

Educação, Inovação e Sustentabilidade na Pesquisa Aplicada

FMEA e gestão de riscos em sistemas produtivos que utilizam machine learning: Uma revisão bibliográfica

William Emidio de Noronha

0000-0002-1714-0937

Marcelo Duduchi Feitosa

0000-0002-0969-4737

Eliacy Cavalcanti Lelis

0000-0002-6432-2354

José Manoel Souza das Neves

0000-0002-7277-9434

Marília Macorin de Azevedo

0000-0003-0225-8155

Resumo – Este estudo tem como proposta demonstrar os conhecimentos gerados por publicações científicas sobre FMEA e gestão de riscos, visando relacionar os assuntos com sistemas produtivos que utilizam Inteligência artificial. A metodologia empregada consiste em uma revisão sistemática da literatura, com uma abordagem qualitativa, descritiva e exploratória, destacando o uso da inteligência artificial em artigos que envolvem FMEA e gestão de riscos em sistemas produtivos. Foram analisados 12 artigos que abordam os termos FMEA, gestão de riscos, inteligência artificial e machine learning, revelando um crescente interesse pelo tema, especialmente nos últimos dois anos. Apesar de não terem sido aplicados filtros na pesquisa, a busca trouxe poucos trabalhos dando o entendimento de ser uma linha de pesquisa a ser explorada. O resultado deste trabalho apresenta a análise dos artigos que exploram diversas abordagens, métodos e técnicas de inteligência artificial utilizadas na avaliação e gerenciamento de riscos e FMEA em sistemas produtivos. Considerando críticas ao método FMEA, como sua ênfase em falhas imediatas, destaca-se que o aprendizado de máquina, baseado em dados históricos e modelos matemáticos, pode auxiliar na previsão e detecção de falhas, possibilitando uma análise mais precisa dos riscos. Esses trabalhos exploram campos da inteligência artificial, como, por exemplo, machine learning e regressão logística, e ressaltam a importância de técnicas precisas, flexíveis e abrangentes para identificar, prever e mitigar riscos em processos produtivos. A originalidade deste estudo se destaca pelo uso de tecnologias recentes.

Palavras-chave: FMEA, Gestão de riscos, Inteligência artificial, Machine Learning, Sistemas Produtivos.

Abstract – . This study aims to demonstrate the knowledge generated by scientific publications on FMEA and risk management, aiming to improve the quality of data in productive systems through the use of Artificial Intelligence. The methodology used consists of a systematic review of the literature, with a qualitative, descriptive and exploratory approach, highlighting the impact of artificial intelligence in work involving FMEA and risk management in production systems. New articles were analyzed that address the terms FMEA, risk management, artificial intelligence and machine learning, revealing a growing interest in the topic, especially in the last two years. Although no filters were applied in the research, the selected articles focused on the relationship between FMEA, risk management, artificial intelligence and machine learning. The search results present 12 articles that explore different approaches, methods and techniques used in risk assessment and management and FMEA. Considering criticisms of the FMEA, such as its emphasis on immediate method failures, it is highlighted that machine learning, based on historical data and models, can help predict and detect failures, providing a more accurate risk analysis. These works explore fields of artificial intelligence, such as machine learning and logistic regression, and highlight the importance of precise, flexible and comprehensive techniques to identify, predict and mitigate risks in production processes. The originality of this study is highlighted by the use of recent technologies.

Keywords: FMEA, risk management, Artificial Intelligence, Machine Learning, Production Systems

1 Introdução

A disponibilidade de dados do ambiente de fabricação que são gerados a partir dos processos, operações ou atividades de manutenção viabiliza novas possibilidades para análises avançadas, como, por exemplo, previsão de comportamento de falha. Possíveis previsões podem considerar falhas de componentes específicos ou até mesmo as propriedades atuais do produto e do componente. (FILZ *et al.*, 2021)

Com o avanço das tecnologias *big data*, *Machine Learning* e inteligência artificial elas veem sendo significativamente aplicadas em diversos campos portanto, desde 2018, pesquisadores começaram a melhorar o FMEA tradicional, utilizando machine learning (SHANG *et al.*, 2021).

Percebido, então, um momento no qual transformações se evidenciam, por exemplo, pela alta disponibilidade de dados há a possibilidade de análises que viabilizam avaliar e até mesmo prever um possível comportamento de falha em um equipamento. Justifica-se, portanto, um estudo cujo objetivo principal visa responder à questão “Quais os conhecimentos gerados nas publicações científicas sobre FMEA e gestão de riscos aliados ao recente desenvolvimento de inteligência artificial, em especial, machine learning quando aplicados em sistemas produtivos?”

Por ser um estudo de natureza qualitativa, descritiva e exploratória o presente trabalho complementa o objetivo principal com a definição dos termos pertinentes ao tema.

Observa-se que esse estudo traz relevância no sentido de que contribui com exposição de trabalhos que podem proporcionar melhorias na área produtiva das empresas, amplia a percepção da receptividade e a adoção de novas tecnologias, em especial *Machine Learning*. No âmbito teórico a relevância é percebida ao trazer significado a conceitos que envolvem o tema. Foi utilizado o método revisão sistemática de literatura de utilizando-se de *strings* de acordo com critérios de busca nas bases *Web of Science* e *Scopus*.

Também é objetivo deste trabalho estimular a curiosidade da academia, gerentes, estudantes, assim como profissionais do que de alguma forma atuam no sistema produtivo e que podem de alguma forma contribuir com a redução lacunas.

2 Objetivo

Como objetivo principal este trabalho tem o de demonstrar quais os conhecimentos gerados nas publicações científicas sobre FMEA e gestão de riscos aliados ao recente desenvolvimento de inteligência artificial, em especial, machine learning quando aplicados em sistemas produtivos. No que tange a objetivos específicos o trabalho discute e traz os conceitos dos termos relacionados ao objetivo principal.

3 Referencial Teórico

Em um trabalho focado na revisão da literatura o referencial teórico confunde-se com o próprio resultado da pesquisa. Sendo assim, o presente referencial teórico discute e traz os conceitos de FMEA, gestão de riscos, inteligência artificial e Machine Learning.

3.1 FMEA

De acordo com Savich e Glushkov (2021) análise de modos e efeitos de falha é uma análise muito popular e eficaz cuja principal vantagem é a organização de grupos de especialistas, que definem os riscos, seus efeitos e possibilita organizar ações preventivas e corretivas. Mas essa análise também traz algumas desvantagens, sendo que a primeira tange as incertezas, a outra é a necessidade de se escolher o evento corretivo entre aqueles que foram sugeridos.

De acordo com Stanojević e Ćirović, (2020) durante o ciclo de vida dos sistemas técnicos, a análise dos riscos precisa e detalhada e FMEA fornece elementos de entrada adequados para a tomada de ações apropriadas, que permite a redução de incertezas e ocorrências indesejadas.

Contudo, em muitos casos, este método mostra fraquezas relacionadas à inconsistência, que é resultado de uma subjetividade insegura durante a determinação de valores para parâmetros que dão Número de Prioridade de Risco, bem como outras deficiências. (STANOJEVIĆ e ĆIROVIĆ 2020)

Continuando o raciocínio Belu *et al.*, (2019) apontam que FMEA é um método proativo para eliminar falhas potenciais que surgem de vários sistemas, como produtos, processos, projetos ou sistemas. FMEA utiliza o número de prioridade de risco (NPR) para determinar a ordem de prioridade de risco de falha modos. NPR é calculado multiplicando os valores de três fatores de risco: gravidade (S), detecção (D) e ocorrência (O).

Concluem apontando que embora as técnicas de FMEA sejam usadas em diferentes indústrias, há muitas situações em que vários especialistas dão suas opiniões sobre um modo de falha, tornando as avaliações de risco muitas vezes vagas e imprecisas. (BELU *et al.*, 2019)

Bartolomé e Benítez, (2022) também conceituam e trazem que a FMEA é uma poderosa ferramenta de qualidade, amplamente utilizada na indústria, para a identificação de modos de falha, seus efeitos e causas.

O processo de análise de modo e efeito de falha é iniciado com várias entradas principais. Algumas dessas entradas tradicionais são os FMEAs de geração mais antiga, relatórios de falha de campo, ações e lições aprendidas. Durante as últimas duas décadas houve foram vários diagramas usados como entradas FMEA importantes. (JAYATILLEKA, 2020)

Com uma visão didática Lélis (2018) traz que FMEA é um método que analisa falhas que já aconteceram ou que ainda podem acontecer para eliminar, ou pelo menos reduzir, sua ocorrência e que pode ser utilizado para analisar um processo ou produto.

Temos, portanto, que o FMEA é utilizado em diferentes indústrias para reduzir o risco de potenciais falhas, mas muitas vezes as avaliações de risco podem se tornar vagas e imprecisas devido às opiniões de vários especialistas.

3.2 Gestão de riscos

A avaliação de riscos desempenha um papel crítico no processo de design, fabricação e produção de produtos para diferentes campos de engenharia. Tradicionalmente, as questões relacionadas à avaliação de risco são abordadas usando o modo de falha e a abordagem de análise de efeitos para realizar a análise de confiabilidade. (WEN *et al.*, 2021)

O gerenciamento de riscos é uma das dez áreas de conhecimento discutidas no *Project Management Body of Knowledge* (PMBOK), que serve como um guia

que deve ser seguido para aumentar as chances de sucesso do projeto. (SOUZA *et al.*, 2021)

A falta de gerenciamento de riscos ou sua aplicação inadequada é uma das razões pelas quais os projetos de desenvolvimento de software falham. (TAVARES *et al.*, 2021)

Santos *et al.*, 2019 trazem que a gestão de riscos é uma atividade vital que permite realizar um planejamento estratégico que reduza a probabilidade de ocorrência e o impacto negativo dos riscos, levando ao sucesso do projeto e desenvolvimento de sistemas computacionais de qualidade. Complementam afirmando que a gestão de riscos é um dos tópicos ensinados em cursos introdutórios e aulas avançadas de engenharia de software, comumente abordadas através de palestras e discussões de casos.

Como uma atividade crítica em diversos processos temos, portanto, que aplicá-la a fim de dirimir os riscos em projetos de produção, por exemplo. E, com sua definição o esforço será direcionado para os conceitos pertinentes à Inteligência artificial (IA).

3.3 Inteligência Artificial

Kaynak, (2021) aponta que o investimento e interesse em IA cresceram nas primeiras décadas do século XXI e acrescenta que seu uso é possibilitado pelo emergente e massivo poder de computação, a coleção de colossais conjuntos de dados (o fenômeno *big data*) e os avanços na análise de dados (de descritivo para preditivo, até mesmo prescritivo) foi aplicado com sucesso a muitos problemas na academia e na indústria. Também traz que o desenvolvimento mais recente é a integração da IA à transformação digital onde está é tida como o principal habilitador e facilitador.

Ferreira *et al.*, 2020 *apud* Russel e Norvig (2004) informam que a IA é definida não somente como sistemas com capacidade de armazenamento e manipulação de dados, mas também sistemas de aquisição, representação e manipulação de conhecimento.

Alarie *et al.*, (2018) afirmam que a IA está exercendo influência em todas as profissões e indústrias. Exemplificam com veículos autônomos, tradução instantânea de idiomas entre outros.

Kaynak, (2021) aponta que no início dos anos setenta e no final dos anos oitenta, a IA fez um retorno glorioso o início do segundo milênio, possibilitado pelo poder de computação massivo emergente, a coleção de colossais conjuntos de dados (o fenômeno *big data*) e os avanços na análise de dados (de descritivo para preditivo, até mesmo para prescritivo). O investimento e o interesse em IA cresceram nas primeiras décadas do século XXI, quando o aprendizado de máquina (*Machine Learning*) foi aplicado com sucesso a muitos problemas na academia e na indústria. As oportunidades oferecidas pelo aprendizado profundo (*Deep Learning*) intensificou o boom.

Em seu trabalho Stanojević e Ćirović, (2020) apontam que a modificação do método FMEA tradicional com a integração de técnicas de IA no caso, pela integração da lógica difusa e pela inclusão de alguns princípios com base na classificação especial de falhas reconhecidas. Aprimora a inconsistência metodológica e algumas das outras deficiências identificadas do método FMEA tradicional.

O método FMEA é aprimorado, o que fornece avaliação de risco de falha mais precisa e, portanto, melhor previsão e minimização de ocorrências indesejadas. (STANOJEVIĆ e ĆIROVIĆ, 2020)

3.3.1 Machine Learning

De acordo com Domingos, (2012) os sistemas de *machine learning* aprendem automaticamente a partir de dados. Isso geralmente o torna uma alternativa muito atraente e na última década, o uso de aprendizado de máquina se espalhou rapidamente em toda a ciência da computação.

Continuando o raciocínio, Murphy (2012) define aprendizado de máquina como um conjunto de métodos que podem detectar automaticamente padrões nos dados e, em seguida, usar os padrões descobertos para prever o futuro dados, ou para realizar outros tipos de tomada de decisão sob incerteza (como planejar como coletar mais dados).

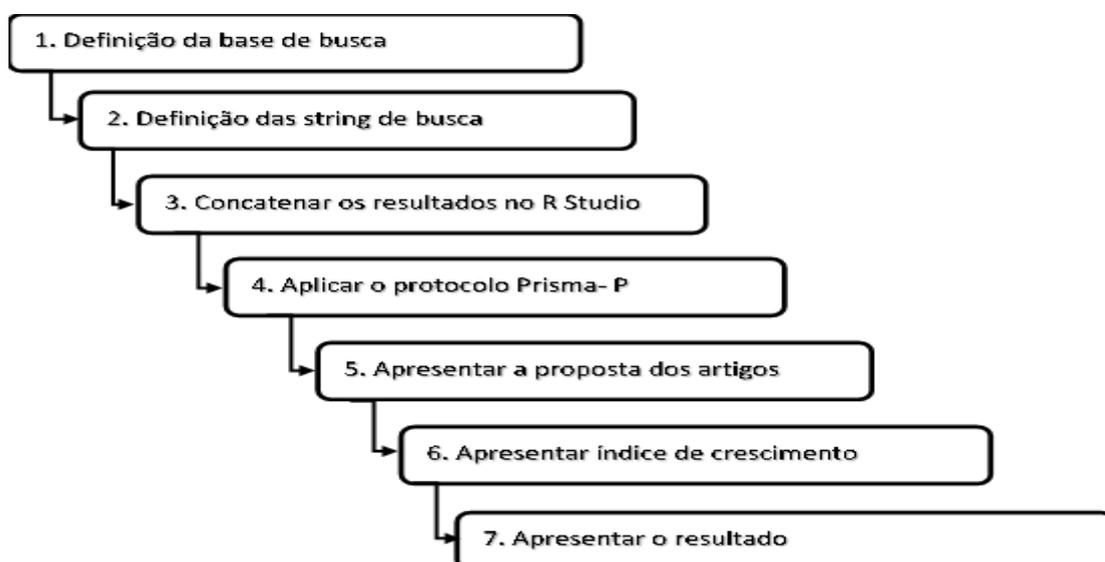
Com as definições percebe-se que a atual disponibilidade de dados propicia o uso de novas tecnologias, o que inclui *machine learning*, para uma diversidade de novas atividades incluindo a previsão de falhas em sistemas produtivos. Com as definições das variáveis o trabalho prossegue com o método utilizado para atingir o objetivo.

4 Método

Por ser uma revisão sistemática da literatura, esse trabalho traz informações qualitativas e que tangem aos estudos prospectados. É descritivo e exploratório pois visa a identificação, registro e análise das características, fatores ou variáveis que se relacionam ao método FMEA relacionando-o a gestão de riscos e aliados ao desenvolvimento de inteligência artificial, em especial, machine learning aplicada em sistemas produtivos. É também um trabalho de ordem quantitativa haja vista, por exemplo, demonstrar a evolução da quantidade de trabalhos ao longo do período pesquisado.

Temos, conforme a figura 1 as etapas que direcionaram ao atingimento do objetivo.

Figura 1- Etapas para atingir objetivo



Fonte: Autores

Na primeira etapa foram selecionadas as bases de dados da Web of Science e Scopus por serem fontes abrangentes e, portanto, que possibilitam encontrar os diversos artigos de acordo com os critérios pré-estabelecidos nas strings de busca.

Na segunda etapa utilizou-se de consultas nas bases de dados da Web of Science e Scopus, sendo estas, direcionadas pela *strings* conforme Quadro 1.

Quadro 1 - Strings de busca

Base de dados	String
Web of Science	ALL=("Machine learning" OR "Artificial Intelligence") AND ALL=(risk assessment) AND ALL=(FMEA)
Scopus	FMEA AND "RISK ASSESSMENT" AND "MACHINE LEARNING" OR "ARTIFICIAL INTELLIGENCE"

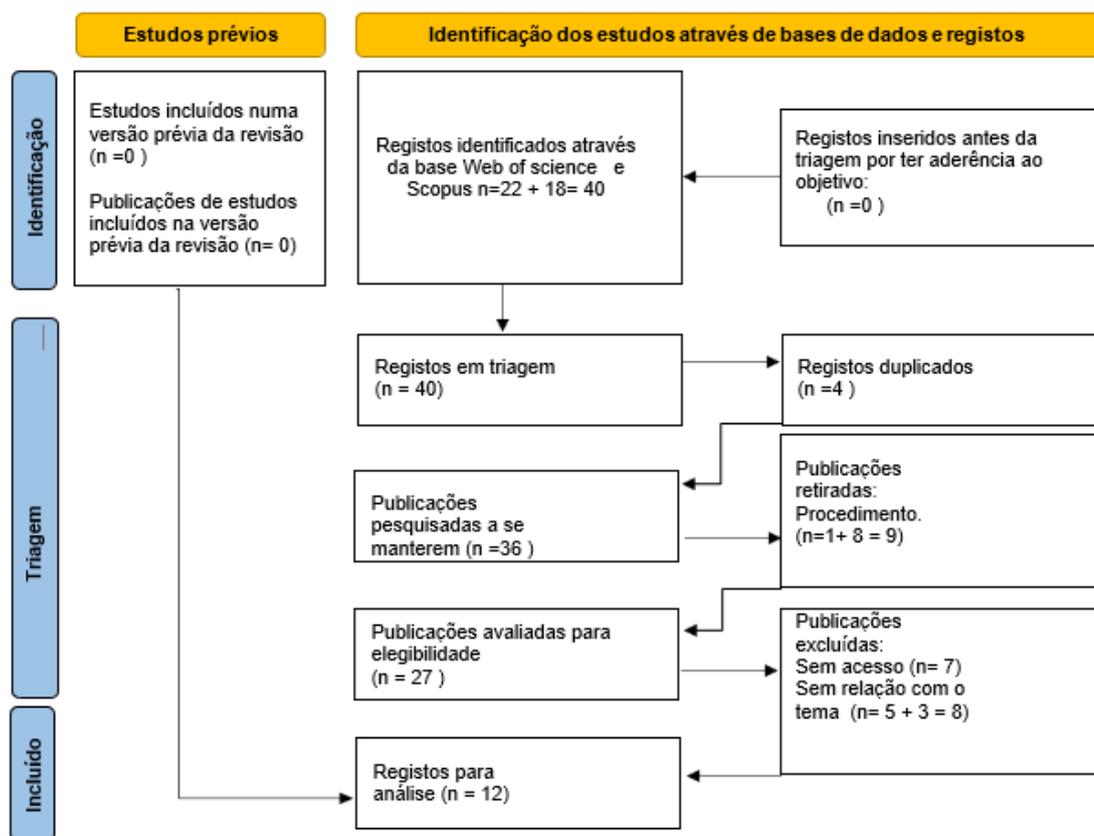
Fonte: Autores

Observa-se que a busca foi aberta no sentido de procurar em todos os campos os artigos da *Web of Science* somando um total de 22 artigos. No caso da busca na base de dados da *Scopus* a busca foi direcionada às palavras-chave o que possibilitou encontrar 18 trabalhos, sendo assim, foi possível encontrar ao todo 40 artigos sendo 4 ocorrências duplicadas nas bases. Posteriormente também foram retirados 9 trabalhos pois representavam procedimentos.

Na terceira etapa foi utilizado do software RStudio na versão 2022.07.1 Build 554 que auxiliou no processo de concatenação dos artigos da base Web of Science por meio da biblioteca bibliometrix juntamente com a função biblioshiny().

Na quarta etapa foi percebida a impossibilidade de acesso a 7 artigos. E, a partir da leitura do resumo concluiu-se que 8 trabalhos não estavam correlacionados com a proposta deste trabalho, sendo assim, foram descartados mais 15 trabalhos, conforme figura 2.

Figura 2 - Fluxograma para revisões sistemáticas que incluem buscas em bases de dados, protocolos e outras fontes



Fonte: Autores

Na quinta etapa após identificar os artigos conseguidos com as strings de busca foi possível, por meio da leitura dos resumos demonstrar, a proposta de uso de inteligência artificial em cada um dos 12 artigos. As propostas são:

a) **AN APPLICATION OF DATA ENVELOPMENT ANALYSIS AND MACHINE LEARNING APPROACH TO RISK MANAGEMENT**

Propõe um método integrado que combina a Análise de Envoltória de Dados (DEA) e o aprendizado de máquina para o gerenciamento de riscos. Inicialmente, o método de eficiência cruzada DEA é utilizado na avaliação dos fatores de risco obtidos da Análise de Modo e Efeito de Falha (FMEA). Esse método supera as desvantagens do FMEA e elimina limitações do DEA, proporcionando uma capacidade de discriminação das unidades de decisão. Para o tratamento e monitoramento de riscos, é utilizado um mecanismo de aprendizado de máquina para prever o grau de risco restante com base em dados simulados do cenário de tratamento de risco. A previsão usando aprendizado de máquina é mais precisa, pois o modelo possui um melhor poder preditivo em comparação ao DEA, que pode conter erros.

b) **RISK ASSESSMENT BY FAILURE MODE AND EFFECTS ANALYSIS (FMEA) USING AN INTERVAL NUMBER BASED LOGISTIC REGRESSION MODEL**

Discute as limitações do uso do Número de Prioridade de Risco (RPN) na Análise de Modo e Efeito de Falha (FMEA) e propõe uma abordagem

sistemática para melhorar seu cálculo. O RPN é normalmente determinado multiplicando-se as pontuações de gravidade, ocorrência e detecção, mas essa suposição pode não ser adequada para aplicações do mundo real. O artigo sugere considerar atributos de risco adicionais e desenvolver uma equação padrão para a medida do RPN usando regressão logística baseada em números intervalares. Ao utilizar a probabilidade de risco de falha ('P') em vez da forma de produto do RPN, a metodologia proposta tem como objetivo fornecer uma abordagem mais realista para a avaliação de riscos.

c) *A FLEXIBLE RISK ASSESSMENT APPROACH INTEGRATING SUBJECTIVE AND OBJECTIVE WEIGHTS UNDER UNCERTAINTY*

Com o objetivo de superar as limitações do método tradicional de análise de modo e efeitos de falha, este artigo propõe uma nova abordagem flexível de avaliação de riscos que integra pesos subjetivos e objetivos sob incerteza. Para lidar com informações incompletas, o método proposto utiliza as informações atualmente disponíveis para preencher as informações ausentes. Por outro lado, o método proposto utiliza um conjunto de termos linguísticos hesitantes fuzzy em vez de um único conjunto de termos linguísticos para lidar com informações hesitantes no processo de avaliação de riscos. Além disso, o método proposto utiliza o conceito de variância estatística para calcular os pesos objetivos dos fatores de risco.

d) *A METHODOLOGY FOR ASSESSING AND MONITORING RISK IN THE INDUSTRIAL WASTEWATER SECTOR*

Propõe um framework que inclui a comparação de dados da literatura e experimentais para quantificar o impacto dos principais parâmetros do processo nos resultados críticos do processo. Do ponto de vista empresarial, a gestão e minimização de riscos serão possíveis quando o número de parâmetros de impacto for baixo e as relações entre diferentes parâmetros forem claramente compreendidas. Os resultados mostram que mesmo apenas a avaliação de riscos técnicos pode fornecer um modelo de plataforma de avaliação para outros tipos de risco. Além disso, os conjuntos de dados estruturados e analisados estatisticamente podem ser usados no desenvolvimento de algoritmos de plataformas de aprendizado de máquina para informar resultados sustentáveis do processo ajustados para várias localidades geográficas e fatores humanos que afetam significativamente o setor industrial de água globalmente.

e) *RISK ASSESSMENT IN DISCRETE PRODUCTION PROCESSES CONSIDERING UNCERTAINTY AND RELIABILITY: Z-NUMBER MULTI-STAGE FUZZY COGNITIVE MAP WITH FUZZY LEARNING ALGORITHM*

Propõe uma abordagem baseada no Mapa Cognitivo Fuzzy de Vários Estágios e na teoria dos números Z (Z-MSFCM) para considerar simultaneamente o conceito de incerteza e confiabilidade nas quantidades de fatores de risco e nos pesos das relações causais no MSFCM. Além disso, uma nova abordagem de aprendizado para Z-MSFCM foi aplicada com base na combinação da Otimização por Enxame de Partículas (PSO) e função de transferência em forma de S (PSO-STF) para preservar o ambiente incerto do problema.

f) *A QUALITY BY DESIGN APPROACH USING ARTIFICIAL INTELLIGENCE TECHNIQUES TO CONTROL THE CRITICAL QUALITY ATTRIBUTES OF RAMIPRIL TABLETS MANUFACTURED BY WET GRANULATION*

Envolve a identificação dos atributos críticos de qualidade e parâmetros críticos do processo para os comprimidos de ramipril. Os dados históricos e o método de análise de modo e efeito de falha (FMEA) foram utilizados para avaliar os riscos. Propõe que as especificações compendiais e internas sejam selecionadas como metas de qualidade. Os parâmetros que afetam o produto e o processo foram utilizados para criar um projeto experimental. Os resultados obtidos podem ser usados para definir o espaço de projeto usando técnicas como planejamento de experimentos, método da superfície de resposta e redes neurais artificiais. O objetivo do projeto foi descobrir conhecimentos ocultos usando softwares de inteligência artificial e estabelecer um espaço de projeto multidimensional para garantir uma qualidade consistente do produto.

g) *EVALUATING THE RISK OF FAILURE MODES WITH EXTENDED MULTIMOORA METHOD UNDER FUZZY ENVIRONMENT*

O método convencional de número de prioridade de risco (RPN) tem sido amplamente criticado por suas deficiências em relação aos pesos dos fatores de risco, cálculo do RPN, avaliação dos modos de falha, entre outros. O artigo propõe que é necessário classificar os modos de falha com base em seus fatores de risco relacionados, buscando superar as limitações e melhorar a capacidade de avaliação da FMEA tradicional. Neste artigo, trata-se os fatores de risco e seus pesos como variáveis fuzzy e os avaliamos usando termos linguísticos fuzzy. Como resultado, propomos um novo modelo de prioridade de risco para avaliar o risco dos modos de falha com base na teoria de conjuntos fuzzy e no método MULTIMOORA.

h) *NOVEL METHODOLOGY FOR DEVELOPING A SAFETY STANDARD BASED ON CLUSTERING OF EXPERTS' ASSESSMENTS OF SAFETY REQUIREMENTS*

A decisão de adotar requisitos específicos de segurança nos padrões é frequentemente baseada no conhecimento e experiência do especialista técnico, sem analisar adequadamente os fatores de risco abordados por cada requisito. Isso pode levar a imprecisões e falta de confiabilidade. Esta pesquisa apresenta uma nova metodologia e uma proposta para melhorar o desenvolvimento de padrões de segurança. A metodologia prioriza os requisitos de segurança do sistema com base em fatores de risco identificados, e utiliza abordagens de agrupamento de dados de aprendizado de máquina quando há muitos requisitos avaliados.

i) *IMPROVED FAILURE MODE AND EFFECT ANALYSIS WITH INTERVAL-VALUED INTUITIONISTIC FUZZY ROUGH NUMBER THEORY*

Propõe o desenvolvimento de um novo conceito de número rugoso fuzzy intuicionístico de valor intervalar (IVIFRN), utilizando o mérito do conjunto fuzzy intuicionístico de valor intervalar para lidar com a incerteza e hesitação dos julgamentos individuais e o benefício do número rugoso para lidar com a imprecisão e subjetividade das avaliações do grupo, e apresenta um novo modelo de FMEA baseado em IVIFRN.

j) *PROSPECTIVE RISK ANALYSIS OF THE ONLINE-ADAPTIVE ARTIFICIAL INTELLIGENCE-DRIVEN WORKFLOW USING THE ETHOS TREATMENT SYSTEM*

Foi realizada uma análise prospectiva de risco do fluxo de trabalho adaptativo com o sistema Ethos utilizando a Análise de Modos e Efeitos de Falha

(FMEA). Uma equipe interprofissional propõe a coleta de possíveis eventos adversos e avaliou sua gravidade, probabilidade de ocorrência e detectabilidade.

k) CONTRIBUTION TO DEVELOPMENT OF RISK ANALYSIS METHODS BY APPLICATION OF ARTIFICIAL INTELLIGENCE TECHNIQUES

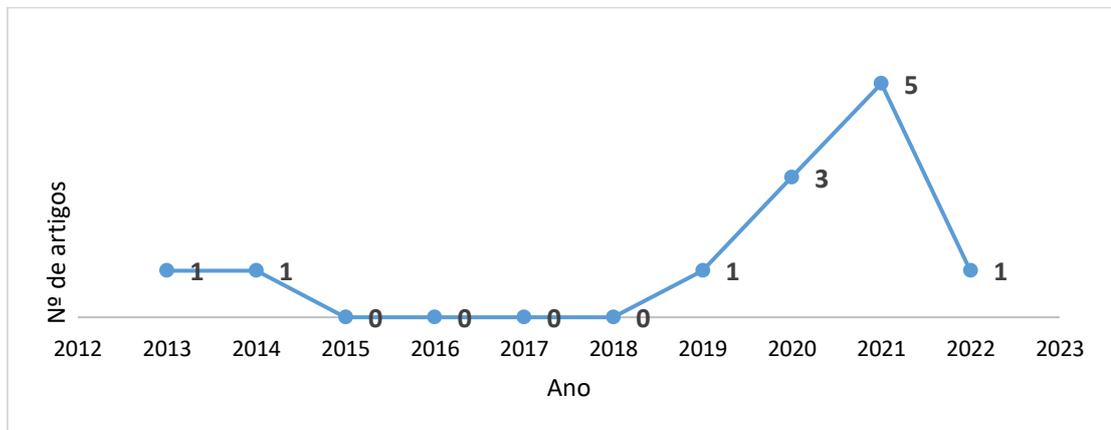
Durante o ciclo de vida de sistemas técnicos, a análise de risco de falha precisa e detalhada fornece elementos de entrada adequados para tomar ações apropriadas, permitindo a redução de incertezas e ocorrências indesejadas. Este artigo mostra uma contribuição para o desenvolvimento da análise de risco de falha baseada no método FMEA. A contribuição para o desenvolvimento de métodos de análise de risco é dada por meio da modificação do método tradicional FMEA.

l) AUTOMATED RISK ASSESSMENT FOR MATERIAL MOVEMENT IN MANUFACTURING

Os movimentos de proximidade entre veículos que transportam materiais em plantas industriais, ou "interfaces", resultam em lesões e fatalidades ocupacionais. A avaliação de riscos para interfaces é atualmente limitada a técnicas como auditorias de segurança, originalmente projetadas para ambientes estáticos. Uma alternativa baseada em dados para ambientes dinâmicos é desejável para quantificar os riscos das interfaces e possibilitar o desenvolvimento de contramedidas eficazes.

Demonstrada a proposta de cada artigo é possível verificar pela Figura 3 o crescimento anual no número artigos, com destaque para os últimos dois anos.

Figura 3 - Quantidade de artigos por ano



Fonte: Autores

No que tange as fontes de conhecimento o destaque fica para a revista Engineering Applications of Artificial Intelligence e Safety Science com respectivamente três e duas publicações, conforme figura 4.

Figura 4 - Principais fontes de conhecimento



Fonte: Autores

5 Resultados e Discussão

Como resultado da análise bibliográfica, há de se destacar algumas informações que relacionam o momento de transformação vivido pelas empresas como, por exemplo, a alta disponibilidade de informações o que proporciona o uso de inteligência artificial na detecção e até mesmo a predição de falhas em sistemas produtivos.

A seguir é feita uma análise com destaques do uso de Inteligência Artificial de cada um dos 12 artigos identificados:

a) ***AN APPLICATION OF DATA ENVELOPMENT ANALYSIS AND MACHINE LEARNING APPROACH TO RISK MANAGEMENT***

Aborda Machine Learning para prever fatores de risco e sua eficácia na mitigação e monitoramento de gerenciamento de riscos.

b) ***RISK ASSESSMENT BY FAILURE MODE AND EFFECTS ANALYSIS (FMEA) USING AN INTERVAL NUMBER BASED LOGISTIC REGRESSION MODEL***

O artigo menciona a modelagem de regressão logística usando o linguagem R e a avaliação do modelo por meio da matriz de confusão, destacando a taxa de classificação correta do modelo.

c) ***A FLEXIBLE RISK ASSESSMENT APPROACH INTEGRATING SUBJECTIVE AND OBJECTIVE WEIGHTS UNDER UNCERTAINTY***

O artigo destaca as principais contribuições de um método proposto de avaliação flexível de riscos. Essas contribuições incluem a consideração de pesos subjetivos e objetivos dos fatores de risco, lidar com informações incertas e faltantes durante o processo de avaliação e o uso de todas as informações disponíveis fornecidas por especialistas para evitar viés nos resultados da avaliação. Embora o texto não mencione explicitamente a inteligência artificial, os elementos presentes no método proposto, como o uso de termos linguísticos fuzzy e o processamento de dados para preencher informações ausentes, são técnicas comumente associadas à inteligência artificial. Portanto, é possível inferir que o método proposto possui uma relação com a inteligência artificial na forma de técnicas e abordagens utilizadas no processo de avaliação de riscos.

d) *A METHODOLOGY FOR ASSESSING AND MONITORING RISK IN THE INDUSTRIAL WASTEWATER SECTOR*

O artigo propõe um framework que inclui a comparação de literatura e dados experimentais para quantificar o impacto dos parâmetros do processo nas saídas críticas do processo. Além disso, sugere que os dados estruturados e analisados estatisticamente possam ser usados no design e desenvolvimento de algoritmos de plataformas de aprendizado de máquina.

e) *RISK ASSESSMENT IN DISCRETE PRODUCTION PROCESSES CONSIDERING UNCERTAINTY AND RELIABILITY: Z-NUMBER MULTI-STAGE FUZZY COGNITIVE MAP WITH FUZZY LEARNING ALGORITHM*

Propõe um algoritmo que apresenta vantagens na criação de diferenciação para a priorização de falhas, considerando relações de causa e efeito e aplicando incerteza no processo de avaliação de riscos em comparação com a técnica FMEA.

f) *A QUALITY BY DESIGN APPROACH USING ARTIFICIAL INTELLIGENCE TECHNIQUES TO CONTROL THE CRITICAL QUALITY ATTRIBUTES OF RAMIPRIL TABLETS MANUFACTURED BY WET GRANULATION*

O projeto possibilitou descobrir conhecimentos ocultos usando softwares de inteligência artificial e estabelecer um espaço de projeto multidimensional para garantir uma qualidade consistente do produto.

g) *EVALUATING THE RISK OF FAILURE MODES WITH EXTENDED MULTIMOORA METHOD UNDER FUZZY ENVIRONMENT*

Este artigo, trata os fatores de risco e seus pesos como variáveis fuzzy e os avalia usando termos linguísticos fuzzy. Os fatores de risco e seus pesos relativos foram tratados como variáveis difusas e avaliados de maneira linguística, em vez de valores numéricos precisos.

h) *NOVEL METHODOLOGY FOR DEVELOPING A SAFETY STANDARD BASED ON CLUSTERING OF EXPERTS' ASSESSMENTS OF SAFETY REQUIREMENTS*

A metodologia é flexível para empregar qualquer algoritmo apropriado baseado em contexto, incluindo aprendizado de máquina ou qualquer algoritmo matemático ou baseado em computador para mapear os valores dos fatores de risco em níveis gerais de risco correspondentes.

i) *IMPROVED FAILURE MODE AND EFFECT ANALYSIS WITH INTERVAL-VALUED INTUITIONISTIC FUZZY ROUGH NUMBER THEORY*

Este artigo desenvolve um novo conceito de número rugoso fuzzy intuicionístico de valor intervalar (IVIFRN), utilizando o mérito do conjunto fuzzy intuicionístico de valor intervalar para lidar com a incerteza e hesitação dos julgamentos individuais e o benefício do número rugoso para lidar com a imprecisão e subjetividade das avaliações do grupo

j) *PROSPECTIVE RISK ANALYSIS OF THE ONLINE-ADAPTIVE ARTIFICIAL INTELLIGENCE-DRIVEN WORKFLOW USING THE ETHOS TREATMENT SYSTEM*

O estudo apontou a necessidade de melhorias que, do lado do cliente, inclui especialmente estabelecer estratégias de validação para monitorar os resultados do processo de adaptação da caixa-preta usando inteligência artificial.

k) CONTRIBUTION TO DEVELOPMENT OF RISK ANALYSIS METHODS BY APPLICATION OF ARTIFICIAL INTELLIGENCE TECHNIQUES

O artigo apresenta o método FMEA aprimorado, proporcionando uma avaliação de risco de falha mais precisa e, conseqüentemente, uma melhor previsão e minimização de ocorrências indesejadas (falhas de elementos, subsistemas, componentes etc., de sistemas técnicos). Isso foi comprovado por meio da análise comparativa do método FMEA tradicional aplicado, bem como do método FMEA modificado, chamado de "inteligente" (IFMEA), em um sistema de pneus para ônibus urbanos.

l) AUTOMATED RISK ASSESSMENT FOR MATERIAL MOVEMENT IN MANUFACTURING

Interfaces e movimentos dos veículos foram simulados fisicamente para treinar e testar o modelo de aprendizado de máquina. O desempenho do sistema automatizado é comparado com a anotação humana para validar a abordagem.

6 Considerações finais

Com base na análise dos artigos identificados, pode-se observar que a aplicação da inteligência artificial e técnicas relacionadas desempenha um papel significativo na avaliação e gestão de riscos em diversos setores, especialmente em empresas que passam por processos de transformação. A alta disponibilidade de dados e o uso de técnicas avançadas, como aprendizado de máquina e algoritmos baseados em inteligência artificial, têm permitido a detecção e predição de falhas em sistemas produtivos, contribuindo para o aprimoramento dos processos e a mitigação de riscos.

Pode-se também destacar diversas abordagens e metodologias que utilizam a inteligência artificial de forma eficaz. Por exemplo, a aplicação de algoritmos de machine learning para prever fatores de risco e a modelagem de regressão logística para avaliar o risco de falhas. Além disso, foram identificadas técnicas como o uso de termos lógica fuzzy, processamento de dados e análise estatística, que estão frequentemente associadas à inteligência artificial.

Embora alguns artigos não mencionem explicitamente a inteligência artificial, é possível inferir sua presença por meio das técnicas e abordagens utilizadas nos processos de avaliação de riscos. A flexibilidade na consideração de pesos subjetivos e objetivos dos fatores de risco, o tratamento de informações incertas e a utilização de todas as informações disponíveis fornecidas por especialistas são exemplos de como a inteligência artificial pode estar incorporada nas metodologias propostas.

Outro ponto importante a ser ressaltado é a utilização de dados estruturados e analisados estatisticamente para o desenvolvimento de algoritmos de aprendizado de máquina, visando ao monitoramento e controle de riscos em setores específicos, como o de tratamento de águas residuais industriais.

Em síntese, os artigos analisados demonstram que a inteligência artificial desempenha um papel relevante na avaliação e gestão de riscos, proporcionando vantagens e aprimoramentos para o FMEA como previsão mais precisa, minimização de ocorrências indesejadas, tal como a redução da subjetividade dos especialistas possibilitando maior garantia de qualidade consistente dos produtos. A aplicação dessas técnicas e abordagens pode auxiliar as empresas na tomada

de decisões mais informadas e eficazes, contribuindo para a melhoria dos processos e o alcance de resultados coerentes com suas respectivas estratégias.

Referências

- Alarie, B.; Niblett, A.; Yoon, A. H. (2018). **How artificial intelligence will affect the practice of law**. In *University of Toronto Law Journal* (Vol. 68, pp. 106–124). University of Toronto Press Inc. <https://doi.org/10.3138/utlj.2017-0052>
- Bartolomé, E.; Benítez, P. (2022). **Failure mode and effect analysis (FMEA) to improve collaborative project-based learning: Case study of a Study and Research Path in mechanical engineering**. *International Journal of Mechanical Engineering Education*, 50(2), 291–325. <https://doi.org/10.1177/0306419021999046>
- Belu, N.; Ionescu, L. M.; Rachieru, N. (2019). **Risk-cost model for FMEA approach through Genetic algorithms-A case study in automotive industry**. *IOP Conference Series: Materials Science and Engineering*, 564(1). <https://doi.org/10.1088/1757-899X/564/1/012102>
- Domingos, P. (2012). **A few useful things to know about machine learning**. *Communications of the ACM*, 55(10), 78-87. doi:10.1145/2347736.2347755.
- Filz, M. A.; Langner, J. E. B.C, Herrmann; Thiede, S. (2021). **Data-driven failure mode and effect analysis (FMEA) to enhance maintenance planning**. *Computers in Industry*, 129. <https://doi.org/10.1016/j.compind.2021.103451>
- Jayatilleka, S. (2020). **Systems engineering modelling diagrams as prerequisites to failure mode and effect analysis**. *Proceedings - Annual Reliability and Maintainability Symposium, 2020-Janua*. <https://doi.org/10.1109/RAMS48030.2020.9153649>
- Kaynak, O. (2021). **The golden age of Artificial Intelligence**. *Discover Artificial Intelligence*, 1(1). <https://doi.org/10.1007/s44163-021-00009-x>
- Lélis, E.C., **Gestão da Qualidade**. Pearson Education. São Paulo - SP. 2018
- Mauri, L.; Damiani, E. (2022). **Modeling Threats to AI-ML Systems Using STRIDE †**. *Sensors*, 22(17), 1–21. <https://doi.org/10.3390/s22176662>
- Murphy, K. P. (2012). **Machine Learning: A Probabilistic Perspective**. MIT Press
- Salay, R.; Angus, M.; Czarnecki, K. (2019). **A Safety Analysis Method for Perceptual Components in Automated Driving**. *Proceedings - International Symposium on Software Reliability Engineering, ISSRE, 2019-Octob*, 24–34. <https://doi.org/10.1109/ISSRE.2019.00013>
- Santos, S.; Carvalho, F.; Costa, Y.; Viana, D.; Rivero, L. (2019). **Risking: A game for teaching risk management in software projects**. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3364641.3364662>
- Savich, E.; Glushkov, S. (2021). **Dmitry Antipov FMEA QUALITY IMPROVEMENT METHOD OF FLAME SPRAYING**. 15(4), 1263–1276.
- Shang, S. S.; Lyv, W. F.; Luo, L. J. (2021). **Improved grey fmea evaluation with interval uncertain linguistic variables and topsis**. *Engineering Letters*, 29(2), 516–525.

Sousa, A.; Faria, J. P.; Mendes-Moreira, J. (2021). **An analysis of the state of the art of machine learning for risk assessment in software projects.** *Proceedings of the International Conference on Software Engineering and Knowledge Engineering, SEKE, 2021-July*, 217–222. <https://doi.org/10.18293/SEKE2021-097>

Stanojević, D.; Ćirović, V. (2020). **Contribution to development of risk analysis methods by application of artificial intelligence techniques.** *Quality and Reliability Engineering International*, 36(7), 2268–2284. <https://doi.org/10.1002/qre.2695>

Tavares, B. G.; Keil, M.; Sanches da Silva, C. E.; Souza, A. D. (2021). **A Risk Management Tool for Agile Software Development.** *Journal of Computer Information Systems*, 61(6), 561–570. <https://doi.org/10.1080/08874417.2020.1839813>

Wen, T. C.; Chung, H. Y.; Chang, K. H.; Li, Z. S. (2021). **A flexible risk assessment approach integrating subjective and objective weights under uncertainty.** *Engineering Applications of Artificial Intelligence*, 103(May), 104310. <https://doi.org/10.1016/j.engappai.2021.104310>

You, J.; Lou, S.; Mao, R.; Xu, T. (2022). **An improved FMEA quality risk assessment framework for enterprise data assets.** *Journal of Digital Economy*, 1(3), 141–152. <https://doi.org/10.1016/j.jdec.2022.12.001>