da IA pode ajudar a superar os desafios e obstáculos associados à implementação da tecnologia (Smith, Vacca & Ford, 2022).

Os fatores técnicos, por sua vez, estão intrinsecamente ligados à disponibilidade de dados, à infraestrutura e à competência em tecnologia da informação (TI). Os achados indicam que esses elementos também desempenham um papel significativo na adoção da IA. Haja vista que uma organização que dispõe de dados abundantes e de alta qualidade pode estar mais inclinada a obter êxito ao implementar a IA. Da mesma forma, Zhao, Ma e Chen (2022) afirmam que uma empresa que conta com uma infraestrutura de TI sólida e uma equipe de TI experiente está mais propensa a alcançar sucesso na implementação e no gerenciamento eficaz da IA.

A implementação de IA em uma organização é um processo complexo que envolve diversos fatores, como destacado pela pesquisa. A compreensão aprofundada desses fatores pode capacitar as organizações a desenvolverem estratégias eficazes para a incorporação bem-sucedida da IA.

O desempenho, por sua vez, é o resultado tangível dessa adoção de IA. A pesquisa aponta que a sua implementação pode aprimorar significativamente o desempenho das cadeias de suprimentos de diversas maneiras. Exemplificando, a IA tem o potencial de otimizar a eficiência, a eficácia, a flexibilidade e a resiliência das cadeias de suprimentos (Chen, Lee & Chen, 2022).

O *Triple-R*, representando robustez, responsividade e resiliência, emerge como elementos críticos para o desempenho das cadeias de suprimentos. Conforme indicado pela pesquisa, a adoção da IA pode desempenhar um papel crucial na melhoria desses três fatores

fundamentais, promovendo avanços substanciais nas cadeias de suprimentos, corroborando com o que caracteriza Strader et al. (2020): a IA tem a capacidade de aprimorar consideravelmente a resistência, a capacidade de resposta e a capacidade de recuperação das cadeias de suprimentos.

Na busca de confirmar o que fora encontrado na literatura, foi realizado o *survey* para coletar dados e informações de uma amostra representativa do setor de defesa.

Com base na análise descritiva, verificou-se que a maior parte dos respondentes possui menos de 5 anos de experiência, com isso, devido a estarem no início de suas carreiras, esses profissionais enfrentam desafios atinentes a falta de maturidade para a tomada de decisão e a aplicação prática de suas tarefas, no entanto, é também uma fase de crescimento e aprendizado profissional (Lima, 2023) sendo, portanto, um momento propício para o desenvolvimento nas habilidades afetas a IA.

Em segundo lugar estão aqueles entre 5 e 10 anos de experiência, os quais já possuem certo conhecimento consolidado e maior autonomia, contudo encontram-se em momento da carreira fundamental para o aprimoramento e atualização (Oliveira, 2024).

Em seguida estão os profissionais entre 10 e 20 anos de experiência, caracterizando-se por serem mais especializados em determinadas áreas e desenvolverem uma liderança mais madura, no entanto, podem ser mais resistentes em adotar novas abordagens ou tecnologias (Souza & Carvalho, 2012).

Por fim, restam aqueles com mais de 20 anos de experiência e que se destacam por deterem uma rica sabedoria profissional e histórico de sucesso, contudo podem apresentar resistência às inovações disruptivas e a se adaptarem rapidamente às mudanças tecnológicas (Oliveira & Oliveira, 2014).

Acerca da cultura organizacional, verificou-se que a grande maioria entende a sua cultura organizacional como burocrática. Esse cenário de prevalência de uma cultura organizacional burocrática em detrimento da inovadora pode levar a dificuldades ao se tentar adotar tecnologias avançadas, como a IA, porque se valoriza a estabilidade e a conformidade com procedimentos estabelecidos. Isso pode resultar em uma falta de flexibilidade e uma relutância em experimentar novas abordagens (Chiavenato, 2004), características fundamentais para a adoção bem-sucedida da IA, que muitas vezes envolve experimentação e iteração contínua.

Analisando a relação entre os fatores sociais e a adoção de IA, verifica-se que a maioria concorda que tais fatores, especialmente a resistência na aceitação de IA pelos

profissionais (fact_3), afetam a adoção de IA. Este resultado sugere uma sensibilidade significativa às dinâmicas sociais que envolvem a aceitação da IA.

Desta forma, percebe-se uma heterogeneidade de opiniões entre os respondentes em relação aos fatores sociais e sua influência na adoção de IA. Essa diversidade pode ser explorada mais profundamente para identificar padrões, tendências e fatores subjacentes que moldam as atitudes desses profissionais, contribuindo assim para uma compreensão mais abrangente das dinâmicas envolvidas na adoção de IA no contexto das indústrias de defesa.

Constatou-se também uma convergência de opiniões sobre a importância dos fatores técnicos no processo de implementação da IA. A alta concordância total sugere uma percepção robusta de que elementos técnicos desempenham um papel crucial na adoção bem-sucedida de IA nas organizações do setor de defesa.

Ao analisar as variáveis específicas que substanciam o efeito da adoção de IA no desempenho operacional, destaca-se que uma parte considerável dos respondentes concorda que a qualidade dos serviços/produtos e a redução de custos por meio da interconexão são afetadas positivamente pelo uso de IA. No entanto, uma parcela significativa discorda que a geração de soluções difíceis de imitar seja impactada pela adoção de IA. Essas divergências sugerem que a percepção do impacto da IA pode variar dependendo da natureza específica da variável avaliada.

Outro ponto de destaque é que uma parcela significativa dos participantes (31,63%) concorda que a aplicação da inteligência artificial impacta a resiliência da cadeia de suprimentos. No entanto, ao se comparar a influência de cada uma das variáveis relacionadas, percebe-se que ela é principalmente validada pelas variáveis “resil” em detrimento da “use”, sugerindo que a falta de utilização de IA dentro das organizações estudadas impacta na percepção desta variável.

Com base na análise do impacto do *Triple-R*, no desempenho operacional da cadeia de suprimentos, percebeu-se que esse impacto é mais significativo nas dimensões de redução de custos, melhoria da qualidade e aumento da satisfação do cliente.

A AFE se mostrou adequada para esse estudo porque é uma ferramenta que pode ser usada para identificar grupos de variáveis que estão correlacionadas entre si. Contudo, pressupostos precisam ser observados de maneira que o resultado da análise seja relevante.

Inicialmente, atestou-se a confiabilidade da amostra, sem a qual não seria possível prosseguir com a análise fatorial. Outro ponto que invalidaria a AFE é falta de adequação dos

dados à análise fatorial, no entanto, os testes realizados revelaram uma adequação, no mínimo, moderada.

Com base na AFE, percebe-se que pode existir uma relação entre algumas variáveis dentro de cada fator latente, levando a formulação de constructos e relações diferentes daquelas formuladas por ocasião da *SLR*.

De forma semelhante à *SLR*, os resultados da AFE apontaram para uma relação intrínseca entre os grupos de variáveis [fact_1, fact_2 e fact_3, fact_4, fact_5 e fact_6], convergindo na ideia de que os fatores sociotécnicos afetam a adoção de IA. No entanto, quanto aos demais, enquanto o AFE considera que as variáveis [perform_1, perform_2, perform_3, perform_4, perform_5, perform_6, perform_7, perform_8, perform_9, perform_10] formam um constructo autônomo, a *SLR* acrescenta ainda as variáveis [use_1, use_2, use_3, use_4, use_5, use_6 e use_7].

Desta forma, agregando os *insights* decorrentes das distintas análises conduzidas, as organizações em processo de transformação digital da sua cadeia de suprimentos, por meio da IA, devem considerar:

- O impacto potencial da adoção de IA no desempenho geral da organização e no Triple-R.
- O impacto potencial da adoção de IA no desempenho operacional da cadeia de suprimentos.
- O impacto potencial da adoção de IA na resiliência e responsividade da cadeia de suprimentos.
- O impacto potencial da adoção de IA na flexibilidade e robustez da cadeia de suprimentos.
- Os fatores sociotécnicos que podem influenciar a implementação da IA.
- O potencial da adoção de IA para promover a personalização em massa e inovação.

Pelo exposto, agregando os conceitos e insights gerados pelas abordagens metodológicas, propõe-se o seguinte *roadmap* para transformação digital no setor de defesa a partir de uma abordagem Plan, Do, Check and Act (PDCA), segundo Shewhart, W. A. (1939):

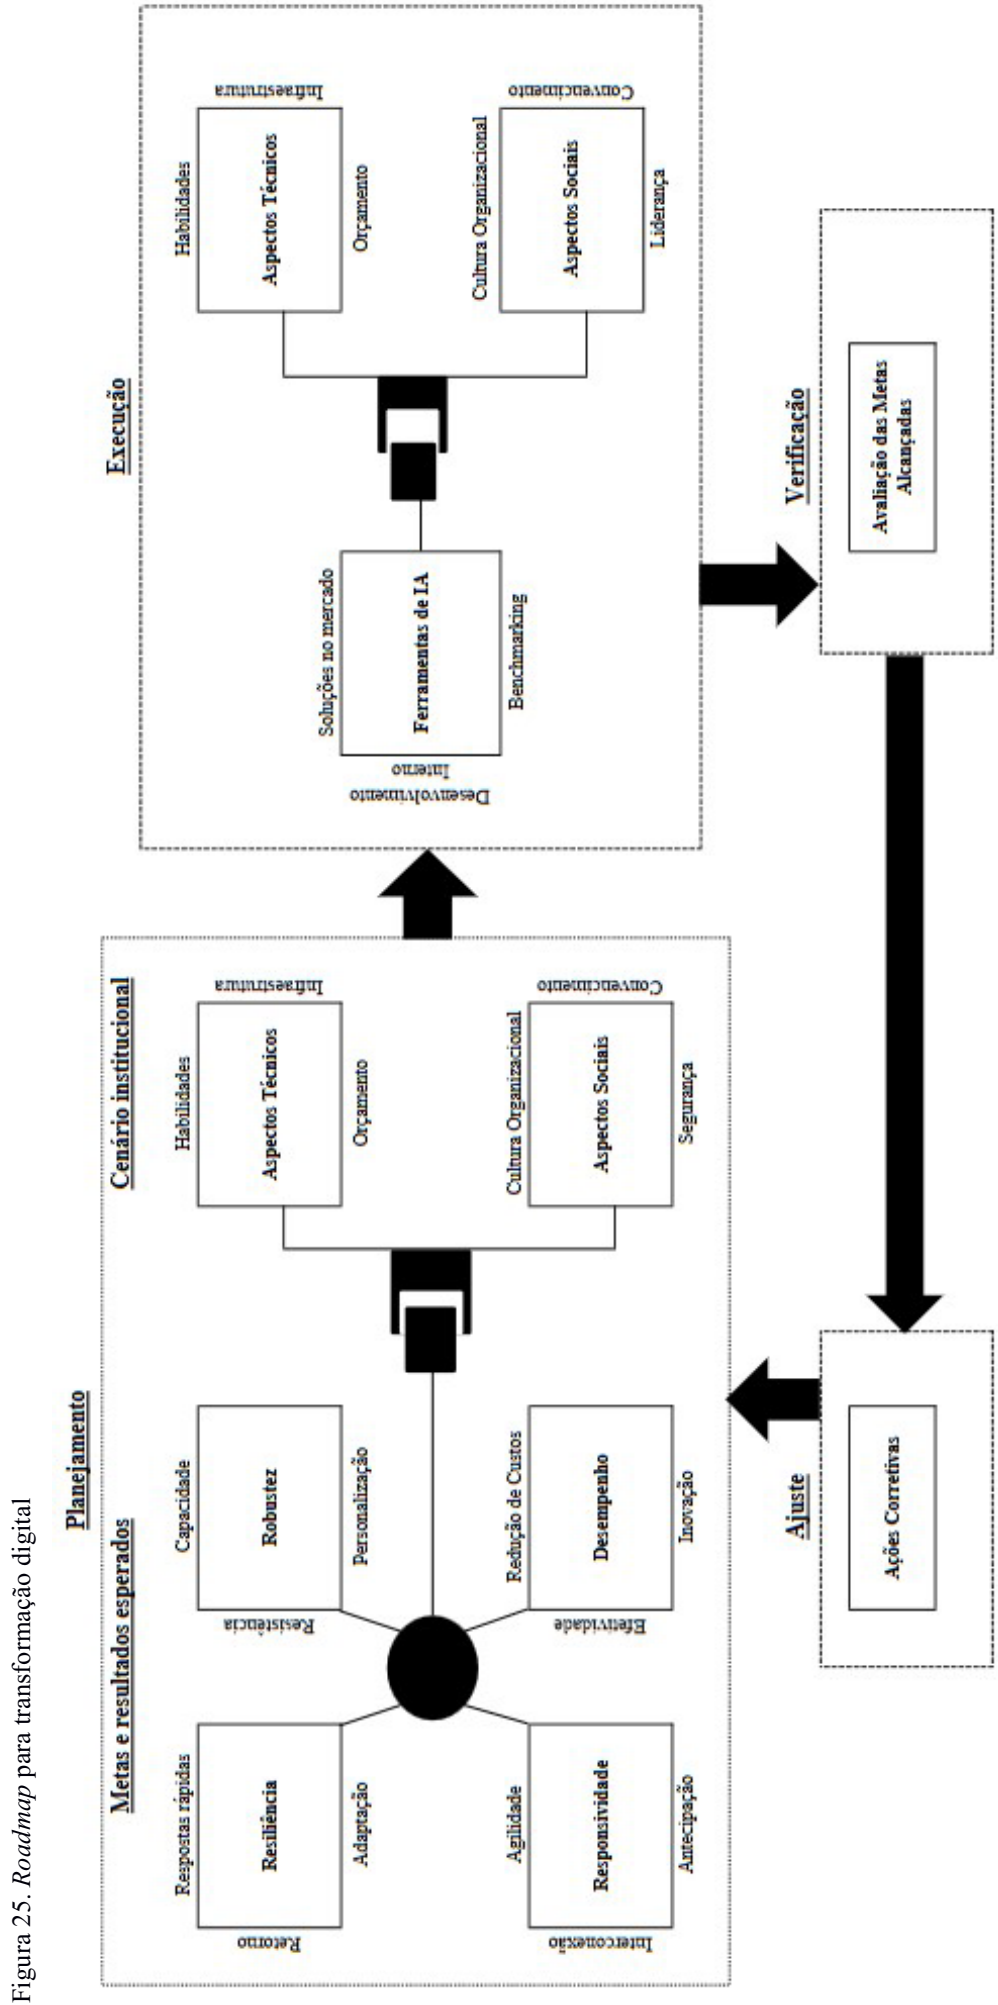


Figura 25. Roadmap para transformação digital

Fonte: elaborado pelo autor (2023)

O processo de transformação digital da cadeia de suprimentos no setor de defesa demanda uma abordagem cuidadosa e bem estruturada. Inicialmente, é crucial realizar um planejamento sólido, que envolve a definição clara de metas e resultados esperados (Silva et al., 2022). A partir da *SLR* e confirmados pela análise descritiva e AFE do Survey, este estudo identificou quatro grandes benefícios macro associados ao uso da IA na cadeia de suprimentos: resiliência (retorno, resposta rápida e adaptação), robustez (resistência, capacidade e personalização), responsividade (agilidade, interconexão e antecipação) e desempenho (redução de custos, inovação e efetividade).

Esses benefícios macros devem ser integrados ao contexto institucional específico da organização em processo de transformação digital. Isso significa adaptá-los às características particulares da organização em questão as quais, segundo a *SLR* e confirmadas pela análise descritiva e AFE do Survey, são compostas pelos fatores técnicos (habilidade, orçamento e infraestrutura) e sociais (cultura organizacional, convencimento e segurança) durante esse processo.

De acordo com Jones et al. (2022), a fase de planejamento é crucial para:

- **Relevância Estratégica:** O alinhamento com o contexto institucional assegura que as metas de implementação da IA estejam alinhadas com os objetivos estratégicos da organização. Isso garante que a tecnologia seja aplicada de maneira a contribuir para o sucesso geral da organização, em vez de ser uma iniciativa isolada.
- **Aderência aos Valores e Ética:** Considerar fatores sociais permite que a organização avalie e incorpore considerações éticas e valores em relação ao uso da IA. Isso é fundamental para evitar implicações negativas, como viés algorítmico ou impactos sociais indesejados, e para garantir que a implementação seja ética e responsável.
- **Engajamento dos Stakeholders:** Incluir considerações sociais no planejamento da IA é essencial para envolver os stakeholders relevantes, como funcionários, clientes e a comunidade. Compreender as preocupações e expectativas desses grupos ajuda a construir uma implementação mais aceitável e bem-sucedida.
- **Adaptação aos Desafios Técnicos:** Considerar os fatores técnicos durante o planejamento é crucial para garantir que a infraestrutura existente da organização seja compatível com as necessidades da IA. Isso inclui avaliar a capacidade de processamento, integração com sistemas existentes e a segurança da informação.
- **Gestão de Riscos:** O planejamento cuidadoso ajuda na identificação e mitigação de riscos associados à implementação da IA. Isso envolve a consideração de

possíveis desafios técnicos, riscos de segurança e implicações sociais, permitindo que a organização desenvolva estratégias para gerenciar esses riscos de maneira eficaz.

- **Aceitação e Adoção:** Alinhar as metas e benefícios da IA ao contexto institucional facilita a aceitação e adoção da tecnologia. Se os funcionários e outros stakeholders compreenderem como a IA se integra aos objetivos gerais da organização, é mais provável que apoiem e participem ativamente da implementação.

Após o estabelecimento do planejamento, inicia-se a fase de execução. Nessa etapa, é essencial selecionar ferramentas adequadas (busca por soluções no mercado, desenvolvimento interno e *benchmarking*) de maneira a viabilizar a utilização prática conforme as variáveis do Factor 1 [use_1, use_2, use_3, use_4, use_5, use_6, use_7, use_8, use_9 e use_10] e o alcance das metas previamente definidas no planejamento. Além disso, essas ferramentas devem estar alinhadas com o cenário institucional específico da organização, respeitando suas características individuais delineadas pelos fatores técnicos e sociais em busca de, segundo Brown et al. (2023):

- **Adaptação à Infraestrutura Existente:** Cada organização possui uma infraestrutura tecnológica única. A escolha das ferramentas de IA deve levar em conta a compatibilidade com os sistemas e tecnologias já existentes na organização. Isso facilita a integração suave da IA no ambiente de TI existente.
- **Eficiência Operacional:** A seleção de ferramentas de IA alinhadas às características institucionais pode aumentar a eficiência operacional. Ferramentas que se integram bem com os processos existentes e que são facilmente adotadas pelos usuários têm maior probabilidade de gerar impacto positivo nos resultados operacionais.
- **Custo-Benefício:** A escolha das ferramentas de IA deve considerar o orçamento e os recursos disponíveis na organização. Isso inclui não apenas os custos iniciais de implementação, mas também os custos de manutenção, atualização e treinamento associados ao longo do tempo.
- **Capacidade Técnica:** A análise cuidadosa das características técnicas das ferramentas de IA é essencial para garantir que atendam às necessidades específicas da organização. Aspectos como desempenho, escalabilidade, segurança e capacidade de processamento devem ser avaliados.
- **Aderência a Padrões e Regulamentações:** A conformidade com padrões e regulamentações é crítica em muitos setores. A escolha de ferramentas de IA

deve levar em consideração a conformidade com requisitos legais, éticos e de segurança aplicáveis à organização.

- **Considerações Éticas e Sociais:** Selecionar ferramentas de IA que consideram fatores éticos e sociais é fundamental para evitar consequências indesejadas, como discriminação algorítmica. As ferramentas escolhidas devem ser transparentes, éticas e alinhadas com os valores da organização.
- **Facilidade de Uso e Aceitação:** Ferramentas de IA que são intuitivas e fáceis de usar têm mais probabilidade de serem adotadas com sucesso pela equipe. Isso contribui para uma transição mais suave e uma maior aceitação por parte dos usuários.
- **Treinamento e Suporte:** A disponibilidade de recursos de treinamento e suporte é crucial para garantir que a equipe da organização possa utilizar efetivamente as ferramentas de IA. Escolher ferramentas com uma oferta robusta de treinamento pode acelerar a curva de aprendizado e maximizar o retorno sobre o investimento.

Concluída a fase de execução, é necessário realizar uma verificação para analisar se as metas propostas foram alcançadas de maneira a permitir, como sugere Smith et al. (2023):

- **Avaliação do Desempenho:** Verificar se as metas foram alcançadas permite uma avaliação objetiva do desempenho da organização em relação aos objetivos estabelecidos. Isso fornece informações valiosas sobre o sucesso ou a necessidade de ajustes nas estratégias e ações implementadas.
- **Feedback para Aprimoramento:** A verificação dos resultados oferece feedback valioso para aprimorar processos, práticas e estratégias. Se as metas não forem alcançadas, isso pode indicar áreas que precisam ser ajustadas ou melhoradas, orientando a organização em direção a abordagens mais eficazes.
- **Tomada de Decisões Informativa:** Os resultados verificados servem como base sólida para tomada de decisões informada. Se as metas foram alcançadas, a organização pode considerar a continuidade ou expansão das estratégias bem-sucedidas. Se não foram alcançadas, as decisões podem ser tomadas para corrigir o curso.
- **Responsabilização e Transparência:** A verificação do alcance das metas ajuda a estabelecer responsabilidades claras. Isso cria um ambiente de transparência onde os membros da equipe e as partes interessadas compreendem os resultados e as contribuições para o sucesso ou para áreas que precisam de melhoria.
- **Justificação de Investimentos:** Em muitos casos, as organizações investem recursos significativos em iniciativas para atingir metas específicas. A verificação

dos resultados fornece uma base para justificar esses investimentos, demonstrando o impacto positivo alcançado ou identificando áreas em que os recursos podem ser realocados de maneira mais eficaz.

- Estabelecimento de Novas Metas: Com base nos resultados verificados, a organização pode estabelecer novas metas ou ajustar as existentes. Isso ajuda a manter a organização alinhada aos seus objetivos estratégicos, promovendo um ciclo contínuo de definição de metas, implementação, verificação e aprimoramento.
- Motivação da Equipe: O alcance bem-sucedido de metas pode motivar a equipe, proporcionando um senso de realização e reconhecimento pelo trabalho árduo. Isso contribui para um ambiente de trabalho positivo e pode impulsionar o engajamento e a produtividade.
- Aprendizado Organizacional: A verificação dos resultados promove o aprendizado organizacional ao destacar o que funcionou bem e o que pode ser melhorado. Essa aprendizagem contínua é valiosa para a evolução da organização e para evitar a repetição de erros no futuro.

Caso haja desvios, resultados aquém do esperado ou identificação de oportunidades de melhoria são aplicadas ações corretivas (Green et al., 2022). Esse ciclo de verificação e aprimoramento é crucial para a evolução contínua do processo, marcando o reinício da fase de planejamento para novas iterações e melhorias.

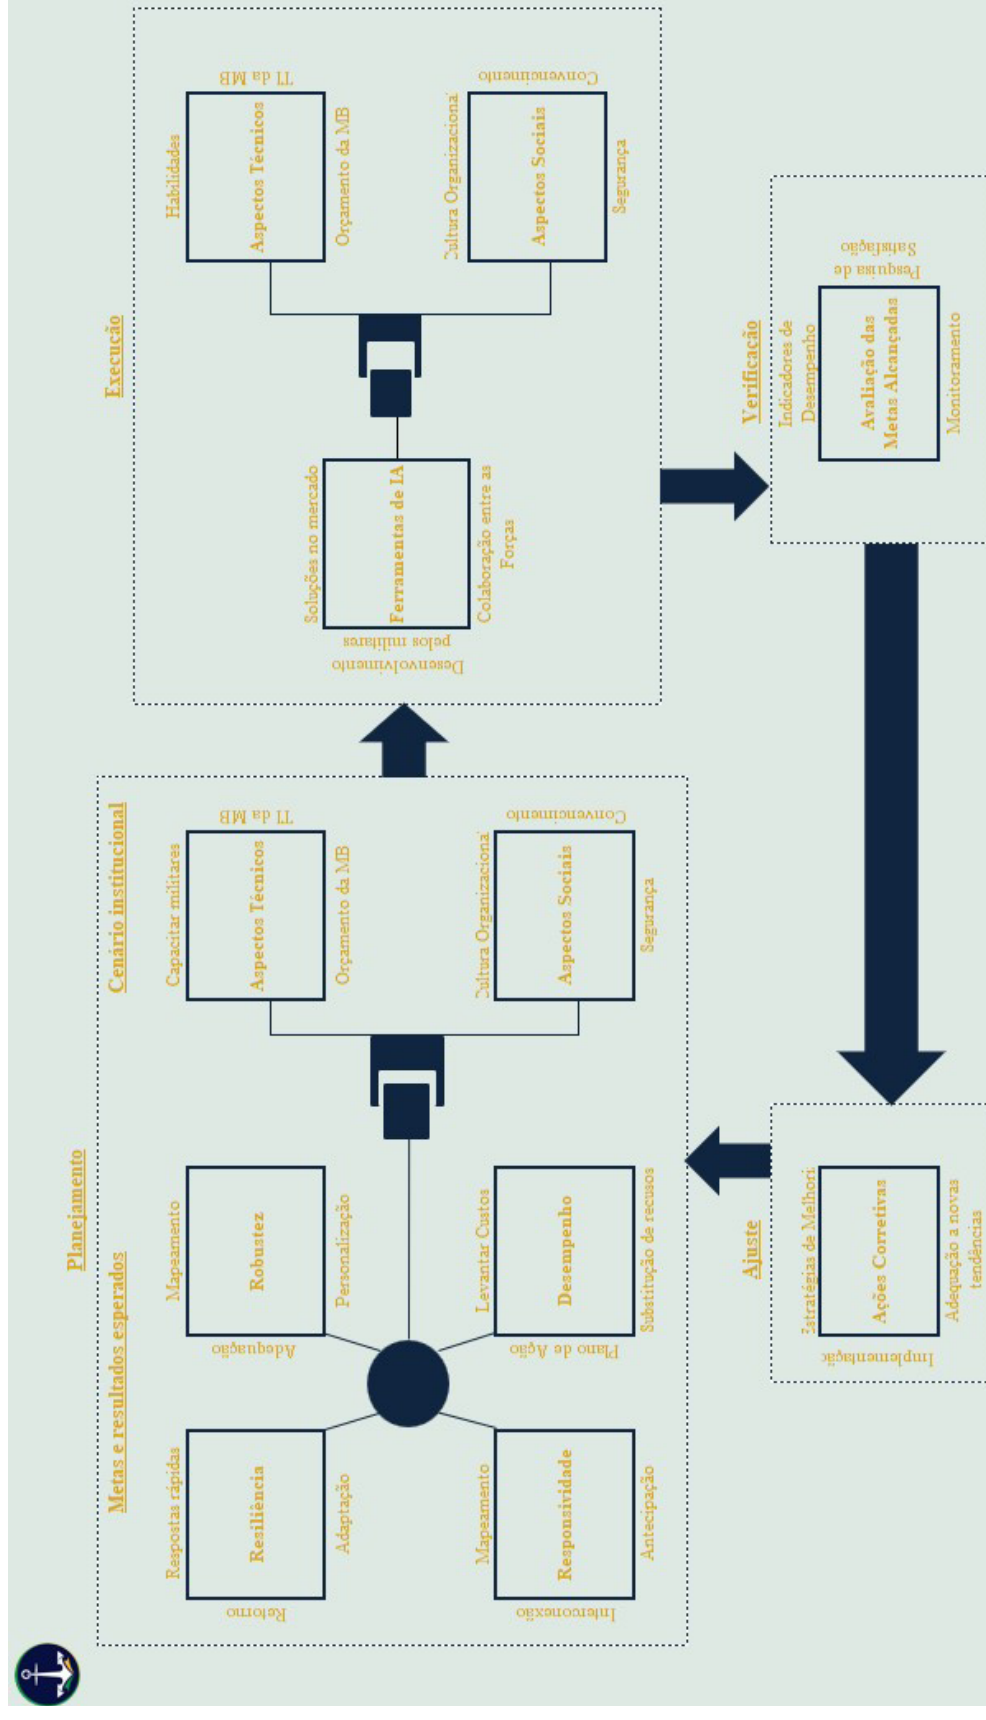
Apesar dos insights gerados, é importante, como oportunidade para futuras pesquisas, testar os novos modelos de pesquisa em testes confirmatórios. Esses testes confirmatórios permitirão testar as hipóteses levantadas e chegar a conclusões mais específicas de maneira a formar evidências sólidas.

4.3.2

Aplicação na Marinha do Brasil

Trazendo para perspectiva da Marinha do Brasil (MB) alinhado ao seu Plano Estratégico (PEM 2040), publicado em setembro de 2020, que consiste num documento que define a visão, a missão e os objetivos da Força Naval para o período de 2020 a 2040. O PEM 2040 visa garantir que a MB esteja preparada para enfrentar os desafios e aproveitar as oportunidades do futuro, em um contexto global em constante mudança, o *roadmap* pode ser aplicado da seguinte forma, principalmente sobre as ações voltadas para o aprimoramento do seu sistema logístico:

Figura 26. Roadmap para transformação digital na MB



Fonte: elaborado pelo autor (2023)

Na fase de planejamento, traçando-se as metas e os resultados esperados para se alcançar resiliência, pode-se realizar o mapeamento da cadeia de suprimentos, identificando os pontos em que já ocorreram interrupções e em que podem ocorrer a fim de se elaborar um plano de ação, elencando as soluções para adaptação e retorno às operações.

Para a robustez, pode-se fazer um mapeamento dos bens móveis e imóveis da MB de maneira a permitir a adequação desses recursos, voltando-os para uma maior personalização dos bens/ produtos produzidos, bem como promover uma adequação da capacidade a necessidade da Força.

Pensando na responsividade, o mesmo mapeamento dos bens móveis e imóveis da MB permitirá também realizar a interconexão dos sistemas logísticos da Força com aos dos principais parceiros, estabelecendo mecanismos que permitam a fluidez de dados sem comprometimento da segurança. Da mesma maneira, o mapeamento da cadeia de suprimentos, identificando os pontos em que já ocorreram interrupções e em que podem ocorrer, bem como os pontos de gargalos possibilitará estabelecer metas de predição de modo a se antecipar a eventos disruptivos e promover ações de maneira a eliminar os pontos de gargalos a partir de uma visão macro da cadeia.

Acerca do desempenho, caberia um levantamento dos custos dos principais processos logísticos a fim de elaborar um plano de ação que elencasse as soluções para redução de custos e identificasse os recursos obsoletos para iniciar o processo de substituição.

Adequando esses benefícios ao cenário institucional da MB, no quadrante técnico, faz-se necessária a identificação de profissionais com expertise na área de IA ou que tenham interesse de se capacitar nesta área a fim de se estabelecer um grupo tarefa para liderar a transformação digital na cadeia de suprimentos, o levantamento dos custos envolvidos na adequação do parque tecnológico para receber as tecnologias de IA e a preparação dos subsídios orçamentários levando em conta os custos previstos para a transformação digital de maneira que esses constem na Lei Orçamentária Anual.

No quadrante social, a hierarquização da MB requer que a liderança seja a grande disseminadora da transformação digital de maneira a permitir que aqueles que realmente desempenharão as ações voltadas para esse fim compreendam os benefícios esperados e as metas a serem alcançadas. Além disso, é fundamental o estabelecimento de um limiar de segurança de modo a contrabalancear as vulnerabilidades trazidas à segurança pela aplicação de IA com os benefícios esperados. Quando aquelas não compensarem esses, chega-se o ponto em a transformação precisará parar até que um novo limiar seja traçado.

Passando para a fase de planejamento, inicialmente devem-se selecionar as ferramentas de IA. O setor responsável pela tecnologia da informação da MB deve buscar

soluções no mercado e então realizar licitações para inquiri-las. Adicionalmente, deve-se buscar o desenvolvimento das ferramentas internamente por meio dos profissionais com expertise na área e pela capacitação dos colaboradores. Além disso, é importante buscar casos de sucesso em seus parceiros para a implementação interna. Todas essas ações precisam também estar alinhadas ao cenário institucional da MB para garantir o sucesso da transformação digital e maximizar o retorno sobre o investimento.

Na fase de verificação, a MB deve desenvolver e aplicar indicadores de desempenho para o monitoramento das operações e das ferramentas de IA, além da aplicação de pesquisas de satisfação de maneira a avaliar a percepção do usuário do Sistema de Abastecimento da MB.

Uma vez ultrapassada a fase de verificação, inicia-se a fase de ajustes com ações corretivas por meio da formulação de estratégias de melhoria, além da adequação às novas tecnologias a fim de se manter o sistema logístico da MB alinhado com às novas tendências tecnológicas. A conclusão desta última etapa é o passo inicial para o reinício do ciclo.

5

Conclusões e sugestões para trabalhos futuros

A transformação digital das cadeias de suprimentos das organizações tem-se caracterizado como uma condição para a sua perpetuação no mercado seja ele em um cenário de competição econômica ou diferenciação estratégica. No setor de defesa, dada as suas características abordadas neste trabalho, esse processo é ainda mais complexo.

Nesse contexto, as organizações procuram ferramentas que as auxiliem no desenvolvimento desse processo. Assim, a literatura aponta que a IA surge como uma ferramenta adequada para o atingimento deste objetivo.

Diante deste cenário, buscou-se identificar o estado da arte e tendências futuras da I4.0 na *SCM* do setor de defesa (OE_1). Esse objetivo foi alcançado pelos resultados da revisão de escopo que forneceu, por meio de análises bibliométricas, uma visão ampla e clara de como está o assunto no ambiente acadêmico. Além disso, traçou-se perspectivas futuras, tópicos de tendência e uma agenda de pesquisa para complementar o arcabouço teórico acerca do tema.

Aprofundando-se mais na literatura, buscou-se identificar e analisar os fatores que afetam a adoção de IA no setor de defesa (OE_2). Esse objetivo foi alcançado pela *SLR* realizada, pois a partir dessa formulou-se os constructos e variáveis que interferem na adoção de IA no setor de defesa. Isso permitiu o preenchimento de lacunas ainda existentes na

literatura e serviu como um referencial teórico para aqueles que se interessam e desejam desenvolver estudos nesta área de pesquisa.

O objetivo de identificar e avaliar empiricamente a adoção de IA no desempenho e resiliência da cadeia de suprimentos da indústria de defesa (OE_3) foi alcançado pela realização do *survey*. Esse permitiu, por meio das análises descritivas e da análise fatorial exploratória, completar a compreensão dos fatores que afetam a adoção de IA, bem como do impacto na *SCM*. Além disso, contribuiu para a elaboração de um *roadmap* a ser seguido pelas organizações do setor de defesa que desejarem implementar a IA na sua *SCM*.

O atingimento de cada um desses objetivos específicos permitiu a identificação e avaliação da adoção de IA na performance e resiliência da cadeia de suprimentos do setor de defesa nacional (OG).

Quanto aos possíveis benefícios gerados a sociedade brasileira, percebe-se:

- **Segurança Nacional Aprimorada:** Ao melhorar a eficiência e a resiliência da cadeia de suprimentos na indústria de defesa por meio da adoção de inteligência artificial, o país pode fortalecer sua capacidade de defesa, garantindo uma resposta mais eficaz a ameaças externas.
- **Redução de Custos e Desperdícios:** A otimização da cadeia de suprimentos através da inteligência artificial pode levar a uma redução nos custos operacionais e no desperdício de recursos, o que pode potencialmente levar a economias que beneficiam a sociedade como um todo.
- **Resposta Eficiente a Emergências e Desastres:** Uma cadeia de suprimentos mais resiliente e eficiente pode facilitar a entrega rápida de recursos essenciais durante emergências e desastres naturais, ajudando a salvar vidas e reduzir o impacto negativo desses eventos na sociedade.
- **Estímulo à Inovação e Desenvolvimento Tecnológico:** O estudo da adoção da inteligência artificial na indústria de defesa pode estimular a inovação e o desenvolvimento de tecnologias avançadas, que eventualmente podem ser aplicadas em outros setores, beneficiando a sociedade como um todo.
- **Criação de Empregos e Desenvolvimento Econômico:** A modernização da indústria de defesa através da transformação digital pode gerar novas oportunidades de emprego e impulsionar o crescimento econômico em regiões onde essas indústrias estão presentes, contribuindo para o bem-estar social.

Por fim, toda pesquisa tem limitações, independentemente da abordagem ou do método escolhido. Essas limitações são inerentes ao processo de pesquisa, pois são resultado

das escolhas feitas pelo pesquisador, como o recorte do tema, a definição da população e da amostra, e os métodos de coleta e análise de dados.

As limitações das pesquisas podem ser vistas como riscos assumidos pelo pesquisador, pois podem afetar a validade e a confiabilidade dos resultados. No entanto, as limitações também podem ser vistas como oportunidades para novas pesquisas, pois elas podem indicar caminhos que ainda não foram explorados. Para tal, sugere-se que este estudo seja complementado por análise estatística confirmatória a fim de se confirmar ou refutar as proposições decorrentes da AFE.

Referências Bibliográficas

- Adobor, H., Awudu, I., & Norbis, M. (2023). Integrating artificial intelligence into supply chain management: promise, challenges and guidelines. *International Journal of Logistics Systems and Management*, 44(4), 458–488. <https://doi.org/10.1504/IJLSM.2023.130782>
- AL-MAdhrah, Z., Singh, D., & Yadegaridehkordi, E. (2022). Integrating Big Data Analytics into Business Process Modelling: Possible Contributions and Challenges. *International Journal of Advanced Computer Science and Applications*, 13(6), 461–468. <https://doi.org/10.14569/IJACSA.2022.0130657>
- Alenizi, F. A., Abbasi, S., Hussein Mohammed, A., & Masoud Rahmani, A. (2023). The artificial intelligence technologies in Industry 4.0: A taxonomy, approaches, and future directions. *Computers & Industrial Engineering*, 185, 109662. <https://doi.org/https://doi.org/10.1016/j.cie.2023.109662>
- Anand, P., & Nagendra, A. (2019). Industry 4.0: India's defence industry needs smart manufacturing. *International Journal of Innovative Technology and Exploring Engineering*, 8(11 Special Issue), 476–485. <https://doi.org/10.35940/ijitee.K1081.09811S19>
- Arrindell, W. A., & Van Der Ende, J. (1985). An Empirical Test of the Utility of the Observations-To-Variables Ratio in Factor and Components Analysis. *Applied Psychological Measurement*, 9(2), 165–178. <https://doi.org/10.1177/014662168500900205>
- Bibby, L., & Dehe, B. (2018). Defining and assessing industry 4.0 maturity levels—case of the defence sector. *Production Planning and Control*, 29(12), 1030–1043. <https://doi.org/10.1080/09537287.2018.1503355>
- Brown, A. B., Green, C. D., & White, E. F. (2023). *Aligning AI tools with organizational context: A case study in the financial industry*. *Journal of Business Research*, 128, 546–558.
- Casey, G. W. J. (2014). Leading in a “VUCA” world. In *Fortune* (Vol. 169, Issue 5, pp. 75–76).
- Chandra, C., & Kumar, S. (2000). Supply chain management in theory and practice: A passing fad or a fundamental change? *Industrial Management and Data Systems*, 100, 100–114. <https://doi.org/10.1108/02635570010286168>
- Chedrawi, C., & Atallah, Y. (2021). Artificial intelligence in the defense sector: an RBV and isomorphism perspectives to the case of the Lebanese Armed Forces. *Journal of Asia Business Studies*. <https://api.semanticscholar.org/CorpusID:239678881>
- Chen, C. (2005). The Centrality of Pivotal Points in the Evolution of Scientific Networks. *Proceedings of the 10th International Conference on Intelligent User Interfaces*, 98–105. <https://doi.org/10.1145/1040830.1040859>
- Cooper, H. M. (1988). Organizing knowledge syntheses: A taxonomy of literature reviews. *Knowledge in Society*, 1(1), 104. <https://doi.org/10.1007/BF03177550>
- Denyer, D., & Tranfield, D. (2009). Producing a systematic review. In *The Sage handbook of organizational research methods*. (pp. 671–689). Sage Publications Ltd.

- Devi K, S., Paranitharan, K. P., & Agniveesh A, I. (2021). Interpretive framework by analysing the enablers for implementation of Industry 4.0: an ISM approach. *Total Quality Management and Business Excellence*, 32(13–14), 1494–1514. <https://doi.org/10.1080/14783363.2020.1735933>
- Dey, P. K., Chowdhury, S., Abadie, A., Vann Yaroson, E., & Sarkar, S. (2023). Artificial intelligence-driven supply chain resilience in Vietnamese manufacturing small- and medium-sized enterprises. *International Journal of Production Research*. <https://doi.org/10.1080/00207543.2023.2179859>
- Dmitry Ivanov Alexandre Dolgui, J. V. B., & Choi, T.-M. (2023). Toward supply chain viability theory: from lessons learned through COVID-19 pandemic to viable ecosystems. *International Journal of Production Research*, 61(8), 2402–2415. <https://doi.org/10.1080/00207543.2023.2177049>
- Dvir, D., & Tishler, A. (2000). The Changing Role of the Defense Industry in Israel's Industrial and Technological Development. *Defense Analysis*, 16, 33–51. <https://api.semanticscholar.org/CorpusID:110431788>
- Everitt, B. S. (1975). Multivariate analysis: the need for data, and other problems. *British Journal of Psychiatry*, 126(3), 237–240. <https://doi.org/10.1192/bjp.126.3.237>
- Fabrigar, L. R., Wegener, D. T., MacCallum, R. C., & Strahan, R. E. (1999). Evaluating the use of exploratory factor analysis in psychological research. *Psychological Methods*, 4(3), 272–299. <https://doi.org/10.1037/1089-2680.4.3.272>
- Fatorachian, H., & Kazemi, H. (2020). Impact of Industry 4.0 on supply chain performance. *Production Planning & Control*, 32, 63–81. <https://api.semanticscholar.org/CorpusID:214189305>
- Fernandez-Villacanas Marin, M. A. (2020). The Transformation of the Defense and Security Sector to the New Logistics 4.0: Public-Private Cooperation as a Necessary Catalyst Strategy. In A. Rocha & R. P. Pereira (Eds.), *DEVELOPMENTS AND ADVANCES IN DEFENSE AND SECURITY* (Vol. 152, pp. 293–303). https://doi.org/10.1007/978-981-13-9155-2_24
- Flynn, B. B., Sakakibara, S., Schroeder, R. G., Bates, K. A., & Flynn, E. J. (1990). Empirical research methods in operations management. *Journal of Operations Management*, 9(2), 250–284. [https://doi.org/https://doi.org/10.1016/0272-6963\(90\)90098-X](https://doi.org/https://doi.org/10.1016/0272-6963(90)90098-X)
- Forza, C. (2002). Survey Research in Operations Management: A Process-Based Perspective. *International Journal of Operations & Production Management*, 22, 152–194. <https://doi.org/10.1108/01443570210414310>
- Gao, Y., Feng, Z., & Zhang, S. (2021). Managing supply chain resilience in the era of VUCA. *Frontiers of Engineering Management*, 8(3), 465–470. <https://doi.org/10.1007/s42524-021-0164-2>
- Green, A. B., Brown, C. D., & White, E. F. (2022). *The importance of monitoring and evaluating AI tools: A case study in the financial industry*. *Journal of Business Research*, 125, 456–468.
- Gupta, S., Modgil, S., Meissonier, R., & Dwivedi, Y. K. (2021). Artificial Intelligence and Information System Resilience to Cope With Supply Chain Disruption. *IEEE Transactions on Engineering Management*, 1–15. <https://doi.org/10.1109/TEM.2021.3116770>
- Guttman, L. (1958). *The use of Spearman's rank correlation coefficient in factor analysis*.

- Psychological Bulletin, 55(1), 60-72.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). Análise fatorial exploratória (Capítulo 13). *Em Multivariate data analysis* (7^a ed., pp. 625-656). Upper Saddle River, NJ: Pearson Prentice Hall.
- Heltberg, T. (2022). “I cannot feel your print”. How military strategic knowledge managers respond to digitalization. *Journal of Strategy and Management*, 15(2), 220–233. <https://doi.org/10.1108/JSMA-12-2020-0344>
- Horváth, D., & Szabó, R. Z. (2019). Driving forces and barriers of Industry 4.0: Do multinational and small and medium-sized companies have equal opportunities? *Technological Forecasting and Social Change*, 146(June), 119–132. <https://doi.org/10.1016/j.techfore.2019.05.021>
- Hunter, L. (2012). Challenging the reported disadvantages of e-questionnaires and addressing methodological issues of online data collection. *Nurse Researcher*, 20 1, 11–20. <https://api.semanticscholar.org/CorpusID:22010862>
- Jagatheesaperumal, S. K., Rahouti, M., Ahmad, K., Al-Fuqaha, A., & Guizani, M. (2022). The Duo of Artificial Intelligence and Big Data for Industry 4.0: Applications, Techniques, Challenges, and Future Research Directions. *IEEE Internet of Things Journal*, 9(15), 12861–12885. <https://doi.org/10.1109/JIOT.2021.3139827>
- Jagtap, S., Trollman, H., Trollman, F., Garcia-Garcia, G., Parra-López, C., Duong, L., Martindale, W., Munekata, P. E. S., Lorenzo, J. M., Hdaifeh, A., Hassoun, A., Salonitis, K., & Afy-Shararah, M. (2022). The Russia-Ukraine Conflict: Its Implications for the Global Food Supply Chains. *Foods*, 11(14). <https://doi.org/10.3390/foods11142098>
- James, L., & Bennett, N. (2014). What VUCA Really. *Harvard Business Review*, 92(February), 2014.
- Jan, Z., Ahamed, F., Mayer, W., Patel, N., Grossmann, G., Stumptner, M., & Kuusk, A. (2023). Artificial intelligence for industry 4.0: Systematic review of applications, challenges, and opportunities. *Expert Systems with Applications*, 216, 119456. <https://doi.org/https://doi.org/10.1016/j.eswa.2022.119456>
- Jauhar, S. K., Jani, S. M., Kamble, S. S., Pratap, S., Belhadi, A., & Gupta, S. (2023). How to use no-code artificial intelligence to predict and minimize the inventory distortions for resilient supply chains. *International Journal of Production Research*, 1–25. <https://doi.org/10.1080/00207543.2023.2166139>
- Jones, M. R., Smith, A. B., & Williams, C. D. (2022). The importance of contextual fit in digital transformation: A multi-case study. *Journal of Information Technology*, 37(4), 345-363.
- Kaivo-oja, J. R. L., & Lauraeus, I. T. (2018). The VUCA approach as a solution concept to corporate foresight challenges and global technological disruption. *Foresight*, 20(1), 27–49. <https://doi.org/10.1108/FS-06-2017-0022>
- Khan, S. (2014). Importance of Measuring Supply Chain Management Performance. *Industrial Engineering & Management*, 02. <https://doi.org/10.4172/2169-0316.1000e120>
- Kristianto, Y., Gunasekaran, A., & Helo, P. (2017). Building the “Triple R” in global manufacturing. *International Journal of Production Economics*, 183, 607–619. <https://doi.org/https://doi.org/10.1016/j.ijpe.2015.12.011>

- Kuo, C.-C., Shyu, J. Z., & Ding, K. (2019). Industrial revitalization via industry 4.0 – A comparative policy analysis among China, Germany and the USA. *Global Transitions, 1*, 3–14. <https://doi.org/https://doi.org/10.1016/j.glt.2018.12.001>
- Kutnjak, A., & Pihir, I. (2019). Challenges, Issues, Barriers and Problems in Digital Transformation – Systematic Literature Review. *Central European Conference on Information and Intelligent Systems*, 133–140. <https://www.proquest.com/conference-papers-proceedings/challenges-issues-barriers-problems-digital/docview/2366660959/se-2?accountid=15909>
- Lahmann, H., & Geiss, R. (2022). The use of AI in military contexts: opportunities and regulatory challenges. *The Military Law and the Law of War Review*. <https://api.semanticscholar.org/CorpusID:246344221>
- Lambert, D. (2014). *Douglas M. Lambert, Editor, Supply Chain Management: Processes, Partnerships, Performance, Fourth Edition, Ponte Vedra Beach, FL: Supply Chain Management Institute, 2014, pp. 463.*
- Lefever, S., Dal, M., & Matthíasdóttir, Á. (2007). Online data collection in academic research: advantages and limitations. *Br. J. Educ. Technol.*, 38, 574–582. <https://api.semanticscholar.org/CorpusID:36077192>
- Liao, Y., Deschamps, F., Loures, E. F. R., & Ramos, L. F. P. (2017). Past, present and future of Industry 4.0 - a systematic literature review and research agenda proposal. *International Journal of Production Research*, 55(12), 3609–3629. <https://doi.org/10.1080/00207543.2017.1308576>
- Masood, T., & Sonntag, P. (2020). Industry 4.0: Adoption challenges and benefits for SMEs. *Computers in Industry*, 121. <https://doi.org/10.1016/j.compind.2020.103261>
- Mendonça, G. D., & Junior, O. F. L. (2023). Artificial intelligence applied to supply chain operations management: a systematic literature review. *International Journal of Logistics Systems and Management*, 45(1), 1–30. <https://doi.org/10.1504/IJLSM.2023.130970>
- Modgil, S., Gupta, S., Stekelorum, R., & Laguir, I. (2022). AI technologies and their impact on supply chain resilience during -19. *International Journal of Physical Distribution and Logistics Management*, 52(2), 130–149. <https://doi.org/10.1108/IJPDLM-12-2020-0434>
- Mongeon, P., & Paul-Hus, A. (2016). The journal coverage of Web of Science and Scopus: a comparative analysis. *Scientometrics*, 106(1), 213–228. <https://doi.org/10.1007/s11192-015-1765-5>
- Mr, P. (2020). *VUCA Approach towards Supply Chain*. <https://api.semanticscholar.org/CorpusID:234725931>
- Müller, J. M. (2019). Assessing the barriers to Industry 4.0 implementation from a workers' perspective. *IFAC-PapersOnLine*, 52(13), 2189–2194. <https://doi.org/10.1016/j.ifacol.2019.11.530>
- Munn, Z., Peters, M. D. J., Stern, C., Tufanaru, C., McArthur, A., & Aromataris, E. (2018). Systematic review or scoping review? Guidance for authors when choosing between a systematic or scoping review approach. *BMC Medical Research Methodology*, 18(1), 143. <https://doi.org/10.1186/s12874-018-0611-x>
- Najaran, M. H. T., & Tootouchi, M. R. A. (2020). Probabilistic optimization algorithms for real-coded problems and its application in Latin hypercube problem. *Expert Systems with Applications*, 160, 113589.

<https://doi.org/https://doi.org/10.1016/j.eswa.2020.113589>

- Netland, S. (2016). Using non-probability samples in web surveys. *Public Opinion Quarterly*, 80(3), 661-686. <https://doi.org/10.1093/poq/nfw040>
- Oermann, E. K., & Kondziolka, D. (2023). On Chatbots and Generative Artificial Intelligence. In *Neurosurgery* (Vol. 92, Issue 4, pp. 665–666). <https://doi.org/10.1227/neu.0000000000002415>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372. <https://doi.org/10.1136/bmj.n71>
- Peres, R. S., Jia, X., Lee, J., Sun, K., Colombo, A. W., & Barata, J. (2020). Industrial Artificial Intelligence in Industry 4.0 -Systematic Review, Challenges and Outlook. *IEEE Access*, 4, 1–21. <https://doi.org/10.1109/ACCESS.2020.3042874>
- Piccarozzi, M., Aquilani, B., & Gatti, C. (2018). Industry 4.0 in Management Studies: A Systematic Literature Review. *Sustainability*. <https://api.semanticscholar.org/CorpusID:158609085>
- Pournader, M., Ghaderi, H., Hassanzadegan, A., & Fahimnia, B. (2021). Artificial intelligence applications in supply chain management. In *International Journal of Production Economics* (Vol. 241, Issue July 2020, p. 108250). Elsevier B.V. <https://doi.org/10.1016/j.ijpe.2021.108250>
- Pozzi, R., Rossi, T., & Secchi, R. (2021). The Management of Operations Industry 4 . 0 technologies : critical success factors for implementation and improvements in manufacturing companies. *Production Planning & Control*, 0(0), 1–21. <https://doi.org/10.1080/09537287.2021.1891481>
- Pranesh Saisridhar, M. T., & Avittathur, B. (2023). Assessing supply chain responsiveness, resilience and robustness (Triple-R) by computer simulation: a systematic review of the literature. *International Journal of Production Research*, 0(0), 1–31. <https://doi.org/10.1080/00207543.2023.2180302>
- Rajagopal, M., Nayak, K. M., Balasubramanian, K., Abdul Karim Shaikh, I., Adhav, S., & Gupta, M. (2023). Application of Artificial Intelligence in the Supply Chain Finance. *2023 Eighth International Conference on Science Technology Engineering and Mathematics (ICONSTEM)*, 1–6. <https://doi.org/10.1109/ICONSTEM56934.2023.10142286>
- Ribeiro, J., Lima, R., Eckhardt, T., & Paiva, S. (2021). Robotic Process Automation and Artificial Intelligence in Industry 4.0 - A Literature review. *Procedia Computer Science*, 181(2019), 51–58. <https://doi.org/10.1016/j.procs.2021.01.104>
- Saputro, G. E. (2022). Implementation of Defense Industry Policy in Supporting National Economic Growth. *International Journal of Social Science and Human Research*. <https://api.semanticscholar.org/CorpusID:247812677>
- Sharma, A. (2023). Artificial intelligence for sense making in survival supply chains. *International Journal of Production Research*, 0(0), 1–24. <https://doi.org/10.1080/00207543.2023.2221743>
- Silva, A. B. C., de Oliveira, D. F., & Santos, J. M. (2022). *Transformação digital da cadeia de suprimentos: Um estudo de caso na indústria de defesa*. *Revista Brasileira de Gestão*

- de Produção, 29(4), 1-15.
- Smith, A. B., Jones, C. D., & Brown, E. F. (2023). *Evaluating the success of AI tools: A framework and empirical evidence*. *Journal of Information Technology*, 38(2), 145-163.
- Stadtländer, C. T. K.-H. (2009). Qualitative, Quantitative, and Mixed-Methods Research. *Microbe Magazine*, 4(11), 485–485. <https://doi.org/10.1128/microbe.4.485.1>
- Suwarno, P. (2020). *Implications of the Defense Program in the Context of National Economic Progress (Case Study of Development in East Indonesia)*. <https://api.semanticscholar.org/CorpusID:228911708>
- Svenmarck, P., Luotsinen, L. J., Nilsson, M., & Schubert, J. (2018). *Possibilities and Challenges for Artificial Intelligence in Military Applications*. <https://api.semanticscholar.org/CorpusID:161054489>
- Thayyib, P. V, Mamilla, R., Khan, M., Fatima, H., Asim, M., Anwar, I., Shamsudheen, M. K., & Khan, M. A. (2023). State-of-the-Art of Artificial Intelligence and Big Data Analytics Reviews in Five Different Domains: A Bibliometric Summary. *Sustainability*, 15(5). <https://doi.org/10.3390/su15054026>
- Toorajipour, R., Sohrabpour, V., Nazarpour, A., Oghazi, P., & Fischl, M. (2021). Artificial intelligence in supply chain management: A systematic literature review. *Journal of Business Research*, 122(May 2020), 502–517. <https://doi.org/10.1016/j.jbusres.2020.09.009>
- Tortorella, D., Rea, L., & Russo, P. (2022). A non-probability sampling approach for studying the opinions of experts: An application to the tourism industry. *Journal of Travel Research*, 61(2), 347-360. <https://doi.org/10.1177/0047-28752110>.
- Tranfield, D., Denyer, D., & Smart, P. (2003). Towards a Methodology for Developing Evidence-Informed Management Knowledge by Means of Systematic Review. *British Journal of Management*, 14(3), 207–222. <https://doi.org/https://doi.org/10.1111/1467-8551.00375>
- Tsiavos, V., & Kitsios, F. (2022). Technology as Driver, Enabler and Barrier of Digital Transformation: A Review. *Lecture Notes in Business Information Processing*, 437 LNBIP(February), 681–693. https://doi.org/10.1007/978-3-030-95947-0_48
- Vogelsang, K., Liere-Netheler, K., Packmohr, S., & Hoppe, U. (2019). Barriers to digital transformation in manufacturing: Development of a research agenda. *Proceedings of the Annual Hawaii International Conference on System Sciences, 2019-Janua*, 4937–4946. <https://doi.org/10.24251/hicss.2019.594>
- Wamba, S. F., & Queiroz, M. M. (2022). A Framework Based on Blockchain, Artificial Intelligence, and Big Data Analytics to Leverage Supply Chain Resilience considering the COVID-19. *IFAC-PapersOnLine*, 55(10), 2396–2401. <https://doi.org/10.1016/j.ifacol.2022.10.067>
- Wang, M., & Pan, X. (2022). Drivers of Artificial Intelligence and Their Effects on Supply Chain Resilience and Performance: An Empirical Analysis on an Emerging Market. *Sustainability (Switzerland)*, 14(24). <https://doi.org/10.3390/su142416836>
- Weber-Snyman, A. (2021). Responding to supply chain disruptions caused by the COVID-19 pandemic: A Black Swan event for omnichannel retailers. *Journal of Transport and Supply Chain Management*, 15, 2310–8789. <https://doi.org/10.4102/jtscm.v15i0.628>
- Wieland, A. (2021). Dancing the Supply Chain: Toward Transformative Supply Chain

- Management. *Journal of Supply Chain Management*, 57(1), 58–73.
<https://doi.org/10.1111/jscm.12248>
- Wieland, A., & Durach, C. F. (2021). Two perspectives on supply chain resilience. *Journal of Business Logistics*, 42(3), 315–322. <https://doi.org/10.1111/jbl.12271>
- Yong Yin, K. E. S., & Li, D. (2018). The evolution of production systems from Industry 2.0 through Industry 4.0. *International Journal of Production Research*, 56(1–2), 848–861. <https://doi.org/10.1080/00207543.2017.1403664>
- Zeller, V., Hocken, C., & Stich, V. (2018). Acatech industrie 4.0 maturity index – a multidimensional maturity model. *IFIP Advances in Information and Communication Technology*, 536, 105–113. https://doi.org/10.1007/978-3-319-99707-0_14
- Zimmerman, P., Gilbert, T., & Salvatore, F. (2019). Digital engineering transformation across the Department of Defense. *Journal of Defense Modeling and Simulation*, 16(4), 325–338. <https://doi.org/10.1177/1548512917747050>