



Integração entre Simulação de Eventos Discretos, Apoio Multicritério à Decisão e Aprendizado de Máquina: Uma Revisão Sistemática da Literatura

Kelly Cristine Franco de Azevedo

Universidade Estadual Paulista (kelly.franco@unesp.br)

Fernando Augusto Silva Marins

Universidade Estadual Paulista (fernando.marins@unesp.br)

Aneirson Francisco da Silva

Universidade Estadual Paulista (aneirson.silva@unesp.br)

Resumo

A transformação digital impulsionada pela Indústria 4.0 tem estimulado o uso de ferramentas computacionais para apoiar decisões em sistemas complexos. Este artigo realiza uma Revisão Sistemática da Literatura (RSL) sobre a integração entre Simulação de Eventos Discretos (DES), Apoio Multicritério à Decisão (AMD) e Aprendizado de Máquina (*Machine Learning* - ML), com o objetivo de identificar tendências e oportunidades de pesquisa. A metodologia seguiu o protocolo PRISMA 2020, abrangendo buscas nas bases Scopus e Web of Science. Foram selecionados 37 estudos que aplicam essas técnicas de forma integrada em diferentes contextos. Os resultados indicam que a maior parte das aplicações ocorre em processos industriais e de manufatura, seguidos pelos setores de transporte e saúde. Observou-se predominância de variáveis contínuas e foco em problemas de planejamento e otimização. A análise bibliométrica revelou o crescimento do uso conjunto de DES, AMD e ML, principalmente em sistemas de apoio à decisão e otimização multicritério. Conclui-se que a integração dessas abordagens representa um campo promissor para o avanço científico e tecnológico, contribuindo para decisões mais precisas, sustentáveis e orientadas por dados na era da Indústria 5.0.



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

Palavras-chave: Simulação de Eventos Discretos, Apoio Multicritério à Decisão, Aprendizado de Máquina, Revisão Sistemática da Literatura, Indústria 4.0.

Abstract

The digital transformation driven by Industry 4.0 has stimulated the use of computational tools to support decision-making in complex systems. This paper presents a Systematic Literature Review (SLR) on the integration of Discrete Event Simulation (DES), Multi-Criteria Decision Making (MCDM), and Machine Learning (ML), aiming to identify trends, gaps, and research opportunities. The methodology followed the PRISMA 2020 protocol, covering searches in the Scopus and Web of Science databases. A total of 37 studies applying these techniques in an integrated manner across different contexts were selected. Results indicate that most applications occur in industrial and manufacturing processes, followed by transportation and healthcare sectors. There is a predominance of continuous variables and a focus on planning and optimization problems. The bibliometric analysis revealed a growing use of DES, MCDM, and ML integration, especially in decision support systems and multi-criteria optimization. It is concluded that the integration of these approaches represents a promising field for scientific and technological advancement, contributing to more accurate, sustainable, and data-driven decision-making in the Industry 5.0 era.

Keywords: Discrete Event Simulation, Multi-Criteria Decision Making, Machine Learning, Systematic Literature Review, Industry 4.0.

Resumen

La transformación digital impulsada por la Industria 4.0 ha estimulado el uso de herramientas computacionales para apoyar la toma de decisiones en sistemas complejos. Este artículo presenta una Revisión Sistemática de la Literatura (RSL) sobre la integración de la Simulación de Eventos Discretos (DES), el Apoyo Multicriterio a la Decisión (AMD) y el Aprendizaje Automático (ML), con el objetivo de identificar tendencias, brechas y oportunidades de investigación. La metodología siguió el protocolo



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

PRISMA 2020, abarcando búsquedas en las bases de datos Scopus y Web of Science. Se seleccionaron 37 estudios que aplican estas técnicas de forma integrada en diferentes contextos. Los resultados indican que la mayoría de las aplicaciones se concentran en procesos industriales y de manufactura, seguidos por los sectores de transporte y salud. Se observó predominio de variables continuas y un enfoque en problemas de planificación y optimización. El análisis bibliométrico reveló un uso creciente de la integración entre DES, AMD y ML, especialmente en sistemas de apoyo a la decisión y optimización multicriterio. Se concluye que la integración de estos enfoques representa un campo prometedor para el avance científico y tecnológico, contribuyendo a decisiones más precisas, sostenibles y basadas en datos en la era de la Industria 5.0.

Palabras clave: Simulación de Eventos Discretos, Apoyo Multicriterio a la Decisión, Aprendizaje Automático, Revisión Sistemática de la Literatura, Industria 4.0.

1. INTRODUÇÃO

A transformação digital impulsionada pela Indústria 4.0 tem remodelado a forma de projetar, operar e otimizar sistemas complexos. Essa nova era produtiva é sustentada por pilares como Internet das Coisas (IoT), Sistemas Ciberfísicos (CPS), *Big Data*, Computação em Nuvem, Inteligência Artificial (AI) e Integração Horizontal e Vertical de Sistemas, que, em conjunto, criam ambientes inteligentes, conectados e altamente responsivos (Sawangwong; Poti, 2023).

Neste contexto, a crescente disponibilidade de dados em tempo real e a necessidade de decisões rápidas e precisas em processos altamente dinâmicos exigem ferramentas capazes de representar sistemas complexos, analisar grandes volumes de informação e apoiar a tomada de decisão com agilidade.

A Simulação de Eventos Discretos (DES) é reconhecida como uma importante ferramenta de apoio à tomada de decisão (Steringer et al., 2019). A DES permite modelar o comportamento de sistemas reais, analisar indicadores de desempenho em diferentes cenários e testar alternativas sem interferir no ambiente físico (Qiao; Wang, 2021). Dessa forma, a simulação tem sido aplicada em diversos setores produtivos e de serviços para analisar filas, gargalos, níveis de serviço e alocação de recursos, subsidiando decisões estratégicas e operacionais.

Entretanto, a DES por si só não garante a identificação da melhor alternativa quando múltiplos critérios, muitas vezes conflitantes, precisam ser considerados (Ha et al., 2019). Nesses casos, o Apoio Multicritério à Decisão (AMD) torna-se essencial. Métodos como AHP, TOPSIS, PROMETHEE, entre outros, permitem avaliar simultaneamente critérios como custo, tempo, impacto ambiental, confiabilidade e nível de serviço de maneira estruturada e transparente (Yannis et al., 2020; Wang et al., 2019). A integração entre DES e AMD amplia o escopo analítico da simulação, favorecendo decisões mais consistentes e justificáveis.

Somando-se a isso, os avanços em Inteligência Artificial, especialmente em Aprendizado de Máquina (*Machine Learning* - ML), possibilitam a introdução de

capacidades de previsão e adaptação dinâmica aos modelos computacionais (O'Sullivan, 2020). Algoritmos de ML, treinados com dados históricos ou em tempo real, podem aprimorar a calibração dos modelos de simulação, prever padrões de comportamento do sistema, identificar variáveis críticas e antecipar riscos operacionais (Alzubaidi et al., 2021). A sinergia entre ML e DES favorece ainda o desenvolvimento de gêmeos digitais (Digital Twins), que conectam modelos virtuais a dados reais para apoiar decisões quase em tempo real.

Dessa forma, a integração entre DES, AMD e ML emerge como uma estratégia robusta para apoiar decisões em sistemas complexos, ao possibilitar a comparação estruturada de alternativas, a otimização de recursos, a redução de custos e o aumento da eficiência em operações dinâmicas. Além disso, essa integração vem expandindo o escopo analítico disponível à pesquisa científica, abrindo espaço para avanços metodológicos e aplicações mais abrangentes.

Portanto, a questão de pesquisa que norteia este trabalho é: Como a integração entre DES, AMD e ML tem sido explorada na literatura para apoiar a tomada de decisão em sistemas complexos, e quais são as oportunidades de evolução teórica e prática dessa integração?

Nesse sentido, o objetivo geral deste artigo é realizar uma Revisão Sistemática da Literatura (RSL) para identificar publicações e resultados do uso conjunto de DES, AMD e ML em diferentes contextos de aplicação. Especificamente, busca-se: Identificar áreas de aplicação, variáveis modeladas, métodos e ferramentas empregados, bem como tendências emergentes e oportunidades de pesquisa sobre o tema; Contribuir para o avanço do conhecimento e fornecer subsídios para o desenvolvimento de soluções alinhadas aos desafios e oportunidades associados à Indústria 5.0.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Simulação de Eventos Discretos (DES)

A Simulação de Eventos Discretos (DES) é uma técnica voltada ao estudo de sistemas que mudam de estado apenas em momentos específicos, de forma descontínua e, muitas vezes, imprevisível, em resposta a eventos que provocam alterações em seu comportamento. Entre um evento e outro, o sistema permanece inalterado, característica que define a natureza “discreta” dessas transformações (Bottani; Casella, 2021).

Essa abordagem é útil em cenários nos quais as mudanças dependem de acontecimentos bem definidos, como a chegada de entidades ao sistema, falhas de equipamentos ou a conclusão de etapas de um processo. Para viabilizar a análise, constrói-se um modelo computacional que reproduz a dinâmica real do processo, permitindo testar diferentes condições, identificar gargalos e avaliar o desempenho em um ambiente totalmente controlado (Qiao; Wang, 2021).

A modelagem por DES funciona como uma representação virtual do sistema, possibilitando mensurar e aperfeiçoar seu desempenho sem necessidade de intervenções físicas ou investimentos elevados. Ao criar um ambiente de testes seguro, a simulação permite compreender o comportamento do sistema em diferentes cenários operacionais e prever o impacto de mudanças antes de aplicá-las, reduzindo riscos, evitando interrupções e minimizando custos que seriam inevitáveis em experimentos no mundo real (Gabriel et al., 2020).

O principal resultado da aplicação da DES consiste na possibilidade de realizar análises estatísticas das ocorrências que influenciam o sistema ao longo do tempo, identificando padrões, tempos de espera, níveis de utilização de recursos e outros aspectos relevantes. Esses resultados fornecem informações quantitativas e confiáveis para apoiar decisões estratégicas e aprimorar a eficiência dos processos (Qiao; Wang, 2021).

Estudos recentes indicam que a DES tem sido aplicada de forma ampla em diferentes setores, permitindo, por exemplo, a avaliação de *layouts* de instalações, a melhoria e otimização de fluxos de recursos e a redução de impactos ambientais e operacionais. Pesquisas também têm explorado a integração de DES com algoritmos de Aprendizado

de Máquina (ML) para prever tempos de processamento, melhorar a eficiência e reduzir desperdícios ou emissões em sistemas complexos.

2.2. Apoio Multicritério à Decisão (AMD)

O Apoio Multicritério à Decisão (AMD) é uma abordagem da Pesquisa Operacional que avalia alternativas complexas considerando múltiplos critérios, sejam eles quantitativos ou qualitativos. As técnicas de AMD permitem tratar diferentes perspectivas simultaneamente, muitas vezes conflitantes, oferecendo decisões mais estruturadas e transparentes. Essa abordagem possibilita ainda organizar grandes volumes de informações e atribuir ou ajustar pesos conforme a consistência dos dados (Ha et al., 2019; Tripathy et al., 2018; Yannis et al., 2020; Wang et al., 2019).

Os métodos AMD podem ser classificados em compensatórios ou não compensatórios. Nos compensatórios, é possível equilibrar os critérios, permitindo que um desempenho inferior em determinado aspecto seja compensado por um desempenho superior em outro, gerando soluções de compromisso (*trade-offs*). Já os não compensatórios avaliam cada critério de forma independente e não permitem compensações; se uma alternativa não atinge um requisito mínimo em qualquer critério, é descartada ou penalizada, sendo adequada para situações nas quais certos fatores são inegociáveis (Almeida; Ferreira; Cavalcante, 2015).

Em diferentes contextos, a AMD tem sido empregada para otimizar sistemas complexos, equilibrando múltiplos objetivos, como eficiência operacional, confiabilidade, sustentabilidade e custos. Estudos recentes demonstram, por exemplo, o uso de estruturas integradas de AMD para selecionar recursos críticos, otimizar a alocação de operações em sistemas industriais e logísticos e melhorar o desempenho de processos multiobjetivo em setores de energia, transporte e manufatura (Sudjono et al., 2025; Nuclear Society of Korea, 2025; Ren et al., 2025). Esses exemplos evidenciam que a AMD constitui uma ferramenta eficaz para lidar com a complexidade de decisões em sistemas dinâmicos.

2.3. Aprendizado de Máquina (ML)

O Aprendizado de Máquina (ML) é um campo da Inteligência Artificial dedicado ao desenvolvimento de algoritmos capazes de melhorar seu desempenho à medida que recebem e processam novos dados. Diferentemente de programas tradicionais, que seguem instruções fixas, os modelos de ML identificam padrões e ajustam suas previsões ou decisões de forma autônoma. Essa característica torna os algoritmos particularmente úteis em situações nas quais o comportamento do sistema muda ao longo do tempo, há grande volume de dados ou escassez de especialistas humanos disponíveis.

Modelos de ML têm sido aplicados em diversas áreas, como previsão de demandas, reconhecimento de padrões, personalização de serviços, manutenção preditiva e análise de grandes volumes de dados operacionais (Alzubaidi et al., 2021). Algoritmos supervisionados ou não supervisionados podem aprender a partir de dados históricos e se adaptar continuamente a novas variáveis ou condições. Essa flexibilidade é fundamental em ambientes dinâmicos, mantendo os modelos relevantes mesmo diante de mudanças frequentes nos processos (Mahesh, 2020).

Além disso, os algoritmos de ML são capazes de identificar padrões complexos e relações ocultas em grandes conjuntos de dados, atualizando previsões e recomendações em tempo real. Isso favorece decisões mais embasadas, possibilita ajustes rápidos e contribui para a melhoria contínua das estratégias operacionais e para o uso mais eficiente de recursos (Ludermir, 2021; Batta, 2020). Estudos recentes destacam o uso de ML para aprimorar a eficiência em operações complexas, melhorando previsões de tempos de processamento, reduzindo erros, otimizando alocação de recursos e aumentando a produtividade geral do sistema (Chu; Yan, 2023; Arbabkhah et al., 2024).

3. MÉTODO

Este artigo adota o procedimento de Revisão Sistemática da Literatura (RSL) com base nas diretrizes propostas por Santos et al. (2022), estruturando-se em quatro fases principais: Planejamento, Pesquisa e Triagem, Avaliação e Síntese e Relato dos Resultados.

I. Planejamento

Na fase de planejamento, foram definidas as palavras-chave e as combinações de busca a partir dos termos centrais do estudo: *Discrete Event Simulation* (DES), *Multi-Criteria Decision Making* (MCDM/MCDA) e *Machine Learning* (ML).

O objetivo dessa etapa foi avaliar a captação dos descritores e verificar se as combinações selecionadas recuperavam amostras representativas e alinhadas ao escopo da pesquisa. A partir dos resultados dessa análise preliminar, que incluiu inspeção de títulos, resumos e palavras-chave foram efetuados pequenos ajustes finos (por exemplo, inclusão/exclusão de termos sinônimos e operadores booleanos) para aprimorar a sensibilidade e especificidade da busca, antes da extração definitiva dos registros nas bases selecionadas.

Ressalta-se que essa análise teve caráter diagnóstico, não constituindo a análise bibliométrica final do estudo. A análise bibliométrica definitiva foi aplicada posteriormente, apenas sobre a base final de estudos elegíveis, conforme procedimento PRISMA descrito nas seções seguintes.

Com a estratégia de busca validada pela análise preliminar, procedeu-se à busca sistemática nas bases Scopus e Web of Science, conforme detalhado na seção de Pesquisa e Triagem. Os resultados obtidos foram então submetidos ao processo PRISMA (Identificação → Triagem → Elegibilidade → Inclusão), incluindo remoção de duplicatas, triagem por título/resumo e leitura integral para verificação de elegibilidade.

II. Pesquisa e Triagem

Após a definição e validação das combinações de palavras-chave, procedeu-se à busca sistemática nas bases de dados Scopus e Web of Science, selecionadas por sua abrangência e relevância na área de Engenharia de Produção e Gestão.

O processo de busca, seleção e filtragem dos estudos seguiu as diretrizes do PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), conforme Page et al. (2021), assegurando transparência, reprodutibilidade e rastreabilidade em todas as etapas.

As fases do protocolo PRISMA foram conduzidas da seguinte forma:

- i. Identificação – aplicação das combinações de busca nas bases selecionadas e exportação dos registros em formato compatível com o software R;
- ii. Remoção de duplicatas – exclusão automática e manual de registros repetidos. Essa etapa foi realizada diretamente no software R, por meio das funções do pacote Bibliometrix, que permitem identificar e eliminar duplicatas com base no título, DOI e nome do periódico;
- iii. Triagem (*screening*) – leitura de títulos e resumos para verificar a aderência dos estudos ao escopo temático, excluindo publicações fora do tema de interesse;
- iv. Elegibilidade – leitura integral dos textos que atenderam aos critérios iniciais, assegurando a presença de estudos que abordassem de forma integrada *Discrete Event Simulation* (DES), *Multi-Criteria Decision Making* (MCDM/MCDA) e *Machine Learning* (ML);
- v. Inclusão – seleção final dos artigos elegíveis que compuseram a amostra para as análises bibliométrica e qualitativa.

Concluídas as etapas de triagem e preparação da base de dados, procedeu-se à fase de Avaliação e Síntese dos trabalhos selecionados.

III. Avaliação e Síntese

A avaliação e síntese dos estudos incluídos na revisão sistemática foram conduzidas por meio de uma análise quantitativa e categórica das publicações selecionadas. Inicialmente, os trabalhos foram agrupados segundo três dimensões principais: tipo de problema abordado, setor de aplicação e tipo de variável utilizada nos modelos. Para cada dimensão, foram definidos critérios de classificação que permitissem consolidar as informações de forma objetiva e comparável entre os estudos.

O tipo de problema foi categorizado com base no objetivo central de cada estudo, considerando, por exemplo, processos industriais, logística, agendamento, outros

problemas e não especificados. O setor de aplicação foi registrado de acordo com o domínio ou contexto no qual as técnicas foram empregadas, incluindo manufatura, transporte, assistência médica, outros e não especificados. Já o tipo de variável foi classificado em contínua, discreta ou categórica, refletindo a natureza dos dados utilizados nos modelos analisados.

Após a categorização, os dados foram sumarizados em uma tabela descritiva (Tabela 1), permitindo identificar padrões e tendências na literatura. A síntese quantitativa possibilitou calcular a frequência relativa de cada categoria, proporcionando uma visão das áreas mais exploradas e dos tipos de variáveis mais recorrentes nos estudos. Essa etapa forneceu subsídios para a interpretação dos resultados e para a discussão sobre o potencial de aplicação das abordagens integradas em diferentes contextos.

IV. Relato dos resultados

O relato dos resultados foi conduzido com o apoio do software R, utilizando o pacote Bibliometrix, uma ferramenta especializada para análise bibliométrica. Essa abordagem possibilitou examinar a literatura de forma quantitativa, visual e reproduzível. Por meio do R, foram gerados gráficos e mapas que permitiram explorar a evolução temporal das publicações, identificar os principais termos e autores, além de construir nuvens de palavras e mapas temáticos representativos dos estudos incluídos na revisão.

Essas análises forneceram uma visão das tendências emergentes, dos temas mais recorrentes e das relações entre conceitos presentes na literatura, complementando a síntese qualitativa e possibilitando uma interpretação mais clara, estruturada e visualmente informativa dos resultados obtidos.

4. RESULTADOS E DISCUSSÕES

4.1. Planejamento

O planejamento da Revisão Sistemática da Literatura (RSL) foi conduzido conforme as diretrizes do PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), conforme Page et al. (2021), com o objetivo de estruturar uma estratégia de busca capaz de abranger, de forma equilibrada, os três eixos centrais do estudo: Simulação de Eventos Discretos (DES), Apoio Multicritério à Decisão (MCDM/MCDA) e Aprendizado de Máquina (ML).

Durante essa fase, buscou-se não apenas definir a combinação de descritores e bases de dados mais adequadas, mas também avaliar a coerência temática e a representatividade da busca em relação ao campo investigado. Para isso, foi realizada uma análise bibliométrica preliminar, conduzida no software R com o auxílio do pacote Bibliometrix e da interface Biblioshiny. A combinação final de palavras-chave definidas para a pesquisa foi a seguinte: ("*discrete event simulation*" OR DES OR "*simulation model*" OR "*process simulation*") AND ("*multi-criteria*" OR "*multicriteria*" OR MCDM OR MCDA) AND ("*machine learning*" OR "*artificial intelligence*" OR "*data-driven*" OR "*intelligent system*" OR "*predictive model*")

Os resultados revelaram que os termos *artificial intelligence*, *machine learning*, *multi-objective optimization*, *optimization* e *discrete event simulation* apresentaram alta frequência de ocorrência, confirmando a adequação da combinação de descritores ao escopo da pesquisa. Essa verificação reforçou a robustez da estratégia, garantindo que as bases Scopus e Web of Science contemplassem os estudos mais relevantes e atualizados da área de Engenharia de Produção e Gestão.

Além disso, a análise das coocorrências de palavras-chave permitiu identificar uma forte interconexão entre as áreas de otimização e inteligência artificial, evidenciando uma tendência crescente de integração dessas abordagens em estudos recentes. Esse resultado indicou que o tema central da revisão representa um campo emergente e multidisciplinar, ainda em consolidação, mas com crescente interesse na literatura científica.

Com base nisso, foi possível refinar o foco da revisão e formular as questões de pesquisa que orientam o estudo, fundamentadas no framework CIMO (Contexto, Intervenção, Mecanismo e Resultados), proposto por Denyer et al. (2008). Essa estrutura permitiu estabelecer relações lógicas entre os objetivos do trabalho e as oportunidades identificadas na literatura, resultando nas seguintes perguntas de pesquisa:


- QP1: Quais são as principais áreas e problemas abordados pela integração entre simulação de eventos discretos, otimização e inteligência artificial (Contexto)?
- QP2: Quais métodos e técnicas de inteligência artificial e otimização têm sido aplicados em conjunto com simulação de eventos discretos (Intervenção)?
- QP3: Como esses métodos são integrados e operacionalizados em termos de modelagem e análise (Mecanismo)?
- QP4: Quais métricas ou indicadores têm sido utilizados para avaliar os resultados obtidos (Resultados)?

O conjunto dessas questões resultou da análise exploratória da literatura inicial, permitindo alinhar os objetivos da revisão às tendências e lacunas observadas nas publicações recentes. Assim, o planejamento definiu os parâmetros da RSL e orientou o escopo teórico e temático das etapas seguintes.

4.2. Pesquisa e Triagem

A Figura 1 apresenta o fluxograma PRISMA 2020, que sintetiza de forma visual o percurso metodológico da revisão e as quantidades de registros em cada fase.

Figura 1: Fluxograma PRISMA 2020



Fonte: Elaborado pelos autores

Na etapa de identificação, foram inicialmente identificados 91 estudos a partir das bases de dados Scopus e Web of Science, sendo 63 registros provenientes da Scopus e 28 da Web of Science. A busca foi realizada considerando os filtros de idioma (inglês) e tipo de documento (artigos e artigos de conferência). Após a consolidação das referências, realizou-se a remoção de duplicatas utilizando o R, resultando na exclusão de 28 registros repetidos. Assim, 68 estudos únicos foram encaminhados para a primeira etapa de triagem, conforme apresentado no fluxograma PRISMA.

Na primeira etapa de triagem, que consistiu na leitura dos títulos e resumos, foram removidos 19 artigos por não atenderem integralmente aos critérios de inclusão previamente estabelecidos. O motivo mais recorrente de exclusão esteve relacionado ao fato de que, embora os estudos mencionassem termos associados às ferramentas de simulação, otimização e aprendizado de máquina nas palavras-chave ou no resumo, a análise do conteúdo revelou que não aplicavam efetivamente técnicas de aprendizado de máquina em suas abordagens metodológicas. Esse resultado evidencia uma limitação comum em buscas automatizadas com operadores booleanos, nas quais alguns registros atendem aos termos da *string* de busca, mas não apresentam aderência prática ao escopo definido para a revisão. Após essa etapa, 49 estudos permaneceram para a fase de elegibilidade, em que foi realizada a leitura completa dos textos.

Na etapa seguinte do processo, correspondente à fase de “publicações pesquisadas para se manterem” no fluxograma PRISMA, os 49 estudos remanescentes passaram por uma avaliação mais detalhada. Nessa fase, cinco artigos foram excluídos devido à indisponibilidade de acesso ao texto completo, o que impossibilitou a verificação adequada dos critérios de elegibilidade. Assim, 44 publicações permaneceram para a fase de elegibilidade, na qual foi realizada a leitura integral dos trabalhos selecionados.

Após a leitura integral dos 44 artigos selecionados na etapa anterior, foi realizada uma análise quanto à aderência às questões de pesquisa (QP1–QP4) e aos critérios de elegibilidade previamente definidos. Nessa etapa, foram identificados 7 artigos que não atendiam de forma suficiente aos objetivos da revisão e, portanto, foram excluídos da base final.

As exclusões ocorreram principalmente por três motivos:

- Ausência de integração explícita entre simulação e métodos de inteligência artificial ou otimização — alguns estudos empregavam apenas simulação isoladamente, sem acoplamento a técnicas de IA, aprendizado de máquina ou abordagem multicritério;

- Foco predominantemente conceitual ou teórico, sem aplicação prática de modelos de simulação de eventos discretos, o que inviabilizou a análise sob a ótica da operacionalização (QP3);
- Escopo temático divergente, quando o estudo, apesar de empregar alguma forma de simulação ou decisão multicritério, não se relacionava diretamente às áreas ou problemas investigados (por exemplo, aplicações puramente visuais, educacionais ou de interface, sem modelagem de desempenho ou otimização).

Assim, 37 artigos permaneceram como amostra final da revisão, representando o conjunto de estudos que efetivamente exploram a integração entre simulação (majoritariamente de eventos discretos), métodos de apoio multicritério e técnicas de inteligência artificial ou aprendizado de máquina. A base final obtida constitui o ponto de partida para a etapa seguinte, de Avaliação e Síntese, apresentada na próxima subseção.

4.3. Avaliação e síntese

A Tabela 1 apresenta a síntese quantitativa dos estudos analisados, agrupados segundo o tipo de problema, o setor de aplicação e o tipo de variável utilizada nos modelos. Esses resultados representam a consolidação das informações obtidas na etapa anterior, permitindo identificar as áreas mais exploradas na literatura.

Tabela 1: síntese quantitativa dos estudos analisados

Tipo de problema	Logística	3	7%
	processos industriais	20	49%
	Agendamento	4	10%
	outros	13	32%
	não especificados	1	2%
Setor de aplicação	Assistência médica	3	9%
	Transporte	5	14%
	manufatura	14	40%
	outros	10	29%
	não especificados	3	9%
Tipo de variável	Contínua	29	59%
	discreta	12	24%
	categórica	8	16%

Fonte: Elaborado pelos autores

Em relação ao tipo de problema, observa-se que os processos industriais representam a categoria mais recorrente, abrangendo 49% dos estudos analisados. Esse resultado evidencia o interesse predominante da literatura em aplicações voltadas à melhoria da eficiência produtiva, planejamento operacional e alocação de recursos, áreas nas quais a integração entre diferentes ferramentas de modelagem e suporte à decisão tem se mostrado promissora. Tal combinação demonstra um potencial para a análise de cenários complexos, possibilitando avaliar alternativas, compreender *trade-offs* e apoiar decisões baseadas em dados. As categorias agendamento (10%) e logística (7%) também apresentaram relevância, refletindo o uso crescente dessas abordagens em problemas de sequenciamento, despacho de tarefas e coordenação de fluxos de materiais e informações. A categoria outros (32%) reúne aplicações diversificadas, como controle de estoques, seleção de fornecedores e estudos estratégicos, enquanto 2% dos trabalhos não especificaram claramente o tipo de problema abordado.

No que se refere ao setor de aplicação, verifica-se que a manufatura se destaca como o domínio mais frequente (40% dos estudos), confirmando a afinidade entre essas ferramentas e os contextos produtivos e industriais. Em seguida, aparecem os setores de transporte (14%) e assistência médica (9%), evidenciando a expansão do uso dessas

ferramentas em operações logísticas e sistemas de saúde, respectivamente. As categorias outros (29%) e não especificados (9%) indicam que parte dos estudos ainda não explicita claramente o domínio de aplicação, o que limita a compreensão do contexto em que as abordagens são utilizadas.

Quanto ao tipo de variável, observa-se a predominância de variáveis contínuas (59%), seguidas por discretas (24%) e categóricas (16%). Essa distribuição sugere que a maioria dos estudos trabalha com dados quantitativos e mensuráveis, coerentes com aplicações que envolvem modelagem detalhada e otimização de desempenho. Por outro lado, a presença significativa de variáveis discretas e categóricas demonstra a capacidade dessas abordagens em lidar também com decisões qualitativas e estruturadas, como classificação de alternativas, priorização de estratégias e avaliação de cenários.

De modo geral, os resultados revelam que os estudos revisados aplicam majoritariamente essas técnicas em contextos industriais e logísticos, com ênfase em problemas de planejamento e execução operacional. Essa tendência reforça o potencial das abordagens integradas de simulação, decisão multicritério e aprendizado de máquina para a análise de sistemas complexos, contribuindo para equilibrar desempenho, custo e eficiência operacional nos diferentes contextos analisados.

4.4. Relato dos resultados

A Figura 2 apresenta a nuvem de palavras gerada a partir das palavras-chave dos estudos incluídos na base final.

The word cloud features several prominent terms in large fonts, including "artificial intelligence" at the bottom center, "decision support systems" above it, and "simulation" in green towards the top left. Other visible words include "multiobjective optimization", "genetic algorithms", "computer simulation", "machine learning", "design", "modeling", "discrete event simulation", "optimization", "decision making", "efficiency", "water supply", "integration", "fuzzy logic", "monte carlo methods", "simulation model", "multi-objective optimization", "reinforcement learning", "energy efficiency", "analytical hierarchy process", "methodology", "agricultural robots", "water resources", "genetic algorithm", "soils", "mcdm", "energy", "data analytics", "demand", "economic analysis", "management", "framework", "promethee", "crops", "activated-sludge model", "absorption", "acid gases", "multi-criteria decision analysis", "multicriteria", "sustainability planning", "discrete-event simulation", "multi-criteria", "multi-objec...", "multi-objective", "multi-criteria", "multi-criteria", "multi-criteria", "multi-criteria". The colors used are primarily blue, purple, green, orange, and brown.


Essa visualização evidencia os termos de maior recorrência e permite compreender os principais temas e enfoques conceituais da literatura analisada. Observa-se que os termos “*artificial intelligence*”, “*decision support systems*” e “*decision making*” aparecem com maior destaque, indicando que as pesquisas revisadas se concentram majoritariamente em abordagens que combinam inteligência artificial, sistemas de apoio à decisão e processos de tomada de decisão complexos.

Além disso, observa-se a presença de palavras como “*sustainability*”, “*energy*”, “*efficiency*” e “*management*”, que indicam uma tendência de ampliação do escopo das

pesquisas, incorporando dimensões de sustentabilidade, gestão de recursos e impacto ambiental. Essa diversidade temática reforça o caráter interdisciplinar do campo, no qual a integração entre simulação, inteligência artificial e métodos de decisão tem sido utilizada para enfrentar problemas reais de alto grau de complexidade, como os que ocorrem em sistemas produtivos, logísticos e portuários.

A Figura 3 apresenta a evolução temporal dos principais termos relacionados ao tema pesquisado, destacando quando cada um passou a ganhar relevância nas publicações científicas. O eixo horizontal representa os anos de publicação (2004–2025), enquanto o eixo vertical mostra as palavras-chave mais frequentes. O tamanho das bolhas indica o volume relativo de publicações associadas a cada termo, e o comprimento da linha horizontal mostra o período de tempo em que o termo esteve em evidência.

Figura 3: Evolução temporal dos termos mais relevantes



Fonte: Elaborado pelos autores

Observa-se que o termo “*simulation*” é o mais antigo e apresenta a maior extensão temporal, indicando que as abordagens baseadas em simulação constituem uma base consolidada da área. Isso reflete o uso histórico de modelos de eventos discretos e simulações computacionais como ferramentas de apoio à tomada de decisão.



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025


A partir de 2010, nota-se o surgimento e fortalecimento dos termos “*decision making*” e “*design*”, evidenciando uma transição do foco puramente técnico para uma perspectiva mais aplicada, voltada à estruturação de processos decisórios e ao desenvolvimento de sistemas de apoio.

Já os termos “*decision support systems*” e “*artificial intelligence*” passam a ganhar destaque a partir de 2014–2015, indicando um período de integração entre simulação, otimização e inteligência artificial. O tamanho expressivo da bolha de *artificial intelligence* revela seu papel central e o rápido crescimento de publicações relacionadas, refletindo o avanço de técnicas como aprendizado de máquina e heurísticas inteligentes aplicadas à otimização de processos.

Nos anos mais recentes (a partir de 2020), os termos “*optimization*” e “*multiobjective optimization*” ganham protagonismo, demonstrando o amadurecimento do campo em direção a abordagens quantitativas e multicritério. Essa tendência aponta para um interesse crescente na utilização de métodos de otimização avançados para resolver problemas complexos de alocação, planejamento e tomada de decisão.

O mapa temático (Figura 4) apresenta a distribuição dos principais temas identificados na literatura, considerando seu grau de relevância (centralidade) e nível de desenvolvimento (densidade). A análise permite compreender quais tópicos estão consolidados, quais estão em ascensão e quais ainda são emergentes ou periféricos dentro do campo que integra simulação, apoio à decisão e aprendizado de máquina.

Figura 4: Mapa temático



Fonte: Elaborado pelos autores

A análise temática evidencia a estrutura conceitual e o grau de desenvolvimento dos principais tópicos de pesquisa relacionados ao problema de alocação de berços e áreas correlatas, revelando tanto temas consolidados quanto emergentes. No quadrante dos temas motrizes (alto grau de densidade e centralidade), destacam-se *decision support systems*, *simulation*, *multicriteria analysis* e *sustainability*, indicando que a literatura apresenta um núcleo bem desenvolvido, voltado à integração entre simulação e métodos multicritério como suporte à tomada de decisão em ambientes complexos. Já os temas básicos, situados no quadrante inferior direito, abrangem *artificial intelligence*, *decision making*, *machine learning* e *multi-objective optimization*. Esses tópicos se configuram como fundamentos metodológicos amplamente aplicados, que sustentam grande parte das



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

pesquisas, mas que ainda se encontram em fase de expansão quanto à sua incorporação nas aplicações específicas do domínio portuário e logístico.

No quadrante superior esquerdo, observam-se os temas de nicho, como *dispatching rules*, *energy efficiency*, GIS e *flexible manufacturing systems* (FMS), que apresentam alta densidade, mas menor centralidade, indicando abordagens especializadas e com forte desenvolvimento interno, porém restritas a subáreas específicas. Por fim, no quadrante inferior esquerdo concentram-se os temas emergentes ou em declínio, entre eles MCDM, *demand*, *sensitivity analysis*, *reinforcement learning* e *integration*, sugerindo campos que podem representar tanto novas direções metodológicas quanto tópicos ainda em consolidação dentro do corpo principal da literatura.

5. CONSIDERAÇÕES FINAIS

A presente Revisão Sistemática da Literatura permitiu mapear e analisar o estado da arte das pesquisas que integram Simulação de Eventos Discretos (DES), Apoio Multicritério à Decisão (AMD) e Aprendizado de Máquina (ML) em diferentes contextos de aplicação. O estudo evidenciou que essa integração representa uma fronteira promissora para o avanço científico e tecnológico, ao combinar a capacidade de modelagem dinâmica e representativa da simulação, a estruturação analítica da decisão multicritério e o caráter preditivo e adaptativo do aprendizado de máquina.

Os resultados mostraram que a maior parte dos trabalhos analisados concentram-se em ambientes industriais e de manufatura, nos quais o uso combinado dessas ferramentas tem se mostrado eficaz para otimizar processos, reduzir custos, aprimorar a alocação de recursos e apoiar decisões operacionais e estratégicas. Também se observou a ampliação das aplicações em setores como transporte, logística e assistência médica, indicando a crescente versatilidade e relevância dessas abordagens em domínios que envolvem sistemas complexos e dados em tempo real.

A análise bibliométrica mostrou que os termos mais recorrentes na literatura estão associados a sistemas de apoio à decisão, inteligência artificial e aprendizado de máquina, indicando que as pesquisas sobre integração de técnicas vêm se consolidando em torno de um núcleo temático robusto e interdisciplinar. Esses resultados refletem o amadurecimento gradual do campo e o avanço no desenvolvimento de abordagens híbridas, capazes de unir modelagem, aprendizado e avaliação multicritério em um mesmo processo decisório. Observa-se, ainda, uma ampliação da diversidade de aplicações e contextos analisados, o que demonstra o crescimento do interesse científico e a relevância prática dessa integração para problemas complexos e dinâmicos.

De modo geral, a literatura analisada demonstra um movimento consistente em direção à integração de abordagens híbridas, capazes de lidar simultaneamente com múltiplos critérios, variabilidade de sistemas e grande volume de dados.

Como contribuição, esta revisão sistemática oferece uma síntese das tendências, métodos e aplicações existentes, além de destacar oportunidades de pesquisa voltadas à incorporação de dados em tempo real, à automação adaptativa de modelos e ao



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

desenvolvimento de gêmeos digitais baseados em DES, AMD e ML. Tais avanços podem contribuir significativamente para a Indústria 5.0, na qual a inteligência colaborativa entre humanos e sistemas ciberfísicos torna-se elemento central para a tomada de decisão eficiente, sustentável e orientada por dados.

REFERÊNCIAS

- A. Najmaei and Z. Sadeghinejad, Green and sustainable business models: Historical roots, growth trajectory, conceptual architecture and an agenda for future research—A bibliometric review of green and sustainable business models, *Scientometrics*, vol. 128, no. 2, pp. 957–999, 2023.
- C. H. dos Santos, J. A. B. Montevechi, J. A. de Queiroz, R. de Carvalho Miranda, and F. Leal, Decision support in productive processes through DES and ABS in the Digital Twin era: a systematic literature review, *Int. J. Prod. Res.*, vol. 60, no. 8, pp. 2662–2681, 2022.
- Z. Xiao, Y. Qin, Z. Xu, J. Antuchevičienė, and E. K. Zavadskas, The journal Buildings: A bibliometric analysis (2011–2021), *Buildings*, vol. 12, no. 1, p. 37, 2022.
- N. Majeed and S. Ainin, Visualizing the evolution and landscape of socio-economic impact research, *Qual. Quant.*, vol. 55, no. 2, pp. 637–659, 2021.
- A. Nita, Empowering impact assessments knowledge and international research collaboration—A bibliometric analysis of Environmental Impact Assessment Review journal, *Environ. Impact Assess. Rev.*, vol. 78, p. 106283, 2019.
- de Alcantara, Mariane Gonçalves, et al. "Systematic literature review on multi-objective simulation optimization." *Complex System Modeling and Simulation* (2025).
- Yannis, George, et al. "State-of-the-art review on multi-criteria decision-making in the transport sector." *Journal of traffic and transportation engineering (English edition)* 7.4 (2020): 413-431.
- Ha, Min-Ho, Zaili Yang, and Jasmine Siu Lee Lam. "Port performance in container transport logistics: A multi-stakeholder perspective." *Transport Policy* 73 (2019): 25-40.
- Tripathy, Partha, Anjali K. Khambete, and Krupesh A. Chauhan. "An innovative approach to assess sustainability of urban mobility—Using fuzzy MCDM method." *Innovative Research in Transportation Infrastructure: Proceedings of ICIIF 2018*. Singapore: Springer Singapore, 2018. 55-63.
- Wang, Han, et al. "An integrated MCDM approach considering demands-matching for reverse logistics." *Journal of cleaner production* 208 (2019): 199-210.

de Almeida, Adiel Teixeira, Rodrigo José Pires Ferreira, and Cristiano Alexandre V. Cavalcante. "A review of the use of multicriteria and multi-objective models in maintenance and reliability." *IMA Journal of Management Mathematics* 26.3 (2015): 249-271.

Bottani, Eleonora, and Giorgia Casella. "Discrete-event simulation in logistics and supply chain management: a scientometric perspective." *Production & Manufacturing Research* 12.1 (2024): 2415038.

Qiao, Dongping, and Yajing Wang. "A review of the application of discrete event simulation in manufacturing." *Journal of Physics: Conference Series*. Vol. 1802. No. 2. IOP Publishing, 2021.

Gabriel, Gustavo Teodoro, et al. "Lean thinking by integrating with discrete event simulation and design of experiments: an emergency department expansion." *PeerJ Computer Science* 6 (2020): e284.

Flores, Maurício Randolpho, et al. "Port Logistics Emissions Control Using Machine Learning to Coordinate the Truck Flow." *International Joint conference on Industrial Engineering and Operations Management*. Cham: Springer Nature Switzerland, 2024.

Piccolo Anauate, Pedro, et al. "An integrated model to evaluate train dispatching rules: a Brazilian port case." *Journal of Simulation* (2025): 1-17.

Vera-Carrasco, Cristóbal, Cristian D. Palma, and Sebastián Muñoz-Herrera. "From Efficiency to Safety: A Simulation-Based Framework for Evaluating Empty-Container Terminal Layouts." *Journal of Marine Science and Engineering* 13.8 (2025): 1424.

Benghalia, Abderaouf, et al. "Machine Learning and Simulation for Efficiency and Sustainability in Container Terminals." *Sustainability* 17.7 (2025): 2927.

Gana, Felipe, et al. "Enhancing Port Logistics through Discrete Event Simulation: A Focus on Rail Operations." *Ports* 2025. 2025. 188-196.

Chu, Zhong, Ran Yan, and Shuaian Wang. "Evaluation and prediction of punctuality of vessel arrival at port: a case study of Hong Kong." *Maritime Policy & Management* 51.6 (2024): 1096-1124.

Arbabkhah, Homayoon, et al. "Automatic identification system-based prediction of tanker and cargo estimated time of arrival in narrow waterways." *Journal of Marine Science and Engineering* 12.2 (2024): 215.

Chen, Zhong Shuo, Jasmine Siu Lee Lam, and Zengqi Xiao. "Prediction of harbour vessel emissions based on machine learning approach." *Transportation Research Part D: Transport and Environment* 131 (2024): 104214.

Dinh, Gia Huy, et al. "Leveraging artificial intelligence to enhance port operation efficiency." *Polish Maritime Research* (2024).

Rao, Aniruddha Rajendra, Haiyan Wang, and Chetan Gupta. "Predictive analysis for optimizing port operations." *Applied Sciences* 15.6 (2025): 2877.

Abouelrous, Abdo, et al. "Real-time policy for yard allocation of transshipment containers in a terminal." *Transportation Research Part B: Methodological* 192 (2025): 103138.

Sawangwong, Anurak, and Poti Chaopaisarn. "The impact of applying knowledge in the technological pillars of Industry 4.0 on supply chain performance." *Kybernetes* 52.3 (2023): 1094-1126.

Thammatadatrakul, Patsorn, and Navee Chiadamrong. "Optimal inventory control policy of a hybrid manufacturing–remanufacturing system using a hybrid simulation optimisation algorithm." *Journal of Simulation* 13, no. 1 (2017)

Steringer, Robert, Helmut Zörrer, Sebastian Zambal, and C. Eitzinger. "Using Discrete Event Simulation in Multiple System Life Cycles to Support Zero-Defect Composite Manufacturing in Aerospace Industry." *IFAC-PapersOnLine* 52, no. 13 (2019)

O'Sullivan, Jamie. "A case-study in the introduction of a digital-twin in a large-scale manufacturing facility." (2020).