



Instituto Politécnico
de Viana do Castelo

**ASSOCIAÇÃO DE POLITÉCNICOS DO NORTE (APNOR)
INSTITUTO POLITÉCNICO DE BRAGANÇA**

**A INFLUÊNCIA DA INTELIGÊNCIA ARTIFICIAL NA OTIMIZAÇÃO DA
CADEIA DE SUPRIMENTOS**

Nadieli Cavalcante Azevedo

Dissertação apresentada ao Instituto Politécnico de Bragança para obtenção do
Grau de Mestre em Gestão das Organizações, Ramo de Gestão de Empresas

Orientada por

Carla Alexandra Soares Gerales

Versão Final

Bragança, dezembro de 2025.



Instituto Politécnico
de Viana do Castelo

**ASSOCIAÇÃO DE POLITÉCNICOS DO NORTE (APNOR)
INSTITUTO POLITÉCNICO DE BRAGANÇA**

**A INFLUÊNCIA DA INTELIGÊNCIA ARTIFICIAL NA OTIMIZAÇÃO DA
CADEIA DE SUPRIMENTOS**

Nadieli Cavalcante Azevedo

Dissertação apresentada ao Instituto Politécnico de Bragança para obtenção do
Grau de Mestre em Gestão das Organizações, Ramo de Gestão de Empresas

Orientada por
Carla Alexandra Soares Gerales

Bragança, dezembro de 2025.

Resumo

Esta dissertação investiga o impacto da inteligência artificial na otimização da cadeia de suprimentos, abordando tanto fundamentos teóricos quanto aplicações práticas, como a automação de processos logísticos por meio da aplicação de tecnologias relativas a Inteligência Artificial. Por meio de uma revisão sistemática da literatura e um estudo de caso no setor automotivo, são destacados os principais avanços proporcionados pela IA, incluindo melhoria na previsão de demanda, redução de custos, aumento da eficiência operacional e aprimoramento na tomada de decisão. O trabalho evidencia também desafios relacionados à integração tecnológica, qualificação de profissionais e questões éticas. Os resultados sugerem que a adoção consciente e estratégica da IA contribui de maneira decisiva para a competitividade, sustentabilidade e inovação das cadeias produtivas, demandando colaboração contínua entre pessoas e sistemas inteligentes.

Palavras-chave: cadeia de suprimentos, inteligência artificial, aprendizado de máquina, sistemas multiagentes.

Abstract

This dissertation investigates the impact of artificial intelligence on supply chain optimisation, addressing both theoretical foundations and practical applications, such as the automation of logistics processes through the application of technologies related to Artificial Intelligence. Through a systematic review of the literature and a case study in the automotive sector, the main advances provided by AI are highlighted, including improved demand forecasting, cost reduction, increased operational efficiency, and improved decision-making. The work also highlights challenges related to technological integration, professional qualification, and ethical issues. The results suggest that the conscious and strategic adoption of AI contributes decisively to the competitiveness, sustainability, and innovation of production chains, requiring continuous collaboration between people and intelligent systems.

Keywords: *supply chain, artificial intelligence, machine learning, multi-agent systems.*

Dedicatória

A Deus, a minha família e ao meu companheiro Gustavo.

Agradecimentos

Ao meu Deus, pela Sua força, bondade e amor.

A minha mãe, Josiana, e minhas irmãs, Rose, Lúdia e Maria, agradeço pelo apoio, pela compreensão nos momentos de estresse. Mesmo estando distante, vocês são parte importante desta conquista.

Ao meu companheiro, Gustavo, minha fonte de inspiração e força, sou grata pelo amor, incentivo, apoio e compreensão. Sua presença e apoio emocional foram fundamentais para que eu pudesse superar os desafios desta jornada. Obrigada por estar ao meu lado.

A minha orientadora, Professora Carla Alexandra Soares Gerales, sou grata pelo apoio constante, pela partilha do saber, por toda disponibilidade ao longo de todo o processo e pelas valiosas contribuições.

Lista de Acrónimos

AI – *Artificial Intelligence*

DES – *Discrete Event Simulation*

HITL – *Human-In-The-Loop*

I4.0 – *Indústria 4.0*

IA – *Inteligência Artificial*

JIT – *Just-in-Time*

JSON – *JavaScript Object Notation*

KNNs – *K-Nearest Neighbors*

LLMs – *Large Language Models*

ML – *Machine Learning*

RITL – *Researcher-In-The-Loop*

RNAs – *Redes Neurais Artificiais*

SCM – *Supply Chain Management*

SCRM – *Supply Chain Risk Management*

SVMs – *Support Vector Machines*

TF-IDF – *Term Frequency-Inverse Document Frequency*

XAI – *Explainable AI*

Índice Geral

Índice Geral	viii
Índice de Figuras	ix
Índice de Tabelas	x
Introdução.....	1
1.1 Objetivo do Trabalho	Error! Bookmark not defined.
1.2 Estrutura do Documento	Error! Bookmark not defined.
2. Metodologia	4
2.1 Método de Investigação	4
2.2 Questões de Investigação.....	6
2.3 Estratégia de Pesquisa	7
2.4 Seleção de Estudos	8
2.5 Extração de Dados e Síntese.....	10
3. Revisão da Literatura	12
3.1 <i>Supply Chain</i> e Seus Componentes	12
3.2 Revisão da Literatura	13
4. IA Aplicada num Processo de <i>Supply Chain</i>	27
4.1 Estudo de Caso.....	27
4.2 Desenvolvimento da Solução Utilizando a Ferramenta CrewAI	28
4.3 Parecer e Comparação ao Processo Manual	46
Conclusões, Limitações e Futuras Linhas de Investigação	48
Referências Bibliográficas	51

Índice de Figuras

Figura 1: <i>Search query</i> no IEEEExplore	8
Figura 2: <i>Search query</i> no Sage Journals.....	8
Figura 3: <i>Search query</i> no Science Direct.	9
Figura 4: Processo de seleção.....	9
Figura 5: Diagrama de interação entre os agentes.....	32
Figura 6: Resultado em <i>Markdown</i>	44
Figura 7: Veículo relativo ao resultado do experimento.....	45

Índice de Tabelas

Tabela 1: *Research queries* por *search engines*. 7

Tabela 2: Critérios de inclusão e exclusão. 10

Introdução

Nos últimos anos, a importância da incorporação de tecnologias inovadoras nas *supply chains* tem sido destacada, particularmente devido ao seu potencial para otimizar os processos logísticos, melhorar a tomada de decisões e aumentar a eficiência global. Os avanços tecnológicos, como os recentes avanços na Inteligência Artificial (IA), revolucionaram os modelos tradicionais, criando sistemas mais inteligentes/cognitivos, interligados e reactivos. Estas tecnologias permitem às empresas responder rapidamente às alterações do mercado, gerir os riscos de forma mais eficaz e reduzir os custos operacionais através da automatização de tarefas repetitivas e do reforço das capacidades de previsão.

Por conseguinte, coloca-se a questão de saber de que forma o impacto das tecnologias revolucionárias, como as do espectro da IA, afecta as *supply chains*, em especial na indústria transformadora, estando na vanguarda destes avanços, transformando as *supply chains* através da utilização de análises avançadas e algoritmos de aprendizagem automática para otimizar vários processos, desde a previsão da procura até ao controlo de qualidade. A adoção de IA tem crescido exponencialmente, impulsionada pela necessidade de maior agilidade, resiliência e sustentabilidade

face a desafios globais complexos, como a pandemia de COVID-19 e as tensões geopolíticas que perturbaram as operações tradicionais (Camur, Ravi & Saleh 2024).

Atualmente, está em curso uma transformação significativa de soluções inovadoras que têm o potencial de revolucionar as operações para as empresas. As empresas estão agilizando seus processos, alcançando níveis mais elevados de eficiência, redução de custos e melhoria do desempenho global. As tecnologias de IA estão agora a ser usadas para analisar grandes volumes de dados, fornecendo insights que ajudam as empresas a tomar decisões baseadas em dados (Toorajipour et al. 2021).

A logística, sendo um componente crítico das *supply chains*, tem beneficiado muito com as inovações. Veículos autônomos, drones e robótica estão a começar a transformar os centros de armazenamento e distribuição, aumentando a velocidade e a precisão do cumprimento das encomendas. Além disso, as plataformas logísticas orientadas otimizam a seleção de transportadoras, o planejamento de rotas e a consolidação de cargas, reduzindo os custos de transporte e as emissões, o que é um impacto relevante na sustentabilidade ambiental. À medida que a IA continua a evoluir, espera-se que as suas aplicações nas *supply chains* se expandam, oferecendo novas oportunidades para as empresas ganharem uma vantagem competitiva no mercado global.

O *Machine Learning* (ML), um subconjunto do IA, tem um impacto significativo na otimização dos processos da *supply chain*, fornecendo ferramentas avançadas para analisar grandes conjuntos de dados, identificar ineficiências e sugerir melhorias. Os algoritmos de ML podem processar dados históricos e em tempo real para prever padrões de procura, otimizar níveis de inventário e melhorar a resiliência da *supply chain*. Estas capacidades de previsão são essenciais para gerir as incertezas na *supply chain* (Hazen et al., 2014).

No gerenciamento de estoque, os sistemas de IA podem automatizar as decisões de reabastecimento, garantindo que os níveis ideais de estoque sejam mantidos e minimizando os custos de retenção. A otimização da logística se beneficia da IA ao aprimorar o planejamento de rotas e o gerenciamento de frotas, levando a tempos de entrega mais rápidos e custos operacionais reduzidos. A IA também é importante para a seleção e o gerenciamento de fornecedores, onde avalia os dados de desempenho do fornecedor, os fatores de risco e os requisitos de conformidade para identificar os fornecedores mais confiáveis e econômicos.

Apesar dos contínuos avanços, a crescente dependência da IA nas *supply chains* levanta questões importantes sobre as implicações mais amplas dessa tecnologia. Embora a IA prometa maior eficiência, redução de custos e melhoria na tomada de decisões, ela também apresenta desafios relacionados a questões éticas, sustentabilidade e a possibilidade de deslocamento da força de trabalho devido à automação. Além disso, a complexidade dos sistemas de IA exige um investimento significativo em tecnologia. É fundamental refletir sobre como essas tecnologias moldarão o futuro das operações comerciais.

Este trabalho oferece uma compreensão abrangente do impacto transformador da IA na gestão da *supply chain* e, ao mesmo tempo, aborda as implicações mais amplas para a sustentabilidade dos negócios, a competitividade e o acesso aos avanços tecnológicos.

Como objetivos, este trabalho tem: (1) analisar criticamente a adoção da IA nas cadeias de suprimentos, começando pela identificação das principais tendências tecnológicas e dos desafios organizacionais que permeiam sua implementação; (2) qualificar o impacto da IA nas operações logísticas e de suprimento das empresas; (3) oferecer uma síntese abrangente, atualizada e fundamentada sobre o estado da arte do uso da IA nesse contexto; (4) oferecer uma exemplificação da aplicação de uma tecnologia de IA emergente num experimento prático exequível; e por fim, (5) transformar essa análise em insights práticos que auxiliem gestores e profissionais de *supply chain* a maximizar benefícios, mitigar riscos e orientar decisões estratégicas de curto e longo prazo.

Por fim, o documento é estruturado da seguinte forma. A secção “Metodologia” consiste na metodologia aplicada para uma revisão da literatura sobre a relação entre *supply chains* e IA. A ferramenta usada e cada aspecto do processo de revisão estão detalhados nessa secção. Em seguida, a secção “Revisão da Literatura” apresenta a revisão da literatura que retrata o estado da arte desses domínios. Ele pesquisa aspectos como o impacto da IA nas *supply chains* por meio de otimização, gerenciamento de riscos, sustentabilidade, identificação de barreiras à adoção e desafios atuais encontrados em sua integração. Na secção “IA aplicada num processo de *supply chain*”, a tecnologia de IA foi aplicada a um processo que faz parte de uma das atividades realizadas em um ambiente de negócios. O objetivo dessa secção é experimentar e explorar uma tecnologia inovadora de IA generativa como uma possível solução para uma tarefa repetitiva que pode ser automatizada. Por fim, na secção “Conclusão e trabalhos futuros”, são feitas as considerações finais, discutidas as implicações da integração da IA e oferecidas recomendações para o setor de gerenciamento de *supply chains*.

1. Metodologia

Neste estudo, a literatura foi revisada usando o software ASReview (ASReview LAB developers, 2024). Esse software permite que os estudos sejam selecionados por meio da triagem do título e do resumo de artigos baixados de repositórios escolhidos pelo revisor. Isso permite uma experiência de triagem confortável que usa aprendizado de máquina para pesquisar primeiro os estudos mais relevantes. Nas seções a seguir, todo o processo será detalhado.

1.1 Método de Investigação

A metodologia usada pela plataforma ASReview é chamada de aprendizado ativo. A plataforma de triagem, ASReview, usa algoritmos de aprendizado de máquina para aprender com o revisor o tipo de estudo procurado. Essa metodologia é realizada em etapas, a saber: seleção da técnica de aprendizado de máquina, pré-treinamento e aprendizado ativo. Esse software, além de aplicar a metodologia de aprendizado ativo por meio do uso de Inteligência Artificial para apoiar a escolha dos estudos a serem analisados, facilita muito o processo de leitura de títulos e resumos por meio de uma interface intuitiva que reduz o esforço necessário durante o processo de triagem por meio

de uma visualização clara e comum a todos os estudos recuperados de repositórios de artigos científicos.

Esse é um tipo de sistema classificado como Human-In-The-Loop (HITL) / Researcher-In-The-Loop (RITL), ou seja, o ser humano que interage com o sistema está atuando ativamente no processo de tomada de decisão. Nesse caso, trata-se de escolher o próximo artigo que será exibido na interface do software para o revisor, a fim de fornecer feedback sobre a relevância do estudo exibido no momento pelo software, no qual o sistema considera iterativamente o feedback para escolher o próximo estudo a ser exibido. Assim, os estudos mais relevantes são mostrados primeiro, ou seja, aqueles com conteúdo mais próximo daqueles classificados anteriormente como relevantes. O modelo melhora gradualmente suas previsões sobre os registros não rotulados restantes no ciclo de aprendizagem ativa. O objetivo é economizar tempo selecionando menos registros que existem em todo o conjunto em interação com a máquina, que se torna “mais inteligente” após cada decisão de rotulagem.

O ASReview permite a realização de três tipos de projetos: oracle, validação e simulação. O modo desejado é o modo oracle. Os modos de validação e simulação usam estudos parciais ou totalmente classificados (título e resumo). O modo oracle acessa um novo conjunto de estudos, escolhido pelo revisor com base em uma pesquisa realizada por meio de consultas de pesquisa nos repositórios de artigos desejados. O modo de validação permite que o usuário valide os rótulos fornecidos por outro revisor em um determinado conjunto de dados. Por fim, o modo de simulação permite que o usuário simule uma revisão em um conjunto de dados completamente rotulado.

Neste trabalho, o objetivo é usar o modo oracle para realizar a revisão em um conjunto de dados totalmente não rotulado. O processo começa com a criação de um novo projeto na interface do ASReview, acessando-o por meio da linha de comando do Windows. O usuário só precisa digitar “cmd” na barra de pesquisa para abrir a linha de comando e “asreview lab” na linha de comando para abrir o ASReview em uma guia do navegador. A próxima etapa é criar um novo projeto, definir um título para o projeto e passar para o upload do conjunto de dados (títulos e resumos) dos estudos selecionados em cada repositório usando as consultas de pesquisa (explicação mais detalhada na seção “Estratégia de pesquisa”). Em seguida, vem a seleção da técnica ML que o usuário deseja utilizar. Essas configurações podem ser ajustadas para fins específicos de revisão, conforme a documentação menciona (Bruin, 2024). As configurações fornecidas foram usadas para a revisão realizada:

- Técnica de extração de recursos: *Term Frequency-Inverse Document Frequency* (TF-IDF)

TF-IDF é uma técnica de extração de recursos leve e fácil usada na mineração de texto que transforma o texto em valores numéricos medindo a importância de uma palavra em um resumo em relação a todo o conjunto de dados (soma de todos os títulos e resumos), o que a torna compatível com modelos de aprendizado de máquina como o Naive Bayes.

- Classificador: Naive Bayes

O classificador Naive Bayes pressupõe que os recursos (frequência de uma palavra em um texto, posição de uma palavra em uma frase, significado semântico de uma palavra) são independentes uns dos outros e é conhecido por sua objetividade e velocidade.

- Estratégia de consulta: *Maximum*

A estratégia de consulta decide qual documento será exibido em seguida com base nas pontuações de relevância computadas. Com a opção máxima (baseada em certeza) selecionada, o ASReview mostrará os documentos em ordem de relevância.

- Estratégia de balanceamento: *Dynamic resampling (Double)*

A estratégia de balanceamento é usada para diminuir o desequilíbrio da classe (proporção relevante/irrelevante) nos dados de treinamento; o padrão é reequilibrar o conjunto de treinamento por meio de uma técnica chamada reamostragem dinâmica, que é definida por padrão como *Dynamic resampling (Double)*. Na documentação, é relatado como importante para o algoritmo ML do ASReview não influenciar o aprendizado com base em rótulos iniciais desbalanceados (muito mais rótulos irrelevantes do que relevantes).

Em conclusão, é realizado um experimento empregando uma abordagem inovadora com uma tecnologia de IA em desenvolvimento (CrewAI) para tirar conclusões sobre os avanços atuais e a aplicabilidade da IA em um processo relacionado à cadeia de suprimentos, discutindo tópicos relevantes relacionados aos aspectos da IA na cadeia de suprimentos encontrados na revisão da literatura. Essa iniciativa visa preencher a lacuna entre os recursos teóricos de IA e as aplicações práticas no gerenciamento da cadeia de suprimentos, oferecendo uma análise abrangente de como as tecnologias emergentes podem ser aplicadas aos processos empresariais atuais. Esta pesquisa contribuirá para o discurso mais amplo sobre a integração da IA nas operações comerciais, destacando o fato da confiança nas soluções geradas pela IA.

1.2 Questões de Investigação

A escolha das *research questions* é motivada pela necessidade de compreender-se o impacto da IA em *supply chains*, especialmente no que diz respeito à otimização, resiliência, gerenciamento de riscos, sustentabilidade e desafios para a implantação desse ramo de tecnologias que são pilares nessa área. A integração da IA apresenta desafios significativos, pois envolve a adaptação de novas tecnologias em um campo que historicamente depende de técnicas estabelecidas há muito tempo. Isso requer uma análise cuidadosa para garantir que a inovação não comprometa processos existentes, mas os melhore. Além disso, há uma crescente preocupação com a sustentabilidade e como a aplicação dessas novas técnicas pode contribuir para questões ambientais, como a redução das emissões de carbono. Portanto, investigar esses aspectos é crucial para desenvolver *supply chains* mais eficientes e sustentáveis.

A seguir, foram definidas as *research questions* que serviram de referência para o desenvolvimento da revisão da literatura:

- Como a aplicação da IA na gestão da cadeia de suprimentos melhora a eficiência e reduz os custos operacionais?
- Qual é o papel da IA no aumento da resiliência da cadeia de suprimentos e na gestão de riscos?
- Como a integração da IA nos processos da cadeia de suprimentos afeta a sustentabilidade e os resultados ambientais?
- Quais são os desafios e as barreiras para a implementação de soluções de IA na otimização da cadeia de suprimentos?

1.3 Estratégia de Pesquisa

Para a estratégia de pesquisa, uma seleção de palavras relacionadas com o tema principal deste trabalho permitiu encontrar os artigos mais relevantes. A consulta de pesquisa é composta por duas partes principais. A primeira refere-se à cadeia de abastecimento e aos seus termos relacionados, enquanto a segunda parte diz respeito à inteligência artificial. A utilização de conectores booleanos permite a construção de uma consulta de pesquisa abrangente que engloba a ideia geral desta investigação, tendo em conta a devida profundidade e especificidade da consulta de pesquisa.

A escolha dos repositórios foi feita com base na relevância de cada repositório, na possibilidade de acesso aos estudos armazenados e na facilidade de recuperação desses estudos. O Science Direct, o Sage Journals e o IEEEExplore foram as plataformas escolhidas pelas razões apontadas. Forneciam estudos relevantes e em quantidade suficiente para serem selecionados. O número de termos, os conectores booleanos e os wild cards obedecem às restrições dos repositórios. Por exemplo, o Science Direct não permite wildcards (símbolo que substitui caracteres desconhecidos dentro de um termo quando se faz a pesquisa) e restringe o número total de conectores booleanos a oito. No Sage Journals, a utilização de wild cards produziu menos resultados do que com os termos completos originais. Por conseguinte, para obter melhores resultados com maior homogeneidade, foram utilizados oito conectores booleanos em todos os repositórios e os wildcards apenas na pesquisa do IEEEExplore.

A Tabela 1 apresenta as consultas realizadas em cada base de dados e seus resultados filtrados para o intervalo de tempo considerado nos critérios de inclusão. Tanto os critérios de inclusão quanto os de exclusão considerados nesta revisão serão discutidos na secção Seleção de Estudos.

Tabela 1: *Research queries por search engines.*

Repositório	Query	Estudos encontrados
IEEEExplore	("supply chain*" OR "logistic* optimiz*" OR "inventory optimiz*" OR "procurement optimiz*") AND ("artificial intelligence" OR "AI" OR "machine learn*" OR "ML") AND ("manufactur*")	724

Repositório	Query	Estudos encontrados
Science Direct	("supply chain" OR "logistics optimization" OR "inventory optimization" OR "procurement optimization") AND ("artificial intelligence" OR "AI" OR "machine learning" OR "ML") AND ("manufacturing")	124
Sage Journals	("supply chain" OR "logistics optimization" OR "inventory optimization" OR "procurement optimization") AND ("artificial intelligence" OR "AI" OR "machine learning" OR "ML") AND ("manufacturing")	923

1.4 Seleção de Estudos

O processo de seleção dos estudos é ilustrado nas Figuras 1, 2, 3 e 4. Foram efetuadas pesquisas nos repositórios digitais (em 30/08/2024), utilizando as consultas de pesquisa descritas na secção anterior, tendo sido recuperados 1771 estudos, dos quais 923 do Sage Journals, 124 do Science Direct e 724 do IEEEExplore. Adicionalmente, em cada repositório, os filtros fornecidos ajudaram a seleccionar os tipos de estudos adequados pretendidos, reduzindo assim o número de estudos antes da triagem.

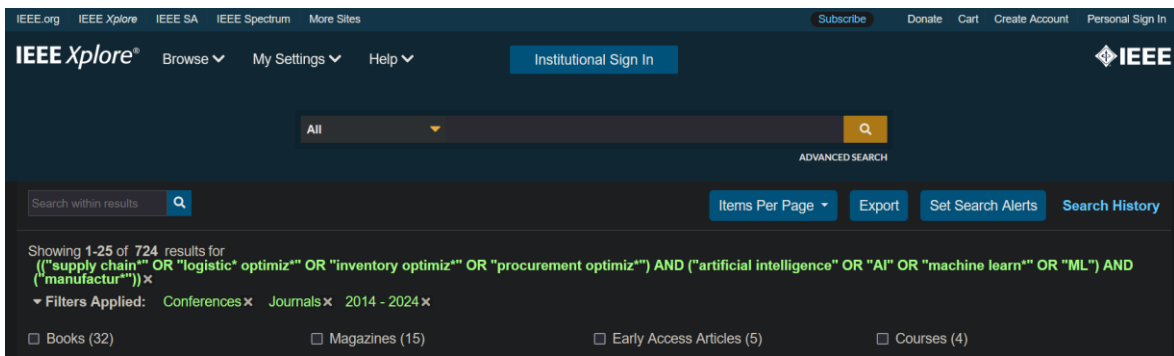


Figura 1: Search query no IEEEExplore.

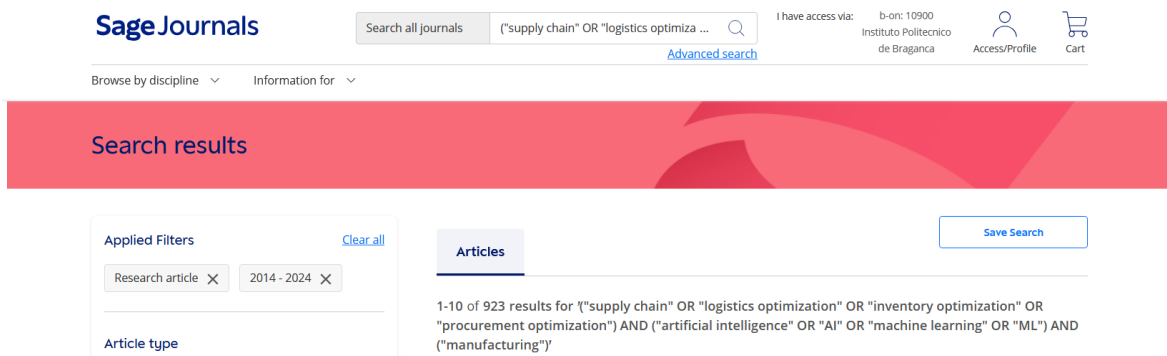


Figura 2: Search query no Sage Journals.

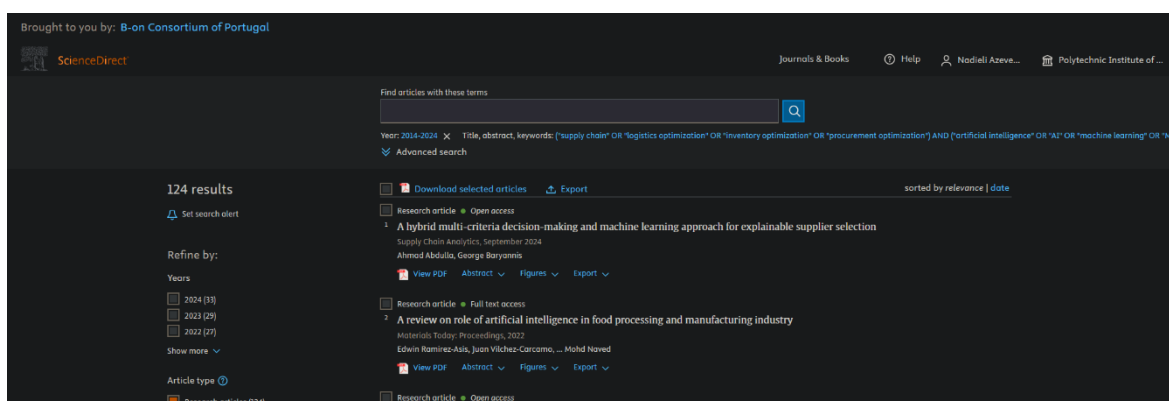


Figura 3: Search query no Science Direct.

Na Science Direct, a consulta de pesquisa foi executada no campo *Title, abstract or author-specified keywords*, a seleção do ano foi restringida aos últimos 10 anos (2014 - 2024), e a opção *Research articles* foi selecionada no menu da barra lateral esquerda de modo a incluir apenas estudos primários. No Sage Journals, a consulta de pesquisa foi executada na barra *All Content* com a restrição da data dos últimos 10 anos, e a seleção *Research article* aplicada no menu da esquerda *Article type*. No IEEEExplore, a consulta de pesquisa foi executada na caixa *Command Search*, o intervalo foi restringido de 2014 a 2024, e os filtros aplicados foram *Conferences* e *Journals*.

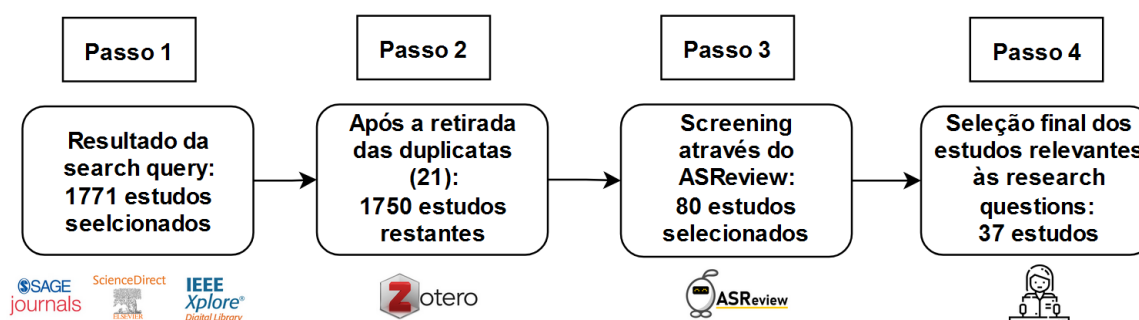


Figura 4: Processo de seleção.

Dos 1771 recuperados, 21 duplicatas foram encontradas e removidas. Em seguida, o ASReview foi utilizado para exibir os artigos mais relevantes. Para este trabalho, o autor optou por parar nos 80 estudos relevantes encontrados devido ao âmbito deste trabalho. Para uma revisão mais alargada e sistemática da literatura, recomenda-se que se limite a um número superior. Após uma inspeção mais aprofundada dos 80 estudos, foram escolhidos 37 com base no conteúdo e na relevância relativamente às questões de investigação deste trabalho. Além disso, foram observados os critérios de inclusão e exclusão, a fim de proporcionar uma seleção robusta de estudos.

Para a seleção do estudo, foram considerados os seguintes critérios de inclusão e exclusão como pode ser visto na Tabela 2.

Tabela 2: Critérios de inclusão e exclusão.

Identificador	Tipo	Critérios
IC1	Inclusão	Estudos da cadeia de abastecimento e da inteligência artificial na indústria transformadora.
IC2	Inclusão	Estudos primários.
IC3	Inclusão	Estudos escritos em inglês.
EC1	Exclusão	Estudos sem resumo ou título.
EC2	Exclusão	Estudos retratados ou não publicados.
EC3	Exclusão	Estudos que não fornecem o documento completo.
EC4	Exclusão	Estudos que não cruzam <i>supply chains</i> com a inteligência artificial.
EC5	Exclusão	Livros, notas, artigos de notícias ou revisões de literatura auto-intituladas.

1.5 Extração de Dados e Síntese

Com base nos resultados das consultas de pesquisa, cada estudo recuperado foi descarregado de acordo com a estrutura de cada repositório. No Science Direct, devido à qualidade da recuperação ser suficientemente específica, todos os estudos puderam ser descarregados manualmente. No IEEEExplore, todos os estudos puderam ser descarregados num ficheiro CSV fornecido pela plataforma. No Sage Journals, cada página apresenta dez estudos. Foi possível descarregar manualmente todos os estudos, o que exigiu cerca de duas horas ao longo de dois dias.

Após a fusão dos resultados de todos os estudos, foram encontrados 21 duplicados, que foram removidos utilizando o Zotero. De seguida, iniciou-se o processo de triagem no ASReview. Os ficheiros RIS da Sage Journals e da Science Direct foram convertidos para o formato CSV e fundidos num único ficheiro CSV. Foi criado um projeto no ASReview em modo Oracle e o ficheiro CSV foi carregado como o conjunto de dados para a triagem. O conhecimento prévio foi adicionado rotulando alguns estudos como relevantes e irrelevantes. Foram aplicadas as predefinições, nomeadamente TF-IDF como técnica de extração de características, Naive Bayes como classificador, estratégia de consulta no máximo e estratégia de equilíbrio em *Dynamic resampling (Double)*.

O processo de revisão começou e terminou depois de terem sido encontrados e etiquetados oitenta estudos relevantes. Esta regra de paragem foi escolhida devido ao tipo de trabalho pretendido para

esta parte do estudo, que é uma revisão da literatura. Os oitenta estudos relevantes iniciais satisfazem a necessidade de rever a literatura relevante para este domínio neste trabalho. Os oitenta trabalhos relevantes apresentados pelo ASReview com base no processo de rotulagem de relevantes e irrelevantes foram utilizados para análise posterior.

Ao descarregar cada um dos 80 artigos, não foi possível aceder aos textos de dois deles. Por esse motivo, estes dois foram imediatamente descartados. Após uma nova inspeção dos 78 artigos restantes, foi realizada uma leitura rápida do conteúdo completo de cada artigo, centrada principalmente nos resultados de cada estudo, pelo que foram seleccionados 37 artigos para uma análise aprofundada. Nesta fase, foi dada ênfase à seleção de artigos que tinham aplicações nas indústrias transformadoras, após uma avaliação da qualidade da escrita e da ligação do conteúdo às questões de investigação. Foram descartados os trabalhos que se concentravam apenas em aspectos técnicos. Na secção Revisão da Literatura, são apresentados os resultados da análise desses estudos.

2. Revisão da Literatura

Nesta secção realiza-se a revisão da literatura seguindo o exposto na secção Metodologia.

2.1 *Supply Chain* e Seus Componentes

Uma das definições mais reconhecidas de *supply chains* refere-se à rede interligada de organizações, recursos, atividades e tecnologias envolvidas na produção e distribuição de bens e serviços desde o ponto de origem até ao consumidor final.

Uma *supply chain* consiste em todas as partes envolvidas, direta ou indiretamente, no atendimento de uma solicitação do cliente. A *supply chain* inclui não apenas o fabricante e os fornecedores, mas também transportadores, armazéns, varejistas e até mesmo os próprios clientes. Dentro de cada organização, como um fabricante, a *supply chain* inclui todas as funções envolvidas no recebimento e no atendimento de uma solicitação do cliente. Essas funções incluem, entre outras, o desenvolvimento de novos produtos, marketing, operações, distribuição, finanças e atendimento ao cliente (Chopra & Meindl, 2016).

Ela engloba as etapas desde o aprovisionamento de matérias-primas até à entrega do produto acabado. O bom funcionamento da *supply chain* é essencial para que as empresas satisfaçam eficazmente as exigências dos clientes e mantenham a competitividade no mercado. Cada elo da cadeia deve trabalhar em coordenação para garantir que os materiais e os produtos fluam sem problemas de uma fase para a seguinte, minimizando os atrasos que se traduzem em ineficiências e, por conseguinte, em perda de valor.

Os principais componentes de uma *supply chain* podem ser divididos em cinco áreas-chave: planeamento, aprovisionamento, fabrico, entrega e devoluções. O planeamento é a componente estratégica em que a previsão da procura e a atribuição de recursos são feitas para alinhar a oferta com a procura dos consumidores. As empresas devem antecipar quais os produtos que serão necessários, em que quantidades e em que regiões. O aprovisionamento envolve a seleção de fornecedores que fornecem as matérias-primas ou os componentes necessários para produzir bens. Esta fase inclui negociações, controlo de qualidade e gestão das relações com os fornecedores.

O fabrico é a fase em que ocorre a transformação efectiva das matérias-primas em produtos acabados. Inclui o planeamento da produção, a gestão das instalações e os processos de garantia de qualidade. As empresas esforçam-se por otimizar os seus processos de fabrico para obterem eficiência, garantindo que os bens são produzidos a tempo e dentro dos limites de custos. Quando os produtos estão prontos, a fase de entrega, frequentemente designada por logística, assegura que os produtos chegam ao consumidor final. Isto envolve sistemas de armazenamento, gestão de inventário, transporte e distribuição que asseguram uma entrega atempada e económica.

A componente de devoluções centra-se na logística inversa, tratando das devoluções, trocas e reparações de produtos. A gestão efectiva desta fase é crucial para a satisfação do cliente e para a sustentabilidade, uma vez que envolve frequentemente a reciclagem ou a renovação de produtos devolvidos. No atual ambiente empresarial globalizado e altamente competitivo, a integração destes componentes através de tecnologias como os sistemas de gestão da *supply chain* e a automatização é vital para garantir agilidade, transparência e resiliência face a desafios como as flutuações da procura ou as perturbações da oferta (Chopra & Meindl, 2016).

2.2 Revisão da Literatura

Nesta secção, será utilizada uma análise dos artigos selecionados para responder às questões de investigação.

RQ1: Como a aplicação da IA na gestão da cadeia de suprimentos melhora a eficiência e reduz os custos operacionais?

Nos últimos anos, a Indústria 4.0 (I4.0) influenciou significativamente os campos do planeamento inteligente da produção em tempo real e da gestão de *supply chains*, alavancando as tecnologias de ML. Bedi et al. (2021) identificam o ML como central para a análise preditiva, que utiliza dados históricos para prever a demanda futura, permitindo que as organizações planejem e otimizem suas *supply chains* de forma proativa, identificando ineficiências dentro da *supply chain*, promovendo melhoria contínua e otimização ao longo do tempo. No contexto da Indústria 4.0, Kediya et al. (2023)

analisam os desafios e oportunidades na gestão da *supply chain*, centrando-se no papel transformador do ML. Observa-se o seu potencial para ultrapassar as limitações das técnicas convencionais, melhorando a fiabilidade e a eficácia da gestão da *supply chain*. Os métodos tradicionais de previsão dependem fortemente de dados históricos, que podem muitas vezes ser inexatos ou incompletos, limitando a sua capacidade de captar relações e padrões complexos.

A globalização e o aumento da concorrência no mercado conduziram a uma rápida inovação e a ciclos de produtos mais curtos, com uma mudança acentuada para produtos orientados para o cliente. Em resposta, o fabrico modular surgiu como uma abordagem relevante, necessitando de uma otimização avançada da *supply chain*. Bhosekar & Ierapetritou (2021) apresentam uma estrutura que incorpora ML para análise de viabilidade, um tipo de análise para determinar se um determinado conjunto de condições é cumprido, utilizando dados históricos do processo para garantir a viabilidade da produção. Especificamente, emprega *Support Vector Machines* (SVMs) para modelar processos de fabrico modulares, permitindo a conceção de *supply chains* que satisfaçam restrições de produção específicas. Esta abordagem orientada para o ML aumenta a precisão das previsões de viabilidade da produção e apoia a otimização das *supply chains* no fabrico modular, alinhando-se com a tendência para modelos de produção flexíveis e centrados no cliente.

A integração de tecnologias disruptivas, em particular a IA generativa, está a transformar a gestão da *supply chain* digital nas empresas transformadoras, melhorando a integração, a flexibilidade e a eficiência de custos. Al-Khatib, Al-Shboul & Khattab (2024) examinam o papel da IA generativa na melhoria do desempenho das *supply chains* através da ambidestria da inovação, da exploração das capacidades existentes e da exploração de novas oportunidades, equilibrando a inovação exploratória (mudanças radicais impulsionadas pelo R&D) com a inovação exploratória (melhorias dentro das competências existentes). As aplicações de IA generativa, como os chatbots e as ferramentas analíticas avançadas, apoiam a análise de grandes volumes de dados e facilitam ambos os tipos de inovação, aumentando o desempenho das *supply chains*.

A aplicação da IA na otimização da *supply chain* está a remodelar a forma como as organizações gerem os seus processos operacionais, permitindo a análise de dados de vários aspectos da *supply chain*, melhorando assim a visibilidade, a tomada de decisões e a eficiência operacional. Os sistemas orientados para a IA otimizam os níveis de inventário, reduzem os encargos com a tomada de decisões e melhoram a precisão e a fiabilidade das principais atividades da *supply chain*, como a coordenação de tarefas e as negociações com fornecedores.

Um impacto notável da IA é no planeamento da procura. Tecnologias como as redes neuronais artificiais são utilizadas para prever a demanda com maior precisão, mitigando questões como previsões de procura tendenciosas e o efeito chicote, em que pequenas flutuações da procura ao nível do consumidor se amplificam em toda a *supply chain* (Kumari et al., 2023). Além disso, os algoritmos de IA podem analisar os dados para aperfeiçoar estas previsões, garantindo um melhor alinhamento entre a procura e a oferta. Através destas capacidades, a IA promove um ambiente de *supply chain* mais reativo e eficiente.

Wang (2024) apresenta uma estrutura baseada no IoT (*Internet of Things*), uma rede de dispositivos interligados que comunicam e trocam dados entre si através da Internet, para otimizar as supply chains de comércio eletrônico transfronteiriço, tirando partido de técnicas de ML e de otimização. A tónica é colocada na previsão do comportamento de recompra dos clientes e dos volumes de encomendas com maior precisão utilizando modelos de ML. A melhoria da previsão da procura utilizando dispositivos inteligentes permite às empresas alinhar melhor o seu planeamento de inventário e produção com a procura real do mercado, minimizando eficazmente a sobreprodução e as rupturas de *stock*.

Tal capacidade do *framework* de ML prever a demanda apoia um planeamento de produção mais eficiente, garantindo que as empresas produzam as quantidades certas nos momentos certos. Isto leva a uma redução dos custos de produção, a uma melhor gestão do inventário e a um fluxo mais suave de mercadorias ao longo da *supply chain*. Em última análise, a integração do ML na estrutura baseada em IoT aumenta a eficiência e a rentabilidade da *supply chain*. Neste contexto, a Gestão 4.0 (*Supply Chain Management (SCM) + I4.0*) incorpora estas tecnologias avançadas para promover operações eficientes em todo o sector. A deteção de anomalias baseada em IA é crucial para monitorizar dados massivos de sensores e identificar desvios do comportamento normal, o que ajuda a manter a estabilidade e o desempenho dos sistemas de fabrico.

No SCM, os sistemas de controlo de visão baseados em IA estão na vanguarda da deteção de falhas e da monitorização de desvios, atuando como assistentes digitais que fornecem informações em tempo real para a engenharia industrial, o planeamento da produção e a gestão da qualidade. Esta integração da IA promove operações mais reactivas e resilientes, alinhando-se com os objectivos da Gestão 4.0 para melhorar a eficiência e a sustentabilidade (Haleem et al., 2023).

Kehayov, Holder & Koch (2022) exploram o papel transformador da IA e do ML na otimização da tomada de decisões no âmbito da gestão da produção e do aprovisionamento. As tecnologias de IA apoiam processos críticos como a afetação de recursos, a pontuação de leads e a análise da interação cliente-vendedor, melhorando a eficiência e a capacidade de resposta nas *supply chains*. Nos departamentos de compras, as técnicas de ML, como as árvores de decisão e as redes neuronais, são utilizadas para automatizar e otimizar tarefas, tratando grandes volumes de dados e permitindo a tomada de decisões autónomas. A partir desta análise, entende-se que os mercados globais se tornam cada vez mais complexos e competitivos e que a adoção da IA é essencial para que as empresas se mantenham competitivas, prometendo um potencial para revolucionar a produção e a gestão de materiais, posicionando-a como uma solução ideal para o futuro da produção e da gestão de *supply chain*.

Em Niranjana, Narayana & Rao (2021), o impacto transformador da IA na logística e na SCM é estudado, centrando-se na forma como a IA aumenta a eficiência e a transparência nas *supply chains*. Com a digitalização dos processos da *supply chain*, a IA permite que as organizações ultrapassem os sistemas legados em direção à análise e automação avançadas através de tecnologias como a robótica e a computação móvel. A IA ajuda a estruturar e a analisar grandes volumes de dados, muitos dos quais continuam a ser subutilizados, fornecendo informações que

conduzem a uma tomada de decisões mais informada. As aplicações na logística e na SCM oferecem oportunidades significativas de redução de custos na previsão da procura, no planeamento da produção, na gestão de inventários e no serviço ao cliente, dando às empresas uma vantagem competitiva.

Nagar et al. (2021) exploram o papel do ML na sustentação das *supply chains* no ambiente dinâmico e competitivo da Indústria 4.0. Como uma ferramenta para otimizar a utilização de recursos, o ML fornece às organizações previsões precisas e conhecimentos acionáveis, facilitando a tomada de decisões eficazes em toda a *supply chain*. Na logística, o ML ajuda a analisar dados essenciais, como o feedback dos consumidores e as condições do mercado, ajudando as organizações a enfrentar potenciais desafios. Também apoia a otimização dos preços através da análise de dados em tempo real, permitindo que os fabricantes definam preços competitivos que se alinhem com as expectativas dos clientes e garantam a rentabilidade. Esta abordagem reduz os custos de inventário em excesso e minimiza o desperdício, promovendo operações mais simples e conseqüentemente eficientes.

Harikrishnakumar & Nannapaneni (2019) investigam a aplicação de algoritmos de ML para a classificação de fornecedores, com o objetivo de ultrapassar os enviesamentos e a subjetividade frequentemente presentes no julgamento humano. O ML melhora as capacidades de tomada de decisão quando lida com problemas de classificação complexos e produz previsões de qualidade que ultrapassam as limitações humanas. O estudo aborda algoritmos de aprendizagem supervisionada, como as máquinas de vectores de apoio (SVM), Naïve Bayes e Árvores de Regressão. Estes algoritmos permitem avaliações de fornecedores mais exactas, eficientes e flexíveis, que são essenciais para lidar com as complexidades da gestão da *supply chain*. Através destas técnicas de ML, o estudo sublinha o valor da adoção de métodos mais objectivos e escaláveis para a classificação de fornecedores, destacando a forma como o ML pode melhorar a precisão da avaliação e reduzir o tempo de processamento, apoiando, em última análise, operações mais eficazes da *supply chain*.

Albadrani, Zohdy & Olawoyin (2020) aprofundam o papel do ML na otimização dos processos de logística de entrada, destacando o seu impacto no planeamento estratégico e tático. Algoritmos de ML como *K-Nearest Neighbors* (KNNs), Árvores de Decisão, SVM e *Redes Neurais Artificiais* (RNAs) demonstram melhorar a tomada de decisões através da previsão de defeitos do sistema e da análise de grandes conjuntos de dados. Esta capacidade fornece informações valiosas sobre as operações logísticas, permitindo um planeamento e uma resolução de problemas mais eficazes. O artigo sublinha que os insights oferecidos pelo ML apoiam os planeadores logísticos na seleção dos conceitos e processos de entrega mais adequados, racionalizando assim a logística de entrada e aumentando a eficiência operacional. Esta abordagem demonstra o potencial do ML para enfrentar desafios logísticos complexos, facilitando, em última análise, uma gestão da logística de entrada mais reactiva e orientada para os dados.

Knoll, Prüglmeier & Reinhart (2016) examinam a integração do ML no planeamento da logística de entrada, centrando-se no potencial do ML para revolucionar a logística através da aprendizagem e

da reaplicação de conhecimentos derivados de processos existentes. Com base em aplicações bem sucedidas na concepção e fabrico de engenharia, o estudo sugere que o ML pode igualmente transformar a logística, melhorando a precisão e a adaptabilidade do planeamento. A abordagem proposta envolve a pré-seleção de características essenciais ao planeamento logístico e a implementação de modelos de ML para automatizar tarefas, como o planeamento de contentores de embalagem e avaliações de integração. O ML permite processos logísticos de entrada mais precisos e eficientes, abrindo caminho para uma gestão logística preditiva e reactiva nas futuras *supply chains* através da automatização destas atividades de planeamento.

Yıldız et al. (2024) salientam o papel da IA na otimização da SCM, especificamente no planeamento de embalagens. As soluções baseadas em IA são cada vez mais aplicadas em todos os sectores para aumentar a eficiência e melhorar os processos de tomada de decisão. O modelo proposto fornece uma abordagem mais precisa e eficiente para lidar com tarefas de classificação complexas em embalagens devido à alavancagem de técnicas avançadas de IA. Esta melhoria contribui para a otimização global das *supply chains*, uma vez que o planeamento preciso das embalagens facilita operações logísticas mais suaves e apoia uma melhor atribuição de recursos.

Singh & Soni (2019) estudam a aplicação de ML na otimização de previsões de lead time de encomendas num sistema de produção Just-in-Time (JIT). O objetivo do JIT é minimizar os custos de inventário, recebendo os bens precisamente quando são necessários, o que exige previsões precisas do tempo de entrega para garantir o bom funcionamento das operações. A previsão destes prazos de entrega é um desafio, uma vez que são afetados por variáveis como os tempos de processamento e de avaria, exigindo que os fornecedores forneçam produtos de forma fiável sem incorrer em custos de sobrecapacidade. Para melhorar a precisão da previsão, o estudo aplica vários algoritmos de ML supervisionados, incluindo regressões, árvores de decisão, floresta aleatória, Lasso e SVM. Estes modelos abordam as incertezas normalmente encontradas em ambientes de produção reais, melhorando assim a eficiência e a fiabilidade dos sistemas JIT. A investigação demonstra como as tecnologias de ML e IA podem reforçar a gestão da *supply chain*, oferecendo ferramentas robustas para lidar com complexidades e reduzir a variabilidade do prazo de entrega na produção JIT.

A aplicação da IA na gestão da *supply chain* melhora significativamente a eficiência e reduz os custos operacionais, melhorando a previsão da procura, otimizando a atribuição de recursos e simplificando as operações. As tecnologias de ML possibilitam a análise preditiva, permitindo às organizações planear e otimizar proativamente as suas cadeias de abastecimento, prevendo com precisão a procura futura. Os sistemas orientados para a IA melhoram a visibilidade e a tomada de decisões, otimizando os níveis de inventário e aumentando a fiabilidade de atividades como a coordenação de tarefas e as negociações com fornecedores. A manutenção preditiva alimentada por IA reduz o tempo de inatividade e prolonga a vida útil das máquinas, enquanto os algoritmos analisam dados de várias fontes, incluindo as redes sociais, para aperfeiçoar as previsões da procura e mitigar problemas como o efeito chicote. Na logística de entrada, a IA automatiza tarefas e analisa grandes conjuntos de dados, conduzindo a operações mais eficientes. Transforma a

gestão das *supply chains*, promovendo operações reactivas, resilientes e rentáveis, alinhadas com os princípios da Indústria 4.0 e da Gestão 4.0.

RQ2: Qual é o papel da IA no aumento da resiliência da cadeia de suprimentos e na gestão de riscos?

As *supply chains* resilientes são importantes para se adaptarem às flutuações do mercado. A fim de captar as complexidades crescentes das aplicações do mundo real, é necessário explorar e desenvolver novas técnicas. O papel da IA generativa está a aumentar rapidamente no desenvolvimento destas capacidades. Revela-se um potencial significativo na criação de vantagens competitivas e na otimização da utilização de recursos. Utilizando uma análise híbrida, a investigação confirma um impacto positivo e estatisticamente significativo da IA generativa no desempenho da *supply chain* digital (Al-Khatib, Al-Shboul & Khattab, 2024).

Os métodos tradicionais debatem-se frequentemente com questões como os requisitos de dados, a dificuldade em captar relações não lineares e a sensibilidade a valores atípicos. Em contrapartida, os modelos de ML, nomeadamente as redes neuronais, têm-se revelado promissores na superação destas limitações devido à sua capacidade de lidar com padrões de dados complexos e não lineares. Singha & Panse (2022) apresentam uma análise comparativa dos modelos de ML para a previsão da procura na *supply chain*, centrando-se na transição das abordagens quantitativas tradicionais para técnicas mais avançadas. Analisam várias aplicações de redes neuronais na gestão de inventários, no planeamento centralizado da *supply chain* e na estimativa de vendas, ilustrando a versatilidade e a eficácia destes modelos em todos os sectores. Aconselha-se a não confiar numa única técnica de previsão, sugerindo que as empresas explorem vários modelos para identificar o mais adequado às suas necessidades específicas. Esta abordagem flexível pode levar a uma maior precisão das previsões, o que é essencial para reduzir custos, otimizar as operações e aumentar a satisfação do cliente através de entregas atempadas. À medida que a previsão da procura na *supply chain* continua a evoluir, a utilização de modelos avançados como as redes neuronais pode capacitar as organizações para melhor satisfazerem as exigências do mercado e os objectivos operacionais.

As *supply chains* enfrentam inúmeros riscos, tanto externos como internos, que podem perturbar as operações, interromper a produção ou atrasar as entregas, criando um efeito de cascata em toda a rede. Chari et al. (2023) propõem uma abordagem baseada em IA para melhorar a identificação de riscos nas cadeias de abastecimento, utilizando a simulação de eventos discretos Discrete Event Simulation (DES). A DES é utilizada para modelar o fluxo de mercadorias na *supply chain*, fornecendo dados valiosos que podem apoiar o desenvolvimento de modelos de IA para priorizar os riscos. As ferramentas de gestão do risco melhoradas por IA podem reforçar a resiliência global das cadeias de abastecimento através da identificação e, por conseguinte, da priorização de potenciais perturbações. Esta integração de DES com tecnologias de IA permite uma gestão de riscos mais proativa, ajudando as organizações a antecipar e mitigar as perturbações antes que

estas se agravem, contribuindo, em última análise, para redes de *supply chain* mais robustas e resilientes.

Baryannis, Dani & Antoniou (2019) investigam o papel da análise de grandes volumes de dados e do ML na gestão do risco da *supply chain* (*Supply Chain Risk Management - SCRM*), centrando-se no compromisso entre o desempenho do modelo e a interpretabilidade. As técnicas de ML, muitas vezes consideradas *black boxes*, fornecem capacidades preditivas poderosas, mas carecem de transparência, uma vez que o seu funcionamento interno não é facilmente compreendido pelos utilizadores. No entanto, o aumento da interpretabilidade tem normalmente impacto no desempenho, diminuindo potencialmente a qualidade das previsões. O artigo sublinha que a interpretabilidade é essencial para criar confiança, uma vez que os modelos transparentes permitem aos utilizadores compreender e validar as etapas que conduzem a uma determinada solução. Esta transparência é especialmente importante para os gestores das *supply chains*, uma vez que promove a confiança nas tomadas de decisão. A resolução deste problema é crucial para promover uma adoção mais ampla das técnicas de ML na SCRM, garantindo que as soluções são eficazes e merecem a confiança dos decisores.

O ML tem um impacto significativo na gestão da *supply chain*, particularmente no contexto da produção em massa, melhorando a eficiência, a capacidade de resposta e o alinhamento com a procura social. As aplicações de IA, como os sistemas especializados e baseados em agentes, optimizam os processos da *supply chain*, incluindo o armazenamento e o controlo de inventário, permitindo operações mais simplificadas. As cadeias de abastecimento modernas geram grandes volumes de dados, mas muitas destas informações valiosas continuam por analisar. Gaurav (2023) compara várias abordagens de previsão, revelando que as técnicas de ML produzem resultados que reflectem melhor os dados reais do que os métodos convencionais. Através destas capacidades, o ML reforça a capacidade de resposta dos sistemas de produção em massa, apoiando uma melhor previsão da procura e permitindo a produção de bens de acordo com as necessidades do mercado em tempo real, beneficiando, em última análise, a sociedade através da redução do desperdício e da melhoria da afetação de recursos.

Van Belle, Guns & Verbeke (2021) examinam o papel da previsão exacta da procura a curto prazo em sistemas JIT no âmbito de *supply chains* multi-echelon (rede complexa de fases ou níveis interligados através dos quais os produtos passam do fornecedor inicial para o cliente final). Nos sistemas JIT, as previsões precisas são essenciais para um planeamento eficaz da *supply chain*, uma vez que os erros de previsão podem conduzir a faltas de abastecimento ou a um excesso de inventário, o que tem um impacto negativo no serviço ao cliente e na rentabilidade. Aplicam-se várias técnicas de ML para melhorar a previsão da procura e salienta-se os benefícios da utilização de informações a jusante, i.e. os dados de vendas diretas dos retalhistas aos clientes finais. Com a integração dos dados de vendas diretas (informações sobre as vendas reais de produtos dos retalhistas aos clientes finais), os fabricantes podem antecipar melhor as flutuações da procura, permitindo previsões mais precisas numa fase anterior, essenciais para o planeamento operacional.

Esta abordagem permite aos fabricantes ajustar as estratégias de produção e de inventário com maior precisão, reduzindo os riscos financeiros associados à volatilidade da procura.

A previsão da demanda na indústria eletrónica é particularmente difícil devido aos padrões voláteis da procura, aos ciclos de vida curtos dos produtos e aos prazos alargados para a expansão da capacidade. Estas complexidades são especialmente acentuadas no sector dos semicondutores, onde as operações de capital intensivo dependem fortemente do cumprimento preciso da demanda e da utilização da capacidade para gerar receitas e rentabilidade. Fu & Chien (2019) apresenta uma *framework* orientado por dados, que combina tecnologias de ML com mecanismos de agregação temporal para melhorar a exatidão da previsão da procura intermitente. Os métodos tradicionais de previsão e o julgamento humano são frequentemente insuficientes neste contexto, uma vez que têm dificuldade em adaptar-se às rápidas flutuações da procura. O quadro apoia decisões mais precisas e ágeis nas *supply chains*, permitindo aos distribuidores de produtos electrónicos aumentar a resiliência e manter a capacidade de resposta num ambiente de mercado altamente dinâmico.

Cavalcante et al. (2019) examinam uma abordagem baseada em dados para melhorar a resiliência da seleção de fornecedores na fabricação digital, combinando ML com simulação. Com o foco crescente na resiliência, particularmente na previsão de probabilidades de interrupção, o estudo destaca como uma abordagem híbrida pode avaliar melhor os perfis de risco do fornecedor e melhorar a confiabilidade da entrega. A integração do ML e da simulação apoia o desenvolvimento de gémeos digitais (réplica virtual feita à imagem e semelhança de um produto ou processo produtivo) para a *supply chain* que servem de modelos virtuais para analisar o desempenho dos fornecedores. Estes gémeos digitais permitem aos fabricantes simular vários cenários, avaliar potenciais perturbações e tomar decisões de seleção de fornecedores mais informadas. Esta abordagem reforça a resiliência da *supply chain*, permitindo uma gestão de risco mais proativa em ambientes de fabrico digital.

Tian et al. (2024) examinam o papel da resiliência da *supply chain* (SCRes, do inglês *Supply Chain Resilience*) na sustentação do desempenho das cadeias de abastecimento da indústria transformadora, particularmente na sequência das perturbações causadas pela pandemia da COVID-19. Estas perturbações sublinharam as vulnerabilidades ao limitarem a mão de obra, os materiais e os consumíveis, levando a encerramentos generalizados das fábricas. A SCRes é destacada como uma capacidade dinâmica essencial para que as organizações se adaptem e recuperem, envolvendo a integração, a construção e a reconfiguração de competências para enfrentar condições em mudança. O estudo sublinha a forma como as tecnologias digitais, especialmente a IA, podem reforçar as SCRes, aumentando a adaptabilidade e a capacidade de resposta das cadeias de abastecimento. Através de informações baseadas em dados, a IA apoia a resiliência da *supply chain*, permitindo que as organizações mantenham o desempenho operacional durante períodos instáveis, melhorando assim a capacidade de inovação e a robustez globais da *supply chain* da indústria transformadora.

Camur, Ravi & Saleh (2024) investigam também o papel do ML no reforço da resiliência, mas com um enfoque específico na previsão das datas de disponibilidade dos produtos durante as

interrupções. As técnicas de ML são utilizadas para estimar a procura e detetar anomalias nos dados de vendas, que são vitais para antecipar potenciais problemas na logística e melhorar a precisão do planeamento dos envios. O ML reforça a resiliência da *supply chain* e apoia a tomada de decisões mais estratégicas através da previsão das datas de disponibilidade dos produtos. O estudo sublinha o potencial transformador da IA e do ML na gestão das *supply chains*.

Wright et al. (2024) exploram uma abordagem dupla à manutenção preditiva no fabrico de semicondutores (indústria electrónica), combinando a modelação probabilística com o ML para melhorar a precisão e a robustez da previsão. O modelo aborda os desafios únicos colocados pelo desequilíbrio de dados, ou seja, em que os dados sobre o tempo de atividade da ferramenta superam largamente os dados sobre o tempo de inatividade da ferramenta. Este desequilíbrio é significativo, uma vez que os dados sobre o tempo de inatividade - críticos para a manutenção preditiva - são frequentemente limitados em comparação com os abundantes dados sobre o tempo de atividade. O modelo proposto utiliza algoritmos avançados de ML e técnicas de síntese de dados para melhorar as previsões dos estados das ferramentas, permitindo a deteção precoce de potenciais falhas. Esta capacidade de antecipação reduz os tempos de inatividade inesperados e apoia a produção contínua, que é essencial no fabrico de semicondutores. O documento destaca a eficácia da combinação de modelos probabilísticos com ML para ultrapassar as limitações de dados e melhorar a fiabilidade dos sistemas de manutenção preditiva, garantindo um processo de fabrico mais suave e resiliente.

A partir dos estudos revisados, chega-se a conclusão de que a resiliência da *supply chain* e a gestão de riscos tiram partido dos modelos de ML para melhorar a previsão da procura, otimizar a utilização de recursos e antecipar potenciais perturbações. Técnicas como a IA generativa e as redes neuronais ultrapassam as limitações dos métodos tradicionais ao lidarem com padrões de dados complexos, conduzindo a previsões mais exactas, reduções de custos. As ferramentas de gestão de riscos baseadas em IA, integradas em simulações como a simulação de eventos discretos, permitem a identificação proativa e a priorização de riscos, reforçando a robustez global das redes de *supply chain*. As aplicações de IA aumentam a capacidade de resposta, apoiam uma melhor seleção de fornecedores e melhoram a manutenção preditiva para reduzir o tempo de inatividade. A IA permite que as organizações se adaptem às flutuações do mercado, mantenham o desempenho operacional durante as interrupções e, por conseguinte, melhorem o apoio à gestão do risco através da criação de *supply chains* muito mais eficientemente resilientes.

RQ3: Como a integração da IA nos processos da cadeia de suprimentos afeta a sustentabilidade e os resultados ambientais?

As *supply chains* globais, embora essenciais para a economia, contribuem significativamente para as emissões de carbono, particularmente através de atividades de transporte e logística que dependem fortemente de combustíveis fósseis. Huang & Mao (2024) enfatizam a necessidade urgente de gerenciar as pegadas de carbono para combater as mudanças climáticas, abordando questões como o aumento das temperaturas e eventos climáticos extremos impulsionados por

emissões não controladas da manufatura e do transporte. As tecnologias da Indústria 4.0, em particular a IA, estão a impulsionar avanços significativos na sustentabilidade ambiental na indústria transformadora. Com a integração da IA com a análise de *Big Data* e a IoT, os fabricantes podem obter uma monitorização em tempo real de processos como o consumo de energia, as emissões, a produção de resíduos e o fluxo de materiais (Kopeinig, Woschank & Olipp (2024)). Este nível de monitorização ajuda a identificar ineficiências e áreas de melhoria, reduzindo assim o impacto ambiental das actividades de fabrico. Jamwal, Agrawal & Sharma (2022) exploram o papel do ML e da aprendizagem profunda na melhoria da sustentabilidade do fabrico no âmbito da Indústria 4.0, destacando algoritmos de inspiração biológica para enfrentar desafios relacionados com informações incompletas e recursos computacionais limitados.

Os algoritmos de optimização orientados para a IA podem ajustar as capacidades de produção, as rotas de transporte e a atribuição de recursos, conduzindo a uma maior eficiência operacional e a reduções significativas das emissões de carbono. Através destas capacidades, a IA inclui tecnologias inovadoras essenciais na criação de *supply chains* mais sustentáveis que se alinham com os objetivos de mitigação das alterações climáticas. A indústria chinesa de semicondutores está a adotar cada vez mais práticas ecológicas, com a transformação digital e a IA na vanguarda destes esforços. A IA estabelece as bases para permitir o monitoramento e relatórios em tempo real de métricas ambientais em todo o processo de fabricação, permitindo o consumo otimizado de energia, redução de resíduos e maior eficiência energética (Shahzad et al., 2024). Estas melhorias não só diminuem as emissões de carbono como também contribuem para a redução de custos. A manutenção preditiva baseada em IA é particularmente valiosa neste contexto, uma vez que antecipa as falhas do equipamento antes de estas ocorrerem, reduzindo o tempo de inatividade e prolongando a vida útil das máquinas. Isto reduz a frequência das substituições de equipamento, diminuindo assim o impacto ambiental. Além disso, quando a IA apoia a optimização de recursos, promove uma economia circular, garantindo uma utilização eficiente dos materiais e minimizando os resíduos. Em conjunto, estas tecnologias conduzem a uma cadeia de fornecimento mais sustentável, alinhando-se com os objetivos de neutralidade de carbono e melhorando o desempenho ambiental da indústria.

A transição para uma economia circular está a ganhar força à medida que as organizações dão prioridade à mitigação das alterações climáticas, à preservação ambiental e à evolução dos comportamentos dos consumidores. Hala, Anass & Youssef (2022) centram-se na integração do ML na cadeia de abastecimento de transporte e tratamento de resíduos para apoiar os objetivos da economia circular, que visam minimizar a utilização de recursos e reduzir o impacto ambiental. Eles reconhecem que a optimização das rotas de transporte, a previsão dos volumes de resíduos e a melhoria dos processos de tratamento com algoritmos de ML facilitam a redução do consumo de recursos e das emissões. Esta integração do ML em estruturas de economia circular apoia sistemas de gestão de resíduos mais sustentáveis, contribuindo para os objetivos mais amplos de preservação ambiental e utilização responsável dos recursos.

Anand et al. (2023) exploram vários modelos de inventário, particularmente os que abordam as complexidades da deterioração do inventário e das emissões de carbono nas *supply chains*. Eles destacam a relevância do cálculo das emissões de dióxido de carbono como um aspecto crítico das práticas sustentáveis da *supply chain*. Os algoritmos de ML são integrados nestes modelos de inventário, onde técnicas de modelação são aplicadas para otimizar os parâmetros, aumentando a rentabilidade e reduzindo os custos nas indústrias de produção. O paper salienta o valor do co-investimento em tecnologias ecológicas, defendendo que esta abordagem pode reduzir as emissões de carbono e aumentar os lucros - apoiando a tendência de desenvolvimento de *supply chains* sustentáveis como parte das estratégias de controlo das emissões de carbono. Também aborda os desafios da gestão de inventários perecíveis, incorporando algoritmos de IA. Através da comparação de soluções ótimas e de lucros totais conjuntos em vários cenários de emissões de carbono, o estudo sugere que o risco e o investimento partilhados entre empresas podem conduzir a uma maior sustentabilidade e rentabilidade. Destaca-se também a forma como a otimização, o risco e a sustentabilidade nas *supply chains* não são interdependentes, mas complementares numa perspetiva interdisciplinar. Além disso, esta integração do ML e das práticas sustentáveis sublinha a importância de melhorar a tomada de decisões em ambientes incertos, abrindo caminho para *supply chains* mais resistentes e ecológicas.

Continuando, o ML demonstra ter uma influência significativa na transição das *supply chains* tradicionais para as ecológicas. Wu & Zuo (2023) destacam a sua aplicação ao aprovisionamento ecológico, em que os algoritmos ajudam a selecionar fornecedores com baixo teor de carbono. Técnicas que envolvem redes neuroanis são utilizadas para prever a eficiência dos fornecedores ecológicos, promovendo assim o aprovisionamento ambientalmente responsável. Os autores sugerem que os avanços no ML podem ter impacto no equilíbrio do mercado, particularmente em condições de informação assimétrica. Estas atualizações tecnológicas podem influenciar factores competitivos como as quantidades de produtos e os preços, conduzindo, em última análise, a resultados mais sustentáveis. As conclusões sublinham a importância do ML na promoção de cadeias de abastecimento ecológicas, apoiando o aprovisionamento com baixo teor de carbono, contribuindo para a redução das emissões e a sustentabilidade ambiental.

Nafei et al. (2024) abordam as complexidades da tomada de decisão na produção sustentável, em particular na seleção de fornecedores ecológicos. Introduzem uma nova abordagem que integra redes neuronais com uma técnica denominada TOPSIS (Técnica de Ordem de Preferência por Similaridade à Solução Ideal). O TOPSIS é um método de tomada de decisões utilizado para identificar soluções a partir de um conjunto de alternativas com base na sua distância em relação a uma solução ideal. É particularmente eficaz em cenários de tomada de decisão multicritério, onde avalia as opções considerando tanto os factores positivos como os negativos. Este *framework* proporciona uma avaliação mais matizada das opções dos fornecedores, equilibrando a viabilidade económica com a sustentabilidade ambiental. A integração de redes neuronais em *frameworks* como o TOPSIS, numa abordagem híbrida, demonstra como as tecnologias inteligentes podem apoiar a gestão sustentável da *supply chain*, abordando os desafios modernos com a adoção eficaz da IA através de uma combinação de considerações económicas e ambientais.

Na indústria transformadora, as ferramentas de ML tornaram-se essenciais para aplicações como o controlo de qualidade, a otimização de processos e a previsão da procura, devido à sua capacidade de aprendizagem e adaptação. Os algoritmos de IA e ML são especialmente valiosos para analisar os grandes volumes de dados gerados nos processos de fabrico, apoiando a manutenção preditiva, a previsão exata da procura e a monitorização das condições. Estas capacidades são fundamentais para promover práticas sustentáveis e melhorar a eficiência global no sector da produção.

O papel da IA na redução de resíduos é crucial para a sustentabilidade, uma vez que permite uma gestão precisa dos recursos e minimiza os resíduos desnecessários, apoiando a utilização de energia e recursos, reduzindo assim a pegada ambiental das operações de fabrico. Facilita também decisões operacionais e de conceção mais sustentáveis, permitindo que os fabricantes antecipem e resolvam as ineficiências antes que estas surjam. Estes algoritmos inteligentes oferecem ferramentas poderosas para a gestão da pegada de carbono, permitindo análises preditivas que apoiam a previsão da procura, a otimização do inventário e a racionalização da logística. Além disso, o ML é particularmente eficaz na sugestão de rotas melhoradas para reduzir as emissões relacionadas com o transporte.

Em suma, a integração da IA nos processos da *supply chain* melhora significativamente a sustentabilidade e os resultados ambientais, otimizando as operações para reduzir as emissões de carbono e o consumo de recursos. As tecnologias de IA, especialmente quando combinadas com a análise de *Big Data* e a IoT, permitem a monitorização em tempo real da utilização de energia, emissões, produção de resíduos e fluxos de materiais, identificando ineficiências e áreas de melhoria. Isto conduz a uma maior eficiência operacional, apoia a transição para uma economia circular e promove o aprovisionamento ambientalmente responsável através de uma melhor seleção de fornecedores. A manutenção preditiva orientada por IA e a otimização de recursos reduzem o desperdício e prolongam a vida útil do equipamento, minimizando ainda mais o impacto ambiental. Globalmente, a integração da IA nos processos da cadeia de abastecimento oferece oportunidades significativas para reforçar a sustentabilidade e melhorar os resultados ambientais, otimizando as operações, reduzindo as emissões e promovendo práticas ecológicas. Através destas capacidades, a IA contribui para uma indústria transformadora mais sustentável e ambientalmente responsável.

RQ4: Quais são os desafios e as barreiras para a implementação de soluções de IA na otimização da cadeia de suprimentos?

Embora o ML tenha um potencial transformador, investigadores como Nagar et al. (2021) sublinham os desafios substanciais que acompanham frequentemente a sua implementação. Para além dos custos iniciais consideráveis, as organizações têm de garantir conhecimentos especializados capazes de alinhar as tecnologias de ML com os dados e as estruturas operacionais existentes. Isto implica não só estabelecer ligações significativas entre os dados de entrada e as funções organizacionais, mas também gerir processos de integração complexos. Para as empresas sem

fortes capacidades internas, navegar por estas complexidades pode constituir um obstáculo significativo à plena concretização dos benefícios do ML.

Ghabak & Seetharaman (2023) identificam várias barreiras à adoção do ML nas *supply chains*, incluindo a falta de recursos, conhecimentos e pessoal qualificado para implementar eficazmente soluções baseadas em IA. Além disso, os elevados custos associados à adoção do ML representam um desafio. Todo o processo de implementação de um modelo ou técnica de ML no ambiente produtivo, desde a aquisição de dados até à sua utilização adequada, não só é dispendioso, como também coloca desafios em termos de privacidade e partilha de dados, que podem não se destacar para os decisores na análise custo-benefício quando consideram essas soluções para a SCM.

Já Niranjan, Narayana & Rao (2021) abordam os desafios associados à IA, incluindo o tratamento das incertezas e dos "information bottlenecks". Os sistemas de IA, embora poderosos, podem tomar decisões erradas se dependerem apenas de entradas de software. Portanto, as organizações devem considerar cuidadosamente os riscos e garantir a implantação bem informada da IA nas cadeias de suprimentos para maximizar os benefícios e mitigar as desvantagens potenciais.

Al-Khatib, Al-Shboul & Khattab (2024) resume desafios como as restrições financeiras e o apoio limitado da gestão, sobretudo na adoção da IA generativa. Uma implementação bem-sucedida da IA requer um forte apoio da gestão de topo e formação adequada para os funcionários. Sem estes fatores, as empresas podem ter dificuldades em integrar eficazmente a IA nos seus processos da cadeia de abastecimento. Além disso, as provas empíricas e as melhores práticas estabelecidas para a sua aplicação são limitadas, o que torna difícil para as empresas adotar e integrar eficazmente a IA generativa. A investigação futura é altamente desejável neste domínio.

Chien et al. (2023) examinam o papel transformador da IA no fabrico de semicondutores e na gestão da *supply chain*, destacando tanto as oportunidades como os desafios. Uma vez que a indústria de semicondutores enfrenta uma complexidade crescente com o avanço da tecnologia, as ferramentas de IA estão a tornar-se essenciais para manter um controlo preciso da produção. O paper salienta o valor da IA para permitir a tomada de decisões em tempo real em ambientes de produção inteligentes, o que é fundamental para aumentar a eficiência e a capacidade de resposta. Um desafio notável discutido é a necessidade de IA explicável (Explainable AI - XAI). Conseguir transparência e consistência na tomada de decisões com IA é essencial para criar confiança entre as partes interessadas, uma vez que os modelos explicáveis permitem que os decisores compreendam e confiem nas recomendações da IA. No entanto, a procura de explicabilidade pode, por vezes, afetar a qualidade dos resultados da IA, isso quando possível, exigindo um equilíbrio cuidadoso entre transparência e desempenho. Embora a IA ofereça soluções poderosas, o estudo aponta para áreas que requerem mais investigação e desenvolvimento, particularmente no que diz respeito ao reforço da transparência e fiabilidade dos sistemas de IA para promover uma adoção mais ampla na cadeia de fornecimento de semicondutores.

Existe uma necessidade crítica de que os modelos de IA sejam interpretáveis e justificáveis para serem úteis nos processos de tomada de decisões. Muitas aplicações atuais de IA não se concentram na interpretabilidade dos resultados, o que é essencial para obter informações e garantir

a aceitação de soluções baseadas em IA. Baryannis, Dani & Antoniou (2019) afirmam que a aplicação de técnicas interpretáveis acarreta uma perda de desempenho e precisão, pelo que um desafio relevante e uma barreira atual na implementação da IA nas cadeias de abastecimento é promover a confiança através de técnicas de IA interpretáveis que não prejudiquem as métricas de desempenho. Além disso, os desenvolvimentos na literatura baseiam-se frequentemente em *frameworks* e conjuntos de dados altamente teóricos. Estes podem não ter sido devidamente testados em fontes de grandes volumes de dados do mundo real (especialmente com dados desequilibrados ou em falta). Isto aponta para um desafio na reprodutibilidade dos resultados dos modelos e técnicas propostos para responder à necessidade de aplicações práticas em SCM.

A implementação de soluções de IA na otimização de *supply chains* enfrenta desafios significativos, incluindo investimentos iniciais substanciais e uma escassez de pessoal qualificado necessário para integrar sistemas complexos de IA nas funções organizacionais existentes. Os custos elevados para adaptação dos sistemas vigentes dissuadem muitas empresas, enquanto as preocupações com a privacidade e a partilha de dados complicam ainda mais a adoção. A necessidade de uma IA explicável é fundamental, uma vez que a transparência gera confiança entre as partes interessadas, mas a sua concretização pode, por vezes, comprometer seu desempenho. Além disso, as provas empíricas limitadas e as melhores práticas estabelecidas, em especial para a IA generativa, dificultam a integração efetiva. Para ultrapassar estas barreiras, é necessário um forte apoio da gestão, formação adequada dos funcionários e investigação orientada para aumentar a transparência, a fiabilidade e a aplicabilidade prática da IA em cenários reais das *supply chains*.

3. IA Aplicada num Processo de *Supply Chain*

Esta secção aborda a descrição do estudo de caso e a aplicação de uma tecnologia emergente de IA, e que tem por objetivo explorar o impacto e benefícios oriundos do uso de tal tecnologia. O foco desta abordagem está no emprego de inteligência artificial generativa para a automação de uma atividade que ocorre repetidamente na cadeia de trabalho na qual se pretende impactar.

Este estudo de caso se baseia numa atividade desenvolvida durante o estágio de inovação numa empresa de manufatura automobilística realizado pela autora deste trabalho o qual será descrito a seguir.

3.1 Estudo de Caso

A empresa está situada em Bragança, dedicada à fabricação de componentes metálicos e acessórios para a indústria automotiva. Como parte de um grupo internacional, ela destaca-se por sua capacidade de adaptação às exigências de mercados globais e pela busca constante de eficiência operacional e inovação nos seus processos produtivos. Sua atuação envolve, entre outros, o fornecimento de bens intermediários que dependem de uma logística ágil, segura e economicamente vantajosa para atender os padrões de competitividade do setor automotivo.

No panorama industrial contemporâneo, a administração dos recursos logísticos tornou-se cada vez mais desafiante. Entre as demandas rotineiras identificadas pela equipe gestora está a necessidade de transportar colaboradores entre diferentes instalações, realizar viagens técnicas, participar de reuniões externas e garantir a dinâmica da mobilidade interna sem comprometer a produtividade das operações. Para atender a estes requisitos, é frequentemente necessário recorrer ao aluguel de veículos, processo que exige tempo, precisão e coordenação eficiente.

O processo tradicional de pesquisa e reserva de veículos para aluguel, realizado de modo manual, demanda que cada colaborador ou gestor envolvido acesse múltiplos sites especializados, compare ofertas e condições, valide critérios específicos (como orçamento, número de passageiros, características das viagens, origem/destino e finalidade profissional), além de comunicar internamente todos os detalhes logísticos relativos à escolha do transporte. Essa multiplicidade de passos representa uma carga operacional relevante, especialmente em empresas do porte da médio-alto, onde o volume de deslocamentos pode ser significativo.

A elaboração do email informativo com os dados de reserva também integra a rotina logística, exigindo do gestor tempo para recolher informações, estruturar a mensagem e disseminar os dados para todos os envolvidos. Mesmo pequenas falhas de comunicação ou atrasos podem resultar em impactos financeiros, atrasos operacionais e insatisfação dos clientes internos.

Entre os principais desafios identificados nesta rotina está a otimização do tempo despendido em tarefas administrativas e a redução do risco de erros humanos, como a escolha inadequada de veículos, falhas na comunicação de dados essenciais, ou a omissão de informações logísticas relevantes. A inexistência de mecanismos sistematizados para pesquisa e divulgação das opções disponíveis prolonga o processo decisório e pode acarretar custos adicionais ou dificuldades inesperadas, como incompatibilidade entre o veículo selecionado e as necessidades específicas da viagem.

A problemática vivenciada pela empresa não está restrita à dimensão do tempo, refletindo-se também na comunicação interna e na previsibilidade das operações. O gerenciamento das viagens profissionais, sobretudo em ambientes de alta rotatividade e demandas variáveis, requer maior agilidade e padronização para alinhar expectativas, cumprir prazos e evitar desperdícios de recursos. Além disso, em setores industrializados como o automotivo, a complexidade logística tende a aumentar conforme se expandem as cadeias de valor e se multiplicam as interfaces entre fornecedores, transportadores e clientes finais. Enquanto operadoras integradas deste ecossistema, as empresas enfrentam o imperativo de evoluir continuamente suas práticas para sustentar sua posição competitiva e responder às pressões externas do mercado globalizado.

3.2 Desenvolvimento da Solução Utilizando a Ferramenta CrewAI

Escolheu-se este estudo de caso por ser uma abordagem prática e acessível tendo em vista as ferramentas disponíveis. Utilizou-se a linguagem de programação Python, ferramentas da OpenAI API (2024) e Serper API (2024), e a *framework* CrewAI (Moura (2024)). O Python é uma linguagem de fácil utilização, utilizando basicamente termos em inglês de fácil interpretação. Adicionalmente,

possui um vasto conteúdo de suporte na internet. As ferramentas utilizadas da OpenAI e Serper são chamadas de API (*Application Programming Interface*). Trata-se de uma forma de executar pesquisas sem a utilização de um browser. Por último, a *framework* CrewAI consiste numa plataforma que estrutura a criação de agentes que utilizam a IA generativa para a realização dessas buscas.

Optou-se por utilizar estas tecnologias por apresentarem um aspecto inovador fortemente relevante. Esta *framework* está em corrente desenvolvimento e vem atraindo muita atenção no setor de tecnologia da IA. Ela apresenta a possibilidade de realizar-se pesquisas com o suporte de IA, utilizando o poderio das chamadas *Large Language Models* (LLMs) e o conteúdo disponível na internet.

O problema a que se pretende receber suporte à tomada de decisão trata da reserva de automóveis para as atividades logísticas da companhia. A recorrente necessidade de se reservar carros para diferentes trajetos requer uma série de características para satisfazer a necessidade em vigor. A escolha do veículo adequado depende de fatores como budget, número de pessoas que vão viajar, origem, destino e duração da viagem. Esses fatores representam um série de critérios que devem ser considerados para a locação do veículo que devidamente satisfaça a requisição de viagem. Para tanto, as tecnologias escolhidas apresentam o valor de oferecer suporte a decisão levando em consideração os critérios descritos, e a informação disponível na internet para a execução da tarefa. A seguir, os passos para execução dessa abordagem serão descritos. Utilizou-se a ferramenta Jupyter Notebooks para a execução do código pretendido.

Inicialmente, executa-se a instalação da biblioteca programática que contém as ferramentas necessárias para a execução do código.

```
pip install crewai==0.28.8 crewai_tools==0.1.6 langchain_community==0.0.29
```

Ignora-se os *warnings* (avisos) em vista da *framework* estar em contínuo desenvolvimento.

```
import warnings  
warnings.filterwarnings('ignore')
```

Em seguida, importa-se a biblioteca programática relativa a *framework* CrewAI.

```
from crewai import Agent, Crew, Task
```

E por fim, importa-se as chaves que permitem a execução das pesquisas através das APIs. Ou seja, senhas que são obtidas somente após cadastros na plataforma e que identificam os usuários que as utilizam. Portanto, são senhas particulares a cada usuário. Foram utilizadas as chaves oferecidas pela plataforma DeepLearningAI (Ng (2024)).

```
import os

from utils import get_openai_api_key, get_serper_api_key

openai_api_key = get_openai_api_key()
os.environ["OPENAI_MODEL_NAME"] = 'gpt-3.5-turbo'
os.environ["SERPER_API_KEY"] = get_serper_api_key()
```

Todo o ocorrido até este instante trata da configuração do ambiente de programação. Daqui em diante, a solução programática será então abordada diretamente. No entanto, é necessário alguma contextualização. O CrewAI permite a criação dos chamados agentes de IA. Esses agentes entidades programáticas que possuem um papel, objetivo, utilizam ferramentas e possuem uma *backstory* definidos pelo designer do sistema. Os agentes então sabem a partir daí o que devem fazer através de sua *role* (papel) e *goal* (objetivo). A realizam através das *tools* (ferramentas) definidas, e utilizam a *backstory* (história de fundo) para integrarem-se ao devido contexto em que se inserem. Isso só é possível devido ao enorme poder cognitivo da IA generativa que é capaz de interpretar e assimilar textos de forma análoga a humana.

Neste próximo passo, são importadas as ferramentas predefinidas pela *framework*. Ambas são utilizadas para recuperar informações de websites.

```
from crewai_tools import ScrapeWebsiteTool, SerperDevTool

search_tool = SerperDevTool()
scrape_tool = ScrapeWebsiteTool()
```

Então, inicia-se a criação do primeiro agente no qual serão definidas as características anteriormente mencionadas. O texto descritivo que preenche a definição dessas características são de caráter pessoal e de experiência do designer. O importante é atentar-se a clareza e precisão dos textos redigidos. Este primeiro agente é responsável por encontrar os veículos disponíveis na internet para reserva. De forma a enriquecer o contexto no qual os agentes desenvolverão seus papéis, a história de fundo é escrita de forma concisa e objetiva, sendo o inglês a língua preferida.

```
rental_coordinator = Agent(
    role="Rental Coordinator",
    goal="Identify appropriate rental cars "
        "based on trip requirements.",
    tools=[search_tool, scrape_tool],
```

```

verbose=True,
backstory=(
    "With a keen eye for detail "
    "and cost efficiency, "
    "you excel at finding and "
    "securing the best rental cars "
    "that meet the company's travel "
    "needs and budget constraints."
)
)

```

O mesmo ocorre para o gerente de logística. A criação deste segundo agente tem por objetivo o desenvolvimento de tarefas paralelas durante o exercício de busca pelo veículo a reservar. Essa característica denominada Multi-Agente tem a mais valia de desenvolver tarefas que agregam valor ao objetivo almejado de forma paralela, ou seja, de forma a realizar tarefas complementares que aumentam a qualidade do resultado final se comparado a apenas um agente. Porém, a definição das tarefas será contemplada mais a frente. Este passo trata apenas da definição dos agentes. O gestor de logística será responsável por determinar o plano de rota incluindo considerações sobre o tempo de viagem e a inclusão de detalhes que sejam relevantes.

```

logistics_manager = Agent(
    role='Logistics Manager',
    goal=(
        "Manage all logistics for the trip "
        "including scheduling and route planning."
    ),
    tools=[search_tool, scrape_tool],
    verbose=True,
    backstory=(
        "Organized and detail-oriented, "
        "you ensure that every logistical aspect of the trip "
        "from scheduling to route optimization "
        "are flawlessly executed to create a seamless experience."
    )
)

```

```
)
)
```

Por último, foi definido o agente de comunicação. Esse agente é responsável por gerar um relatório a fim de ser utilizado para comunicar os trabalhadores envolvidos na viagem. Este terceiro agente resume as informações acerca do itinerário, duração da viagem e os detalhes relevantes.

```
communications_agent = Agent(
    role='Communications Agent',
    goal=(
        "Effectively communicate travel plans to employees."
    ),
    tools=[search_tool, scrape_tool],
    verbose=True,
    backstory=(
        "Clear and communicative, you ensure "
        "that all employees are informed "
        "about their travel arrangements "
        "and are prepared for their work trips."
    )
)
```

Um diagrama representando a interação entre os agentes é exibido na Figura 5.

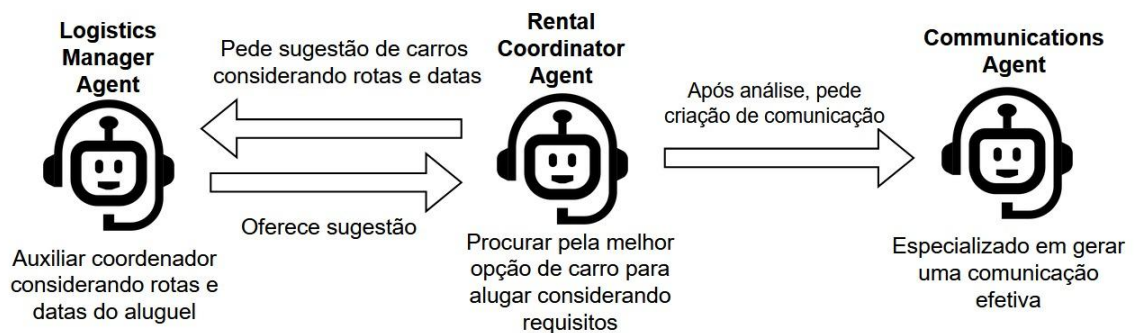


Figura 5: Diagrama de interação entre os agentes.

Esta etapa consiste na definição das características importantes relativamente a reserva. Nomeadamente, a empresa de reservas, o modelo do carro, o website da empresa, o local de coleta do veículo, e a datas de toma e devolução do veículo.

```
from pydantic import BaseModel
```

```
class RentalDetails(BaseModel):
```

```
    rental_company: str
```

```
    car_model: str
```

```
    website: str
```

```
    pickup_location: str
```

```
    start_date: str
```

```
    end_date: str
```

Em “rental_task”, a tarefa a ser realizada pelo agente que coordena a reserva é descrita. Entre os dados relevantes incluídos na descrição da tarefa estão o destino e origem da viagem, o número de passageiros que o carro irá levar, e o tipo de viagem para proporcionar o devido escopo e contexto o sistema cognitivo que irá interpretar e dar vida ao agente. O resultado esperado dessa tarefa é um arquivo comumente usado no mundo da programação chamado JavaScript Object Notation (JSON) que servirá para salvar as informações que o sistema foi capaz de obter acerca do veículo sugerido.

```
rental_task = Task(  
    description="Find a vehicle in {start_city} "  
                "that meets criteria to arrive in {end_city} "  
                "from a {start_date} to {end_date} "  
                "with {number_of_passengers} passengers "  
                "for a given {type_of_trip} type of trip.",  
    expected_output="All the details of a specifically chosen "  
                    "vehicle you found to accommodate the trip.",  
    human_input=True,  
    output_json=RentalDetails,  
    output_file="rental_details.json",
```

```

    agent=rental_coordinator
)

```

Em seguida, a tarefa do gestor de logística que consiste em sugerir uma rota de viagem analisando a cidade de partida e de destino e o tipo de viagem pretendida. Observa-se que apesar de haver o "type_of_trip", por ser o objetivo deste trabalho uma viagem exclusiva a trabalho, reforçou-se isso ao fim com o termo "and for work purposes". Isto ocorreu porque durante o processo de testes, o resultado inicialmente apresentado pelo LLM não foi satisfatório. Foi comum a sugestão de trajetos que incluíam aspectos turísticos. Ao tornar o motivo da viagem mais explícito, o resultado recebido foi aprimorado. Porém, observa-se que tal comportamento é oriundo da LLM. Os modelos de linguagem que são os sistemas cognitivos desta atividade são tanto os fatores propulsores quanto limitantes. Como denotado na quarta célula, o modelo utilizado é o GPT 3.5 Turbo.

```

logistics_task = Task(
    description="Coordinate rental for the trip "
               "from {start_date} to {end_date} "
               "for a given {type_of_trip} type of trip"
               "exclusively done by car "
               "and for work purposes.",
    expected_output="Suggest the best route considering "
                   "the {start_city} and the {end_city}.",
    human_input=True,
    async_execution=True,
    agent=logistics_manager
)

```

Na tarefa de comunicação o objetivo é gerar um relatório que auxilie a comunicação de detalhes pertinentes aos trabalhadores que irão viajar. É esperado um relatório no formato *Markdown* para que facilite a leitura.

```

communications_task = Task(
    description="Communicate travel plans to the employees, "
               "ensuring they are aware "

```

```

        "of their itineraries for the {type_of_trip} "
        "following the Rental Coordinator choice.",
    expected_output="Report on communication activities "
        "and employee acknowledgments "
        "following exclusively the "
        "final output of the Rental Coordinator "
        ", and the report is "
        "formatted as markdown.",
    output_file="communications_report.md",
    agent=communications_agent
)

```

Nesta etapa, a definição da *crew* (equipa) é realizada. O coordenador de reserva, o gestor de logística e o agente de comunicação e suas tarefas são descritas como parte de uma equipa que irá cooperar para a realização da atividade. O termo "verbose = True" significa que texto acerca do processo de raciocínio do LLM é explicitado.

```

rental_management_crew = Crew(
    agents=[rental_coordinator,
            logistics_manager,
            communications_agent],

    tasks=[rental_task,
            logistics_task,
            communications_task],

    verbose=True
)

```

O "event_details" contém os detalhes importantes a serem considerados pelos agentes.

```
event_details = {  
    'type_of_trip': "Work trip",  
    'start_city': "Porto Airport Francisco Sá Carneiro, Portugal",  
    'end_city': "Mós, Bragança, Portugal",  
    'start_date': "2024-10-28",  
    'end_date': "2024-10-30",  
    'number_of_passengers': 4  
}
```

Em "result", os dados são alimentados aos agentes e o processo de raciocínio é iniciado.

```
result = rental_management_crew.kickoff(inputs=event_details)
```

O resultado apresentado foi de um carro encontrado numa plataforma de reserva. O carro apresentado de fato existe e apresenta um valor interessante (22 euros por dia). O raciocínio apresentado pelo sistema é apresentado abaixo:

```
[INFO]: == Starting Task: Find a vehicle in Porto Airport Francisco Sá  
Carneiro, Portugal that meets criteria to arrive in Mós, Bragança, Portugal  
from a 2024-10-28 to 2024-10-30 with 4 passengers for a given Work trip  
type of trip.
```

```
> Entering new CrewAgentExecutor chain...
```

```
Thought: To find a suitable rental car that meets the specified criteria,  
I need to first identify car rental options available at Porto Airport  
Francisco Sá Carneiro for the specified dates and suitable for a work trip  
with 4 passengers.
```

```
Action: Search the internet
```

Action Input: {"search_query": "car rental options Porto Airport Francisco Sá Carneiro available from 2024-10-28 to 2024-10-30 for 4 passengers"}

[...]

This is the agent final answer: For the work trip from Porto Airport Francisco Sá Carneiro to Mós, Bragança, Portugal from 2024-10-28 to 2024-10-30 for 4 passengers, the suitable vehicle is a Volkswagen Golf or similar medium car. It is available for rental at a price of \$38.26 for the 2-day duration. This vehicle meets the criteria for accommodating 4 passengers comfortably and falls within a reasonable cost range. The rental can be picked up and returned at Francisco Sá Carneiro Airport.

[INFO]: == Starting Task: Communicate travel plans to the employees, ensuring they are aware of their itineraries for the Work trip following the Rental Coordinator choice.

> Entering new CrewAgentExecutor chain...

> Entering new CrewAgentExecutor chain...

Thought: To start planning the logistics for the trip, I need to establish the best route from Porto Airport Francisco Sá Carneiro to Mós, Bragança, considering we are using a Volkswagen Golf or a similar car model. First, I should find a suitable route that optimizes travel time and distance for the dates specified.

Action: Search the internet

Action Input: {"search_query": "best driving route from Porto Airport Francisco Sá Carneiro to Mós, Bragança"}

Thought: To effectively communicate the travel plans to employees, I first need to gather all necessary information about the car rental arrangements made by the Rental Coordinator, including any updates or confirmations.

Action: Ask question to co-worker

Action Input: {"coworker": "Rental Coordinator", "question": "Can you provide me with the latest update on the car rental arrangements for the upcoming work trip?", "context": "We need to inform our employees about their travel plans. The rental is supposed to be a Volkswagen Golf or similar, picked up at Francisco Sá Carneiro Airport, from October 28, 2024, to October 30, 2024. The rental company and specific website details are undisclosed."}

> Entering new CrewAgentExecutor chain...

[...]

Thought: The website content requires JavaScript and cookies which I cannot interact with. To proceed, I'll select a different link from the search results that may provide the necessary information about the driving route from Porto Airport to Mós, Bragança. The ViaMichelin website often provides detailed driving routes including distance, cost, and time estimates, which could be useful for planning the trip.

Action: Read website content

Action Input: {"website_url": "https://www.viamichelin.com/routes/results/braganca-5300-braganca-continental_portugal-portugal-to-porto-4000-porto-continental_portugal-portugal"}

[...]

Thought: I now know the final answer

Final Answer: The car rental arrangements for the upcoming work trip at Francisco Sá Carneiro Airport are as follows:

- Rental Car Option: Volkswagen Golf or similar medium car
- Pick-up and Drop-off Location: Francisco Sá Carneiro Airport
- Rental Duration: October 28, 2024, to October 30, 2024
- Price for 2 days: Approximately \$38.26

This information was obtained from Booking.com, which provides a range of rental options from various companies at the airport. Please ensure to make your booking as soon as possible to secure these rates and availability.

> Finished chain.

The car rental arrangements for the upcoming work trip at Francisco Sá Carneiro Airport are as follows:

- Rental Car Option: Volkswagen Golf or similar medium car
- Pick-up and Drop-off Location: Francisco Sá Carneiro Airport
- Rental Duration: October 28, 2024, to October 30, 2024
- Price for 2 days: Approximately \$38.26

This information was obtained from Booking.com, which provides a range of rental options from various companies at the airport. Please ensure to make your booking as soon as possible to secure these rates and availability.

Thought: Now that I have the details about the car rental arrangements, I need to create a clear and detailed communication to send to all employees

involved in the work trip, ensuring they understand the specifics of their travel arrangements.

Final Answer:

Subject: Upcoming Work Trip - Car Rental Details

Dear Team,

As part of your upcoming work trip scheduled from October 28, 2024, to October 30, 2024, we have arranged for your transportation needs during your stay. Below are the details of the car rental:

- Vehicle Type: Volkswagen Golf or similar medium car
- Pick-up and Drop-off Location: Francisco Sá Carneiro Airport
- Rental Period: October 28, 2024, to October 30, 2024
- Estimated Cost: \$38.26 for 2 days

The reservation has been sourced through Booking.com, which offers a variety of rental options. We advise you to confirm your booking promptly to secure these rates and ensure availability.

Please ensure that you have your driver's license and any necessary documents ready for the car rental. Should you have any questions or require further assistance, feel free to reach out.

Safe travels and have a productive trip!

Best Regards,

[Your Name]

[Your Position]

[...]

This is the agent final answer: The best driving route from Porto Airport Francisco Sá Carneiro to Mós, Bragança, as provided by ViaMichelin, includes comprehensive details on the journey, distance, time, and costs. Here's a summary of the key information:

1. **Route Description**: The route from Porto to Bragança is well-detailed with options for the fastest, cheapest, and shortest paths. Depending on traffic conditions, different routes might be optimal.
2. **Distance and Time**: The exact distance and estimated travel time can vary based on the selected route and current traffic conditions. ViaMichelin provides real-time updates to ensure the most accurate planning.
3. **Costs**: The route's cost includes toll charges and fuel costs, which are calculated based on the type of vehicle used (in this case, a Volkswagen Golf or similar). Detailed cost breakdowns are available, which can be adjusted based on the number of passengers to aid in carpooling scenarios.
4. **Navigation and Guidance**: ViaMichelin offers GPS navigation with voice guidance, which can be accessed via their mobile app. This feature will assist in real-time during the journey from Porto to Mós, Bragança.

This route plan should ensure a seamless and efficient driving experience from Porto Airport Francisco Sá Carneiro to Mós, Bragança, tailored to the specifics of the trip and the vehicle used.

Please provide a feedback: ok

Thought: After receiving feedback indicating that a re-evaluation is required, I should ensure that my final answer provides the complete and detailed content requested, specifically focusing on the driving directions, costs, and logistics aspects detailed in the ViaMichelin content.

Final Answer: The best driving route from Porto Airport Francisco Sá Carneiro to Mós, Bragança, as detailed by ViaMichelin, includes the following information:

- **Journey Details**: The route calculation from Bragança to Porto by car or motorbike can be tailored based on the route selected, offering options for the fastest, cheapest, or shortest journey. ViaMichelin provides real-time traffic impact assessments to adjust the estimated travel time accordingly.

- **Distance and Costs**: The exact distance between Bragança and Porto varies based on the selected route. The platform also calculates the cost of the journey, which includes toll charges and fuel costs. These costs are detailed on both motorways and other roads, and the breakdown can be adjusted according to the number of travelers, which is useful for carpooling.

- **Navigation Assistance**: ViaMichelin offers GPS navigation with voice guidance through its mobile apps, facilitating real-time directions during travel.

- **Additional Features**: The ViaMichelin platform also allows users to view detailed maps of both Bragança and Porto, find MICHELIN Guide listed restaurants along the route, and even book accommodations directly through their partnership with Booking.com, with no additional cost for booking through ViaMichelin.

- **Customization and Planning**: Users can calculate their route from Bragança to Porto with options to customize the journey according to their preferences for speed, cost, or distance. The "Detailed trip cost" feature provides a tailored summary of expenses, including fuel and tolls, which can be adapted for different numbers of passengers.

This detailed route planning from ViaMichelin ensures that travelers from Porto Airport Francisco Sá Carneiro to Mós, Bragança have a well-informed, cost-effective, and convenient journey, taking into account various travel preferences and real-time road conditions.

> Finished chain.

Na próxima célula o resultado no formato JSON é apresentado.

```
import json
from pprint import pprint

with open('rental_details.json') as f:
    data = json.load(f)

pprint(data)

{
  'car_model': 'Volkswagen Golf or similar',
  'end_date': '2024-10-30',
```

```

'pickup_location': 'Francisco Sá Carneiro Airport',
'rental_company': 'undisclosed',
'start_date': '2024-10-28',
'website': 'https://cars.booking.com/search-
results?aid=2311236&coordinates=41.236698150634766%2C-
8.670960426330566&cor=pt&doDay=30&doHour=10&doMinute=0&doMonth=11&doYear
=2024&driversAge=30&dropCoordinates=41.236698150634766%2C-
8.670960426330566&dropFtsType=A&dropLocation=&dropLocationIata=OP0&dropL
ocationName=Aeroporto%20Francisco%20S%C3%A1%20Carneiro&ftsType=A&label=-
8UhDNI81QHWMfAOWyJjXywS652804039142%3Ap1%3Ata%3Ap1%3Ap2%3Ac%3Ap%3Aneg%
3Afi%3Atikwd-
17380633801%3Alp9051350%3Ali%3Adec%3Adm&location=&locationIata=OP0&locat
ionName=Aeroporto%20Francisco%20S%C3%A1%20Carneiro&prefcurrency=EUR&pref
lang=br&puDay=28&puHour=10&puMinute=0&puMonth=11&puYear=2024 '
}

```

Por fim, o texto referente ao resultado pelos agentes é apresentado no formato *Markdown* (Figura 6) para leitura no Jupyter Notebook e o resultado encontrado no “Booking.com” (Figura 7).

```

from IPython.display import Markdown

Markdown("communications_report.md")

```

Subject: Upcoming Work Trip - Car Rental Details

Dear Team,

As part of your upcoming work trip scheduled from **October 28, 2024, to October 30, 2024**, we have arranged for your transportation needs during your stay. Below are the details of the car rental:

- **Vehicle Type:** Volkswagen Golf or similar medium car
- **Pick-up and Drop-off Location:** Francisco Sá Carneiro Airport
- **Rental Period:** October 28, 2024, to October 30, 2024
- **Estimated Cost:** \$38.26 for 2 days

The reservation has been sourced through **Booking.com**, which offers a variety of rental options. We advise you to confirm your booking promptly to secure these rates and ensure availability.

Please ensure that you have your driver's license and any necessary documents ready for the car rental. Should you have any questions or require further assistance, feel free to reach out.

Safe travels and have a productive trip!


Best Regards,

[Your Name]
[Your Position]

Figura 6: Resultado em *Markdown*.

Desconto de 15% aplicado

Kia Ceed Estate ou carro familiar similar



- 5 lugares
- 1 mala grande
- Quilometragem ilimitada


- Manual
- 1 mala pequena

Preço por 2 dias: ~~€ 27~~ **€ 23**

Cancelamento grátis


Aeroporto de Porto
Transfer

[Ver oferta](#)

 **7.5** Bom
3000+ avaliações

[Informações importantes](#) [Enviar orçamento](#)

Fiat 500 Cabrio ou carro premium similar



- 4 lugares
- 1 mala grande
- Quilometragem ilimitada


- Manual
- 2 Malas pequena

Preço por 2 dias: **€ 24**

Cancelamento grátis

Aeroporto de Porto
Transfer


[Ver oferta](#)

 **7.9** Bom
2000+ avaliações

[Informações importantes](#) [Enviar orçamento](#)

Desconto de 15% aplicado

Volkswagen Golf ou carro médio similar



- 5 lugares
- 1 mala grande
- Quilometragem ilimitada


- Manual
- 1 mala pequena

Preço por 2 dias: ~~€ 26~~ **€ 22**

Cancelamento grátis


Aeroporto de Porto
Transfer

[Ver oferta](#)

 **7.5** Bom
3000+ avaliações

[Informações importantes](#) [Enviar orçamento](#)

Ford Focus ou carro médio similar



- 5 lugares
- 1 mala grande
- Quilometragem ilimitada


- Manual
- 1 mala pequena

Preço por 2 dias: **€ 24**

Cancelamento grátis

Aeroporto de Porto
Transfer


[Ver oferta](#)

 **8.1** Muito bom
400+ avaliações

[Informações importantes](#) [Enviar orçamento](#)

Desconto de 15% aplicado

Volkswagen T-Roc ou SUV similar



- 5 lugares
- 1 mala grande
- Quilometragem ilimitada


- Automático
- 1 mala pequena

Preço por 2 dias: ~~€ 32~~ **€ 27**

Cancelamento grátis

Aeroporto de Porto
Transfer

[Ver oferta](#)

 **7.5** Bom
3000+ avaliações

[Informações importantes](#) [Enviar orçamento](#)

Figura 7: Veículo relativo ao resultado do experimento.

A seguir, o texto referido em *Markdown*:

"Subject: Upcoming Work Trip - Car Rental Details

Dear Team,

As part of your upcoming work trip scheduled from October 28, 2024, to October 30, 2024, we have arranged for your transportation needs during your stay. Below are the details of the car rental:

Vehicle Type: Volkswagen Golf or similar medium car

Pick-up and Drop-off Location: Francisco Sá Carneiro Airport

Rental Period: October 28, 2024, to October 30, 2024

Estimated Cost: \ \$38.26 for 2 days

The reservation has been sourced through Booking.com, which offers a variety of rental options. We advise you to confirm your booking promptly to secure these rates and ensure availability.

Please ensure that you have your driver's license and any necessary documents ready for the car rental. Should you have any questions or require further assistance, feel free to reach out.

Safe travels and have a productive trip!

Best Regards,

[Your Name]

[Your Position]"

Percebe-se que o valor estimado referente a reserva para dois dias como estipulado não faz sentido. O valor por dia encontrado é equivalente a 22 euros, logo era esperado 44 euros. Este valor de 38,26 aparenta ser o que é definido como alucinação. O sistema atualmente não é capaz de efetivamente trabalhar com números de maneira satisfatória, e por tanto é importante ter atenção a esse fato e manter-se um grau de confiança equilibrado principalmente no que se relaciona a números. Apesar disso, os resultados retornados apresentam um nível satisfatório com relação a existência da recomendação proferida pelo sistema.

3.3 Parecer e Comparação ao Processo Manual

O experimento realizado demonstra tanto o potencial promissor quanto as limitações atuais da aplicação da IA generativa. O uso da IA nessa abordagem agêntica, com o auxílio de LLMs, demonstra a capacidade de interpretar requisitos, interagir com a Internet e produzir resultados em uma tarefa cognitiva, imitando o comportamento humano. Isso indica que a IA generativa pode automatizar significativamente as tarefas repetitivas, apoiar a tomada de decisões e melhorar a eficiência operacional.

No entanto, o experimento também destaca um desafio crítico que afeta a confiança humana na IA generativa: a questão da precisão, especialmente com dados numéricos. O sistema de IA forneceu um custo de aluguel estimado de 38,26 euros para um aluguel de carro de dois dias, enquanto o

valor esperado deveria ter sido de 44 euros com base na tarifa diária de 22 euros. Essa discrepância, conhecida como uma “alucinação” da IA, revela que, embora a IA possa gerar informações plausíveis, ela nem sempre produz dados precisos ou confiáveis, especialmente quando são necessários cálculos.

Manter um nível de intervenção humana, especialmente em pontos críticos de decisão, é fundamental para a aprovação adequada das recomendações geradas pela IA. Essa abordagem híbrida aproveita os pontos fortes da IA e do julgamento humano. Aumentar a capacidade do sistema de IA de explicar seu raciocínio e suas fontes de dados melhora a transparência e a confiança, como podemos ver nas explicações de pensamentos fornecidas pelo próprio sistema neste experimento. No entanto, uma explicação mais detalhada sobre como as conclusões são alcançadas é essencial para realmente alavancar a confiança dos utilizadores.

A identificação destes obstáculos e a análise do contexto operacional demonstram que existe potencial para reestruturação da forma como as tarefas de pesquisa, reserva e comunicação logística são conduzidas. A expectativa reside na elaboração de novos métodos que permitam superar as limitações observadas, minimizar o esforço humano envolvido e aprimorar os indicadores de desempenho da organização no âmbito das viagens técnicas e do transporte corporativo.

Outro aspecto que exige atenção surge da dependência das informações hospedadas abertamente na internet. Ainda que a procura por veículos automóveis de passeio seja facilitada pela existência de múltiplas plataformas e bases de dados públicas, tal comodidade não se verifica em segmentos como o aluguel de camiões ou outros veículos especializados, cujas ofertas são dispersas ou inexistentes nos canais tradicionais. Esse fator limita a eficiência das práticas logísticas, expondo a empresa ao risco de indisponibilidade de soluções rápidas em situações críticas.

Conclusões, Limitações e Futuras Linhas de Investigação

A IA está reformulando a forma como as empresas gerenciam suas *supply chains*, tornando-as mais inteligentes, mais eficientes e melhores para o meio ambiente. Quando surgem problemas - seja uma remessa atrasada ou uma mudança repentina na procura - a IA atua como um sistema de alerta. Ela identifica possíveis problemas antes que eles se tornem grandes problemas e sugere maneiras de contorná-los. É semelhante a ter um gerente altamente experiente que pode identificar tendências e tomar decisões rápidas, mas que pode processar grandes quantidades de informações 24 horas por dia. Sua integração às *supply chains* mostrou benefícios substanciais na melhoria da eficiência, no aumento da resiliência e na promoção da sustentabilidade, mas também revelou vários desafios de implementação.

As aplicações de IA, em particular as técnicas de ML, melhoram significativamente a eficiência e reduzem os custos operacionais na gestão da *supply chain* quando devidamente introduzida e incorporada. A análise preditiva com recurso à IA permite às organizações prever com precisão a procura futura, possibilitando um planeamento e uma otimização proativos. Outras técnicas de IA

melhoraram as previsões de viabilidade da produção e a gestão de estoques, reduzindo as ineficiências. Os sistemas orientados para a IA otimizam os níveis de inventário, reduzem os encargos com a tomada de decisões e melhoram atividades essenciais como a coordenação de tarefas e as negociações com fornecedores. A manutenção preditiva com recurso à IA minimiza o tempo de inatividade e prolonga a vida útil das máquinas. Nos processos de logística e de entrada, os algoritmos de ML automatizam tarefas e analisam grandes conjuntos de dados, levando a reduções de custos e a operações mais eficientes.

Na resiliência e na gestão de riscos, a IA tem vindo a melhorar a previsão da procura, a otimizar a utilização de recursos e a antecipar potenciais perturbações. As ferramentas de gestão de riscos baseadas em IA, integradas em simulações, têm permitido a identificação proativa e a priorização de riscos, reforçando as redes da cadeia de abastecimento. Essas aplicações apoiam uma melhor seleção de fornecedores e melhoram a manutenção preditiva para reduzir o tempo de inatividade, permitindo que as organizações se adaptem às flutuações do mercado e mantenham o desempenho operacional durante as perturbações.

Além disso, a integração da IA nos processos da *supply chain* afetou positivamente a sustentabilidade e os resultados ambientais através da otimização das operações para reduzir as emissões de carbono e o consumo de recursos. Combinada com a análise de grandes volumes de dados, a IA tem sido capaz de monitorizar em tempo real a utilização de energia, as emissões, a produção de resíduos e os fluxos de materiais, identificando assim ineficiências e apoiando correções para reduzir o impacto ambiental do setor da produção. Os algoritmos de otimização baseados em IA são capazes de ajustar as capacidades de produção e as rotas de transporte, contribuindo para aumentar a eficiência operacional e reduzir o impacto ambiental. Por fim, a utilização da IA na aquisição ecológica e na gestão de resíduos apoia a transição para uma economia circular, promovendo o aprovisionamento e as operações ambientalmente responsáveis.

No entanto, a implementação de soluções de IA na otimização da cadeia de abastecimento enfrenta desafios significativos. Os elevados investimentos iniciais e a falta de pessoal qualificado são considerados os principais obstáculos. A integração de sistemas complexos de IA com as funções organizacionais existentes requer competências especializadas, que muitas empresas não possuem. As preocupações com a privacidade dos dados e a complexidade do tratamento de grandes conjuntos de dados aumentam as dificuldades. Conseguir uma IA explicável é outro ponto crítico que é essencial para criar confiança entre os stakeholders, alavancando assim a adoção de tecnologias de IA nos processos das *supply chains*. É importante garantir que as decisões da IA façam sentido para todos os envolvidos - ninguém quer confiar numa *black box* para tomar decisões importantes. No entanto, a procura de transparência pode, por vezes, comprometer seu desempenho. As provas empíricas limitadas e as melhores práticas estabelecidas, especialmente para tecnologias como a IA generativa, tornam a integração efetiva um desafio. Para ultrapassar estes obstáculos, é necessário um forte apoio da gestão, formação adequada dos funcionários e investigação orientada para aumentar a transparência, a fiabilidade e a aplicabilidade prática da IA em cenários de *supply chain*.

Para aproveitar todos os benefícios da IA generativa, as organizações devem começar com aplicações de baixo risco, implantando a IA em áreas em que os erros têm impacto mínimo, e passar gradualmente para operações mais críticas à medida que o sistema se mostrar confiável. O foco na inteligência colaborativa, usando a IA para aumentar as capacidades humanas em vez de substituí-las, incentiva a colaboração entre os sistemas de IA e os trabalhadores para melhorar os processos de *supply chain*. O experimento realizado neste trabalho demonstra o potencial das tecnologias de IA para aprimorar os recursos de automação, permitindo um desempenho cooperativo que simula o trabalho em equipe humano. Porém, a confiança humana na IA generativa é um fator essencial para sua adoção bem-sucedida.

Em conclusão, a integração da IA generativa nas operações da *supply chain* é uma promessa significativa para aumentar a eficiência, reduzir o desperdício de tempo em tarefas repetitivas e apoiar a tomada de decisões. No entanto, para aproveitar plenamente esses benefícios, é essencial abordar os desafios e as limitações dessas tecnologias. Apesar desses desafios, a IA representa uma ferramenta poderosa para modernizar as *supply chains*. Com planejamento e comprometimento adequados, as empresas podem usar a IA para se manterem competitivas e, ao mesmo tempo, tornarem-se mais eficientes e ambientalmente responsáveis. Não se trata de substituir os tomadores de decisão humanos, mas sim de dar a eles ferramentas melhores para fazer escolhas mais inteligentes.

Como trabalho futuro, será fundamental aprofundar a investigação sobre a adoção de IA nas cadeias de abastecimento, de modo a assegurar que a transformação tecnológica contribua não apenas para a competitividade, mas também para a responsabilidade corporativa, ou seja, políticas que promovam o uso da IA no ambiente de trabalho de forma ética e que se atente ao bem-estar do trabalhador. E do ponto de vista prático, a utilização das LLMs de forma local com o objetivo de utilizar-se dados empresariais que não estão e nem podem estar disponíveis na Internet. O emprego dessas tecnologias de forma desligada da internet demanda conhecimento técnico altamente elevado. Com a popularização dessas tecnologias, o emprego de IA poderá ser mais alargado para utilizadores que não detenham tanto conhecimento específico da área tecnológica.

A programação não é a minha área de formação. O processo de desenvolvimento deste trabalho deu-se por meio de aprendizado online gratuito. Minha formação é na área de Administração, porém sou entusiasta das tecnologias que possuem potencial para revolucionar a Gestão de Empresas, área na qual atuo e que tem muito a ganhar com os avanços proporcionados pela IA.

Referências Bibliográficas

- Albadrani, A., Zohdy, M. A. & Olawoyin R. (2020). "An Approach to Optimize Future Inbound Logistics Processes Using Machine Learning Algorithms". Em: 2020 IEEE International Conference on Electro Information Technology (EIT), pp. 402–406. doi: 10.1109/EIT48999.2020.9208238.
- Al-Khatib, A. W., Al-Shboul, M. A. & Khattab, M. (2024). "How can generative artificial intelligence improve digital supply chain performance in manufacturing firms? Analyzing the mediating role of innovation ambidexterity using hybrid analysis through CB-SEM and PLS-SEM". Em: *Technology in Society* 78, p. 102676. issn: 0160-791X. doi: <https://doi.org/10.1016/j.techsoc.2024.102676>. url: <https://www.sciencedirect.com/science/article/pii/S0160791X24002240>.
- Anand, M. C. J., Moorthy, C. B., Sivamani, S., Indrakumar, S., Kalairasi, K. & Barhoi, A. (2023). "Fuzzy Intelligence Inventory Decision Optimization Model of Sustainability and Green Technologies for Mixed Uncertainties of Carbon Emission". Em: 2023 International Conference on Information Management (ICIM), pp. 78–82. doi: 10.1109/ICIM58774.2023.00020.
- ASReview LAB developers (2024). ASReview LAB - A tool for AI-assisted systematic reviews. Versão v1.6.3. doi: 10.5281/zenodo.13629181. url: <https://doi.org/10.5281/zenodo.13629181>.
- Baryannis, G., Dani, S., & Antoniou, G. (2019). "Predicting supply chain risks using machine learning: The trade-off between performance and interpretability". Em: *Future Generation Computer Systems* 101, pp. 993–1004. issn: 0167-739X. doi: <https://doi.org/10.1016/j.future.2019.07.059>. url: <https://www.sciencedirect.com/science/article/pii/S0167739X19308003>.
- Bedi, P., Upreti, K., Rajawat, A. S., Shaw, R. N. & Ghosh, A. (2021). "Impact Analysis of Industry 4.0 on Realtime Smart Production Planning and Supply Chain Management". Em: 2021 IEEE 4th International Conference on Computing, Power and Communication Technologies (GUCON), pp. 1–6. doi: 10.1109/GUCON50781.2021.9573563.
- Bhosekar, A. & Ierapetritou, M. (2021). "A framework for supply chain optimization for modular manufacturing with production feasibility analysis". Em: *Computers & Chemical Engineering* 145, p. 107175. issn: 0098-1354. doi: <https://doi.org/10.1016/j.compchemeng.2020.107175>. url: <https://www.sciencedirect.com/science/article/pii/S0098135420306621>.
- Bruin, J. (2024). ASReview LAB Documentation. url: <https://asreview.readthedocs.io/en/stable/index.html> (acedido em 30/08/2024).
- Camur, M. C., Ravi, S. K. & Saleh, S. (2024). "Enhancing supply chain resilience: A machine learning approach for predicting product availability dates under disruption". Em: *Expert Systems with Applications* 247, p. 123226. issn: 09574174. doi:

- <https://doi.org/10.1016/j.eswa.2024.123226>. url: <https://www.sciencedirect.com/science/article/pii/S0957417424000915>.
- Cavalcante, I. M., Frazzon, E. M., Forcellini, F. A. & Ivanov D. (2019). "A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing". Em: *International Journal of Information Management* 49, pp. 86–97. issn: 0268-4012. doi: <https://doi.org/10.1016/j.ijinfomgt.2019.03.004>. url: <https://www.sciencedirect.com/science/article/pii/S0268401219301422>.
- Chari, A., Marti, S., Johansson, B., Despeisse, M., Stahre, J. & Lopes, P. V. (2023). "Modeling Risk Prioritization of a Manufacturing Supply Chain using Discrete Event Simulation". Em: *2023 Winter Simulation Conference (WSC)*, pp. 2064–2075. doi: 10.1109/WSC60868.2023.10407643.
- Chien, C., Hans Ehm, J. W. F., Kempf, K. G., Mönch, L. & Wu, C. (2023). "Production-Level Artificial Intelligence Applications in Semiconductor Supply Chains". Em: *IEEE Transactions on Semiconductor Manufacturing* 36.4, pp. 560–569. doi: 10.1109/TSM.2023.3322142.
- Chopra, S. & Meindl, P. (2016). *Supply Chain Management: Strategy, Planning, and Operation*. England: Pearson.
- Fu, W. & Chien, C. (2019). "UNISON data-driven intermittent demand forecast framework to empower supply chain resilience and an empirical study in electronics distribution". Em: *Computers & Industrial Engineering* 135, pp. 940–949. issn: 03608352. doi: <https://doi.org/10.1016/j.cie.2019.07.002>. url: <https://www.sciencedirect.com/science/article/pii/S0360835219303936>.
- Gaurav, R. L. (2023). "The Impact of Machine Learning on Supply Chain Management in Relation with Mass Production for Society". Em: *2023 First International Conference on Advances in Electrical, Electronics and Computational Intelligence (ICAEECI)*, pp. 1–4. doi: 10.1109/ICAEECI58247.2023.10370785.
- Ghabak, V. & Seetharaman, A. (2023). "Integration of Machine Learning in Agile Supply Chain Management". Em: *2023 15th International Conference on Computer and Automation Engineering (ICCAE)*, pp. 6–12. doi: 10.1109/ICCAE56788.2023.10111340.
- Hala, H., Anass, C. & Youssef, B. (2022). "Machine Learning For the Future Integration of the Circular Economy in Waste Transportation and Treatment Supply Chain". Em: *IFAC-PapersOnLine* 55.10. 10th IFAC Conference on Manufacturing Modelling, Management and Control MIM 2022, pp. 49–54. issn: 2405-8963. doi: <https://doi.org/10.1016/j.ifacol.2022.09.366>. url: <https://www.sciencedirect.com/science/article/pii/S2405896322016342>.
- Haleem, A., Javaid, M., Singh, R. P., Suman, R. & Khan, S. (2023). "Management 4.0: Concept, applications and advancements". Em: *Sustainable Operations and Computers* 4, pp. 10–21. issn: 2666-4127. doi: <https://doi.org/10.1016/j.susoc.2022.10.002>. url: <https://www.sciencedirect.com/science/article/pii/S2666412722000277>.

- Harikrishnakumar, D. A. R. & Nannapaneni, K. K. S. (2019). "Supervised Machine Learning Approach for Effective Supplier Classification". Em: 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA), pp. 240–245. doi: 10.1109/ICMLA.2019.00045.
- Hazen, B. T., Boone, C. A., Ezell, J. D. & Jones-Farmer, L. A. (2014). "Data quality for data science, predictive analytics, and big data in supply chain management: An introduction to the problem and suggestions for research and applications". Em: International Journal of Production Economics 154, pp. 72–80.
- Huang, R. & Mao, S. (2024). "Carbon Footprint Management in Global Supply Chains: A Data-Driven Approach Utilizing Artificial Intelligence Algorithms". Em: IEEE Access 12, pp. 89957–89967. doi: 10.1109/ACCESS.2024.3407839.
- Jamwal, A., Agrawal, R., & Sharma, M. (2022). "Deep learning for manufacturing sustainability: Models, applications in Industry 4.0 and implications". Em: International Journal of Information Management Data Insights 2.2, p. 100107. issn: 2667-0968. doi: <https://doi.org/10.1016/j.jjime.2022.100107>. url: <https://www.sciencedirect.com/science/article/pii/S2667096822000507>.
- Kediya, S., Santhanam, R., Kayande, R. A., Sharma, A., Sure, Y. & Disawal, V. (2023). "Smart Supply Chain Management and Big Data Analysis Using Machine Learning in Industry 4.0". Em: 2023 International Conference on Communication, Security and Artificial Intelligence (ICCSAI), pp. 500–505. doi: 10.1109/ICCSAI59793.2023.10421144.
- Kehayov, M., Holder, L. & Koch, V. (2022). "Application of artificial intelligence technology in the manufacturing process and purchasing and supply management". Em: Procedia Computer Science 200. 3rd International Conference on Industry 4.0 and Smart Manufacturing, pp. 1209–1217. issn: 1877-0509. doi: <https://doi.org/10.1016/j.procs.2022.01.321>. url: <https://www.sciencedirect.com/science/article/pii/S1877050922003301>.
- Knoll, D., Prüglmeier, M., & Reinhart, G. (2016). "Predicting Future Inbound Logistics Processes Using Machine Learning". Em: Procedia CIRP 52. The Sixth International Conference on Changeable, Agile, Reconfigurable and Virtual Production (CARV2016), pp. 145–150. issn: 2212-8271. doi: <https://doi.org/10.1016/j.procir.2016.07.078>. url: <https://www.sciencedirect.com/science/article/pii/S2212827116308770>.
- Kopeinig, J., Woschank, M., & Olipp, N. (2024). "Industry 4.0 Technologies and their Implications for Environmental Sustainability in the Manufacturing Industry". Em: Procedia Computer Science 232. 5th International Conference on Industry 4.0 and Smart Manufacturing (ISM 2023), pp. 2777–2789. issn: 1877-0509. doi: <https://doi.org/10.1016/j.procs.2024.02.095>. url: <https://www.sciencedirect.com/science/article/pii/S1877050924002722>.
- Kumari, N., Chaudhary, D., Kaur, H. & Yadav, A. L. (2023). "Artificial Intelligence in Supply Chain Optimization". Em: 2023 International Conference on IoT, Communication and Automation Technology (ICICAT), pp. 1–6. doi: 10.1109/ICICAT57735.2023.10263631.

- Moura, J. (2024). CrewAI, The Leading Multi-Agent Platform. url: <https://www.crewai.com/> (acedido em 14/09/2024).
- Nafei, A., Azizi, S. P., Edalatpanah, S. A. & Huang, C. (2024). "Smart TOPSIS: A Neural Network-Driven TOPSIS with Neutrosophic Triplets for Green Supplier Selection in Sustainable Manufacturing". Em: *Expert Systems with Applications* 255, p. 124744. issn: 0957-4174. doi: <https://doi.org/10.1016/j.eswa.2024.124744>. url: <https://www.sciencedirect.com/science/article/pii/S0957417424016117>.
- Nagar, D., Raghav, S., Bhardwaj, A., Kumar, R., Singh, P. L. & Sindhwani, R. (2021). "Machine learning: Best way to sustain the supply chain in the era of industry 4.0". Em: *Materials Today: Proceedings* 47. 3rd International Conference on Computational and Experimental Methods in Mechanical Engineering, pp. 3676–3682. issn: 2214-7853. doi: <https://doi.org/10.1016/j.matpr.2021.01.267>. url: <https://www.sciencedirect.com/science/article/pii/S2214785321003564>.
- Ng, Andrew (2024). DeepLearningAI. url: <https://www.deeplearning.ai/> (acedido em 14/09/2024).
- Niranjan, K., Narayana, K. S. & Rao, M. V. A. L. N. (2021). "Role of Artificial Intelligence in Logistics and Supply Chain". Em: *2021 International Conference on Computer Communication and Informatics (ICCCI)*, pp. 1–3. doi: 10.1109/ICCCI50826.2021.9402625.
- OpenAI API (2024). OpenAI API. url: <https://platform.openai.com/docs/overview> (acedido em 14/09/2024).
- Serper API (2024). Serper API. url: <https://serper.dev/> (acedido em 14/09/2024).
- Shahzad, F., Zaiied, Y. B., Shahzad, M. A. & Mahmood, F. (2024). "Insights into the performance of green supply chain in the Chinese semiconductor industry". Em: *International Journal of Production Economics* 273, p. 109286. issn: 0925-5273. doi: <https://doi.org/10.1016/j.ijpe.2024.109286>. url: <https://www.sciencedirect.com/science/article/pii/S0925527324001439>.
- Singh, S. & Soni, U. (2019). "Predicting Order Lead Time for Just in Time production system using various Machine Learning Algorithms: A Case Study". Em: *2019 9th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, pp. 422–425. doi: 10.1109/CONFLUENCE.2019.8776892.
- Singha, D. & Panse, C. (2022). "Application of different Machine Learning models for Supply Chain Demand Forecasting: Comparative Analysis". Em: *2022 2nd International Conference on Innovative Practices in Technology and Management (ICIPTM)*. Vol. 2, pp. 312–318. doi: 10.1109/ICIPTM54933.2022.9753864.
- Tian, S., Wu, L., Ciano, M. P., Ardolino, M. & Pawar K. S. (2024). "Enhancing innovativeness and performance of the manufacturing supply chain through datafication: The role of resilience". Em: *Computers & Industrial Engineering* 188, p. 109841. issn: 0360-8352. doi: <https://doi.org/10.1016/j.cie.2023.109841>. url: <https://www.sciencedirect.com/science/article/pii/S0360835223008653>.

- Toorajipour, R., Sohrabpour, V., Nazarpour, A., Oghazi, P. & Fischl, M. (2021). "Artificial intelligence in supply chain management: A systematic literature review". Em: *Journal of Business Research* 122, pp. 502–517. issn: 0148-2963. doi: <https://doi.org/10.1016/j.jbusres.2020.09.009>. url: <https://www.sciencedirect.com/science/article/pii/S014829632030583X>.
- Van Belle, J., Guns, T. & Verbeke, W. (2021). "Using shared sell-through data to forecast wholesaler demand in multi-echelon supply chains". Em: *European Journal of Operational Research* 288.2, pp. 466–479. issn: 0377-2217. doi: <https://doi.org/10.1016/j.ejor.2020.05.059>. url: <https://www.sciencedirect.com/science/article/pii/S0377221720305208>.
- Wang, W. (2024). "A IoT-Based Framework for Cross-Border E-Commerce Supply Chain Using Machine Learning and Optimization". Em: *IEEE Access* 12, pp. 1852–1864. doi: [10.1109/ACCESS.2023.3347452](https://doi.org/10.1109/ACCESS.2023.3347452).
- Wright, T., Tse, B., Nsiye, E., Azinrod, T., Medina, D. & Mondesire, S. (2024). "Probabilistic Modeling and Machine Learning for Preventative Maintenance Prediction in Semiconductor Manufacturing". Em: *2024 35th Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC)*, pp. 1–6. doi: [10.1109/ASMC61125.2024.10545532](https://doi.org/10.1109/ASMC61125.2024.10545532).
- Wu, T. & Zuo, M. (2023). "Green supply chain transformation and emission reduction based on machine learning". Em: *Science Progress* 106.1. PMID: 36972522, p. 00368504231165679. doi: [10.1177/00368504231165679](https://doi.org/10.1177/00368504231165679). eprint: <https://doi.org/10.1177/00368504231165679>. url: <https://doi.org/10.1177/00368504231165679>.
- Yıldız, S. N., Okay, F. Y., Islamov, A. & Özdemir, S. (2024). "Improved Chain-based Multi-Output Classification for Packaging Planning". Em: *Procedia Computer Science* 231. *14th International Conference on Emerging Ubiquitous Systems and Pervasive Networks / 13th International Conference on Current and Future Trends of Information and Communication Technologies in Healthcare (EUSPN/ICTH 2023)*, pp. 697–702. issn: 1877-0509. doi: <https://doi.org/10.1016/j.procs.2023.12.159>. url: <https://www.sciencedirect.com/science/article/pii/S1877050923021713>.