

O Estado da Arte da Aplicação da Inteligência Artificial (IA) e Aprendizagem Automática (AA) ao Cálculo de Estrutura

Francisco Júnior Lopes dos Reis Soares

Dissertação submetida para satisfação parcial dos requisitos do grau de
MESTRE EM ENGENHARIA CIVIL-ESPECIALIZAÇÃO EM ESTRUTURAS E GEOTECNIA

Orientador: Professor Doutor João Manuel Pires Macedo

JULHO DE 2024

MESTRADO EM ENGENHARIA CIVIL 2023/2024

DEPARTAMENTO DE ENGENHARIA CIVIL

Tel. +351-22-508 1901

✉ m.ec@fe.up.pt

Editado por

Faculdade de Engenharia da Universidade do Porto

Rua Dr. Roberto Frias

4200-465 PORTO

Portugal

Tel. +351-22-508 1400

✉ feup@fe.up.pt

🌐 <http://www.fe.up.pt>

Reproduções parciais deste documento serão autorizadas na condição que seja mencionado o Autor e feita referência a Mestrado em Engenharia Civil – 2023/2024 - Departamento de Engenharia Civil, Faculdade de Engenharia da Universidade do Porto, Porto, Portugal, 2024

As opiniões e informações incluídas neste documento representam unicamente o ponto de vista do respetivo Autor, não podendo o Editor aceitar qualquer responsabilidade legal ou outra em relação a erros ou omissões que possam existir.

Este documento foi produzido a partir de versão eletrónica fornecida pelo respetivo Autor.

Dedicatória

Esta dissertação dedico a minha Mãe, Gabriela Reis, pelo amor e carinho, por acreditar em min mesmo nos momentos onde as minhas chamas perderam o ardor, incessantemente tiveste lá a soprar, mantendo o mesmo espírito, independentemente das circunstâncias. Dedico também a minnha namorada, Sara Figueiredo, pela compreensão e carinho nos momentos atribulados.

Aos meus amigos Francisco Pereira, Francisco Neves, Elgner Ramos, João Neves, já sabem "Brother from another Mother!". Ao meu Irmão, Valdir Reis, junto brincamos, junto crescemos, sempre na palhaçada, agradeço por seres homen de grande coração e lutador, a min inspiras-me.

A beleza é transitória mas a mente é transcendente.

Francisco Soares

Agradecimentos

Agradeço ao Sr. Professor Augusto Sousa por todo o suporte, consigo apreendi o verdadeiro significado de que nem todos os heróis usam capa. Ao Professor João Macedo agradeço pelo carácter e força de vontade, espero que na minha trajetória, algum dia os possa fazer sentir orgulho por terem apostado em min!

Resumo

O estudo realizado centra-se na aplicação da Inteligência Artificial (IA) e Aprendizagem Automática (AA) no cálculo estrutural, com o objetivo de demonstrar o impacto destas tecnologias na melhoria da eficiência, precisão e segurança em processos de engenharia civil. A investigação revela que as técnicas tradicionais, como o Método dos Elementos Finitos (FEA), ainda dominam a prática no cálculo estrutural, porém, apresentam limitações ao lidar com comportamentos não lineares e incertezas complexas. A IA e AA oferecem uma nova abordagem, permitindo uma análise mais robusta e precisa através de métodos como redes neurais artificiais (RNA), algoritmos genéticos, otimização por enxame de partículas (PSO) e outras técnicas de Aprendizagem Automática.

A metodologia utilizada baseou-se no protocolo PRISMA, assegurando uma análise abrangente e sistemática da literatura científica mais relevante entre 2015 à 2024. Esta revisão examina cinco áreas principais: previsão de comportamento estrutural, otimização de projeto estrutural, análise e deteção de falhas estruturais, modelação e simulação avançada, e avaliação de risco e segurança estrutural. Cada uma destas áreas é discutida em detalhe, destacando os métodos de IA aplicados, os principais resultados obtidos e as limitações de cada abordagem.

A previsão de comportamento estrutural através de IA tem mostrado melhorias significativas na precisão, particularmente em situações dinâmicas, como sismos e cargas cíclicas. Modelos preditivos baseados em AA, como redes neurais profundas, provaram ser eficazes na previsão de falhas e no comportamento de materiais. O uso da IA para otimização estrutural é outro campo promissor, onde técnicas como o PSO e redes neurais híbridas têm sido aplicadas com sucesso em projetos de otimização de vigas e treliças de betão armado, alcançando melhores resultados de custo e eficiência.

A dissertação também discute a análise e deteção de falhas estruturais, uma área onde a IA, particularmente as redes convolucionais e sistemas de visão computacional, demonstram grande potencial na deteção precoce de fissuras em estruturas de betão armado. A aplicação da IA na modelação e simulação estrutural avançada permite simulações mais detalhadas e com maior capacidade preditiva, otimizando processos de design e prevendo o desempenho estrutural com maior precisão.

Os resultados revistos demonstram que a IA, apesar do seu grande potencial, ainda enfrenta desafios, nomeadamente na necessidade de grandes volumes de dados para treinar os modelos e na dificuldade em interpretar os resultados dos modelos de AA. Contudo, as perspetivas futuras indicam que o desenvolvimento de técnicas híbridas e a integração com métodos tradicionais, como o FEA, podem superar estas limitações.

Palavras Chaves: Inteligência Artificial, Aprendizagem Automática , Cálculo Estrutural

Abstract

This study focuses on the application of Artificial Intelligence (AI) and Machine Learning (ML) in structural calculations, aiming to demonstrate the impact of these technologies on improving efficiency, accuracy, and safety in civil engineering processes. The research reveals that traditional techniques, such as the Finite Element Method (FEM), still dominate practice in structural calculations but show limitations when dealing with nonlinear behaviors and complex uncertainties. AI and ML offer a new approach, enabling more robust and precise analysis through methods such as Artificial Neural Networks (ANN), Genetic Algorithms, Particle Swarm Optimization (PSO), and other machine learning techniques.

The methodology used was based on the PRISMA protocol, ensuring a comprehensive and systematic review of relevant scientific literature from 2015 to 2024. This review examines five main areas: structural behavior prediction, structural design optimization, structural failure analysis and detection, advanced simulation and modeling, and risk assessment and structural safety. Each of these areas is discussed in detail, highlighting the AI methods applied, the main results obtained, and the limitations of each approach.

Predicting structural behavior through AI has shown significant improvements in accuracy, particularly in dynamic situations such as earthquakes and cyclic loads. Predictive models based on machine learning, such as deep neural networks, have proven effective in predicting failures and material behavior. The use of AI for structural optimization is another promising field, where techniques such as PSO and hybrid neural networks have been successfully applied to optimize the design of reinforced concrete beams and trusses, achieving better cost and efficiency outcomes.

The dissertation also addresses structural failure analysis and detection, an area where AI, particularly convolutional neural networks and computer vision systems, show great potential in early detection of cracks in reinforced concrete structures. The application of AI in advanced structural modeling and simulation allows for more detailed simulations with greater predictive capability, optimizing design processes and predicting structural performance with greater accuracy.

The results obtained indicate that AI, despite its great potential, still faces challenges, namely the need for large volumes of data to train models and the difficulty in interpreting machine learning model results. However, future perspectives suggest that the development of hybrid techniques and integration with traditional methods such as FEM may overcome these limitations. Continuous real-time data streams are recommended to improve the monitoring and predictive maintenance of structures, as well as the exploration of advanced AI techniques to predict failures under extreme conditions.

Keywords: Artificial Intelligence, Machine Learning, Structural Calculation

ÍNDICE GERAL

Agradecimentos	ii
Resumo	iii
1 Introdução	3
2 Metodologia	7
2.1 Métodos	7
2.2 Objetivos e Questões	8
2.3 Estratégia de Pesquisa	8
2.4 Critérios de Inclusão e Exclusão	8
2.5 Fontes de Pesquisa e Ferramentas	9
2.6 Fluxo do Trabalho	9
3 Enquadramento Geral	11
3.1 Marcos Históricos da Inteligência Artificial	12
4 Classificação e Categorização do IA	23
4.1 IA clássico	24
4.1.1 Algoritmos Genéticos e Otimização por Enxame de Partículas	24
4.1.2 Autómatos Celulares	25
4.1.3 Algoritmo de Evolução Diferencial	25
4.1.4 Sistemas Especialistas	26
4.1.5 Lógica Fuzzy	26
4.1.6 Gramática de Design Generativo	27
4.2 IA Moderno	28
4.2.1 Aprendizagem supervisionada	28
4.2.2 Aprendizagem não supervisionada	29

4.2.3	Aprendizagem por Reforço (Reinforcement Learning)	30
4.2.4	O aprendizagem profundo (Deep Learning)	30
5	IA e AA em Estruturas	35
5.1	Previsão de Comportamento Estrutural	35
5.1.1	Análise dos Estudos	37
5.2	Otimização de Projeto Estrutural	66
5.2.1	Análise de Estudos	66
5.3	Análise e Detecção de Falhas Estruturais	85
5.3.1	Análise dos Estudos:	85
5.4	Simulação e Modelação Estrutural Avançada	100
5.4.1	Análise dos Estudos	100
5.5	Avaliação de Risco e Segurança Estrutural	123
5.5.1	Análise dos Estudos	124
6	Conclusão	131
7	Anexo-A1	133

Introdução

Nos últimos anos, a engenharia estrutural tem experimentado uma revolução silenciosa impulsionada por avanços em inteligência artificial (IA) e aprendizagem automática (AA). Estas tecnologias, anteriormente confinadas ao domínio da informática, têm sido progressivamente integradas em diversas disciplinas de engenharia, impulsionando novas formas de resolver problemas complexos e otimizando processos. Esta dissertação explora a aplicação de IA e AA no cálculo estrutural, destacando a importância destas tecnologias na melhoria da precisão de cálculo, eficiência de execução, melhoria do critério de custos e bem como na segurança das estruturas.

Tradicionalmente, o cálculo estrutural dependia de métodos analíticos e numéricos convencionais, como o método dos elementos finitos (FEM). Esse método têm sido implementado de forma eficazes ao longo de várias décadas, embora haja avanços no processamento dos cálculos com recursos a placas gráficas, GPU's, este, apresenta certas limitações inerentes em termos de recursos computacionais quando se trata de previsão de respostas não lineares e comportamentos complexos em estruturas submetidas a condições de carga dinâmicas, tais como sismos, ventos extremos e cargas cíclicas.

Zienkiewicz, Taylor e J. Z. Zhu (2005), reconhecidos e respeitados no desenvolvimento do FEM, destaca que este método é essencial, mas a sua aplicação em cenários complexos, frequentemente requer simplificações que podem comprometer a precisão da previsão. Acrescentando que Adeli e S. Kumar (1995), um dos pioneiros na integração de IA demonstrou nos seus estudos as limitações da aplicação do FEM comparativamente a aplicação de redes neurais de artificiais (RNA), onde FEM possui dificuldades em lidar com incertezas de parâmetros de entrada, condições de carga, alteração dos materiais e condições de contornos, que face a alteração desses parâmetros ocorre variabilidade na precisão dos resultados, principalmente em situações de análise de falhas ou do comportamento sob condições extremas. Importante referir que o método FEM dado a sua natureza de cálculos, com o progressivo escalar de complexidade estrutural, onde existem um grande número de elementos, principalmente em casos de análise-não linear em domínios tridimensionais requer implementação de fortes recursos

computacionais.

Com o advento de computadores sofisticados de alta capacidade de processamento, resultado de anos de desenvolvimentos de hardware principalmente com avanços em microchips, acompanhados de algoritmos avançados de IA, emergem soluções promissoras para superar tais limitações. A inteligência artificial, que engloba uma ampla gama de técnicas desde algoritmos genéticos até a redes neurais, oferece novas abordagens para modelação e previsão de comportamentos complexos em sistemas estruturais. A aprendizagem automática, um subcampo da IA, permite que os sistemas aprendam padrões a partir de dados e façam previsões ou decisões com mínima intervenção humana. Estas tecnologias são particularmente úteis em cenários onde grandes volumes de dados estão disponíveis. G. Chen e Y. Liu (2020), nos seus estudos demonstram os benefícios da combinação de um sistema híbrido AA e FEA, para a melhoria da precisão de previsão de modelos de comportamento estrutural, complementando assim algumas das limitações do método FEA.

O crescente interesse na aplicação de IA e AA no cálculo estrutural é evidenciado pelo aumento significativo no número de artigos científicos e publicações académicas sobre o tema. Nos últimos anos, houve uma proliferação de pesquisas que exploram diversas facetas da integração dessas tecnologias na engenharia estrutural. Estudos têm abordado aspetos da previsão de comportamento estrutural, otimização de projeto estrutural, análise e deteção de falhas estruturais conhecido como monitorização estrutural, simulação e modelação estrutural avançada, design generativo, avaliação de risco e segurança estrutural. Esta tendência reflete não só a viabilidade técnica das aplicações de IA e AA, mas também o reconhecimento de sua importância e potencial para transformar práticas tradicionais, melhorando assim a eficiências dos resultados nos cálculos estruturais, tal como é possível averiguar nos estudos de P. Liu (2023), onde demonstra a capacidade de monitorização de edifícios a tempo real, com recursos a redes neurais profundas, permitindo assim prever danos e falhas estruturais, demonstrando a capacidade de revolucionar as práticas tradicionais onde exigiam modelos complexos de análise.

Perante as diversas fases que constituem o ciclo de vida de um projeto estrutural, tais como concepção estrutural, pré dimensionamento, validação das soluções estruturais, elaboração das peças desenhadas acompanhado dos seus respetivos pormenores construtivos, e tanto como trabalhos executados a posteriori de manutenção, controlo e reabilitação das estruturas são constituídos por tarefas exaustivas que requerem a coordenação de diversos agentes, então nesta dissertação, procura estabelecer as tecnologias emergentes relativamente a inteligência artificial que possam auxiliar nos cálculos, explorando assim os grandes tópicos da inteligência artificial.

No campo da simulação e modelagem, IA e AA oferecem novas maneiras de criar modelos precisos e detalhados de sistemas estruturais. As técnicas de IA permitem a criação de simulações que consideram

uma vasta gama de variáveis e condições, proporcionando uma compreensão mais completa do comportamento estrutural. Isso é particularmente útil em situações onde os métodos tradicionais de simulação seriam excessivamente complexos ou demorados.

O design generativo é uma área emergente que combina IA com princípios de design para criar soluções inovadoras. Usando algoritmos de IA, é possível gerar automaticamente várias opções de design que atendem a critérios específicos de desempenho e estética. Este processo não só acelera o desenvolvimento de novos designs, mas também pode resultar em formas e estruturas que seriam difíceis de conceber manualmente. O design generativo tem o potencial de revolucionar a forma como as estruturas são concebidas, oferecendo soluções mais eficientes e esteticamente agradáveis. A monitorização estrutural com foco em cálculo é um campo onde a IA pode proporcionar melhorias significativas. Sensores integrados em estruturas podem coletar dados em tempo real sobre a performance e integridade das mesmas. Algoritmos de AA podem analisar esses dados para detetar anomalias e prever falhas, permitindo a manutenção preditiva e melhorando a segurança. Este tipo de monitorização é essencial para garantir a longevidade e segurança das infraestruturas, especialmente em ambientes onde a deterioração pode ter consequências graves.

Então ao longo desta dissertação será demonstrado a metodologia de revisão quantitativa e qualitativa da literatura, efetuando um breve e sucinto enquadramento histórico da IA, contendo capítulo dedicado à compreensão de algumas técnicas de IA e bem como a categorização do IA. Serão abordados campos específicos de aplicação de IA dentro da engenharia Estrutural, tais como previsão de comportamento estrutural, otimização de projeto estrutural, análise e deteção de falhas estruturais, simulação e modelação estrutural avançada, avaliação de risco e segurança estrutural no cálculo estrutural. Tendo sempre em consideração os principais autores em cada campo, analisando os seus estudos e as suas limitações.

2

Metodologia

2.1 Métodos

Ao longo da conceção deste trabalho será efectuado uma pesquisa exaustiva de conteúdos relativamente à aplicação da inteligência artificial (AI) e AA, direccionados para o cálculo das estruturas de engenharia civil. Um dos principais objetivos consiste na exploração de materiais e conteúdos da AI e automação na engenharia civil direccionadas para a área de especialização Estruturas, logo, um dos pontos fulcrais consiste na seleção quantitativa e qualitativa, passando por análise sistemática e criteriosa dos materiais e métodos desenvolvidos, pavimentando bases necessárias para a compreensão, integração e identificação dos tópicos correntes da inteligência artificial recorrendo a sintetização do corpo de conhecimento geral estabelecendo assim o estado de arte dentro do âmbito da discussão desta dissertação.

A estratégia adotada para a elaboração da pesquisa de artigos e documentações é baseada no método do protocolo PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), onde são estabelecidos um conjunto de diretrizes standards composto por checklist e fluxogramas que proporcionam aos pesquisadores da comunidade académica um sistema claro na delimitação racional das metodologias a serem empregadas para a identificação, triagem, elegibilidade, exclusão e inclusão de conteúdos pertinentes, com foco na melhoria da qualidade e transparência dos trabalhos elaborados ao longo das revisões sistemáticas, assegurando uniformidade, credibilidade e consistência adequada nos aspetos críticos da concretização da revisão bibliográfica e literária.

2.2 Objetivos e Questões

Uma das premissas para a construção racional e organizativa da dissertação, parte pela definição nítida dos objetivos holísticos da literatura em foco, então como tal, é essencial enunciar por tópicos as questões objetivas, preenchendo assim uma das diretrizes do protocolo PRISMA.

Q1. Qual é o estado corrente de desenvolvimentos e implementação da inteligência Artificial e Automação para cálculo de estruturas?

Q2. Quais são as principais técnicas utilizadas pelos autores e quais foram os resultados obtidos?

Q3. Quais são os objetivos e resultados obtidos, bem como as suas fragilidades?

2.3 Estratégia de Pesquisa

De acordo com o conjunto de critérios estabelecidos pelo protocolo PRISMA, esta dissertação segue de forma sistemática um fluxo de trabalho, onde são descritos passo a passo o processo de compilação das literaturas do âmbito de estudos baseados num conjunto de palavras chaves e filtros avançados de pesquisa baseados em critérios de elegibilidade, inclusão e exclusão assentes na ótica do estudo, passando por análise multi-critério e rastreio dos resumos, onde são referenciadas as ferramentas utilizadas para obtenção da literatura bibliográfica.

O processo de triagem da literatura requer a recolha quantitativa e revisão qualitativa das documentações adequadas ao objetivo do estudo, criando assim o agrupamento máximo possível, cobrindo o vasto campo científico, provendo um processo averiguável, dentro das limitações inerentes aos recursos e as bases de dados selecionadas.

2.4 Critérios de Inclusão e Exclusão

Nesta revisão, foram incluídos os estudos que aplicam IA do subcampo de AA especificamente dedicados ao cálculo estrutural, sendo obtidos um enorme número de artigos científicos. Devido ampla utilização de filtros para cobertura de vasto número de documentação, foi a posteriori filtrado a quantidade, dada as limitações de qualquer escritor que abarcar um grande volume de artigos, incidindo naqueles considerados mais relevantes. Então foram também excluídos artigos onde as condições de livre acesso a comunidade eram limitadas e artigos onde o âmbito de estudo não iam de encontro com a óptica deste trabalho embora haja várias aplicações de IA nem todas são dedicadas ao cálculo estrutural. Tendo em conta que foram utilizadas múltiplas bases de dados para cobertura do âmbito em análise, ferramentas como Mendeley e EndNote (recorrendo às licenças de utilização providências pela comunidade académica da Universidade

do Porto) foram essenciais para anexação dos ficheiros, filtragem de ficheiros e reconhecimento de duplicados.

2.5 Fontes de Pesquisa e Ferramentas

A pesquisa foi realizada recorrendo às bases em dados académicas como Scopus, Web of Science, ACM digital Library, Engineering Village, Applied Science Journal, IOPscience, ScienceGate, SN Applied Science and Research Gate sendo utilizada ferramenta WEB, Connected Papers, onde proporciona ao investigadores a capacidade de conectar os artigos que antecederam e bem como os trabalhos realizados a posteriori como foco na mesma perspectiva apresentada pelo artigo em análise. Importante também referir a utilização da ferramenta web, open source, typeset, que auxiliou bastante na revisão da literatura mediante ao volume de dados.

2.6 Fluxo do Trabalho

Numa primeira instância foram selecionados um conjunto de TITLE-ABS-KEY, como é possível ver pela lista de combinações de palavras chaves disponibilizada em anexo, onde estes constituíram o elemento fulcral para obtenção do conjunto de artigos. Com a pesquisa foi possível obter aproximadamente 2262 documentos, contendo desde artigos a conference papers, de vários campos. Após a seleção no motor de pesquisa dos devidos campos e subcampos de interesse nas bases de dados, foi possível reduzir para metade o número de artigos. Com filtrações pertinentes e auxílio da ferramenta EndNote foi possível reduzir o número de duplicados resultando em aproximadamente 234 artigos. Após a revisão, foram selecionados de acordo com os seus respectivos campos:

C1. Previsão de Comportamento Estrutural: 30 artigos

C2. Otimização de Projeto Estrutural: 20 artigos

C3. Análise e Detecção de Falhas Estruturais: 20 artigos

C4. Simulação e Modelação Estrutural Avançada: 30 artigos

C5. Avaliação de Risco e Segurança Estrutural: 7 artigos

Enquadramento Geral

Isaac Newton disse: - "Se eu fui capaz de ver mais longe é porque estava de pé nos ombros de gigantes.", então um homem sábio encontra respostas do futuro nos acontecimentos do passado. Embora seja a frase contemplativa, busca trazer à tona o fato de que somos produtos de uma linha contínua temporal, onde feitos e conquistas são registradas de modo a munir o presente de ferramentas a auxiliar na progressão das próximas gerações. Todo e qualquer sociedade está assente sobre ombros de gigantes, embora hoje em dia os mídia e os agentes beneficiários, promovem a admiração, acompanhada de um toque de veneração do magnífico, estimulando ideias sugestivas de que a inteligência artificial surgirá de forma inusitada e espontânea, com objetivo a motivar investimentos, muitas das soluções, formulações e teorias matemáticas fundamentais da Inteligência Artificial são de décadas e por vezes séculos, tais como as funções Logísticas, concebidas pelo Pierre François Verhulst (1844-1845) que são primordiais para a construção de Redes Neurais, ferramenta da aprendizagem profunda (Deep Learning) importante para elaboração do reconhecimento facial, tais como outros trabalhos do Leonhardt Euler (1707-1783) sobre Logaritmo Natural, incluindo também contribuições de Thomas Bayes (1701-1761) fulcrais para otimização de Blockchain recorrendo a Naive Bayes. O AI é resultado também da compilação de diversos desenvolvimentos matemáticos que foram pavimentados no século XVII e século. XX.

Para compreender a razão da emergência exponencial de múltiplas tecnologias atuais consideradas inovadoras e disruptivas, requer estabelecer que IA é constituída por marcos, períodos onde, mesmo existente o conhecimento teórico para a sua aplicação, existiam limitações físicas, onde para o desenvolvimento do IA como conhecemos atualmente, tal era necessário a proliferação e desenvolvimento de hardware suficientemente capazes para sua implementação. Então em meados dos anos 2000 e 2010 começa a notar-se os primeiros sinais de desenvolvimentos inovadoras e disruptivas, devido à proliferação de modo economicamente viável para as massas, de Servidores Cloud suficientemente capazes a fazer face ao elevado consumo de recursos requeridos para o aprimoramento de "Machine Learning" e "Deep Learning", munido do vasto conhecimento e bases de dados disponibilizados pela maior biblioteca de

conhecimento do mundo, conhecida como a “World Wide Web”, promovendo a partilha de trabalhos e códigos fonte.

3.1 Marcos Históricos da Inteligência Artificial

Alan Turing (1912-1954) foi um grande matemático britânico que efetuou diversas contribuições para as áreas da Criptologia, Matemática, Lógica, Filosofia e Biologia, sendo o resultado destas, a formação de áreas como Ciência da Computação, Ciência Cognitiva, Inteligência Artificial e Vida Artificial.

Em 1936 Alan Turing publicou a tese, “ON COMPUTABLE NUMBERS, WITH AN APPLICATION TO THE ENTSCHIEDUNGSPROBLEM”, onde formalizou o conceito de computabilidade, estabelecendo os limites do que se pode computar por uma máquina face às suas limitações, respondendo ao clássico problema “THE ENTSCHIEDUNGSPROBLEM”, introduzido pelo David Hilbert e Wilhelm em 1928, onde Hilbert e Wilhelm propuseram a existência de um algoritmo geral capaz de decidir sobre qualquer preposição de um sistema de axiomas matemático permitindo a validação ou não. Nos trabalhos de Alan Turing e Alonzo Church, demonstra-se a insolubilidade deste problema. Turing propôs que qualquer função pode ser resolvida por meio de um algoritmo e todo algoritmo pode ser computado por uma máquina de Turing, estabelecendo assim um dos marcos para formalização do termo Ciência da Computação. Turing foi um dos principais participantes na concepção do Bombe, equipamento utilizado para descriptar o Enigma durante a Segunda Guerra Mundial. Em 1945, Turing foi recrutado para a criação do ACE “Automatic Computing Engine” primórdios para o desenvolvimento do primeiro computador.

Em 1943 Warren McCulloch e Walter Pitts publicaram “A Logical Calculus of the Ideas Immanent in Nervous Activity”, consistindo assim no primeiro modelo matemático para a concepção de Redes Neurais Artificiais, com isso estabeleceram a simulação artificial do funcionamento dos neurónios onde o processamento das unidades lógicas são capazes de desempenhar operações booleanas básicas, replicáveis e computáveis, possibilitando formulações matemáticas e logarítmicas, gerando assim, Redes Neurais.

Em 1950, Turing publicou “Computing Machinery and intelligence” onde propôs como a famosa provocante frase “Can a machine think?”, acompanhado do “Turing test” que proporciona um elaborado teste de avaliação se as máquinas exibem capacidade de comportamento inteligente indistinguível do comportamento intelectual de um ser humano, sendo que Turing suscita questões sobre a própria consciência artificial.

Em 1951, Marvin Minsky e Dean Edmonds, construíram o SNARC (Stochastic Neural Analog Reinforcement Computer), onde um simulador de rede neural baseado em hardware, considerado um dos primeiros computadores a simular a operação de redes neurais. O SNARC usava tubos de vácuo e motores elétricos para modelar neurônios e sinapses, e foi uma tentativa inicial de replicar processos da aprendizagem e comportamento do cérebro.

Em 1952, Arthur Lee Samuel, engenheiro eletrotécnico da MIT concebeu um programa básico de damas para o computador da IBM 701, onde recorrendo a técnica da aprendizagem automática e métodos heurísticos consegue a capacidade de autoaprendizagem, avaliação e melhoria das posições das peças no tabuleiro.

Em 1955, com a cooperação de 10 célebres intelectuais acadêmicos (Jhon McCarthy, Alan Newell, Marvin Minsky, Arthur Samuel, Oliver Selfridge, Claude Shannon, Herbert Simon, Nathaniel Rochester, Ray Solomonoff, Trenchard More) com apoios dos fundos monetários provenientes da fundação Rockefeller conceberam uma proposta/projeto/workshop onde se deu origem ao termo Inteligência Artificial. Durante um período de 2 meses intensivos de Workshop, onde efetuaram revisão do conhecimento do âmbito, estabeleceram o programa de Inteligência Artificial e Algoritmia, sendo que em 1956 foi oficializado como unidade de especialização acadêmica na Faculdade de Dartmouth nos Estados Unidos da América.

Em 1956, Herbert A. Simon e Allen Newell desenvolveram o primeiro software de AI, “Logic Theorist”, projetada a provar os teoremas da lógica, simulando o processo lógico do raciocínio humano, onde demonstra que através de processos computacionais é possível replicar o cognitivo humano proveniente da manipulação simbólica da informação. As contribuições de Simon e Newell, revelaram o potencial dos computadores realizarem tarefas onde previamente eram elaboradas unicamente pelos recursos intelectuais humanos.

Em 1957, Frank Rosenblatt inventou o “perceptron” um dos primeiros modelos de redes neurais artificiais enquanto trabalhava no Cornell Aeronautical Laboratory; este modelo inspirado na biologia dos neurônios cerebrais foi das primeiras tentativas em simular o funcionamento neuronal, com base no hardware “Mark I Perceptron” e com a combinação de circuitos eletrônicos e mecanismos de pesos onde os mesmo serviam para aprender a classificar as entradas. As contribuições do Frank Rosenblatt foram cruciais para o desenvolvimento das redes neurais de multicamadas e bem como o desenvolvimento do “Deep Learning”.

Em 1964, Daniel G. Bobrow desenvolveu um programa inovador, STUDENT, onde demonstrava a capacidade dos computadores compreenderem e solucionar problemas expressas em linguagem natural. Com as diversas contribuições de Daniel G. Bobrow no campo da inteligência artificial e ciências

da computação, recebeu diversos prêmios e reconhecimentos ao longo da sua carreira sendo reconhecido como pioneiro no desenvolvimento do NLP, Processamento de Linguagem Natural.

Em 1965 com a colaboração de Edward Feigenbaum, Bruce G. Buchanan, Joshua Lederberg and Carl Djerassi, foi concebido o projeto Dendral, consistindo num dos primeiros sistemas de automatização e interpretação de dados de espectrometria de massa das estruturas moleculares de compostos químicos, pois esta tarefa de determinação das estruturas moleculares era bastante tediosa. O funcionamento do sistema era predominante em conhecimentos especializados em química orgânica para inferir estruturas moleculares a partir de dados experimentais, então aplicando técnicas de raciocínio heurístico, reduz-se o campo de busca de modo que seja possível encontrar a solução mais viável, também aplicava árvores de decisão, “Decision Trees”, para representar as estruturas moleculares com bases em regras químicas e heurísticas.

Em 1966, Joseph Weizenbaum, matemático, desenvolveu no MIT um programa de Processamento de Linguagem Natural, com base em scripts de análise dos inputs dos utilizadores onde se gerava outputs em resposta aos utilizadores, sendo assim criado o primeiro programa de interação entre AI e humanos, “chatbot”, chamado de ELIZA. Neste mesmo período desenvolve-se “Shakey”, o primeiro robô móvel, pela Stanford Research Institute, com o financiamento do ARPA (Advanced Research Project Agency). Este projeto representou um marco histórico para a robótica, onde foi possível demonstrar a viabilidade de um robô autónomo equipado de sensores de toque “bumpers”, scanner de alcance “rangefinder” e câmaras. Todo o sistema operava com um computador “on-board” possuindo perceção visual com planeamento e execução em tempo real de tarefas, incorporado com navegação autónoma, ou seja o sistema de decisões e planeamento acarretava algumas técnicas de Inteligência Artificial como STRIPS (Stanford Research Institute Problem Solver), Processamento de Linguagem Natural, visão computacional etc.

Em 1968 Terry Winograd, cientista da computação e professor emérito de Stanford, desenvolveu como parte da sua tese de doutoramento no MIT, uma técnica de Linguagem Natural chamada SHRDLU, com o princípio de combinação sintaxe, semântica e análise contextual, onde o sistema é capaz de decompor as frases e construí-las em comando, possibilitando ao utilizar num mundo virtual, mover e interagir com blocos, capaz de armazenar o histórico de comandos. Este foi um grande avanço no Processamento de Linguagem Natural, sendo o seu contributo fulcral no desenvolvimento de assistentes virtuais, interface de utilizadores e sistemas de diálogo automatizados.

Em 1969, Arthur E. Bryson e Yu-Chi Ho publicaram o livro "Applied Optimal Control: Optimization, Estimation, and Control" considerado uma referência clássica na área de optimização de sistemas dinâmico, onde implementa a teoria de controle Ótimo para minimizar ou maximizar uma determinada função de custos ao longo do tempo e bem como a aplicação da programação de dinâmica, algoritmo de

Gradiente e princípio de Pontryagin embora tais autores não sejam diretamente associados a inteligência artificial, essas técnicas são de extrema relevância para algoritmos da aprendizagem de retro propagação e reforço de sistemas dinâmicos, conceitos elementares para o desenvolvimento da arquitetura das Redes Neural de multicamadas.

Em 1973 no Japão, na Universidade de Waseda, foi desenvolvido o primeiro robô humanoide de propósito geral, munido de aspectos de mobilidade, manipulação, percepção e interação, composto por atuadores elétricos que permitiam o movimento das articulações dos braços, pernas e cabeça. O sucesso deste projeto inspirou milhares de gerações no ramo da robótica e inteligência artificial, pois o sistema complexo, onde integrava sistemas específicos para locomoção, manipulação e percepção, equipados de sensores visuais e sistemas auditivos, de captação de áudio para conversão em comandos verbais proveniente da interação. Os conceitos abordados e incorporados neste sistema foram fulcrais para o aprimoramento e refinação do IA e Robótica.

Entre 1973 a 1980 aconteceu uma pronunciada diminuição dos investimentos direcionados à investigação e desenvolvimento no campo da Inteligência Artificial, chamado do Inverno da IA, onde diversos governos adotaram postura céptica mediante promessas exageradas e desempenhos aquém do expectável, embora houvesse indícios que os robôs e inteligência artificial passariam a ser o futuro. No período em questão, havia limitações do hardware que incapacitavam o desempenho do software mediante a limitada capacidade do processamento e memória, que resultava na impossibilidade de aplicação de algoritmos complexos para realização de tarefas complexas, para além da falta de dados e limitações de sistemas especializados. Então neste período foram realizados relatórios de avaliação do ponto situação por vários governos, onde os resultados obtidos foram negativos, resultando no corte dos orçamentos e readequação dos recursos considerados prioritários para o período, tais como microeletrônica e a computação convencional, sendo que desta mudança de financiamentos resultaram os microprocessadores, transistores e circuitos integrados.

Em 1980 foi introduzido “Symbolics Lisp Machines” pela MIT lab e Symbolics, Inc., uma linha de computadores com hardware e software otimizados especificamente para executar código Lisp, que consistia numa linguagem de programação amplamente utilizada para desenvolvimento de IA, onde arquitetura das máquinas eram suficientemente capazes a nível de processamento, memória e performance para manipular a estruturas de dados complexas para a implementação de IA, constituindo assim os primeiros indícios para o renascimento do IA.

Em 1981, Danny Hills engenheiro eletrotécnico pioneiro da computação paralela e Inteligência Artificial, desenvolveu no MIT uma máquina de processamento paralelo massivo, Connection Machine, um super-computador projetado para conectar um conjunto de processadores em rede, onde o primeiro modelo

tinha a capacidade de aglomerar até 65.536 processadores simples funcionando em paralelo, permitindo comunicação eficiente entre eles. Este supercomputador é utilizado para executar tarefas complexas permitindo o desenvolvimento de algoritmos complexos da aprendizagem de máquina, redes neurais e entre outras técnicas de IA modernas. O impacto deste desenvolvimento foi reconhecido por várias organizações sendo o resultado da arquitetura deste sistema a origem dos GPU's e ramos da computação gráfica.

Em 1985, Judea Pearl pioneiro no raciocínio Probabilístico, introduziu as Redes Bayesianas que são um conjunto de modelos gráficos que representam a relação probabilística entre variáveis permitindo inferências probabilísticas eficientes. Esta ferramenta é fundamental para os campos de IA, medicina e biologia pois possibilita a previsão, diagnóstico médico, reconhecimento de padrões e entre outros problemas onde a modelação de incerteza é crucial. Para além dos seus contributos com as redes de Bayesianas é importante referir as suas contribuições revolucionárias para teoria de causalidade, que consiste na aplicação de estruturas matemáticas rigorosas para inferir relações causais a partir de dados observacionais.

Em meados de 1989 com a cooperação de Yann LeCun, Yoshua Bengio e Patrick Haffner, desenvolveram as Redes Neurais Convolucionais, que são ferramentas do “Deep Learning” amplamente utilizados no campo da visão computacional. Com os seus contributos foi possível utilizar um computador para reconhecimento de caracteres dos dígitos manuscritos, como por exemplo cheques bancários. Estes cientistas influenciaram de forma profunda a academia e a indústria, com as suas pesquisas influenciaram significativamente as áreas de visão computacional no reconhecimento de padrões, utilizados no reconhecimento de vídeo e áudio; também é importante referir que os seus contributos no processamento de linguagem natural influenciaram de forma indireta a criação de ferramentas de análise de sentimentos e classificação de texto utilizadas nas redes sociais bem como na classificação de grande volume de documentos, tradução automática e resumo de textos.

Em meados de 1997 Sepp Hochreiter e Jürgen Schmidhuber, cientistas Alemães da Universidade Técnica de Munique propuseram as Redes Neurais Recorrentes de Longo Prazo (LSTM-Long Short Term Memory), onde identificaram o problema do gradiente desvanecente, problema que consiste numa limitação crítica das Redes Neurais Recorrentes (RNNs) que dificultava a aprendizagem de dependências de longo prazo, propondo LSTM que consiste numa arquitetura de rede neural recorrente que ultrapassa este problema, recorrendo a uma estrutura que inclui células de memória, portas de entrada, portas de saída e portas de esquecimento, regulando o fluxo de informação que preservam os gradientes. Com isto, as redes neurais aprendiam e armazenavam informações por longos períodos. O impacto desses desenvolvimentos refinaram as técnicas de Processamento de Linguagem Natural introduzindo

capacidades de lembrança de longo prazo que são de extrema importância para modelação de sequências temporais onde é necessário capturar dependência de longo alcance entre palavras e frases, introduzindo o desenvolvimentos de novas arquiteturas e métodos de treino, constituindo isto um grande avanço na tradução automática, reconhecimento facial, análise de sentimentos, geração de texto e de extrema importância para indústrias como saúde, finanças e tecnológicas, com fortes aplicações para análise de dados e tomadas de decisões.

Neste mesmo período 1997 o supercomputador IBM Deep Blue, projetado especificamente para jogar o xadrez, venceu Garry Kasparov o campeão mundial de xadrez, demonstrando assim a capacidade da inteligência Artificial superar os humanos numa das tarefas mais árduas do ponto intelectual.

Em 2011, IBM Watson, uma plataforma de inteligência artificial desenvolvida pela IBM um sistema de vários algoritmos da aprendizagem de máquina, processamento de linguagem natural e recuperação de informações onde o hardware possuía uma arquitetura massivamente paralela que permitia análise simultânea de grandes volumes de dados, venceu os campeões Ken Jennings e Brad Rutter num programa icónico de perguntas chamado “Jeopardy!”.

Neste mesmo período a Apple lançou a Siri, um assistente virtual que assimila e reconhece os comandos emitidos pelos padrões vocais gerando resposta mediante a interação, baseados no processamento de linguagem natural e aprendizagem de máquina, tendo este sistema sido desenvolvido pela organização independente SRI International envolvida no projecto CALO (Cognitive Assistant that Learns and Organizes) com fundos monetários da DARPA que posteriormente foi adquirida pela Apple com aplicação comercial e implementadas nos seus dispositivos eletrónicos.

Em 2012, Alex Krizhevsky, Ilya Sutskever e Geoffrey Hinton apresentaram AlexNet, uma rede neural convolucional profunda que revolucionou a visão computacional. AlexNet venceu a competição ImageNet Large Scale Visual Recognition Challenge (ILSVRC) com uma margem significativa, demonstrando o poder das CNNs para realizar tarefas de reconhecimento de imagem. A arquitectura deste sistema consistia na construção de oito camadas treináveis de redes neurais recorrendo a técnicas como ReLu (Rectified Linear Unit) para ativação e dropout de modo a evitar um dos grandes problemas de treinamento chamado de “overfitting”. Com esta contribuição deu-se início a uma nova era da aprendizagem profundo com foco nas Redes Neurais Convolucionais, recorrendo a técnicas de treino e algoritmia como Backpropagation que treinava de forma eficiente as redes profundas. Com as colaborações desta equipa de cientistas foi possível desenvolver bastantes técnicas da aprendizagem supervisionado e não supervisionado tais como auto encoders, máquinas de Boltzman restritas (RRBMs) e deep belief network (DBNs)

Em 2013 Diederik Kingma and Max Welling apresentaram os Variational Autoencoders (VAEs) no

seu artigo "Auto-Encoding Variational Bayes". Os VAEs são uma classe de modelos generativos que combinam autoencoders com métodos de inferência variacional. Os VAEs visam aprender uma representação compacta e contínua dos dados, permitindo a geração de novos exemplos a partir de amostras do espaço latente. Os VAEs consistem em uma rede neural encoder que mapeia os dados de entrada para uma distribuição latente, e uma rede neural decoder que reconstrói os dados a partir de amostras da distribuição latente. Os VAEs permitem a interpolação e edição de dados no espaço latente, facilitando a manipulação de imagens, como mudar atributos faciais ou criar transições suaves entre diferentes imagens; são amplamente utilizados para gerar imagens e vídeos realistas, permitindo a criação de novos dados a partir de amostras do espaço latente, podem ser utilizados para detectar anomalias em dados, identificando exemplos que não se ajustam bem à distribuição aprendida pelo modelo.

Em 2014, Ian Goodfellow introduziu as Redes Adversariais Generativas (GANs) em seu artigo "Generative Adversarial Nets". Esta arquitetura da aprendizagem profunda é composta por duas redes neurais que competem entre si numa rede geradora e uma rede discriminadora, onde a rede geradora cria dados sintéticos que se assemelha aos dados reais e a rede discriminatória fica encarregue de distinguir quais são os dados reais e os dados sintéticos, com isto, estas duas redes ficam encarregues de treinarem entre si próprio de modo a aumentar as suas habilidades, gerando após cada interação dados cada vez mais realistas. O resultado desta abordagem são plataformas capazes de gerar imagem de pessoas, objetos e cenários vídeo-gráficos ultrarrealistas que suscitam questões sobre ética, políticas de segurança, privacidade, direitos de imagem e bem como introduz questões sobre a própria arte reproduzindo obras capazes de suscitar questões sobre a realidade, introduzindo novos domínios e universos. Como por exemplo "DeepFakes" que são capazes de reproduzir imagens e áudios de figuras públicas e políticas capazes de manipular e intervir no cenário político e económico de um país.

Em 2015, DeepMind introduziu a DQN (Deep Q-Network), consistindo numa rede neural que aprende a jogar vários jogos do Atari 2600 diretamente de pixels brutos e pontuações, recorrendo a um sistema de redes neurais profundas com aprendizagem por reforço, onde agentes aprendem a tomar ações num dado contexto com base num sistema de recompensa cumulativa, superando assim o desempenho humano em muitos desses jogos. Esta mesma empresa, DeepMind, foi adquirida pela Google. Para além desse marco, a própria empresa é responsável por várias conquistas em jogos complexos como Go, xadrez e shogi que requerem pensamento estratégico profundo e avaliações de posições. A abordagem destes desenvolvimentos de IA generalizado permite que a própria IA seja capaz da aprendizagem em vários domínios e tarefas, resultando na capacidade de melhorar diagnósticos médicos, previsão de doenças e otimização de tratamentos bem como nas áreas de energia onde são utilizadas para o aumento da eficiência do consumo energético e redução da pegada de carbono.

Em 2017 foi introduzida pelo Ashish Vaswani um artigo "Attention is All You Need" onde propôs a arquitetura revolucionária de processamento de linguagem natural (PLN) ao substituir as redes neurais recorrentes (RNNs) e convolucionais (CNNs) por mecanismos de atenção auto-regressiva (self-attention), intitulado de arquitetura Transformer. Esta arquitetura permite que o modelo dê diferentes pesos a diferentes palavras na sequência de entrada ao processar cada palavra, capturando dependências de longo alcance de maneira mais eficaz do que as RNNs, onde cada palavra na sequência é comparada com todas as outras palavras para se possa calcular uma ponderação, permitindo ao modelo focar nas partes mais relevantes da entrada. Esta abordagem é a essência do Chat-GPT (Generative Pre-trained Transformer), são também aplicadas para prever estruturas de proteínas e modelar interações químicas, demonstrando sua versatilidade e poder em domínios científicos, como por exemplo na classificação de imagens e detecção de objetos no campo da visão computacional.

Em 2018 no campo da Inteligência Artificial foi a atribuição do Prémio Turing a Geoffrey Hinton, Yann LeCun e Yoshua Bengio pelas suas contribuições pioneiras no desenvolvimento da aprendizagem profunda (Deep Learning). Este prémio, considerado o "Nobel da Computação", reconheceu o impacto transformador da aprendizagem profunda na IA moderna.

Nesta mesma data vários estudos, relativamente à aprendizagem profunda, expandiram do simples ambiente teórico e académico e obtiveram ampla aplicações práticas no ramo da saúde para detecção de doenças. Foi estabelecido pela DeepMind vários parceiros estratégicos sendo o mais notável Moorfields Eye Hospital em Londres, onde analisaram, diagnosticaram e recomendaram tratamentos para mais de 50 doenças oculares, sendo um dos exemplos a detecção de doenças oculares graves como retinopatia diabética e degeneração macular relacionada com a idade.

Neste mesmo período foi introduzido o primeiro modelo de muitas da série GPT, pela OpenAI como o artigo "Improving Language Understanding by Generative Pre-Training", possuindo 117 milhões de parâmetros, introduzindo a técnica de pré-treinamento generativo, sendo o primeiro modelo de treinamento não supervisionado dedicado a grande corpus de texto que em seguida é ajustada de forma supervisionada para tarefas específicas.

Em 2018, a empresa japonesa Groove X apresentou ao mundo o seu robô emocional chamado LOVOT. Este robô foi projetado com o objetivo de oferecer companhia e apoio emocional, utilizando tecnologias avançadas de IA, robótica e interação social. O lançamento do LOVOT marcou um momento significativo no desenvolvimento de robôs sociais, destacando-se como uma inovação única dentro da robótica de assistência emocional.

Em 2019, a Google integrou o modelo BERT em seu sistema de pesquisa. O BERT é um modelo de

linguagem pré-treinamento que utiliza a arquitetura de Transformers para melhorar a compreensão do contexto em pesquisas baseadas em linguagem natural.

Neste mesmo período, a DeepMind alcançou novos progressos com o AlphaFold, uma IA desenvolvida para prever a estrutura tridimensional das proteínas. Esta tecnologia utiliza aprendizagem profundo para resolver um dos problemas mais complexos da biologia, o problema de dobramento de proteínas.

Em 2019, o AlphaFold foi capaz de prever estruturas proteicas com uma precisão sem precedentes, classificando-se em primeiro lugar no CASP13, uma competição internacional sobre previsão de estruturas proteicas.

Em 2019, a aplicação da IA continuou a transformar a área da saúde, com avanços em diagnósticos médicos, como por exemplo o modelo Lung Cancer Detection AI da Google Health que demonstrou a capacidade de superar radiologistas na detecção precoce de cancro do pulmão em imagens de tomografia, sendo que esses avanços cruciais para a melhoria de diagnósticos médicos resultando na verificação do grande potencial da IA.

Em 2020, durante a pandemia de COVID-19, a IA desempenhou um papel crucial no desenvolvimento acelerado de vacinas. Modelos da aprendizagem profunda foram utilizados para analisar grandes volumes de dados genômicos, ajudando na identificação de potenciais alvos vacinais e na previsão de interações entre o vírus e o sistema imunológico humano. As empresas de biotecnologia, como a Moderna, usaram IA para otimizar o design da vacina contra a COVID-19, o que acelerou o processo de desenvolvimento e a fase de testes.

Em 2020, a Nvidia anunciou a versão beta da sua plataforma Omniverse, um ambiente colaborativo em tempo real para a criação de modelos 3D. O Omniverse permite que artistas, engenheiros e desenvolvedores possam colaborar na criação de modelos, simulações e elementos 3D de alta fiabilidade, utilizando tecnologias como física simulada e inteligência artificial para recriar o comportamento físico dos materiais. O Omniverse incorpora motores de física avançada e IA para simular o comportamento e características de objetos, simulando desde colisões á movimento de fluidos e partículas, aglomerando entre outros aspectos dedicados a design, engenharia e entretenimento, suportados por ferramentas como Autodesk Maya, Unreal Engine e Blender, com níveis de realismo inédito em simulações 3D, proporcionando aos engenheiros e designers plataforma de simulação de protótipos digitais, testando o comportamento de produtos em simulações reais antes da fase de produção física.

Em 2021, a OpenAI introduziu o sistema de IA multimodal DALL-E, um modelo capaz de gerar imagens a partir de descrições textuais. Este modelo, baseado na mesma arquitetura GPT-3, combina processamento de linguagem natural e geração de imagens.

Em 2022, a DeepMind revelou o AlphaTensor, uma IA projetada para encontrar algoritmos mais rápidos e eficientes para a multiplicação de matrizes, ultrapassando de forma drástica os algoritmos padrões de strassen, reduzindo assim o número de operações aritméticas. O AlphaTensor foi inspirado no sucesso de sistemas anteriores, como o AlphaGo e o AlphaZero, dedicados a aplicações técnicas mais avançadas para modelos científicos. Esses algoritmos são capazes de aumentar a eficiência energética em grandes centros de dados, são capazes de colmatar as limitações de escalabilidade, otimizam o tempo de processamento e recursos computacionais, possibilitando o treinamento de modelos da aprendizagem profunda mais complexas, especificamente em redes neuronais convolucionais e transformers. Simulações como as usadas em dinâmica de fluidos computacional (CFD), análise de elementos finitos (FEA) e métodos numéricos em geral podem beneficiar da redução na complexidade algorítmica proporcionada pelos novos algoritmos descobertos pelo AlphaTensor. Em problemas de engenharia que envolvem a resolução de grandes sistemas de equações lineares, principalmente para o âmbito de estudo, dedicadas a cálculos e análise estrutural, a otimização das operações matriciais melhoram drasticamente a precisão das simulações de cálculo.

Em 2023, foi marcado pelo boom da IA generativa multimodal. A evolução dos modelos de linguagem multimodal (LMMs) permitiu que a IA não apenas gerasse texto, mas também criasse imagens, vídeos e música a partir de descrições. Esta capacidade ampliou o uso da IA em áreas como educação, arte, medicina e política, mostrando o impacto da IA em tarefas complexas, como responder a questões médicas detalhadas e gerar argumentos persuasivos para debates políticos. É importante distinguir LMMs das GANs pois as LMMs processam e integram múltiplas modalidades de dados tais como texto, imagem, som e vídeos ao mesmo tempo numa mesma arquitetura com aplicabilidade na tradução multimodal, assistência médica, artes digitais e simulação de realidades aumentadas, enquanto que GANs possui a seguinte particularidade, gera novos dados com base num conjunto de dados treinados. Estes são considerados a vanguarda de pesquisas de IA, porém, possuem as suas particularidades embora em certos casos sejam aplicados à mesma arquitetura.

Outro marco importante em 2023, foi a implementação do Ato de IA da União Europeia (AI Act), que está se tornando o primeiro avanço legislativo para regulamentação do uso de IA em diversas indústrias. A lei visa garantir o uso seguro e ético da IA, especialmente em áreas de alto risco, como saúde e segurança. Esta legislação destaca a crescente preocupação global com os impactos éticos e sociais do uso da IA em larga escala.

4

Classificação e Categorização do IA

De acordo com o exposto no capítulo anterior a IA tem sofrido bastantes desenvolvimentos, sendo o fluxo exponencial demarcado por períodos de bastante investigações, colaborações e implementações mediante os investimentos e períodos de limitações físicas (Hardware) que incapacitavam certas aplicações específicas, que só foram possíveis devido à evolução do hardware. Assim podemos separar as técnicas e métodos de IA, com base na classificação tecnológica, em dois blocos.

O primeiro bloco de IA, considerado como IA clássica ou IA simbólico, consiste num conjunto de métodos onde a abordagem baseia-se na manipulação de símbolos e regras lógicas para resolução dos problemas e tomadas de decisões, sendo uma das características marcantes o uso de algoritmos de lógica formal, desenvolvidas entre 1950 e 1980, tal como Expert system.

Outros tipos de técnicas específicas da IA clássica são Genetic algorithm (GA), Particle Sawn optimization (PSO) , Cellular autómatas(CA), Differential evolution algorithm(DEA), Fuzzy Logic, Generative design grammar e entre outros. Embora algumas dessas técnicas sejam reconhecidas como IA clássica devido ao período de desenvolvimento, esses, especialmente os algoritmos de métodos meta-heurísticos PSO e GA, são de forte aplicação na otimização de resultados na busca em grandes espaços, são especialmente de fácil aplicação e compreensão, o que promove a sua aplicação em sistemas Híbridos de IA, como poderá averiguar a partir das análises de autores no capítulo 5.

O segundo bloco de IA considerada como IA moderna ou IA de bases de dados, engloba um conjunto de técnicas e abordagens caracterizada pela sua forte capacidade de manipulação de dados, pela autoaprendizagem e adequabilidade mediante o volume de informação, constituído por um conjunto de algoritmos avançados de AA para criação de sistemas dedicados à realização de tarefas complexas. Sendo este campo definido como aprendizagem automática (AA ou ML). Dentro do campo de AA, podemos dividi-lo em quatro subcampos principais: aprendizagem supervisionada, aprendizagem não supervisionada, aprendizagem por reforço e Aprendizagem profunda (Deep Learning) sendo muito importante referir que para além dessas subárea, temos subáreas híbridas tais como Aprendizagem Semi-Supervisionada, Aprendizagem

Auto-Supervisionada, Aprendizagem Online, Aprendizagem Multi-Agente, Meta-Aprendizagem.

4.1 IA clássico

4.1.1 Algoritmos Genéticos e Otimização por Enxame de Partículas

Os Algoritmos Genéticos (Genetic Algorithms - GA) são inspirados nos princípios da evolução biológica e seleção natural propostos por Darwin. Estes algoritmos trabalham com um conjunto de soluções candidatas, representadas como cromossomas, que passam por operações de seleção, cruzamento e mutação. A cada geração, as soluções são avaliadas por uma função de aptidão que determina a qualidade de cada uma. Uma das suas principais características é a capacidade de realizar buscas estocásticas em grandes espaços de busca, sendo particularmente eficaz em problemas de otimização complexos. No entanto, a convergência para a solução ótima global nem sempre é garantida.

A Otimização por Enxame de Partículas (Particle Swarm Optimization - PSO), por sua vez, é inspirada no comportamento de bandos de aves e cardumes de peixes. Neste algoritmo, várias partículas exploram o espaço de soluções, ajustando o seu movimento com base na sua própria experiência e na dos seus vizinhos. As partículas movem-se em direcção à melhor solução conhecida, tornando-o um método eficaz para otimização contínua em problemas de grande dimensão. Além disso, é de fácil implementação e requer poucos parâmetros de controlo.

As abordagens como GA e PSO, embora sejam consideradas “clássicas”, apresentam benefícios para otimização em espaços de busca grandes e não lineares, especialmente em problemas como a análise estrutural. Estas técnicas utilizam algoritmos evolutivos e de enxame, que são robustos em termos de encontrar soluções globais, mas tendem a ser menos eficientes conforme o aumento de escalabilidade do problema. PSO, por exemplo, demonstra bom desempenho para problemas de otimização de média escala, mas sua eficiência computacional decresce em problemas massivos com alta dimensionalidade.

Estudos como os de Kashani et al. (2022) destacam que técnicas evolutivas como PSO e GA continuam a ser amplamente utilizadas em problemas de otimização estrutural devido à sua capacidade de explorar amplos espaços de busca e lidar com problemas não lineares.

Estudos de Gad (2022) procuram uma variante melhorada de forma a fazer face ao problema intrínseco dos algoritmos PSO de lidar com condições e restrições impostas, onde o mesmo tende a ficar preso em soluções inviáveis, não respeitando as restrições. Neste estudo verifica-se que o mesmo possui limitações na capacidade de encontrar soluções globais em problemas altamente não lineares.

A principal vantagem destes métodos PSO e GA é a capacidade de encontrar soluções robustas em problemas de otimização multidimensionais, como o design de estruturas ou otimização de materiais. No

entanto, essas técnicas têm desafios em termos de escalabilidade quando aplicadas a problemas de grande dimensão, como mencionado por Gad (2022).

A PSO, tem sido frequentemente melhorada através de hibridizações com algoritmos como o Differential Evolution (DE) para aumentar a eficiência e evitar convergência prematura, especialmente em problemas de grande escala. Isso é visto em trabalhos como os de H. Liu, Cai e Y. Wang (2010), onde a integração de operadores evolutivos e ajustes de parâmetros na PSO resultou em algoritmos mais escaláveis e capazes de lidar com a complexidade computacional crescente nos domínios da engenharia estrutural.

4.1.2 Autômatos Celulares

Os Autômatos Celulares (Cellular Automata - CA) são modelos matemáticos que evoluem ao longo do tempo com base em regras locais. Cada célula da grelha tem um estado que é atualizado de acordo com o estado das células vizinhas. Apesar da simplicidade das suas regras, este método pode gerar comportamentos complexos, sendo aplicado em várias áreas, incluindo a modelação de fenómenos físicos, como a propagação de ondas ou a difusão de calor, para aplicações em simulações urbanas e de crescimento urbano, para prever o uso do solo e o impacto de políticas de desenvolvimento urbano A. G.-O. Yeh e X. Li (2002) e aplicação em design complexo de redes de esgotos nas infraestrutura Y. Guo et al. (2007).

4.1.3 Algoritmo de Evolução Diferencial

O algoritmo de Evolução Diferencial (Differential Evolution Algorithm - DEA), tal como o GA, é baseado numa abordagem populacional. No entanto, o DEA foca-se mais na diferenciação e recombinação de soluções, utilizando diferenças entre vetores candidatos para criar novas soluções. Esta técnica é conhecida pela sua robustez e eficiência em problemas contínuos, sendo frequentemente utilizada para encontrar soluções próximas do ótimo global. Estes algoritmos têm sido amplamente aplicados em otimizações estruturais, especialmente na minimização de peso e na melhoria de desempenho de estruturas sujeitas a várias restrições, casos notórios são aqueles dedicados para otimização de treliças metálicas com o objectivo de minimização de peso estrutural, Charalampakis e Tsiatas (2019), aplicam DEA para otimização de dimensionamento de treliças onde os seus resultados superam outras técnicas evolutivas em termos de precisão e convergência para o ótimo global, e verificam que em estruturas sujeitas a várias restrições, como tensões máximas e deslocamentos, são capazes de reduzir o peso sem comprometer a integridade estrutural.

Estudos de Guerlement, Targowski, Gutkowski, et al. (2001), onde o algoritmo DEA foi utilizado na otimização de treliças de secção oca em aço, conforme o código EC3, demonstra a versatilidade do

algoritmo, que é capaz de lidar com problemas de grande dimensão e alta complexidade, permitindo a otimização de secções transversais, garantindo a conformidade com as normas europeias de projeto de estruturas metálicas.

4.1.4 Sistemas Especialistas

Os Sistemas Especialistas (Expert Systems) são sistemas de IA que utilizam uma base de conhecimento composta por factos e regras lógicas, capturando o conhecimento especializado de peritos numa área específica. Através de um motor de inferência, estes sistemas podem deduzir novas informações ou tomar decisões com base nas regras armazenadas. São amplamente utilizados em domínios bem definidos e especializados, onde a precisão é crucial. No entanto, a sua manutenção e escalabilidade podem ser um desafio em áreas onde o conhecimento está em constante evolução.

Os sistemas especialistas têm-se mostrado ferramentas valiosas na engenharia estrutural, com aplicações recentes centradas em áreas como a manutenção preditiva, otimização de projetos e monitorização de saúde estrutural (SHM). Estas tecnologias, que combinam inteligência artificial com grandes volumes de dados, permitem uma melhor gestão de infraestruturas, assegurando a sua durabilidade e desempenho ao longo do tempo. M. Z. Naser (2020) explorou a aplicação de sistemas especialistas em projetos de infraestrutura durante eventos extremos, como incêndios, propondo um sistema que avalia a resistência ao fogo de estruturas de aço. Outro estudo de X. Zhu e Law (2015) focou-se na monitorização estrutural, destacando a interação entre veículos e pontes para detectar falhas e desgastes ao longo do tempo. Estes exemplos mostram como os sistemas especialistas são usados para prever falhas e otimizar a manutenção, com base na análise contínua de dados. Estudos como o Höll e Humer (2023) sistemas especialistas são integrados ao processo de monitorização através da aplicação de transfer learning para análise de dados de ondas guiadas (guided waves) sendo o foco na captura e interpretação dos dados complexos de danos estruturais, com base em simulações e dados reais de sensores para diagnóstico automático de falhas. Rodrigues et al. (2023) combina AA para lidar com os efeitos ambientais no comportamento estrutural sendo os sistemas especialistas aplicados na seleção e interpretação de sinais capturados por sensores para diagnosticar problemas em estruturas, com este sistema, conseguem diferenciar entre variações normais causadas por fatores ambientais e problemas estruturais genuínos, garantindo que os engenheiros possam focar em danos reais.

4.1.5 Lógica Fuzzy

A Lógica Fuzzy (Fuzzy Logic) é uma extensão da lógica booleana tradicional, permitindo a representação de valores parciais de verdade, o que é particularmente útil para lidar com incertezas. A lógica fuzzy

utiliza conjuntos fuzzy e regras para modelar sistemas com fronteiras difusas entre estados. Ao contrário da lógica clássica, que trabalha apenas com valores binários, onde algo é estritamente verdadeiro (1) ou falso (0), a lógica difusa permite que variáveis assumam qualquer valor entre 0 e 1. Isto possibilita representar e tratar graus de verdade, o que é mais adequado para muitos problemas práticos onde a informação é incerta, ambígua ou subjetiva. Este tipo de abordagem é aplicado em sistemas de controle, onde a suavidade e a tolerância a incertezas são fundamentais, como em muitos processos industriais. São importantes para tomadas de decisões onde requer avaliação do desempenho e segurança, pertinentes em condições de variação de carga e propriedades dos materiais.

No estudo de Sahu et al. (2016) aplica-se a Lógica Fuzzy combinada com a análise de elementos finitos (FEA) para projetar e avaliar o comportamento estrutural de robôs industriais e outras estruturas mecânicas complexas. Esta abordagem foi eficaz na modelação de parâmetros estruturais sujeitos a incertezas, como a resistência e a flexibilidade dos materiais, permitindo otimizar o design com base em múltiplos critérios de desempenho.

No estudo de C. Peng et al. (2024) aplicaram a Lógica Fuzzy combinada com ISM-MICMAC para análise de risco na construção de pontes giratórias sobre linhas ferroviárias. A pesquisa enfatiza a importância da Lógica Fuzzy na avaliação de interdependências complexas e na melhoria da gestão de riscos.

Fujino e Hadipriono (1994) pioneiros na aplicação de Lógica Fuzzy para a análise de falhas em árvores de falhas, tem sido utilizado para sistemas complexos de modelação das incertezas e diagnóstico de falhas estruturais, esta abordagem permitiu tratar de incerteza associada a falhas potenciais em sistemas como pontes e edifícios, melhorando a confiabilidade da análise de falhas.

4.1.6 Gramática de Design Generativo

A Gramática de Design Generativo (Generative Design Grammar) baseia-se em regras formais que geram formas ou soluções de design com base em parâmetros e restrições específicas, ou seja na ideia de que a complexidade de um design pode ser produzida de forma algorítmica, semelhante às regras gramaticais que estruturam uma língua. Este método permite explorar automaticamente múltiplas soluções de design, criando possibilidades inovadoras e muitas vezes não intuitivas. Tem sido utilizado para a otimização de projetos estruturais e arquitetônicos, proporcionando soluções eficientes e otimizadas.

No estudo de Cascone et al. (2021) aplicam GDG no design de estruturas diagrid em edifícios altos. Utilizam uma gramática de forma para definir as regras de geração de padrões estruturais, otimizando o peso e a rigidez do edifício. Essas regras permitem que o sistema gere múltiplos designs viáveis com base em parâmetros de carga e resistência, adaptando-se às variações de altura e largura do edifício. O GDG é aplicado para acomodar diferentes especificações de rigidez e para otimizar o desempenho estrutural ao

longo do edifício.

No estudo de Kicinger, Arciszewski e De Jong (2005) exploram representações gerativas de sistemas estruturais de aço, utilizando autômatos celulares para gerar novos conceitos de design para edifícios altos. O GDG é usado para criar representações complexas e padrões estruturais inovadores que não seriam alcançados por métodos tradicionais de design paramétrico. A gramática formal utilizada é aplicada para produzir novas formas e otimizar o comportamento estrutural, sendo que o sistema pode aprender e adaptar-se ao longo do processo de design.

No estudo de He, Y.-H. Wang e J. Zhang (2023) utilizam GDG juntamente com modelos de difusão e Building Information Modeling (BIM) para automatizar o design de estruturas. Neste contexto, GDG é empregado para gerar soluções de design estrutural que são otimizadas automaticamente com base em dados de BIM e nas especificações do projeto. A gramática estrutural permite criar múltiplas variações de design e selecionar a melhor solução com base em critérios de eficiência estrutural.

No estudo de Regenwetter, Nobari e Ahmed (2022) discutem o uso de modelos gerativos profundos no design de engenharia, onde o GDG é combinado com redes neurais para gerar automaticamente novos designs com base em critérios de otimização, como topologia e comportamento estrutural. A gramática formal usada ajuda a controlar o processo gerativo, garantindo que os designs gerados atendam aos requisitos de desempenho e viabilidade.

4.2 IA Moderno

4.2.1 Aprendizagem supervisionada

A aprendizagem supervisionada caracteriza-se por treinar modelos utilizando um conjunto de dados rotulados, onde para cada entrada existe uma saída correta previamente conhecida que serve de referência. Durante o treino, o modelo ajusta os seus parâmetros com base no erro entre as previsões e os rótulos corretos, utilizando técnicas como a retropropagação. O objetivo é que o modelo aprenda a generalizar para novos dados, fazendo previsões precisas em exemplos que não foram vistos durante o treino. Essa abordagem é amplamente aplicada em problemas de classificação (como reconhecimento de objetos) e regressão (como previsão de preços no mercado financeiro), onde existe uma quantidade significativa de dados rotulados disponíveis para orientar o processo da aprendizagem .

No domínio da aprendizagem supervisionada, várias técnicas são amplamente utilizadas para resolver problemas complexos em diferentes domínios. Tais como Regressão Linear, Regressão Logística, Máquinas de Vetores de Suporte (SVM), Redes Neurais Artificiais (RNA), Árvores de Decisão, Floresta Aleatória (Random Forest), k-Nearest Neighbors (k-NN), Naive Bayes, Perceptrão Multicamadas (Multi-

layer Perceptron - MLP) , Boosting (AdaBoost, Gradient Boosting), Bagging (Bootstrap Aggregating), Regressão de Vetores de Suporte (SVR).

Dada a escala de elementos que seria necessários abarcar de modo a providenciar total compreensão de cada uma dessas técnicas, será recomendado o livro - *Artificial Intelligence By Example, Denis Rothman, Vol.2*, onde são expostos pelo especialista passo a passo a aplicação de cada um dos elementos aqui apresentados, bem como devidos exercícios práticos de aplicações reais em indústrias e interpretação dos códigos. Então ao longo deste trabalho, serão referidos apenas aqueles considerados relevantes e recorrentes à ótica do âmbito de estudo.

4.2.2 Aprendizagem não supervisionada

A aprendizagem não supervisionada é crucial em cenários onde os dados não estão rotulados, o que implica que o modelo deve identificar padrões e estruturas de forma autônoma. Ao contrário da aprendizagem supervisionada, onde os algoritmos são orientados por dados rotulados, na aprendizagem não supervisionada o sistema processa dados brutos e procura identificar padrões subjacentes, estruturas ocultas ou relações intrínsecas nos dados. O objetivo central é a descoberta de grupos, associações ou a simplificação dos dados em menor dimensão, de forma autônoma, sem qualquer orientação explícita quanto ao que o algoritmo deve aprender.

As técnicas da aprendizagem não supervisionada são: Análise de Componentes Principais (PCA), Análise de Agrupamento (Clustering), Mapas Auto-Organizáveis (SOM - Self-Organizing Maps), Modelos de Mistura de Gaussianas (GMM - Gaussian Mixture Models), Redes Bayesianas. Sendo as mais recorrentes:

- Algoritmos de agrupamento (clustering), que consiste no agrupamento automático dos dados em subconjuntos (clusters) com base na similaridade dos dados sem necessidade de fornecer rótulos ou categorias.
- Algoritmo k-means particiona os dados em grupos de acordo com a proximidade minimizando a variância dentro de cada grupo enquanto algoritmos de agrupamento hierárquico criam árvore hierárquica de clusters, que permite uma análise mais flexível e detalhada.
- Análise de Componentes Principais (PCA) ou Autoencoders, são aplicados para reduzir a quantidade de variáveis num conjunto de dados, mantendo a maior quantidade possível de informação relevante. Estes métodos são fundamentais em situações onde o volume de dados é demasiado elevado para ser analisado ou visualizado diretamente, permitindo uma compressão eficiente dos dados sem perder a essência da informação.

4.2.3 Aprendizagem por Reforço (Reinforcement Learning)

Aprendizagem por Reforço centram-se na interação de um agente com um ambiente, onde o objetivo é maximizar uma recompensa cumulativa ao longo do tempo. Em termos gerais, o agente aprende a tomar decisões a partir de um ciclo de tentativa e erro, sendo recompensado ou penalizado com base nas suas ações. Esta forma da aprendizagem é particularmente útil em problemas de controle e otimização de sistemas, que podem ser diretamente aplicáveis em diversos contextos de engenharia, incluindo análise estrutural. As principais técnicas da aprendizagem por Reforço são: Q-Learning, SARSA, Deep Q-Networks, Policy Gradient Methods, REINFORCE, Proximal Policy Optimization, Actor-Crítico, Deep Deterministic Policy Gradient, Twin Delayed DDPG, Policy Search, Algoritmos de Planeamento Dinâmico.

4.2.4 O aprendizagem profundo (Deep Learning)

O aprendizagem profundo é uma subárea da aprendizagem automática que utiliza redes neurais profundas para modelar padrões complexos em grandes volumes de dados. Redes neurais profundas são compostas por múltiplas camadas de neurônios artificiais que aprendem representações hierárquicas dos dados. O aprendizagem profundo é particularmente eficaz em tarefas como reconhecimento de imagem, processamento de linguagem natural e tradução automática. Suas vantagens incluem a capacidade de capturar padrões complexos e generalizar bem em tarefas de alta dimensionalidade. No entanto, redes profundas requerem grandes quantidades de dados e poder computacional significativo para treinamento, além de serem suscetíveis ao sobreajuste se não forem regularizadas adequadamente.

As técnicas aprendizagem profunda são : Redes Neurais Convolucionais (CNNs), Redes Neurais Recorrentes (RNNs), Autoencoders (AEs), Redes Gerativas Adversariais (GANs), Redes Neurais Profundas (DNNs), Transformers, Redes Neurais de Memória Temporal (TNNs), Generative AI, Modelos de Difusão.

- Redes Neurais Recorrentes ("Recurrent Neural Networks", RNN) e Long Short-Term Memory (LSTM) são projetadas para dados sequenciais, como séries temporais e texto. As RNNs possuem laços de retroalimentação que permitem a passagem de informações de um passo de tempo para o próximo, enquanto as LSTMs utilizam células de memória e portas para regular o fluxo de informações e preservar dependências de longo prazo. Elas são utilizadas em tradução automática, geração de texto e análise de séries temporais. As RNNs e LSTMs são avançadas porque conseguem manter e processar informações sequenciais, capturando dependências temporais de forma eficaz. Suas vantagens incluem a capacidade de capturar dependências temporais e processar sequências de comprimento variável. No entanto, enfrentam problemas de desvanecimento e explosão do

gradiente e exigem treinamento computacionalmente intensivo. Bibliotecas como TensorFlow, Keras e PyTorch são amplamente utilizadas para implementar RNNs e LSTMs.

- **Redes Neurais Gráficas (Graph Neural Networks, GNN)** generalizam redes neurais para dados estruturados como grafos, permitindo a aprendizagem sobre relacionamentos complexos entre entidades. As GNNs propagam informações entre os nós do grafo através de arestas, permitindo a agregação de características dos nós vizinhos para capturar a estrutura global do grafo. Elas são aplicadas em análise de redes sociais, predição de propriedades moleculares e sistemas de recomendação. As GNNs são avançadas devido à sua capacidade de lidar com dados estruturados e interconectados, extraindo informações valiosas das relações entre os dados. Grafos são estruturas compostas por nós (vértices) e arestas (edges), onde os nós representam entidades e as arestas representam relações entre essas entidades. As GNNs funcionam iterativamente, onde cada nó atualiza seu estado com base nos estados de seus vizinhos, permitindo que a rede aprenda representações ricas dos grafos. Suas vantagens incluem a capacidade de modelar dados interconectados e relacionamentos complexos, enquanto suas limitações incluem complexidade computacional elevada e desafios na escalabilidade para grafos muito grandes. Ferramentas como DGL (Deep Graph Library) e PyTorch Geometric são utilizadas para implementar GNNs.
- **A inteligência artificial generativa (Generative AI)** é uma parte da aprendizagem profunda que se concentra na criação de novos dados que são semelhantes aos dados de treinamento. Técnicas de Generative IA incluem Redes Generativas Adversariais (GANs) e Modelos de Difusão. Redes Generativas Adversariais (Generative Adversarial Networks), GAN) que consistem em duas redes neurais concorrentes sendo um gerador e outro discriminador, que detêm a capacidade de se treinarem mutuamente. As GANs envolvem um jogo de soma zero onde o gerador tenta enganar o discriminador criando amostras realistas, enquanto o discriminador tenta melhorar sua capacidade de distinguir entre amostras reais e falsas. Elas são utilizadas para geração de imagens realistas, aprimoramento de resolução de imagens e criação de dados sintéticos. As GANs são consideradas avançadas porque conseguem gerar dados sintéticos altamente realistas, revolucionando áreas como a criação de conteúdo digital. Suas vantagens incluem a capacidade de gerar dados de alta qualidade e aplicabilidade a uma variedade de domínios. No entanto, o treinamento de GANs pode ser instável, sensível a hiperparâmetros e difícil de alcançar um equilíbrio entre o gerador e o discriminador. Ferramentas como TensorFlow, Keras e PyTorch suportam a implementação de GANs.
- **Modelos de Difusão (Diffusion Models)** são uma classe de modelos generativos que iterativamente transformam dados ruidosos em amostras de dados reais, inspirados por processos de difusão

física. Os modelos de difusão começam com dados ruidosos e, através de um processo iterativo de refinamento, gradualmente transformam esses dados em amostras realistas, simulando um processo físico de difusão inversa. Eles são utilizados em geração de imagens, síntese de áudio e modelação de dados de alta dimensionalidade. Os modelos de difusão são considerados avançados pela sua abordagem inovadora de geração de dados que permite criar amostras realistas a partir de ruído. Suas vantagens incluem a capacidade de gerar dados de alta qualidade e robustez em várias aplicações de síntese de dados. No entanto, eles requerem um processo de treinamento intensivo e bastante recurso computacional para gerar amostras. Bibliotecas como PyTorch e TensorFlow, juntamente com implementações especializadas de modelos de difusão, facilitam a implementação desses modelos.

- Os transformadores ("Transformers") utilizam mecanismos de atenção para modelar relações entre todos os elementos de uma sequência simultaneamente, superando limitações de dependência sequencial das RNNs. Os transformadores utilizam mecanismos de atenção auto-regressiva que permitem que cada elemento de uma sequência preste atenção a todos os outros elementos, proporcionando uma representação mais rica e detalhada dos dados. Eles são aplicados em modelos de linguagem como GPT-3 e BERT, tradução automática e compreensão de linguagem natural. Os transformadores são avançados devido à sua capacidade de processar dados sequenciais de maneira paralela e eficiente, capturando dependências de longo alcance. Suas vantagens incluem eficiência paralela, melhor captura de dependências de longo alcance e escalabilidade para grandes conjuntos de dados. No entanto, eles requerem grande poder computacional e memória, além de serem complexos de treinar e ajustar. Bibliotecas como Hugging Face Transformers e TensorFlow oferecem suporte abrangente para implementações de transformadores.

IA e AA em Estruturas

5.1 Previsão de Comportamento Estrutural

A evolução do campo de Previsão de Comportamento Estrutural no âmbito dos cálculos estruturais tem seguido uma trajetória marcada pelo surgimento e desenvolvimento de métodos computacionais, culminando, nas últimas décadas, na aplicação de Inteligência Artificial (IA) e Aprendizagem Automática (AA). A capacidade de prever o comportamento de estruturas sob diferentes cargas e condições é fundamental para a segurança e eficácia dos projetos de engenharia civil, e a utilização de IA tem revolucionado este processo.

No início, a previsão do comportamento estrutural baseava-se essencialmente em métodos analíticos clássicos, como a teoria da elasticidade e a mecânica dos sólidos, onde as simplificações eram necessárias para que os cálculos pudessem ser realizados manualmente ou com ferramentas numéricas convencionais. No entanto, com o crescimento exponencial da capacidade de processamento dos computadores, métodos como o Método dos Elementos Finitos (FEA) tornaram-se padrão no campo. No final do século XX e início do século XXI, a aplicação de técnicas de IA emergiu como uma abordagem complementar e, em muitos casos, superior em termos de eficiência computacional e precisão.

Os primeiros estudos envolvendo IA no cálculo estrutural focavam-se, sobretudo, na utilização de redes neurais artificiais (RNA) para a previsão de respostas estruturais a partir de grandes conjuntos de dados. Estes modelos mostraram-se especialmente eficazes em ambientes onde existiam dados históricos sobre o comportamento de estruturas similares. Um estudo seminal nesta área foi realizado por Adeli e C. J. Yeh (1989), onde uma rede neuronal foi treinada para prever a resposta de uma viga sob carga, mostrando que as RNA poderiam aprender o comportamento estrutural complexo sem a necessidade de modelação explícita de todas as variáveis envolvidas.

No início da década de 2000, houve uma crescente integração de técnicas de IA com o Método dos Elementos Finitos (FEA), visando otimizar o desempenho computacional. A IA foi utilizada para reduzir

o tempo de computação ao prever soluções aproximadas para certos problemas estruturais, ou para identificar padrões de falhas em malhas finitas de elementos estruturais. Esta fase foi caracterizada pela forte aplicação de algoritmos genéticos, lógica difusa e redes neuronais profundas para melhorar a precisão dos modelos preditivos. Como é possível averiguar pelos estudos do Coello e Christiansen (2000)

Com o aumento da disponibilidade de dados e a melhoria dos algoritmos da aprendizagem profunda (Deep Learning), a última década testemunhou um crescimento significativo no uso de redes neuronais convolucionais (CNNs) e redes neuronais recorrentes (RNNs) para prever o comportamento estrutural de edifícios, pontes e outras infraestruturas complexas. Estes avanços permitem a análise em tempo real e a previsão de danos estruturais a partir de dados coletados por sensores distribuídos.

Um exemplo é o trabalho de Ni et al. (2022), que aplicou métodos de aprendizagem profunda multivariadas para prever o comportamento não linear de estruturas de betão sob carga cíclica, com resultados promissores na previsão de fissuras e falhas estruturais.

Tendo isso em consideração será apresentado alguns estudos correntes de desenvolvimentos de IA no campo de previsão de comportamento estrutural de modo a que se possa compreender as tendências, as vantagens e as suas limitações.

5.1.1 Análise dos Estudos

- O estudo desenvolvido por Abuodeh, Abdalla e Hawileh (2019) teve como objetivo principal desenvolver e validar um modelo de rede neural artificial (ANN) para prever a capacidade de resistência ao corte de vigas de betão armado reforçadas com fibras de polímeros (FRP). Adicionalmente, os autores utilizaram um diagrama de interpretação neural (NID) para identificar quais os parâmetros geométricos e mecânicos que mais influenciam a capacidade de resistência ao corte. A metodologia consiste na aplicação combinada de uma ANN, para prever a resistência ao corte com base em dados experimental, e de um NID, que permite interpretar os pesos dos parâmetros e destacar os fatores mais relevantes na previsão. Os resultados obtidos demonstraram que o modelo ANN, ajustado com os parâmetros selecionados pelo NID, apresentou uma maior precisão em comparação com o modelo que utilizou todos os parâmetros disponíveis. O coeficiente de determinação (R^2) do modelo ajustado foi de 0,819, com um erro médio quadrático (RMSE) de 2,68. Já o modelo que utilizou todos os parâmetros obteve um coeficiente de determinação de 0,639 e um erro médio quadrático de 9,36. Estes resultados evidenciam que a seleção criteriosa dos parâmetros geométricos e mecânicos melhoram significativamente a precisão do modelo.

Limitações

No entanto, o estudo apresenta algumas limitações. A principal está relacionada com a dependência de uma base de dados específica, limitada a certos tipos de vigas e materiais, o que pode restringir a generalização do modelo para outros contextos. Além disso, o ajuste da rede neural, necessário para lidar com diferentes configurações de parâmetros, pode ser computacionalmente exigente e requer técnicas de validação robustas para evitar o “overfitting”.

Perspetivas Futuras

Como perspetiva futura, os autores recomendam a expansão da base de dados experimental para incluir diferentes tipos de vigas e materiais de reforço, como as fibras de polímero (GFRP) ou aço. Sugerem ainda a combinação de redes neuronais artificiais com técnicas de otimização de modelos, como os algoritmos genéticos (GA), com o objetivo de melhorar a precisão das previsões em condições mais diversas e exigentes.

- O estudo desenvolvido por J. Li et al. (2019) teve como objetivo principal criar um modelo de inteligência artificial (IA) capaz de prever com precisão o ciclo de fadiga de materiais compósitos de poliéster reforçado com fibra de vidro. O estudo focou-se na aplicação de um modelo de Extreme Learning Machine (ELM) e comparou o seu desempenho com o modelo de rede neural de regressão generalizada (GRNN), com o intuito de determinar a durabilidade e vida útil dos materiais sob condições específicas de carga. O método de IA utilizado foi o Extreme Learning Machine (ELM), que é caracterizado pela utilização de uma rede de uma única camada de feed-forward (SLFN) para resolver problemas de regressão, evitando métodos iterativos e calculando diretamente os pesos da camada de saída através de uma solução de mínimos quadrados. Este método foi comparado com o GRNN, uma versão amplamente utilizada da rede neural artificial, que serviu de modelo de comparação. Os resultados obtidos indicaram que o ELM superou significativamente o GRNN em termos de precisão preditiva. Durante a fase de teste do modelo ELM, o erro quadrático médio (RMSE) e o erro percentual absoluto médio (MAPE) foram reduzidos em 39% e 38%, respetivamente, em comparação com o modelo GRNN. As variáveis mais influentes na previsão do ciclo de fadiga foram as dimensões geométricas das amostras e as tensões aplicadas, sem a necessidade de considerar a orientação das fibras, o que simplificou o modelo.

Limitações

O estudo apresentou algumas limitações, sendo a principal a necessidade de realizar mais testes experimentais para aumentar a robustez do modelo preditivo, uma vez que os dados utilizados eram relativamente limitados. Além disso, o estudo não considerou o impacto de diferentes temperaturas e condições ambientais extremas, o que pode afetar o comportamento de fadiga dos materiais compósitos.

Perspetivas Futuras

Como perspetiva futura, os autores sugerem expandir o uso do modelo ELM para outros tipos de materiais compósitos e incluir diferentes condições de carga e temperaturas, a fim de melhorar a precisão preditiva. Também recomendam a integração de métodos híbridos que combinem o ELM com técnicas de otimização, visando melhorar ainda mais a precisão e eficiência dos modelos preditivos.

- O estudo desenvolvido por X.-G. Zhou, Hou e J. Peng (2023) teve como objetivo criar um método eficiente para avaliar a resistência de estruturas de tubos de aço preenchidos com betão (CFST), submetidas a corrosão localizada aleatória e a cargas axiais de longo prazo. A abordagem baseou-se na aplicação de modelos da aprendizagem automática (ML) para prever a capacidade de resistência dessas estruturas em diferentes cenários de corrosão. Foram utilizados sete modelos da aprendizagem automática, destacando-se o XGBoost e a Regressão por Processo Gaussiano (GPR). Estes modelos foram aplicados para prever a resistência dos CFST sob condições de corrosão uniforme e localizada. Além disso, os métodos de active learning (AL) foram implementados para otimizar a seleção de dados de treino, permitindo melhorar a precisão dos modelos com uma quantidade reduzida de dados. Através da otimização dos hiperparâmetros, os modelos foram ajustados para respeitar os mecanismos estruturais envolvidos. Os resultados indicaram que o CFST com corrosão localizada aleatória apresentou uma redução significativa na sua capacidade de resistência em comparação com CFST com corrosão uniforme. A utilização de métodos de active learning permitiu que os modelos atingissem um desempenho semelhante ao de um modelo que utilizasse todos os dados disponíveis, utilizando apenas 63% dos mesmos, o que demonstra a eficiência do método proposto. O XGBoost e o GPR foram os modelos que exibiram melhor desempenho, com valores de R^2 superiores a 0,99, mostrando a elevada precisão das previsões.

Limitações

Entre as limitações identificadas no estudo, destaca-se a necessidade de aumentar o volume de dados experimentais sobre CFSTs corroídos, o que permitirá melhorar a generalização dos modelos. A complexidade da modelação da corrosão localizada aleatória requer ainda uma maior validação experimental, de modo a abranger uma maior diversidade de cenários de corrosão.

Perspetivas Futuras

Como perspetiva futura, os autores recomendam a aplicação dos métodos da aprendizagem automática e active learning no estudo de outros componentes estruturais sujeitos a condições adversas, como a corrosão. Além disso, o aumento do número de experimentos relatados deverá contribuir para um desempenho e robustez superiores dos modelos de AA desenvolvidos.

- O estudo desenvolvido por Megahed, Mahmoud e Abd-Rabou (2024) teve como objetivo principal desenvolver modelos da aprendizagem automática (ML) para prever a capacidade de compressão axial de colunas de aço preenchidas com betão (CFST) de tipo curto, conhecidas como stub columns. O estudo baseou-se num vasto banco de dados experimental que incluiu colunas de diferentes formas, como circulares, retangulares e de dupla camada, e comparou os resultados

preditivos dos modelos de AA com normas de projeto estabelecidas. Foram aplicados vários modelos da aprendizagem automática, incluindo Regressão por Processo Gaussiano (GPR), Regressão Simbólica (SR), Regressão por Vetores de Suporte (SVR) otimizada com Otimização por Enxame de Partículas (PSO), Redes Neurais Artificiais (ANN), XGBoost (XGB), CatBoost (CATB), Random Forest (RF) e LightGBM (LGBM). A otimização de hiperparâmetros foi realizada utilizando Bayesian Optimization (BO), com o intuito de melhorar o desempenho preditivo dos modelos. Os resultados mostraram que os modelos CATB, GPR e XGB se destacaram em termos de precisão preditiva, com um erro percentual absoluto médio (MAPE) inferior a 2,5% para as colunas curtas de CFST. Estes modelos superaram as fórmulas tradicionais de design, como as normas AISC360 e EC4, que apresentaram erros de previsão superiores. O estudo também propôs equações de design simplificadas com base no modelo de Regressão Simbólica (SR), oferecendo uma abordagem prática e interpretável para prever a capacidade de compressão axial dessas colunas.

Limitações

No entanto, o estudo apresenta algumas limitações, sobretudo relacionadas com a complexidade de interpretar alguns dos modelos de AA mais avançados, como o GPR e o XGBoost, no contexto de aplicações práticas para o design estrutural. Além disso, a precisão dos modelos depende fortemente da qualidade e abrangência do banco de dados experimental utilizado, o que pode afetar a generalização dos resultados.

Perspetivas Futuras

Como perspectiva futura, os autores recomendam a aplicação contínua de técnicas da aprendizagem automática para prever a capacidade de outros tipos de colunas e componentes estruturais. Além disso, sugerem a exploração de abordagens híbridas que combinem AA com métodos tradicionais de análise estrutural. A aplicação de técnicas de como SHAP (Shapley Additive Explanations), é também apontada como uma possível melhoria, permitindo uma maior compreensão das previsões dos modelos.

- O estudo desenvolvido por C. Li, M. Zhang e X. Zhang (2023) teve como objetivo principal criar um modelo preditivo robusto baseado em aprendizagem profunda para prever o comportamento de fluência do betão, utilizando uma abordagem inovadora com redes neurais convolucionais unidimensionais (1D CNN). O estudo focou-se em superar os desafios associados aos dados tabulares de fluência, como a falta de correlações espaciais e a presença de ruído, recorrendo a uma base de dados da Universidade Northwestern (NU). A abordagem metodológica consistiu na aplicação de uma 1D CNN com uma camada de ordenação suave, o que permitiu a transformação dos dados tabulares em pseudo-imagens multicanais, possibilitando a extração de correlações espaciais relevantes. Adicionalmente, foi utilizado um codificador de redução de ruído baseado em redes residuais (DRNN) para melhorar a qualidade dos dados e aumentar a precisão preditiva, mitigando o ruído presente na base de dados.

Os resultados obtidos indicaram uma melhoria significativa na precisão preditiva em comparação com os métodos tradicionais de previsão de fluência. O erro médio absoluto (MAE) foi reduzido de 7,48 para 5,83, enquanto o desvio padrão quadrático médio (RMSE) foi reduzido de 10,76 para 8,88. O modelo mostrou-se eficaz em capturar as complexas relações entre a fluência do betão e variáveis como a relação água-cimento e o tipo de aditivos utilizados.

Limitações

No entanto, o estudo apresentou algumas limitações, nomeadamente no que respeita à generalização do modelo para cenários com dados que não se encontravam no intervalo de treino, especialmente em casos com padrões complexos de ruído. A CNN unidimensional pode também apresentar limitações na captura de características espaciais mais detalhadas, o que pode influenciar a performance em situações mais complexas.

Perspetivas Futuras

Como perspetiva futura, os autores sugerem a exploração de modelos temporais, como as redes LSTM (Long Short-Term Memory), para capturar o comportamento da fluência ao longo do tempo. A utilização de redes adversárias generativas (GANs) também foi proposta como uma forma de melhorar a modelação de dados ruidosos, permitindo uma simulação mais realista do comportamento do betão em condições adversas.

- O estudo realizado por Islam et al. (2024) teve como objetivo principal o desenvolvimento de um modelo baseado em aprendizagem profunda para prever com elevada precisão a resistência à compressão do betão de alto desempenho (HPC). O estudo explorou quatro abordagens distintas da aprendizagem profunda, nomeadamente BiLSTM (Bidirectional Long Short-Term Memory),

CNN (Convolutional Neural Network), GRU (Gated Recurrent Unit) e LSTM (Long Short-Term Memory), sendo o desempenho de cada uma comparado na previsão da resistência à compressão a partir de um conjunto de dados experimentais. A metodologia aplicada consistiu no treino de quatro modelos da aprendizagem profunda utilizando um conjunto de dados com variáveis como a quantidade de cimento, escória de alto-forno, cinzas volantes, agregado grosso, areia, água e idade do betão, sendo a resistência à compressão a variável dependente. Os modelos foram treinados com 80% dos dados disponíveis e testados com os 20% restantes, permitindo uma avaliação robusta do desempenho preditivo. Os resultados indicaram que o modelo GRU foi o que obteve melhor desempenho, com um coeficiente de determinação (R^2) de 0,990 na fase de treino e de 0,961 na fase de teste. Todos os modelos utilizados apresentaram um desempenho satisfatório, com valores de R^2 superiores a 0,940. Estes resultados destacam o potencial dos modelos da aprendizagem profunda na previsão da resistência à compressão do HPC, superando as metodologias tradicionais de previsão empregues no campo da engenharia civil.

Limitações

Entre as limitações do estudo, destaca-se o risco de overfitting inerente aos modelos da aprendizagem profunda, devido à sua complexidade. Além disso, a necessidade de grandes volumes de dados para o treino dos modelos representa um desafio prático, uma vez que a qualidade dos dados disponíveis pode afetar diretamente o desempenho preditivo.

Perspetivas Futuras

No futuro, os autores sugerem a investigação de métodos híbridos que combinem aprendizagem profunda com algoritmos de otimização, de modo a melhorar ainda mais a precisão das previsões e reduzir o tempo computacional. Propõem também a utilização de redes adversariais generativas (GANs) para tratar dados ruidosos e aumentar a fiabilidade da previsão das propriedades mecânicas do betão.

- O estudo desenvolvido por Guler et al. (2023) teve como objetivo principal prever a capacidade ao corte de vigas de betão armado reforçadas com fibras de polímero (FRP) montados à superfície (NSM), utilizando redes neurais artificiais (RNA). A pesquisa procurou identificar as principais variáveis que influenciam a capacidade ao corte e aplicar técnicas da aprendizagem automática para aumentar a precisão das previsões em comparação com os métodos tradicionais utilizados em engenharia civil. A metodologia utilizada baseou-se no treino de redes neurais artificiais (RNA) com dados experimentais de vigas de betão armado reforçadas com NSM FRP. Foram utilizados dois softwares principais, o Neural Designer e o Orange Data Mining, ambos utilizados para criar e treinar redes neurais profundas. A pesquisa explorou a combinação de diversas variáveis

de entrada, como as dimensões das vigas, as propriedades dos materiais e as taxas de reforço, para prever com precisão a capacidade ao corte das vigas. Os resultados obtidos indicaram que as RNA foram capazes de prever a capacidade ao corte com elevada precisão, apresentando coeficientes de determinação (R^2) superiores a 0,96 tanto para os dados de treino como para os de teste. A simplificação das variáveis de entrada, através da eliminação de características menos relevantes, contribuiu para um melhor desempenho preditivo e reduziu o risco de sobreajustamento (overfitting). O Neural Designer demonstrou melhores resultados em comparação com o Orange Data Mining, devido às suas opções avançadas de ajuste de hiperparâmetros.

Limitações

Contudo, o estudo apresentou algumas limitações. Entre elas, destaca-se a dependência de um grande volume de dados experimentais para treinar o modelo com precisão. Além disso, a ausência de dados detalhados sobre a contribuição específica de cada material (betão, aço e FRP) afetou a capacidade do modelo em prever as contribuições separadas destes componentes. O modelo também apresentou dificuldades em generalizar previsões para dados fora do intervalo de treino.

Perspetivas Futuras

Como perspectiva futura, os autores recomendam o aumento da quantidade de dados experimentais disponíveis e a exploração de métodos híbridos que combinem RNA com algoritmos de otimização. A integração de ferramentas da aprendizagem automática em programas de análise estrutural poderá melhorar a adoção desta técnica nas práticas de engenharia civil.

- O estudo desenvolvido por Sarir et al. (2021) teve como objetivo criar modelos preditivos baseados em Programação de Expressão Genética (GEP), Redes Neurais Artificiais otimizadas por Enxame de Partículas (neuro-swarm) e Algoritmo de Otimização de Baleias (WOA) para prever a capacidade de carga axial de colunas de aço preenchidas com betão (CFST). A investigação procurou comparar diferentes abordagens, a fim de otimizar o desempenho preditivo e melhorar o design das colunas CFST.

Foram aplicadas três técnicas principais de AA: Programação de Expressão Genética (GEP), que desenvolveu equações preditivas para a capacidade de carga; as Redes Neurais Artificiais (ANN), otimizadas com Otimização por Enxame de Partículas (PSO) para ajustar os pesos e vieses da rede neural; e o Algoritmo de Otimização de Baleias (WOA), que foi utilizado para maximizar a capacidade de carga das colunas CFST. A GEP destacou-se por criar modelos preditivos baseados em expressões matemáticas, enquanto o PSO foi utilizado para otimizar os parâmetros das redes neurais, e o WOA foi implementado para encontrar a configuração de carga mais eficiente. Os

resultados indicaram que a técnica GEP obteve a maior precisão preditiva, com coeficientes de determinação (R^2) de 0,928 para o conjunto de treino e 0,939 para o conjunto de teste, demonstrando um desempenho superior ao da PSO-ANN e da ANN não otimizada. O Algoritmo de Otimização de Baleias (WOA) destacou-se ao maximizar a capacidade de carga das colunas CFST, alcançando um valor máximo de 23.436,63 kN.

Limitações

No entanto, o estudo apresentou algumas limitações. A dependência de dados experimentais para treinar os modelos é um fator limitante, assim como a complexidade computacional inerente à aplicação das técnicas de otimização. Além disso, os modelos preditivos desenvolvidos são específicos para colunas CFST, podendo não ser diretamente aplicáveis a outros tipos de estruturas compostas sem modificações adicionais.

Perspetivas Futuras

Como perspectiva futura, Sarir et al. (2021) sugerem a aplicação de técnicas da aprendizagem automática para prever a capacidade de carga de outros tipos de estruturas compostas e a exploração de novos algoritmos de otimização para melhorar ainda mais a precisão dos modelos preditivos.

- O estudo desenvolvido por T.-A. Nguyen, K. L. Nguyen e Ly (2024) teve como objetivo principal criar um modelo universal da aprendizagem automática (ML) para prever a capacidade de carga última (ULC) de colunas de tubo de aço preenchido com betão (CFST), considerando diversos parâmetros geométricos e propriedades dos materiais. O estudo procurou fornecer uma ferramenta preditiva útil na tomada de decisões de design.

Foram aplicadas três técnicas de boosting no estudo: CatBoost, LightGBM e XGBoost (XGB). Os modelos foram ajustados utilizando busca em grelha e validação cruzada em cinco divisões, e uma simulação de Monte Carlo foi utilizada para uma análise mais aprofundada. O modelo XGB destacou-se como o mais preciso, sendo posteriormente utilizado para a análise de importância das características, avaliação do desempenho local e análise de sensibilidade.

Os resultados indicaram que o modelo XGB forneceu previsões altamente precisas da ULC, com um coeficiente de determinação (R^2) de 0,999 e um erro quadrático médio (RMSE) de 391,306 kN. O estudo demonstrou que o XGB superou os modelos existentes que se baseavam num único tipo de seção transversal de colunas CFST, revelando-se robusto na previsão de diferentes geometrias de colunas.

Limitações

A principal limitação foi a falta de dados experimentais suficientes para colunas com secções elípticas e retangulares, o que pode ter um impacto negativo na precisão preditiva para essas formas. Além disso, a variabilidade geométrica e de materiais representa um desafio, limitando a capacidade do modelo de generalizar as previsões para colunas com características diferentes das incluídas na base de dados analisada.

Perspetivas Futuras

T.-A. Nguyen, K. L. Nguyen e Ly (2024) sugerem que investigações futuras devam focar-se em expandir a base de dados experimental de colunas CFST, melhorando assim a precisão preditiva para diferentes geometrias. A inclusão de novos parâmetros geométricos e de mais dados experimentais pode melhorar ainda mais a aplicabilidade prática do modelo.

- O estudo desenvolvido por Narang, R. Kumar e Dhiman (2023) teve como objetivo realizar uma revisão sistemática das metodologias da aprendizagem automática aplicadas para prever a capacidade de compressão axial (ACC) de colunas de aço preenchidas com betão (CFST). Este estudo foca-se em identificar as técnicas mais comuns da aprendizagem automática e comparar a sua eficácia em relação aos métodos tradicionais de previsão utilizados na engenharia estrutural. O estudo abrange várias técnicas da aprendizagem automática, incluindo redes neurais artificiais (ANN), máquinas de vetor de suporte (SVM), programação de expressão genética (GEP) e árvores de decisão (DT). Estas técnicas foram aplicadas para prever a capacidade de compressão axial das colunas CFST com base em várias características estruturais e propriedades dos materiais utilizados nas colunas. Além disso, foram também analisados algoritmos de otimização, como o PSO (Particle Swarm Optimization), que melhoraram os resultados preditivos ao ajustar os parâmetros dos modelos.

Os resultados obtidos a partir da revisão indicam que as técnicas da aprendizagem automática fornecem previsões mais precisas da ACC das colunas CFST em comparação com os métodos tradicionais, como os códigos de design. As redes neurais artificiais (ANN) e os algoritmos de otimização, como o PSO e a GEP, demonstraram uma precisão superior na modelação de dados complexos, proporcionando resultados mais fiáveis na previsão da capacidade de compressão axial das colunas.

Limitações

Contudo, o estudo apresenta algumas limitações. Uma das principais é a falta de integração das técnicas da aprendizagem automática em aplicações práticas na engenharia estrutural. Além disso, o desempenho dos modelos preditivos depende fortemente da qualidade e do volume dos dados experimentais disponíveis, sendo este um fator que pode limitar a generalização das previsões.

Perspetivas Futuras

Narang, R. Kumar e Dhiman (2023) sugerem que as investigações futuras se concentrem na implementação de técnicas da aprendizagem automática em projetos práticos de engenharia. A integração de dados experimentais mais robustos e a utilização de técnicas híbridas poderão melhorar ainda mais a precisão dos modelos preditivos, contribuindo para uma maior aplicabilidade nas práticas de design estrutural.

- O estudo desenvolvido por Luo et al. (2021) teve como objetivo criar um modelo preditivo baseado em Redes Convolucionais Temporais (TCN) para prever deformações estruturais, utilizando dados temporais provenientes do monitorização de grandes infraestruturas, como pontes e túneis. A intenção foi melhorar a precisão preditiva, capturando características temporais complexas presentes nos dados de monitorização. As Redes Convolucionais Temporais (TCN) aplicadas neste estudo são uma evolução das redes convolucionais unidimensionais, especificamente otimizadas para séries temporais. As TCN utilizam convoluções dilatadas, o que permite capturar dependências de longo prazo sem aumentar significativamente a complexidade computacional, tornando-as mais eficientes em termos de execução e precisão.

Os resultados indicaram que o modelo TCN proposto foi significativamente mais preciso do que outros métodos como LSTM, GRU e WNN. O erro quadrático médio (RMSE) foi reduzido em 44,15%, o erro absoluto médio (MAE) em 66,48% e o erro percentual absoluto médio (MAPE) em 82,03%, demonstrando a eficácia do TCN na previsão de deformações estruturais em comparação com outros métodos de redes neurais.

Limitações

Entre as limitações, o estudo destacou a dificuldade em otimizar os hiperparâmetros da rede, o que pode aumentar o tempo de treino, especialmente em redes mais profundas. Além disso, os dados utilizados para a validação do modelo estavam limitados a um único projeto de infraestrutura, o que restringe a capacidade de generalização do modelo para outros tipos de estruturas ou ambientes.

Perspetivas Futuras

Como perspectiva futura, Luo et al. (2021) sugerem a exploração de dados de monitorização espacial e o uso de múltiplos sensores para melhorar ainda mais a precisão preditiva. Além disso, a inclusão de técnicas mais eficientes para a otimização de hiperparâmetros também é apontada como uma área promissora para o desenvolvimento de novos modelos.

- O estudo realizado por Hassan et al. (2023) teve como objetivo realizar uma revisão sistemática sobre a aplicação de técnicas da aprendizagem automática (ML) na previsão de propriedades mecânicas e de durabilidade de diferentes tipos de betão. A análise centrou-se na identificação dos métodos de AA mais utilizados e nos resultados obtidos pela literatura recente, com foco na previsão de propriedades como a resistência à compressão, resistência à tração e o módulo de elasticidade. Foram utilizados diversos algoritmos da aprendizagem automática, incluindo redes neurais artificiais (ANN), máquinas de vetor de suporte (SVM), árvores de decisão (DT), técnicas de boosting e programação genética. Estas técnicas foram aplicadas para avaliar a precisão preditiva de várias propriedades do betão, com diferentes números de parâmetros de entrada. A análise comparativa dos métodos AA em relação aos modelos tradicionais demonstrou que as redes neurais e os algoritmos de boosting tiveram o melhor desempenho preditivo. Os resultados indicam que as técnicas da aprendizagem automática são extremamente eficazes na previsão das propriedades do betão, oferecendo melhorias significativas em comparação com os modelos empíricos convencionais. Em alguns casos, os coeficientes de determinação (R^2) chegaram a 0,99, o que evidencia a elevada precisão preditiva dos modelos ML.

Limitações

No entanto, o estudo identificou algumas limitações. A principal limitação reside na falta de grandes volumes de dados ou de uma diversidade significativa de tipos de betão utilizados para treinar os modelos de ML. Além disso, foi identificada a necessidade de maior integração de técnicas de aprendizagem automática em projetos práticos de engenharia civil, o que ainda é uma barreira significativa.

Perspetivas Futuras

Como perspectiva futura, Hassan et al. (2023) sugerem que futuras pesquisas se concentrem no aumento da base de dados disponível para treinar modelos da aprendizagem automática e na utilização de técnicas híbridas que combinem aprendizagem automática com métodos tradicionais de engenharia estrutural. O desenvolvimento de ferramentas acessíveis que permitam aos engenheiros utilizar aprendizagem automática na previsão das propriedades do betão é também uma recomendação importante.

- O estudo realizado por Ravikumar e Rajkumar (2023) teve como objetivo prever o deslocamento

máximo de lajes de betão armado submetidas a cargas explosivas, Foram explorados três algoritmos da aprendizagem automática: Random Forest Algorithm (RFA), K-Nearest Neighbor (KNN), e Decision Tree (DT), com o intuito de melhorar a precisão das previsões do comportamento estrutural das lajes expostas a explosões. Os três métodos de aprendizagem automática foram aplicados a um conjunto de dados experimentais que incluía 93 pontos de dados. Estes dados continham informações estruturais relevantes, como as dimensões da laje, a resistência à compressão do betão, o módulo de elasticidade do aço e do betão, entre outros parâmetros essenciais para a previsão do deslocamento máximo das lajes. Os resultados obtidos mostraram que o Random Forest Algorithm (RFA) foi o método mais preciso, com um coeficiente de determinação (R^2) de 99% e um erro médio absoluto (MAE) de 9,236 mm. O algoritmo K-Nearest Neighbor (KNN) também apresentou um bom desempenho, com um R^2 de 90,6% e um MAE de 16,912 mm, enquanto o Decision Tree (DT) teve o desempenho mais fraco, com um R^2 de 56,1% e um MAE de 27,898 mm.

Limitações

No entanto, o estudo apresentou algumas limitações, nomeadamente a dependência de dados experimentais para o treino dos modelos, o que pode dificultar a generalização das previsões para outros cenários. Além disso, a variabilidade dos parâmetros de entrada utilizados no treino pode impactar a precisão dos modelos da aprendizagem automática .

Perspetivas Futuras

Como perspetiva futura, Ravikumar e Rajkumar (2023) sugerem o desenvolvimento de ferramentas preditivas mais robustas que possam integrar um maior número de parâmetros relacionados com as explosões e realizar previsões em tempo real para diferentes configurações de lajes de betão. Também recomendam a exploração de novos algoritmos ou abordagens híbridas para melhorar ainda mais a precisão das previsões em futuros estudos.

- O artigo de Alhusban, Alhusban e Alkhawaldeh (2024a), teve como principal objetivo avaliar a aplicação de técnicas de AA em membros de betão armado reforçados com fibras de polímero (FRP). A investigação visou determinar a eficácia dessas técnicas na previsão do comportamento estrutural de membros de betão reforçado com FRP, comparando os resultados com os métodos empíricos tradicionais amplamente utilizados na engenharia estrutural. Foram aplicadas redes neurais artificiais (ANN), regressão linear (LR), máquinas de vetores de suporte (SVM) e modelos de ensemble como random forest (RF) e extreme gradient boosting (XGBoost). Esses modelos foram treinados para prever diferentes aspectos do comportamento dos membros reforçados com FRP, incluindo a resistência à flexão, ao corte e o confinamento de pilares. Cada técnica foi

ajustada e testada para fornecer a melhor previsão com base nos dados experimentais disponíveis. Os objetos de estudo foram membros de betão armado reforçados com polímeros de fibra (FRP) sob várias condições estruturais, como resistência à flexão, corte e confinamento de pilares. Os resultados mostraram que as técnicas da aprendizagem automática proporcionaram previsões significativamente mais precisas do que os métodos empíricos tradicionais. Em particular, as redes neurais artificiais e o XGBoost destacaram-se na previsão da resistência à flexão e ao corte, enquanto o random forest apresentou melhor desempenho na previsão da força de ligação do FRP. No caso do confinamento de pilares, as técnicas da aprendizagem automática revelaram-se mais fiáveis e precisas em relação aos métodos empíricos.

Limitações

No entanto, o estudo identificou algumas limitações, como a necessidade de selecionar cuidadosamente os algoritmos mais adequados e de otimizar os parâmetros para cada aplicação estrutural específica. O desempenho dos modelos da aprendizagem automática depende também da qualidade e dimensão do conjunto de dados utilizado, sendo que a existência de uma distribuição desequilibrada pode afetar a robustez dos resultados preditivos.

Perspetivas Futuras

Como perspetiva futura, Alhusban, Alhusban e Alkhawaldeh (2024a) sugerem a expansão das bases de dados experimentais e o desenvolvimento de algoritmos especializados para diferentes tipologias de membros de betão reforçados com FRP. A integração de técnicas da aprendizagem automática com a modelação por elementos finitos é igualmente recomendada para permitir uma análise mais robusta e abrangente do comportamento estrutural.

- O estudo desenvolvido por Haroon et al. (2021) teve como objetivo prever o comportamento torsional de vigas de betão armado (RC) utilizando redes neurais artificiais (ANN). O estudo procurou fornecer uma análise abrangente e paramétrica da resposta torsional dessas vigas, um problema complexo que não é abordado de forma adequada pelos métodos tradicionais de engenharia.

O modelo aplicado baseou-se em redes neurais artificiais (ANN) com a técnica de back-propagation para prever a resistência torsional máxima das vigas RC. O treino e validação do modelo foram realizados com uma base de dados experimental composta por 159 vigas RC, coletadas de estudos anteriores. Para aumentar a precisão das previsões, foram aplicados métodos de pré-processamento de dados, como análise de componentes principais (PCA) e autoencoder, que ajudaram a otimizar a entrada de dados para o modelo. Os objetos de estudo foram vigas de

betão armado reforçadas com aço transversal e longitudinal. Os resultados mostraram que as ANN foram significativamente mais eficazes na previsão da resistência torsional em comparação com os métodos tradicionais, como os códigos de projeto ACI 318-19, EC2-04, CSA-14 e JSCE-07. O coeficiente de variação (CV) das previsões utilizando as ANN foi de 5,47% para o PCA e de 2,86% para o autoencoder, enquanto os métodos de código de projeto apresentaram coeficientes de variação superiores a 20%. O modelo ANN também capturou de forma mais precisa a influência de variáveis como a quantidade de reforço longitudinal e transversal na resistência torsional das vigas.

Limitações

Apesar dos resultados promissores, o estudo identificou algumas limitações. A precisão do modelo ANN depende da qualidade e extensão da base de dados utilizada para treino. As previsões podem ser menos fiáveis quando aplicadas a vigas cujos parâmetros estejam fora do intervalo coberto pela base de dados experimental.

Perspetivas Futuras

Para o futuro, Haroon et al. (2021) sugerem a expansão da base de dados experimental para melhorar a generalização do modelo ANN. Recomenda-se também a exploração de outras técnicas da aprendizagem automática para otimizar ainda mais as previsões do comportamento torsional. Além disso, propõe-se a integração de modelos numéricos com as redes neurais para melhorar a capacidade preditiva dos sistemas.

- O estudo desenvolvido por Çevik et al. (2015) teve como objetivo revisar a aplicação das máquinas de vetores de suporte (SVM) na engenharia estrutural, avaliando a eficácia desta técnica em diversos problemas estruturais. O artigo apresentou três estudos de caso para avaliar o desempenho das SVM em comparação com métodos tradicionais e outras técnicas da aprendizagem automática. O método de máquinas de vetores de suporte (SVM) foi aplicado para prever a capacidade última de carga em três diferentes estudos de caso: lajes de betão armado reforçadas com polímeros de fibra (FRP), consolas de betão reforçadas com fibras de aço (SFRC) e vigas de betão armado com cantos. Foram exploradas diferentes funções de kernel, incluindo linear, polinomial, radial e sigmoidal, bem como dois tipos de regressão por vetores de suporte (SVR): Nu-SVR e Epsilon-SVR. Os dados experimentais recolhidos foram utilizados para treinar os modelos de SVM e avaliar a sua capacidade preditiva em relação aos métodos empíricos tradicionais. Os objetos de estudo incluíram lajes reforçadas com FRP, consolas de betão com SFRC e vigas de betão armado. Em termos de resultados, os modelos SVM superaram os métodos empíricos na precisão preditiva.

No caso das lajes reforçadas com FRP, o modelo SVM apresentou um erro quadrático médio (MSE) de 485,2, em comparação com os 2260,9 obtidos pelo método empírico. O coeficiente de correlação (R^2) foi de 0,994, demonstrando a elevada precisão do SVM na previsão da carga de punção das lajes. Para as consolas de SFRC, o SVM obteve um MSE de 4,735 e um R^2 de 0,975, evidenciando a sua capacidade de generalização. Nas vigas com cantos, o modelo SVM também apresentou um R^2 elevado de 0,997, confirmando a sua eficácia.

Limitações

No entanto, o estudo também identificou algumas limitações, como a complexidade na escolha do tipo de kernel e na seleção dos parâmetros de hiperplaneamento, que dependem de tentativa e erro. Além disso, o desempenho do modelo SVM depende fortemente da qualidade e quantidade dos dados experimentais disponíveis.

Perspetivas Futuras

Como perspetiva futura, Çevik et al. (2015) sugerem a integração de SVM com outras técnicas de modelação numérica, como a modelação por elementos finitos, para melhorar a precisão em problemas estruturais complexos. Recomenda-se também a expansão das bases de dados experimentais, visando melhorar a robustez dos modelos SVM e torná-los aplicáveis a uma gama mais ampla de situações estruturais.

- O estudo realizado por Wan e M. Xu (2024) aplicou um modelo de perceptron multicamadas (MLP) em conjunto com algoritmos meta-heurísticos para prever a resistência ao corte não drenado (USS) em solos sensíveis. O objetivo principal foi aumentar a precisão e a eficiência dos métodos preditivos, superando as limitações dos métodos tradicionais em geotecnia, que muitas vezes dependem de correlações empíricas e apresentam ineficiências em termos de tempo e custo. O modelo de perceptron multicamadas (MLP) foi combinado com três algoritmos de optimização meta-heurística: dynamic control cuckoo search (DCCS), bonobo optimizer (BO) e smell agent optimization (SAO). Esses algoritmos foram utilizados para otimizar as previsões da USS, com base em quatro variáveis de entrada: peso de sobrecarga (OBW), limite líquido (LL), atrito de manga (SF) e limite plástico (PL). O conjunto de dados experimental foi dividido em 70% para treino e 30% para teste, seguindo as melhores práticas para garantir a robustez do modelo. Os objetos de estudo foram solos sensíveis, e os resultados mostraram que os modelos híbridos propostos com MLP e os três algoritmos de optimização apresentaram um desempenho significativamente superior aos métodos tradicionais. O modelo otimizado com DCCS (MLDC3) destacou-se, alcançando um coeficiente de determinação (R^2) de 0,9949 e um erro quadrático médio (RMSE) de 73,474

na fase de treino, o que indica uma excelente capacidade preditiva da USS. O estudo demonstrou que a combinação do MLP com o DCCS é altamente eficaz, reduzindo os erros de previsão e aumentando a precisão em relação aos métodos convencionais.

Limitações

Entre as limitações do estudo, destaca-se o desafio de selecionar adequadamente os hiperparâmetros dos algoritmos meta-heurísticos, dada a sua complexidade. Além disso, o desempenho do modelo depende diretamente da qualidade e abrangência dos dados experimentais disponíveis, o que pode limitar a sua aplicabilidade a diferentes tipos de solos ou condições geotécnicas.

Perspectivas Futuras

Como perspectiva futura, Wan e M. Xu (2024) sugerem a expansão dos conjuntos de dados utilizados no treino dos modelos e a exploração de outros algoritmos de otimização meta-heurística, visando melhorar ainda mais a precisão dos modelos preditivos. Além disso, recomendam a integração de técnicas da aprendizagem automática com análises numéricas avançadas, uma área promissora para melhorar a modelação do comportamento geotécnico.

- O estudo realizado por Hakim et al. (2024) tem como objetivo desenvolver e comparar duas técnicas de inteligência artificial, as redes neurais artificiais (ANNs) e os sistemas de inferência neuro-fuzzy adaptativos (ANFIS), para prever a resistência ao corte de vigas de betão armado (RC) sem estribos. O foco está em determinar qual das técnicas oferece maior precisão preditiva, contribuindo para um design estrutural mais eficaz e eficiente. Foram utilizadas duas abordagens principais: as ANNs e o ANFIS. As variáveis de entrada para ambos os modelos incluíram parâmetros essenciais como a resistência à compressão do betão, a profundidade e a largura efetiva da viga, a relação vão-profundidade, a proporção de aço longitudinal e a resistência ao escoamento do aço. Ambos os modelos foram treinados com uma base de dados composta por 506 conjuntos de dados experimentais de vigas RC sem estribos, permitindo avaliar o desempenho preditivo em diferentes cenários estruturais. Os resultados indicaram que o ANFIS superou o ANN em termos de desempenho preditivo. O ANFIS demonstrou um menor erro quadrático médio (MSE) e uma correlação mais forte entre os dados previstos e os dados reais. No conjunto de treino, o ANFIS obteve um MSE de 0.0000618, significativamente inferior ao MSE apresentado pelo ANN, especialmente em situações onde os dados eram ruidosos ou insuficientes. A arquitetura híbrida do ANFIS mostrou-se mais eficaz para a previsão da resistência ao corte de vigas RC, proporcionando uma precisão superior à do modelo ANN.

Limitações

Apesar dos resultados positivos, o estudo identificou algumas limitações. A principal limitação decorre da dependência dos dados experimentais disponíveis. A precisão dos modelos pode ser comprometida por dados insuficientes ou de baixa qualidade, sendo a ANN particularmente sensível a essas condições. Adicionalmente, o tempo de computação necessário para treinar as ANNs pode ser significativamente maior em comparação com o ANFIS.

Perspetivas Futuras

Para investigações futuras, Hakim et al. (2024) sugerem a integração de modelos ANFIS com algoritmos de otimização para melhorar ainda mais a precisão preditiva. Recomenda-se também a expansão dos conjuntos de dados e a aplicação de técnicas híbridas, que podem contribuir para o desenvolvimento de modelos preditivos mais robustos e generalizáveis.

- O estudo realizado por Alagundi e Palanisamy (2022) teve como objetivo desenvolver um modelo de redes neurais artificiais (ANN) para prever a resistência ao corte em juntas de vigas-colunas interiores de betão armado (RC). Este modelo pretende fornecer uma ferramenta preditiva mais precisa e eficaz em comparação com os métodos tradicionais de dimensionamento de juntas, superando as limitações de modelos anteriores ao captar melhor a não linearidade dos parâmetros envolvidos. O modelo de ANN foi treinado com um conjunto de dados composto por 100 espécimes de juntas de vigas-colunas RC sujeitas a cargas cíclicas. As variáveis de entrada incluíram fatores como a largura e profundidade da junta, a resistência à compressão do betão, a percentagem de área de armadura nas vigas e colunas, o nível de carga da coluna e a percentagem de reforço da junta. O modelo foi desenvolvido com base no algoritmo de Levenberg-Marquardt, com uma arquitetura de 8 neurónios na camada de entrada, 11 na camada oculta e 1 neurónio na camada de saída. Os resultados mostraram que o modelo ANN apresentou um excelente desempenho preditivo, com coeficientes de correlação (R^2) de 0,9602 para o conjunto de treino, 0,9842 para o teste e 0,9865 para a validação. O erro quadrático médio (MSE) foi inferior a 0,005 em todos os conjuntos, demonstrando uma elevada precisão na previsão da resistência ao corte das juntas. Em comparação com métodos normativos tradicionais, como o ACI 352, o modelo ANN foi significativamente mais preciso, captando a influência de variáveis importantes que não são consideradas nas fórmulas empíricas.

Limitações No entanto, o estudo identificou algumas limitações. A principal limitação está na dependência de dados experimentais. A qualidade e a variedade dos dados utilizados são cruciais para a capacidade de generalização do modelo, e os dados utilizados no estudo são limitados a um tipo específico de juntas

e condições de carregamento.

Perspetivas Futuras Como perspectiva futura, Alagundi e Palanisamy (2022) sugerem a ampliação da base de dados experimental, incorporando diferentes tipos de juntas e condições de carga. Além disso, recomendam a integração de outros métodos da aprendizagem automática para melhorar ainda mais a precisão e aplicabilidade dos modelos preditivos.

- O estudo de Simwanda e Ikotun (2024) teve como objetivo prever a capacidade de torque em membros tubulares de dupla camada preenchidos com betão (CFDST) sob torção pura, utilizando algoritmos da aprendizagem automática (ML). O estudo também implementou explicações aditivas de Shapley (SHAP) para interpretar os resultados dos modelos de ML, identificando os fatores mais influentes na previsão da capacidade de torque desses membros estruturais. Foram aplicados diversos algoritmos da aprendizagem automática, incluindo CatBoost, XGBoost, Gradient Boosting Machine (GBM), Random Forest (RF) e Decision Tree (DT). A análise SHAP foi utilizada para interpretar as previsões dos modelos, destacando as variáveis mais influentes, como a resistência à compressão do betão e as dimensões dos tubos de aço. O conjunto de dados utilizado para treino e teste dos modelos incluiu parâmetros experimentais e numéricos provenientes de ensaios de CFDST submetidos a torção pura. Os resultados indicaram que os modelos CatBoost e XGBoost apresentaram o melhor desempenho, com coeficientes de determinação (R^2) elevados e erros quadráticos médios (RMSE) inferiores quando comparados com os métodos analíticos tradicionais. A análise SHAP revelou que as variáveis mais importantes para a previsão da capacidade de torque são a resistência à compressão do betão e as propriedades dos tubos de aço. Esses modelos de aprendizagem automática demonstraram ser significativamente mais precisos do que as fórmulas tradicionais, oferecendo uma ferramenta preditiva mais eficaz para o design estrutural de membros CFDST.

Limitações

Apesar dos resultados positivos, o estudo identificou algumas limitações. A eficácia dos modelos da aprendizagem automática depende da qualidade e variedade dos dados disponíveis para treino. Além disso, a complexidade da análise com SHAP pode dificultar a interpretação dos resultados em certos casos, especialmente quando se lidam com grandes volumes de dados e variáveis complexas.

Perspetivas Futuras

Como perspectiva futura, Simwanda e Ikotun (2024)) sugerem a integração de análises probabilísticas para aumentar a resiliência estrutural dos membros CFDST. Além disso, propõem a exploração de técnicas híbridas que combinem aprendizagem automática com métodos tradicionais de otimização. A expansão

da base de dados e a aplicação da metodologia a diferentes geometrias de membros CFDST também são recomendadas para futuras investigações.

- O estudo realizado por Kaloop et al. (2020) teve como objetivo prever a resistência à compressão de betão de alto desempenho (HPC) utilizando o modelo de Gradient Tree Boosting Machine (GBM). Além disso, o artigo propõe uma comparação do desempenho do GBM com outros modelos, como a regressão de crista com núcleo (KRR) e a regressão por processo Gaussiano (GPR), visando melhorar a precisão da previsão da resistência à compressão do HPC. No método aplicado, o modelo GBM foi utilizado para prever a resistência à compressão após a extração das variáveis mais influentes por meio de Multivariate Adaptive Regression Splines (MARS). A técnica MARS foi empregada para selecionar os parâmetros mais relevantes, como a idade do betão, o teor de cimento e a proporção de aditivos. O modelo GBM foi então aplicado a um conjunto de dados que incluía 1030 amostras experimentais de betão de alto desempenho, considerando oito variáveis de entrada, incluindo cimento, escória de alto-forno, água e aditivos. Os resultados mostraram que o modelo GBM teve um desempenho superior em relação ao KRR e GPR, apresentando um coeficiente de correlação (R^2) de 0,992 para o conjunto de treino e 0,965 para o teste. A idade do betão foi identificada como o fator mais influente na previsão da resistência à compressão, seguida pela quantidade de cimento e água. O GBM demonstrou uma precisão significativamente maior do que os outros modelos, com um erro médio absoluto (MAE) de 0,037 MPa e um erro quadrático normalizado (NRMSE) de 26,5%.

Limitações

Apesar dos resultados positivos, o estudo destaca algumas limitações. A eficácia do modelo GBM pode ser restringida pela complexidade dos dados e pela necessidade de um ajuste fino dos parâmetros para evitar o overfitting. Além disso, a capacidade de generalização do modelo para outros tipos de betão e misturas pode exigir ajustes adicionais e validação com novos conjuntos de dados.

Perspetivas Futuras

Como perspectiva futura, Kaloop et al. (2020) recomendam que futuras pesquisas explorem a combinação de modelos híbridos que integrem técnicas da aprendizagem automática com métodos tradicionais de engenharia, com o objetivo de melhorar ainda mais a previsibilidade da resistência à compressão. O estudo também sugere a expansão da base de dados para incluir uma variedade maior de misturas de betão e condições de cura.

- O estudo realizado por J. Guo, L. Wang e Shan (2023) tem como objetivo prever o comportamento histerético de colunas de betão armado (RC) utilizando redes neurais LSTM bidirecionais

(BLSTM). O foco principal é desenvolver uma metodologia baseada em dados que possa prever com precisão as curvas de histerese de componentes estruturais, auxiliando na mitigação de desastres estruturais sob cargas cíclicas. O método de IA aplicado neste estudo consistiu no desenvolvimento de uma rede LSTM bidirecional (BLSTM), que utiliza dados temporais provenientes de simulações numéricas e experimentos de campo. O modelo foi treinado com uma combinação de dados do banco de dados PEER e simulações geradas pelo software OpenSEES. A camada de corte foi utilizada para modelar as características temporais, ajustando os dados para previsões mais precisas e evitando a perda de informação, o que melhorou o desempenho geral da rede. Os objetos de estudo incluíram 1015 colunas de RC simuladas e 400 colunas experimentais. Os resultados mostraram que o modelo BLSTM apresentou uma precisão robusta, com erro absoluto médio (MAE) variando de 1% a 3% para as colunas simuladas e de 1% a 7% para as colunas experimentais. A precisão do modelo BLSTM superou a de redes neurais convolucionais (CNN), alcançando um coeficiente de determinação (R^2) de 0,9993 para as simulações e 0,9989 para os dados experimentais, indicando um excelente ajuste entre os valores preditivos e os dados reais.

Limitações

A principal limitação reside na necessidade de uma maior diversidade de dados experimentais para melhorar a capacidade de generalização do modelo, especialmente em colunas com características mais variadas. Além disso, o desempenho do modelo em cenários mais complexos ainda precisa ser investigado em futuras pesquisas.

Perspectivas Futuras

Como perspectiva futura, os autores sugerem a expansão da aplicação do modelo para prever outros comportamentos estruturais e explorar a utilização da aprendizagem por transferência (transfer learning) para resolver diferentes problemas de previsão em engenharia civil. O objetivo é desenvolver um modelo universal que possa ser ajustado para diversos cenários com pequenos lotes de dados.

- O estudo realizado por Z. Ding et al. (2024) tem como objetivo desenvolver um modelo de previsão da tensão última em tendões de betão pré-esforçado, utilizando o método de seleção de características baseado na análise de componentes de vizinhança (NCA) e o algoritmo de árvores de regressão reforçadas por gradiente (GBRT). A proposta é melhorar a precisão preditiva e otimizar os custos computacionais, através da redução da dimensionalidade dos dados. O método de IA aplicado combina o modelo GBRT com otimização bayesiana para o ajuste de hiperparâmetros, complementado pela técnica NCA para selecionar as variáveis mais relevantes. O conjunto de dados consistiu em 251 resultados experimentais de vigas de betão pré-esforçado simplesmente apoiadas.

A validação do modelo foi realizada com a análise de correlação condicional independente (ICE), permitindo avaliar a importância de cada variável nas previsões. Os objetos de estudo foram vigas de betão pré-esforçado com tendões sem aderência. O modelo GBRT demonstrou um coeficiente de determinação (R^2) de 0,9330, indicando uma alta precisão na previsão da tensão última dos tendões. O erro quadrático médio (RMSE) foi de 85,84 MPa, enquanto o erro percentual médio absoluto (MAPE) foi de 4,77%. A análise identificou que as variáveis mais influentes na previsão da tensão incluíram a tensão efetiva de pré-esforço, a resistência à compressão do betão e a área dos tendões.

Limitações

O modelo GBRT é sensível à presença de outliers, o que pode impactar negativamente a precisão preditiva. Além disso, a inclusão de mais dados experimentais, especialmente em diferentes configurações de vigas, poderia melhorar a capacidade de generalização do modelo.

Perspetivas Futuras

Como perspectiva futura, os autores recomendam a expansão do modelo para incluir vigas com tendões aderentes, bem como a investigação do uso de outras técnicas da aprendizagem automática que possam aumentar a precisão preditiva. A integração de métodos híbridos e aprimoramentos na seleção de características são também sugeridos para aumentar a robustez do modelo.

- O estudo realizado por Elhishi, Elashry e El-Metwally (2023) tem como objetivo avaliar o desempenho de oito modelos da aprendizagem automática na previsão da resistência do betão, utilizando técnicas de explicabilidade da inteligência artificial (XAI) para aprimorar a interpretação dos modelos. O foco do artigo é a aplicação da técnica SHAP (Shapley Additive Explanations), que visa fornecer aos engenheiros civis insights mais claros sobre o comportamento do betão em diferentes composições e condições de carga. Os oito modelos da aprendizagem automática analisados incluem regressão linear, regressão Ridge, LASSO, árvores de decisão, Random Forests, XGBoost, SVM (máquina de vetor de suporte) e redes neurais artificiais (ANN). Os modelos foram treinados com um conjunto de dados padrão que continha 1030 amostras de betão, considerando variáveis como cimento, água, agregados grossos e finos, superplastificantes, escória e cinzas volantes. O modelo XGBoost foi identificado como o mais eficaz, apresentando uma precisão superior, e foi analisado com a técnica SHAP para oferecer interpretações detalhadas. Os resultados indicaram que o modelo XGBoost alcançou um coeficiente de determinação (R^2) de 0,91 e um erro quadrático médio (RMSE) de 4,37, superando os outros modelos testados. Os objetos de estudo incluíram diferentes composições de betão, com variações nos componentes

principais, como cimento e agregados. A análise realizada com a técnica SHAP revelou que as variáveis mais impactantes na previsão da resistência do betão foram o cimento, a idade do betão e o superplastificante, enquanto a água apresentou a maior correlação negativa.

Limitações

A principal limitação foi a necessidade de ajuste fino dos hiperparâmetros, além da alta sensibilidade do modelo a dados de treino ruidosos. O conjunto de dados utilizado, embora padrão, pode não representar completamente todas as variações de misturas de betão encontradas na prática.

Perspetivas Futuras

Como perspetiva futura, os autores recomendam que futuras investigações se concentrem na expansão do conjunto de dados para incluir mais variáveis relacionadas ao tempo de cura e às propriedades mecânicas do betão. A combinação de técnicas de explicabilidade, como SHAP, com outras abordagens da aprendizagem automática pode oferecer um maior nível de transparência e confiabilidade nos resultados preditivos.

- O estudo realizado por Di et al. (2023) investiga o comportamento ao corte de vigas de betão reforçadas com barras de fibras de polímero (FRP) e estribos. O principal objetivo é desenvolver um modelo preditivo da capacidade de corte, utilizando redes neuronais artificiais (ANN) combinadas com um algoritmo genético (GA). A proposta visa superar as limitações dos modelos semi-empíricos existentes, que frequentemente falham em prever a complexidade dos mecanismos de corte em elementos reforçados com FRP. O método de IA aplicado consiste em um modelo híbrido de ANN otimizado por algoritmos genéticos (GA-ANN). Foi compilado um banco de dados experimental com 120 amostras, incluindo variáveis de entrada como a largura da viga, profundidade efetiva, razão de vão para profundidade, resistência à compressão do betão e outras propriedades do FRP, como módulo de elasticidade e razão de reforço longitudinal e transversal. As redes neuronais foram treinadas e otimizadas com o GA para melhorar a precisão na previsão da capacidade de corte. Os resultados mostraram que o modelo GA-ANN alcançou um coeficiente de determinação (R^2) de 0,91 e um erro quadrático médio (RMSE) de 22,6 kN, superando as previsões feitas pelo código CSA S806-12. O modelo melhorou a precisão em 18,2% para R^2 e reduziu o RMSE em 52,5%. Este modelo demonstrou eficácia ao considerar os efeitos de acoplamento entre os parâmetros de projeto, como a razão de reforço longitudinal e o módulo de elasticidade do FRP.

Limitações

A complexidade computacional do modelo GA-ANN é uma restrição significativa, exigindo grandes quantidades de dados experimentais e considerável poder computacional para o treinamento das redes

neuronaís. Além disso, a aplicabilidade dos resultados pode ser limitada a vigas com características semelhantes às do banco de dados utilizado.

Perspetivas Futuras

Para as perspectivas futuras, os autores recomendam a aplicação da abordagem GA-ANN em outros tipos de estruturas e a expansão da base de dados experimental para incluir diferentes variações geométricas e materiais de reforço. Sugere-se também o desenvolvimento de metodologias mais eficientes que possam reduzir a carga computacional e melhorar a generalização do modelo.

- O estudo realizado por Lin e Ibraheem (2024) investiga a aplicação de técnicas da aprendizagem automática (ML) para estimar as vibrações de estruturas de betão reforçadas com nanocompósitos avançados, como o óxido de grafeno (GOP). A integração desses nanocompósitos visa melhorar as propriedades mecânicas e a durabilidade das estruturas, no entanto, prever o seu comportamento vibracional permanece um desafio devido à complexidade não linear dos materiais. O método de IA aplicado no estudo envolve redes neurais artificiais (ANN), que utilizam dados gerados a partir de modelação matemática como entrada para prever as respostas de vibração. A metodologia de aprendizagem automática explora as relações entre as propriedades dos materiais, as configurações estruturais e as condições ambientais, permitindo prever o comportamento vibracional de forma eficiente. O artigo também discute desafios relacionados à seleção de características, à qualidade dos dados, à complexidade do modelo e à interpretabilidade. Os objetos de estudo foram estruturas de betão reforçadas com nanocompósitos de óxido de grafeno. O modelo da aprendizagem automática proposto demonstrou a capacidade de capturar com precisão os padrões vibracionais dessas estruturas, oferecendo previsões mais precisas do que os métodos tradicionais de modelação analítica. A integração do GOP aumentou a rigidez e, consequentemente, a frequência natural das estruturas analisadas, especialmente em frações maiores de GOP.

Limitações

As principais limitações apontadas incluem a dependência da qualidade dos dados de entrada e a complexidade dos modelos necessários para capturar adequadamente as relações entre as variáveis envolvidas. Além disso, a seleção de características e o ajuste dos modelos de aprendizagem automática exigem um esforço adicional para melhorar a precisão das previsões.

Perspetivas Futuras

Como perspectiva futura, os autores sugerem que pesquisas adicionais explorem a aplicação de técnicas híbridas da aprendizagem automática, integrando vários modelos de aprendizagem automática para aprimorar a robustez e a precisão preditiva em estruturas de betão reforçadas com nanocompósitos. O uso

da aprendizagem automática para a manutenção preventiva e a otimização do desempenho estrutural é identificado como um campo promissor para investigações futuras.

- O estudo realizado por Deng, R. Zhang e Xue (2022) tem como objetivo aplicar o método de manipulação de dados em grupo (GMDH) para prever as condições últimas (resistência à compressão e deformação axial) de cilindros de betão confinados com polímero reforçado com fibras (FRP). A pesquisa visa melhorar a precisão das previsões em comparação com modelos de confinamento existentes, oferecendo uma referência eficaz para aplicações práticas. No que diz respeito ao método de IA aplicado, o artigo utiliza o algoritmo GMDH, que é uma técnica da aprendizagem indutiva. Este método foi utilizado para desenvolver um modelo preditivo com base em uma base de dados experimental que contém 221 amostras de cilindros de betão normal confinados com FRP. O GMDH é estruturado como uma rede neural polinomial, dividida em três camadas (entrada, oculta e saída), sendo a seleção de neurônios baseada no desvio quadrático médio. Os coeficientes são ajustados por mínimos quadrados para otimizar o ajuste entre as previsões e os valores reais. Os resultados obtidos indicam que o modelo GMDH demonstrou superioridade em relação aos modelos tradicionais, alcançando um coeficiente de determinação (R^2) de 0,97 para a resistência à compressão e 0,91 para a deformação axial última, superando nove modelos existentes. A análise de correlação revelou que variáveis como a tensão de confinamento, a razão de rigidez e a espessura da camisa de FRP tiveram o maior impacto nas previsões de resistência e deformação axial.

Limitações

O modelo GMDH depende fortemente da qualidade e variedade dos dados experimentais disponíveis. Além disso, a complexidade computacional do método, que envolve um grande número de neurônios e camadas ocultas, pode representar um desafio para sua implementação em larga escala.

Perspetivas Futuras

Para as perspetivas futuras, os autores recomendam que pesquisas adicionais explorem a aplicação do método GMDH em outros tipos de betão e em diferentes condições de confinamento. O desenvolvimento de interfaces gráficas de utilizador (GUI) para facilitar a aplicação em projetos estruturais também foi sugerido como um passo importante para transformar o modelo em uma ferramenta prática para a engenharia.

- O estudo realizado por Wakjira et al. (2022) tem como objetivo desenvolver uma ferramenta de previsão rápida, precisa e inteligente (FAI) para a capacidade flexional de vigas de betão armado com barras de polímero reforçado com fibras (FRP-RC). O modelo de previsão é baseado em um

modelo da aprendizagem automática denominado super-learner, que busca superar as limitações das diretrizes e equações existentes para o dimensionamento de FRP-RC, que muitas vezes carecem de precisão e são baseadas em dados experimentais limitados. No que diz respeito ao método de IA aplicado, o estudo utiliza um modelo de super-learner, que combina múltiplos algoritmos da aprendizagem automática, como árvores de decisão, AdaBoost, e gradient boosted decision trees (GBDT), para produzir um único modelo preditivo robusto. Foram utilizados dados de 132 ensaios experimentais de vigas FRP-RC, e o desempenho do super-learner foi comparado com modelos baseados em equações de diretrizes existentes, como ACI 440.1R-15 e CAN/CSA-S806-12. A otimização dos hiperparâmetros foi realizada por meio de grid search combinado com validação cruzada de 10 folds. Os resultados indicaram que o modelo de super-learner superou significativamente os modelos baseados em equações tradicionais. O coeficiente de determinação (R^2) foi de 99,63%, com um erro absoluto médio percentual (MAPE) de 3,37% e um erro quadrático médio (RMSE) de 2,91 kN.m. O modelo super-learner demonstrou uma precisão consideravelmente maior na previsão da capacidade flexional das vigas FRP-RC em comparação com os modelos baseados nas diretrizes ACI e CAN/CSA.

Limitações

Apesar do desempenho positivo, uma limitação identificada é que, embora o modelo super-learner tenha superado as equações tradicionais, ele ainda depende de um grande conjunto de dados experimentais para manter sua precisão. A generalização do modelo pode ser limitada a contextos que disponham de dados experimentais suficientes.

Perspetivas Futuras

Para as perspectivas futuras, os autores sugerem a incorporação de modelos da aprendizagem automática orientados pela física para melhorar ainda mais a precisão e a capacidade de generalização do modelo FAI. Além disso, recomenda-se a atualização contínua do banco de dados com novos dados experimentais para ampliar a aplicabilidade do modelo.

- O estudo realizado por Berradia et al. (2023) tem como objetivo desenvolver um modelo de estimação baseado no método GMDH (Group Method of Data Handling) para prever a capacidade de carga axial de colunas circulares de betão reforçadas com fibras de polímero (GFRP). A pesquisa visa melhorar a precisão das previsões utilizando um conjunto de dados experimental significativo, que contém múltiplos parâmetros relevantes para descrever o comportamento das colunas sob compressão axial. O método de IA aplicado no estudo é o GMDH, uma técnica especial de rede neuronal que utiliza o método dos mínimos quadrados para estimar os coeficientes das equações

nas diferentes camadas da rede. O GMDH foi treinado com um conjunto de dados que incluiu 61 colunas circulares de betão reforçadas com GFRP, retirado de estudos experimentais anteriores. O modelo foi avaliado com base em métricas estatísticas, como o erro absoluto médio (MAE), o erro quadrático médio (RMSE) e o coeficiente de determinação (R^2), para verificar a sua precisão preditiva. Os resultados obtidos demonstraram que o modelo baseado em GMDH foi capaz de prever a capacidade de carga axial das colunas com um alto grau de precisão. Comparado com outros modelos teóricos e empíricos, o GMDH obteve um MAE de 195,67 kN, um RMSE de 255,41 kN e um R^2 de 0,94. Esses resultados indicam que o modelo proposto tem uma boa correlação com os dados experimentais e pode ser utilizado para prever com precisão a capacidade de compressão de colunas de betão reforçadas com GFRP em projetos de engenharia estrutural.

Limitações

As principais limitações referem-se à generalização do modelo GMDH para outros tipos de colunas de betão que não estão incluídas no conjunto de dados. Além disso, o modelo foi validado apenas com colunas circulares reforçadas com GFRP, o que pode restringir a sua aplicabilidade a outras geometrias ou materiais.

Perspetivas Futuras

Como perspectivas futuras, os autores sugerem a possibilidade de expandir o modelo GMDH para incluir outros tipos de colunas e materiais, visando aumentar a sua aplicabilidade em diferentes contextos estruturais. Futuros estudos também poderão focar na melhoria da eficiência computacional do modelo, de forma a torná-lo mais rápido e acessível para aplicações práticas na engenharia civil.

- O artigo de Dhakal et al. (2023) tem como principal objetivo desenvolver um modelo de previsão baseado em redes neurais artificiais (ANN) para estimar com precisão o desempenho de compressão de colunas circulares de betão confinadas com polímeros reforçados com fibra (FRP). O estudo analisa a influência de seis parâmetros-chave, incluindo o diâmetro da coluna, a espessura do FRP, a resistência à compressão do betão sem FRP, e o módulo de elasticidade do FRP, no aumento da resistência à compressão quando as colunas são confinadas. Para o método de IA aplicado, foi utilizado um modelo de redes neurais artificiais (ANN), desenvolvido através da ferramenta Neural Designer, que prevê a resistência à compressão final de colunas de betão confinadas com FRP. O modelo foi treinado com uma base de dados de 170 amostras experimentais, e os parâmetros selecionados incluem o diâmetro da coluna, a espessura do FRP, a resistência inicial do betão, o módulo de elasticidade do FRP e a tensão de compressão do FRP. O modelo ANN foi projetado para identificar as relações não lineares entre esses parâmetros e a resistência

à compressão, resultando em uma precisão elevada, com um erro percentual médio de 3,72. Os resultados obtidos demonstraram que o modelo ANN superou modelos teóricos tradicionais, como os de Fardis, Lam e Mander, em termos de precisão preditiva da resistência à compressão. O modelo ANN obteve uma correlação de $R^2 = 0,45$ e um erro quadrático médio (RMSE) de 29,39, indicando um ajuste eficaz entre os valores preditos e os reais. A análise dos coeficientes de correlação revelou que a resistência à compressão sem FRP é o fator mais influente, seguida pela resistência à tração e pelo módulo de elasticidade do FRP. O estudo também observou uma correlação negativa fraca entre a razão diâmetro-espessura e a resistência à compressão final.

Limitações

Entre as limitações do estudo, destaca-se o tamanho relativamente reduzido do conjunto de dados (170 amostras), o que pode restringir a capacidade de generalização do modelo ANN. Além disso, a pesquisa não analisa o impacto de diferentes tipos de FRP ou de condições ambientais variáveis nas previsões de desempenho, o que poderia aumentar a robustez e aplicabilidade prática do modelo.

Perspetivas Futuras

Para as perspectivas futuras, os autores recomendam a expansão da base de dados para incluir uma maior diversidade de amostras e condições, o que aumentaria a precisão e a generalização do modelo ANN. Também sugerem a incorporação de mais variáveis relacionadas às propriedades do FRP, como diferentes configurações de confinamento e tipos de fibras, para melhorar ainda mais a precisão preditiva do modelo.

- O artigo de H. Li et al. (2024) tem como objetivo principal desenvolver modelos de previsão generalizados que melhorem a capacidade de suporte de carga local de estruturas de betão, com ênfase nas zonas de ancoragem. A pesquisa busca superar as limitações dos modelos de previsão existentes, que frequentemente subestimam ou sobrestimam a capacidade de carga local em betão de alta resistência e ultra-alta resistência. Além disso, o estudo aborda a flexibilidade energética nos sistemas de construção, promovendo a sustentabilidade ambiental e a otimização do uso de materiais. Para o método de IA aplicado, o artigo utiliza uma combinação de redes neurais artificiais (ANN) e análise de ajuste (FA). As ANN são empregadas para prever a capacidade de carga local do betão, considerando fatores como a resistência do betão, a relação de aspecto da área local e a presença de condutas. Um modelo de análise de ajuste (FA) é implementado para calibrar e validar as previsões com dados experimentais. Os modelos propostos são comparados com abordagens normativas existentes, como os modelos GB50010-2010, CECS104:99, ACI318-19, e AASHTO. Os resultados demonstraram que os modelos FA e ANN superaram significativamente

os modelos normativos na previsão da capacidade de suporte local do betão. O desempenho dos modelos foi avaliado através de métricas como MAPE (erro percentual absoluto médio), RMSE (erro quadrático médio), e o coeficiente de determinação (R^2). As ANN e o modelo FA alcançaram valores de R^2 entre 0,93 e 0,94, superando os modelos normativos, que apresentaram valores variando entre 0,7 e 0,9. As previsões do modelo AASHTO subestimaram a capacidade de carga, enquanto os modelos GB50010-2010 e ACI318-19 tenderam a superestimar os dados experimentais.

Limitações

O estudo identifica algumas limitações, destacando que o desempenho do modelo depende da qualidade dos dados experimentais utilizados para o treino e validação. Além disso, os modelos foram testados predominantemente com betão de alta e ultra-alta resistência, podendo necessitar de validação adicional para betão de resistência convencional. Outra limitação mencionada é a aplicação restrita dos modelos a zonas de ancoragem e estruturas específicas.

Perspetivas Futuras

Para as perspetivas futuras, os autores sugerem que investigações adicionais explorem a aplicação dos modelos propostos a outros tipos de estruturas e cenários de carga. Também é recomendada a integração de dados em tempo real e sistemas de monitorização inteligente, permitindo ajustes dinâmicos nas previsões de capacidade de suporte local à medida que novos dados são recolhidos durante a vida útil das estruturas.

- O artigo de Milad et al. (2022) tem como principal objetivo desenvolver modelos da aprendizagem automática em conjunto (ensemble) para prever a deformação de compósitos reforçados com polímeros de fibra (FRP). O estudo busca superar as limitações dos modelos empíricos existentes, proporcionando uma abordagem mais robusta e precisa para a previsão da deformação de compósitos FRP em estruturas de engenharia civil, utilizando dados experimentais para treinar os modelos. Para o método de IA aplicado, foram desenvolvidos três modelos da aprendizagem automática ensemble: XGBoost (Extreme Gradient Boosting), MARS (Multivariate Adaptive Regression Splines) e Random Forest (RF). Esses modelos foram aplicados a um conjunto de dados com 729 amostras experimentais de compósitos FRP, utilizando variáveis de entrada que incluem propriedades geométricas, propriedades de resistência e características do FRP. A precisão dos modelos foi avaliada com base em métricas como o erro quadrático médio (RMSE), o erro absoluto médio (MAE) e o coeficiente de determinação (R^2). Os resultados mostraram que o modelo Random Forest teve a melhor performance entre os três modelos, alcançando um RMSE

de aproximadamente 0,15 e um R^2 de 0,99. O modelo MARS também apresentou resultados aceitáveis, especialmente ao utilizar menos parâmetros de entrada. Comparado aos modelos empíricos existentes, os modelos da aprendizagem automática demonstraram uma capacidade superior de previsão da deformação dos compósitos FRP, apresentando uma precisão significativamente maior.

Limitações

As limitações do estudo incluem a dependência de um conjunto de dados experimental limitado, o que pode restringir a generalização dos modelos para diferentes configurações estruturais e materiais. Além disso, os modelos requerem dados de alta qualidade para alcançar desempenho ótimo, e o processo de coleta de tais dados pode ser dispendioso e demorado.

Perspetivas Futuras

Para as perspectivas futuras, os autores sugerem que futuras investigações devem focar no desenvolvimento de modelos híbridos que combinem técnicas da aprendizagem automática com abordagens baseadas em física, para melhorar ainda mais a precisão e aplicabilidade dos modelos. Também é recomendado o uso de conjuntos de dados mais abrangentes, que incluam diferentes materiais e condições de carga, para aumentar a generalização dos modelos.

5.2 Otimização de Projeto Estrutural

Os primeiros métodos de otimização estrutural surgiram na década de 1960, com o foco em técnicas clássicas, como a programação linear e a programação não linear. Esses métodos se baseiam em funções objetivo e restrições baseadas em critérios de segurança e eficiência de materiais. Ghaboussi e M. (1991) foram pioneiros na introdução de métodos de otimização baseados em redes neurais, evidenciando o potencial da IA em cálculos estruturais.

Nos anos 1990, a utilização de métodos numéricos, como o Método dos Elementos Finitos (FEA), permitiu uma análise mais precisa do comportamento estrutural. Bendsøe e Kikuchi (1988) apresentaram um método de otimização topológica, permitindo a busca por distribuições ótimas de material em estruturas Bendsøe et al.(1988). Esse trabalho abriu caminho para a combinação de métodos de otimização com simulações estruturais.

Com a popularização da AA na última década, as técnicas de IA foram integradas de forma mais abrangente nos processos de otimização estrutural. Modelos preditivos baseados em redes neurais, como os utilizados por Islam et al. (2024), mostraram-se eficazes na previsão de comportamento estrutural e na otimização de designs.

Recentemente, a combinação de técnicas de IA com métodos tradicionais de otimização resultou em abordagens híbridas mais robustas. Yücel, Nigdeli e Bekdaş (2023), por exemplo, desenvolveram um modelo híbrido que combina otimização por enxame de partículas e redes neurais, demonstrando melhorias significativas na precisão preditiva e na eficiência do design.

5.2.1 Análise de Estudos

- O estudo realizado por Yücel, Bekdaş e Nigdeli (2023) visa avaliar e comparar o desempenho de três diferentes técnicas da aprendizagem automática: Regressão por Vetores de Suporte (SVR), k-vizinhos mais próximos (k-NN) e bagging — na previsão de parâmetros ótimos para dois modelos estruturais distintos: uma treliça de 3 barras e uma viga de betão armado simplesmente apoiada. O principal objetivo deste estudo consiste em determinar qual das metodologias oferece os melhores resultados em termos de precisão e eficiência temporal na otimização do projeto estrutural. No que se refere ao método de inteligência artificial aplicado, foram utilizadas as três técnicas mencionadas. A Regressão por Vetores de Suporte (SVR) é um método adequado para prever resultados de regressão em problemas não lineares, minimizando o erro de estimativa. Por sua vez, a técnica k-vizinhos mais próximos (k-NN) é uma abordagem de classificação que pode também ser aplicada a problemas de regressão, utilizando a proximidade dos dados para prever

valores desconhecidos. Por fim, o bagging, um método de agregação de modelos, combina várias sub-modelos para melhorar a precisão e reduzir o erro de previsão. Os resultados obtidos revelaram que, no modelo de treliça de 3 barras, o método SVR apresentou o melhor desempenho, com os menores valores de erro absoluto médio (MAE) e erro quadrático médio (RMSE) em comparação com as outras técnicas. No entanto, para a viga de betão armado, o bagging demonstrou ser mais eficaz na previsão de parâmetros como a altura e a área da armadura. De uma forma geral, os modelos de redes neurais artificiais (ANNs), conforme testados em estudos anteriores, ainda proporcionaram os melhores resultados, com o menor desvio entre os valores preditos e os reais.

Limitações

É importante ressaltar que o estudo apresenta algumas limitações. A aplicação das técnicas da aprendizagem automática é condicionada pela qualidade e quantidade dos dados utilizados para o treino dos modelos. Embora o SVR e o bagging tenham demonstrado resultados positivos, os autores destacam que a complexidade computacional dos algoritmos pode representar um entrave em aplicações práticas, especialmente em estruturas de grande escala.

Perspetivas Futuras

Em relação às perspetivas futuras, os autores sugerem que trabalhos subsequentes possam concentrar-se na aplicação das técnicas estudadas a outros tipos de estruturas, como arranha-céus e pontes. Além disso, a combinação das técnicas da aprendizagem automática com algoritmos metaheurísticos, como o algoritmo genético ou de busca harmónica, pode proporcionar melhorias adicionais na otimização do projeto estrutural.

- O estudo realizado por Hong e D. H. Nguyen (2023) desenvolve uma abordagem baseada em redes neurais artificiais (ANN) combinada com o algoritmo Hong-Lagrange, visando otimizar vigas de betão armado com reforço de aço (SRC). O estudo otimiza simultânea três funções objetivas: custo (Cib), emissões de CO₂ e peso (W), proporcionando um conjunto de soluções ótimas sob restrições de igualdade e desigualdade. O método utilizado consiste num algoritmo Hong-Lagrange integrado com redes neurais artificiais (ANN), que resolve problemas de otimização multi-objetivo. A ANN é treinada com 200.000 amostras geradas por cálculos de mecânica estrutural, e a função objetiva unificada (UFO) é formulada com base nas frações de peso das três funções objetivas. Este modelo é utilizado para criar uma fronteira de Pareto, que representa as soluções ótimas para as diferentes combinações de custos, emissões de CO₂ e peso. Os resultados obtidos demonstraram que a abordagem ANN-Hong-Lagrange conseguiu identificar um conjunto de soluções ótimas, com um custo estimado de 219,279.1 KRW/m e um erro de apenas -0,14% em comparação com

os cálculos tradicionais de mecânica estrutural. A fronteira de Pareto gerada inclui 343 soluções otimizadas para vigas SRC, permitindo aos engenheiros escolher entre soluções que minimizam o custo, as emissões ou o peso, de acordo com as suas prioridades.

Limitações

No entanto, uma das limitações do estudo é a elevada complexidade computacional associada ao treino de redes neurais com grandes conjuntos de dados, o que requer hardware de alto desempenho. Adicionalmente, o estudo foi focado em vigas com condições de carregamento específicas, o que pode restringir a generalização para outros tipos de estruturas ou ambientes de carregamento.

Perspetivas Futuras

Em relação às perspetivas futuras, é sugerido que estudos subsequentes expandam o uso do algoritmo ANN-Hong-Lagrange para outros tipos de estruturas, como quadros estruturais e colunas, visando uma otimização mais abrangente. Também se recomenda o desenvolvimento de software prático baseado em IA para automação de tarefas de design estrutural.

- O estudo realizado por X. Ding (2024) foca na previsão da resistência ao corte não drenada (USS) de solos sensíveis utilizando um modelo híbrido de inteligência artificial baseado no sistema de inferência neuro-fuzzy adaptativo (ANFIS) e algoritmos de otimização meta-heurística. O objetivo principal deste estudo foi aplicar o sistema de inferência neuro-fuzzy adaptativo (ANFIS) combinado com três algoritmos de otimização meta-heurística — Equilibrium Slime Mould Algorithm (ESOMA), School-Based Optimization (SBO) e Slime Mould Algorithm (SMA) — para prever com precisão a resistência ao corte não drenada (USS) de solos sensíveis. O estudo visa melhorar a precisão e a eficiência dos métodos convencionais de previsão do USS, que frequentemente apresentam limitações em relação à correlação dos dados de campo. O método aplicado consistiu no Adaptive Neuro-Fuzzy Inference System (ANFIS), que combina as capacidades da aprendizagem das redes neurais artificiais com a lógica fuzzy para criar um modelo preditivo robusto. Para otimizar o desempenho do ANFIS, foram utilizados os três algoritmos meta-heurísticos mencionados, que melhoraram a capacidade de previsão ao ajustar os hiperparâmetros e minimizar erros durante o processo de otimização. Os resultados obtidos indicaram que o modelo ANFEA, que combina o ANFIS com o algoritmo ESOMA, apresentou o melhor desempenho entre os modelos avaliados, com um coeficiente de determinação (R^2) de 0,9946 e um erro quadrático médio (RMSE) de 62,95 KPa na fase de teste. Este modelo superou os outros métodos (ANFSO e ANFSA), demonstrando uma melhoria significativa na precisão da previsão da resistência ao corte dos solos. O estudo validou que a combinação do ANFIS com algoritmos de otimização pode

oferecer uma solução eficiente para prever o USS com alta precisão.

Limitações

No entanto, uma das limitações do estudo é a necessidade de grandes conjuntos de dados experimentais para treinar os modelos, o que pode não estar disponível em todos os cenários práticos. Além disso, o desempenho dos algoritmos de otimização meta-heurística pode ser influenciado pelas características do solo e pela qualidade dos dados de entrada, o que pode restringir a generalização dos resultados para diferentes tipos de solo.

Perspetivas Futuras

Em relação às perspectivas futuras, o estudo sugere que trabalhos subsequentes explorem a aplicação do modelo ANFIS em outros contextos de engenharia geotécnica, como a previsão de liquefação e a estabilidade de encostas. Também se recomenda a investigação de novos algoritmos de otimização para melhorar ainda mais o desempenho do ANFIS e reduzir o tempo de processamento, permitindo a aplicação em projetos de engenharia de grande escala.

- O estudo realizado por Salihi e Hamad (2024) aplica redes neurais artificiais (ANN) e Gradient Boosting, para prever a capacidade de resistência ao corte de lajes de betão armado reforçadas com barras de polímero reforçado com fibra (FRP). O objetivo principal deste estudo foi desenvolver e comparar técnicas preditivas baseadas em redes neurais artificiais (ANN) e Gradient Boosting para calcular a capacidade de resistência ao corte de lajes de betão armado com barras de FRP, superando os métodos tradicionais de design, como ACI 440.1R-15 e CAN/CSA S806-12, assim como as abordagens existentes na literatura. O método aplicado consistiu na utilização de duas técnicas principais da aprendizagem automática. A primeira, as Redes Neurais Artificiais (ANN), foi utilizada para modelar e prever a capacidade de resistência ao corte com base em parâmetros como a profundidade efetiva das lajes, resistência à compressão do betão e o módulo de elasticidade das barras de FRP. A segunda técnica, o Gradient Boosting (GB), foi introduzida pela primeira vez neste contexto e demonstrou resultados superiores, apresentando um coeficiente de determinação (R^2) de 0,98, enquanto o modelo ANN alcançou um R^2 de 0,96. Os resultados obtidos indicaram que o modelo Gradient Boosting apresentou o melhor desempenho, com um R^2 de 0,98, superando o modelo ANN (R^2 de 0,96) e os modelos de design convencionais. O estudo destacou a eficácia das técnicas da aprendizagem automática em prever com precisão a capacidade de resistência ao corte de lajes reforçadas com FRP, representando um avanço significativo em relação aos métodos tradicionais.

Limitações

Entretanto, uma limitação do estudo foi o tamanho relativamente pequeno do conjunto de dados utilizado (99 amostras), o que pode restringir a generalização dos modelos para outras configurações de lajes e condições de carga. O estudo também reconhece que são necessárias mais investigações para incorporar diferentes tipos de FRP, como o Basalt-FRP.

Perspetivas Futuras

Em relação às perspectivas futuras, o estudo sugere que futuros trabalhos se concentrem na aplicação de técnicas da aprendizagem automática em outros tipos de lajes e barras de FRP, bem como na utilização de conjuntos de dados maiores e mais variados para melhorar a generalização dos modelos. A integração de outros algoritmos de otimização, como o Extreme Gradient Boosting, também poderá ser explorada para aprimorar a precisão e a eficiência.

- O estudo realizado por Hou e X. G. Zhou (2022) tem como objetivo principal o desenvolvimento modelos da aprendizagem automática (ML) para prever com precisão a resistência à compressão axial de colunas circulares de CFST. A investigação utilizou uma base de dados composta por 2.045 colunas CFST testadas experimentalmente e comparou o desempenho de cinco métodos de ML: back-propagation neural network (BPNN), genetic algorithm optimized BPNN (GA-BPNN), radial basis function neural network (RBFNN), Gaussian process regression (GPR) e regressão linear múltipla (MLR). As técnicas da aprendizagem automática aplicadas no estudo incluíram BPNN, GA-BPNN, RBFNN, GPR e MLR. Os modelos foram treinados utilizando uma combinação de parâmetros selecionados com base em análises mecânicas e correlação estatística para melhorar a precisão das previsões. O algoritmo GPR destacou-se pelo seu desempenho superior, fornecendo previsões mais precisas e a possibilidade de estimar a incerteza das previsões. Os resultados obtidos mostraram que o modelo GPR obteve a maior precisão, com um coeficiente de determinação (R^2) de 0,999 para o conjunto de treino e de 0,986 para o conjunto de teste. O modelo GA-BPNN também apresentou um bom desempenho, com valores de R^2 de 0,993 e 0,983 para treino e teste, respetivamente. A subdivisão da base de dados entre colunas curtas e longas melhorou significativamente a precisão dos modelos, especialmente no caso das colunas longas, onde os modos de falha diferem.

Limitações

As limitações do estudo incluem a dependência de uma base de dados de experimentos realizados em diferentes épocas e regiões, o que pode introduzir variações sistemáticas nos resultados. Além disso, a precisão do modelo depende da qualidade e extensão dos dados experimentais disponíveis, sendo

necessário realizar mais estudos para validar os modelos em outros tipos de CFST ou em diferentes condições de carga.

Perspetivas Futuras

Em relação às perspectivas futuras, os autores sugerem a expansão do uso de técnicas da aprendizagem automática para prever o comportamento de CFSTs sob diferentes condições de carga, bem como a introdução de novas técnicas de otimização para melhorar a eficiência dos modelos. Recomenda-se também a aplicação dos métodos em estruturas mais complexas e em condições dinâmicas.

- O estudo realizado por Hanoon, Zand e Yaseen (2022) foca na previsão da capacidade de flexão de vigas de aço preenchidas com betão (CFST) através de um modelo híbrido de inteligência artificial. O objetivo principal deste estudo foi desenvolver um modelo numérico híbrido que combina redes neurais artificiais (ANN) com o algoritmo de otimização por enxame de partículas (PSO) para prever a capacidade de resistência à flexão e a rigidez de vigas CFST. O modelo foi validado contra resultados experimentais existentes e comparado com normas internacionais, como a EC4 e a AISC. O método aplicado consistiu em um modelo híbrido de Rede Neural Artificial (ANN) otimizado com Particle Swarm Optimization (PSO). O modelo ANN foi treinado com dados experimentais de vigas CFST, e o PSO foi utilizado para ajustar os hiperparâmetros da rede, melhorando a precisão na previsão de parâmetros como o momento de flexão (M_u) e as rigidezes iniciais (K_i) e de serviço (K_s). Os resultados obtidos demonstraram que o modelo híbrido PSO-ANN é uma abordagem precisa para prever a capacidade de flexão e a rigidez de vigas CFST, apresentando coeficientes de variação entre 4,98% e 9,53%. Os resultados mostraram que o modelo superou as previsões obtidas por métodos tradicionais, como EC4 e AISC, com valores de R^2 variando de 0,933 a 0,989, indicando uma alta precisão.

Limitações

Uma limitação do estudo foi a complexidade computacional envolvida no ajuste dos parâmetros da rede neural através do PSO. Além disso, o estudo sugere que a generalização do modelo pode ser limitada a geometrias e tipos de materiais específicos utilizados nos testes.

Perspetivas Futuras

Em relação às perspectivas futuras, os autores sugerem que trabalhos subsequentes explorem a aplicação do modelo PSO-ANN a outros tipos de estruturas e condições de carga, como colunas e vigas sob cargas dinâmicas. Melhorias no algoritmo PSO e a integração com outros métodos de otimização também são recomendadas para aumentar ainda mais a precisão e eficiência.

- O estudo realizado por Pak e Paal (2022) foca na investigação e comparação de diferentes técnicas de transfer learning aplicadas à previsão da resistência lateral de colunas de betão armado, utilizando uma quantidade limitada de dados de treino. O objetivo principal deste estudo foi abordar o problema da escassez de dados em engenharia estrutural, propondo a utilização de transfer learning para melhorar a precisão dos modelos de previsão em cenários com poucos dados experimentais. O método de inteligência artificial aplicado consistiu na comparação de três abordagens de transfer learning: Instance Weighting Kernel Ridge Regression (IW-KRR), Two-stage TrAdaBoost.R2 e Double-Weighted Support Vector Transfer Regression (DW-SVTR). Esses métodos foram aplicados a conjuntos de dados de colunas de betão armado, transferindo conhecimento de uma tarefa de origem (domínio) para uma tarefa de destino, que apresentava diferentes características estruturais, como a forma da seção e a resistência à compressão. Os resultados obtidos demonstraram que a aplicação de técnicas de transfer learning resultou numa melhoria significativa na previsão da resistência lateral, especialmente em contextos onde havia escassez de dados no domínio de destino. O método DW-SVTR destacou-se como o mais eficaz, superando os outros modelos em termos de precisão, com coeficientes de determinação (R^2) superiores a 0,95 em todas as simulações. Os modelos de transfer learning também apresentaram desempenho superior às estimativas baseadas nas normas de design ACI 318-19.

Limitações

Entre as limitações identificadas, destaca-se a complexidade computacional associada à utilização de técnicas de transfer learning, especialmente quando existem grandes discrepâncias entre os domínios de origem e destino nos seus conjuntos de dados. Adicionalmente, a precisão dos modelos é fortemente dependente da qualidade e quantidade dos dados de origem utilizados.

Perspetivas Futuras

Em relação às perspetivas futuras, os autores sugerem que futuras pesquisas explorem a aplicação de técnicas de transfer learning em outros problemas de engenharia estrutural, como a previsão de falhas em materiais e estruturas complexas. Além disso, a integração de informações baseadas em física com abordagens da aprendizagem automática pode potencialmente melhorar ainda mais a precisão das previsões.

- O estudo realizado por Katlav e Ergen (2024) foca no desenvolvimento de modelos baseados em AA para prever a capacidade de carga de momento de vigas híbridas de betão armado, compostas por betão de ultra-alto desempenho (UHPC) e betão de resistência normal (NSC). O objetivo principal deste estudo foi explorar como esses modelos podem substituir métodos analíticos tradicionais,

proporcionando previsões mais rápidas e precisas. O método de inteligência artificial aplicado consistiu na utilização de 10 algoritmos de machine learning, incluindo XGBoost, Random Forest (RF), Support Vector Regression (SVR) e Redes Neurais Multicamadas (MLP). Foi realizada uma análise detalhada de desempenho, na qual o XGBoost se destacou, demonstrando a melhor precisão de previsão. Além disso, o método Shapley Additive Explanations (SHAP) foi empregado para avaliar a importância das variáveis de entrada no modelo preditivo. Os resultados obtidos indicaram que o XGBoost apresentou a melhor performance, com coeficiente de determinação (R^2) de 0,996 no conjunto de treino e 0,945 no conjunto de teste. O estudo revelou que os parâmetros mais influentes na capacidade de carga das vigas híbridas foram a profundidade efetiva, a espessura da camada inferior de UHPC e a resistência à compressão do UHPC.

Limitações

As principais limitações identificadas incluem o tamanho relativamente pequeno do conjunto de dados utilizado, o que pode comprometer a capacidade de generalização dos modelos. A ausência de padrões internacionais para o dimensionamento de vigas híbridas foi também mencionada como um desafio para a validação completa do modelo.

Perspetivas Futuras

Em relação às perspectivas futuras, o estudo sugere que novos trabalhos podem expandir a base de dados experimental para melhorar a confiabilidade dos modelos preditivos e explorar outros fatores que influenciam a capacidade de momento das vigas híbridas. Adicionalmente, propõe-se a implementação do modelo em software de design para aplicações práticas.

- O estudo realizado por Ampanavos, Nourbakhsh e C. Y. Cheng (2022) tem como enfoque a utilização de AA para auxiliar no desenvolvimento de layouts estruturais durante a fase inicial do design arquitetônico. O principal objetivo do estudo foi desenvolver um sistema denominado Approxiframer, que utiliza aprendizagem automática para gerar automaticamente layouts estruturais com base em esboços arquitetônicos de plantas de edifícios. A ferramenta foi projetada para apoiar arquitetos na fase inicial do design, oferecendo soluções estruturais viáveis em tempo real, o que facilita a exploração criativa e reduz conflitos futuros com engenheiros estruturais. O método de inteligência artificial aplicado consistiu numa Rede Neural Convolucional (CNN), treinada para prever a posição de elementos estruturais, como colunas, com base em esboços de plantas. A CNN foi treinada com um conjunto de dados sintético, contendo diferentes configurações de edifícios e os respectivos layouts estruturais, e foi avaliada com base no erro percentual na previsão das posições dos elementos estruturais. Os resultados obtidos mostraram que o modelo Approxiframer

conseguiu gerar layouts estruturais em tempo real com um erro médio de 2,21% na previsão da posição das colunas. O sistema demonstrou eficácia em prever layouts para plantas ortogonais de edifícios, tanto para pequenas quanto para grandes estruturas, revelando um potencial significativo para auxiliar arquitetos na fase de design conceptual, gerando soluções estruturais de forma rápida e precisa.

Limitações

As principais limitações identificadas incluem a acumulação de erros em previsões iterativas e a dependência de dados de treino sintéticos. Além disso, o sistema ainda está restrito a plantas ortogonais de edifícios com estruturas metálicas rígidas, o que pode limitar a sua aplicação a outros tipos de estruturas.

Perspetivas Futuras

Em relação às perspetivas futuras, o estudo sugere que novos trabalhos devem explorar a aplicação da abordagem ApproxiFramer a outros tipos de sistemas estruturais e considerar a integração de mais variáveis, como a seleção de perfis e materiais. A inclusão de feedback iterativo com arquitetos é também sugerida como uma melhoria para ajustar as soluções propostas durante o processo de design.

- O estudo realizado por B. S. Negi, Bhatt e N. Negi (2024) foca na melhoria da eficiência do processo de construção de estruturas de betão, utilizando técnicas da aprendizagem automática para otimização do desempenho e segurança sísmica. O principal objetivo deste estudo foi desenvolver um modelo híbrido de otimização baseado em redes neurais artificiais (ANN) e otimização por enxame de libélulas (Dragonfly Optimization), visando melhorar a eficiência de fabricação de estruturas de betão, especialmente no que respeita à avaliação da segurança sísmica. A investigação aborda a necessidade de combinar eficiência na produção com segurança estrutural, tendo em conta os perigos sísmicos e a sustentabilidade. O método de inteligência artificial aplicado consistiu numa rede neural artificial (ANN) otimizada por Dragonfly Optimization, utilizada para prever a capacidade sísmica de estruturas de betão armado. A técnica de análise discriminante linear (LDA) foi empregue para a extração de características, enquanto a normalização Z-score foi utilizada como método de pré-processamento de dados. A arquitetura FDO-ANN (Fine-Tuned Dragonfly Optimized ANN) foi implementada para otimizar a seleção de características, garantindo que o modelo fosse preciso e eficiente na previsão do comportamento estrutural sob eventos sísmicos. Os resultados obtidos mostraram que o modelo FDO-ANN alcançou uma precisão de 95,6%, superando métodos tradicionais como árvore de decisão (DT), floresta aleatória (RF) e AdaBoost, que obtiveram 89,1%, 91,4% e 93,1%, respetivamente. O modelo também demonstrou melhorias nos indicadores de Recall (96,8%) e F1-score (97,8%), evidenciando a sua eficácia em prever a

segurança sísmica e a eficiência de fabricação de estruturas de betão.

Limitações

As principais limitações identificadas incluem a necessidade de grandes volumes de dados para otimizar os parâmetros do modelo, o que pode tornar a aplicação prática desafiante em cenários onde os dados não são facilmente acessíveis. Além disso, o tempo necessário para treinar os modelos de otimização pode ser considerável.

Perspetivas Futuras

Em relação às perspetivas futuras, o estudo sugere que novas investigações explorem a integração de dados em tempo real nos modelos preditivos, permitindo decisões mais rápidas em contextos de fabricação. A implementação de fluxos contínuos de dados pode melhorar a adaptabilidade do modelo em situações práticas.

- O estudo realizado por Bekdaş, Yücel e Nigdeli (2021) aborda a otimização de variáveis de design estrutural através da utilização de algoritmos de metaheurística e redes neurais artificiais (ANN). O principal objetivo deste estudo foi investigar três projetos de engenharia estrutural distintos, com o intuito de determinar variáveis de design ótimas e estimar parâmetros de design de forma rápida e eficaz. Para tal, foram realizadas duas operações de otimização utilizando o algoritmo de busca de harmonia (HS) e redes neurais artificiais (ANN) para prever os valores ótimos das variáveis de design. O método de inteligência artificial aplicado consistiu no uso do algoritmo de busca de harmonia (HS) para a otimização de parâmetros, juntamente com uma rede neural artificial (ANN) para a previsão dos valores ótimos das variáveis de design. A ANN foi treinada para estimar diretamente os parâmetros de design e a função objetiva para três projetos estruturais de referência, incluindo uma treliça de 3 barras, uma treliça de 10 barras e uma viga de betão armado. Os resultados obtidos indicaram que a ANN se revelou eficaz na previsão de valores ótimos das variáveis de design, apresentando pequenos erros em relação aos valores obtidos pelo método de busca de harmonia. As redes neurais artificiais demonstraram ser uma ferramenta eficiente e rápida para prever os resultados ótimos de qualquer modelo de design estrutural, permitindo uma significativa economia de tempo em comparação com métodos de otimização tradicionais.

Limitações

As principais limitações identificadas incluem a necessidade de grandes quantidades de dados para o treino das redes neurais artificiais, bem como a complexidade computacional associada à implementação dos algoritmos de busca de harmonia. Adicionalmente, o estudo está limitado a apenas três modelos estruturais de referência, o que pode restringir a aplicabilidade direta dos resultados a outros tipos de

estruturas.

Perspetivas Futuras

Em termos de perspectivas futuras, o estudo sugere que novos trabalhos podem concentrar-se na expansão do conjunto de dados de treino para incluir uma variedade maior de tipos de estruturas. Além disso, a exploração do uso de métodos híbridos que combinem redes neurais artificiais com outros algoritmos de otimização pode contribuir para a melhoria da precisão e eficiência dos resultados.

- O estudo realizado por Pizarro e Massone (2021) foca no desenvolvimento de uma plataforma de design estrutural para edifícios de betão armado com paredes de corte, utilizando redes neurais profundas (DNN) para prever a espessura e o comprimento das paredes. O objetivo principal deste estudo é acelerar o processo de design, que tradicionalmente exige múltiplas interações entre as equipas de arquitetura e engenharia, implementando soluções pré-definidas com base em projetos anteriores. O método de inteligência artificial aplicado consiste num modelo de redes neurais profundas (DNN) que foi alimentado com informações de projetos arquitetónicos e de engenharia de 165 edifícios residenciais de betão armado construídos no Chile. O modelo foi treinado para prever a espessura e o comprimento dos segmentos de parede, utilizando 30 características geométricas e topológicas. O processo de modelação incluiu técnicas de normalização e regularização, como batch normalization, e a implementação de um algoritmo de back-propagation para minimizar o erro de previsão. Os resultados obtidos indicaram que o modelo DNN teve um desempenho excecional, alcançando coeficientes de determinação (R^2) de 0,995 para a espessura das paredes e 0,994 para o comprimento, quando treinado com uma base de dados aumentada. Estes resultados demonstram que o modelo é altamente eficaz na previsão das dimensões das paredes com base em planos arquitetónicos. A plataforma desenvolvida reduziu significativamente o tempo de iteração entre as equipas de arquitetura e engenharia, oferecendo uma solução inicial fiável para o design de paredes.

Limitações

As principais limitações identificadas referem-se à dependência do modelo em relação à base de dados disponível, que consiste predominantemente em edifícios residenciais chilenos. Assim, a generalização dos resultados para outros tipos de edifícios ou regiões pode exigir ajustes no modelo ou a expansão da base de dados.

Perspetivas Futuras

Em termos de perspectivas futuras, os autores sugerem que investigações adicionais se concentrem na expansão da base de dados para incluir diferentes tipos de edifícios e localizações, além de explorar

a integração da plataforma com ferramentas de modelação numérica avançada, como o método dos elementos finitos, para aumentar ainda mais a precisão e aplicabilidade do modelo.

- O estudo realizado por Kallioras e Lagaros (2020) apresenta uma nova metodologia denominada DL-Scale, que combina técnicas de otimização topológica com aprendizagem profunda para reduzir a carga computacional e melhorar a usabilidade em otimizações estruturais. O objetivo principal do artigo é aplicar redes de crença profunda (Deep Belief Networks - DBNs) para acelerar o processo de otimização topológica em modelos estruturais altamente discretizados, especialmente em problemas de malha densa. A metodologia proposta utiliza uma combinação da técnica de otimização topológica Solid Isotropic Material with Penalization (SIMP) e redes de crença profunda (DBNs). A DBN é treinada para identificar padrões ocultos nas densidades iniciais dos elementos finitos e correlacioná-los com as densidades finais propostas pela SIMP, resultando em uma redução significativa no número de iterações necessárias para resolver problemas de otimização topológica com malhas densas. Os resultados obtidos foram baseados em problemas de otimização topológica aplicados a estruturas de vigas simples, com diferentes populações de elementos finitos (20.000, 50.000, 75.000 e 100.000). A metodologia DL-Scale demonstrou uma redução de até 72% no tempo de execução em comparação com o método SIMP tradicional. Adicionalmente, a qualidade da solução final, medida pelo valor da função objetivo, foi ligeiramente superior no DL-Scale, com uma redução entre 1,00% e 2,00% no valor da função objetivo em todos os testes realizados.

Limitações

As limitações identificadas referem-se ao desempenho dependente da arquitetura da DBN utilizada e à qualidade dos dados de treino. Além disso, a abordagem foi testada principalmente em problemas bidimensionais, sendo necessária uma avaliação mais abrangente em problemas tridimensionais e com diferentes condições de carga.

Perspetivas Futuras

Em termos de perspectivas futuras, os autores sugerem que futuras investigações devem focar na generalização da metodologia DL-Scale para outros tipos de problemas de otimização topológica, incluindo aqueles em três dimensões. Melhorias na arquitetura das redes de crença profunda também são recomendadas para aumentar a eficiência e aplicabilidade da técnica.

- O estudo realizado por Kashani et al. (2022) pretende realizar uma revisão abrangente de técnicas de otimização baseadas em população (metaheurísticas) aplicadas à engenharia estrutural. A revisão concentra-se na eficiência e aplicabilidade desses algoritmos na resolução de problemas de otimização estrutural, como o design de estruturas, otimização de trusses e vigas, além de questões

relacionadas à otimização global em engenharia civil. A análise contempla uma variedade de algoritmos metaheurísticos, incluindo algoritmos evolutivos, como algoritmos genéticos (GA), otimização por enxame de partículas (PSO), busca por harmonia (HS) e outros métodos inspirados na natureza. O foco da revisão é explorar a aplicação desses algoritmos na otimização de estruturas, com o objetivo de minimizar o peso, reduzir custos de construção e melhorar a eficiência do design. A comparação do desempenho dos algoritmos em diversos problemas de benchmark na área de engenharia estrutural também é um ponto central do estudo. Os resultados obtidos incluem uma vasta gama de problemas estruturais, como a otimização de trusses, quadros e outros elementos estruturais, utilizando diferentes métodos de metaheurística. Os achados demonstram que os algoritmos baseados em população, como o PSO e o GA, têm demonstrado grande eficiência em problemas de design estrutural, superando métodos tradicionais. Adicionalmente, a revisão destaca que os metaheurísticos são particularmente eficazes na resolução de problemas com espaços de solução não lineares e não convexos, comuns na engenharia estrutural.

Limitações

As limitações identificadas referem-se à falta de garantias sobre a obtenção da solução ótima global por parte dos algoritmos metaheurísticos. O desempenho desses algoritmos pode variar significativamente conforme o problema, sendo a seleção de parâmetros adequados crítica para o sucesso da otimização.

Perspectivas Futuras

Em termos de perspectivas futuras, o artigo sugere que investigações subsequentes devem concentrar-se no desenvolvimento de novos algoritmos híbridos que combinem a exploração global dos metaheurísticos com métodos mais tradicionais de otimização. Recomenda-se também a exploração da aplicação dessas técnicas a uma maior diversidade de problemas complexos na engenharia estrutural, assim como a melhoria do desempenho computacional dos algoritmos em cenários de alta dimensão.

- O estudo realizado por Qian, Y. Xu e H. Li (2022) tem como objetivo propor uma nova rede neural aprimorada pela função de descrição topológica (TDF-NN) para otimização topológica. A proposta visa melhorar a eficiência computacional e a qualidade da solução, superando limitações dos métodos tradicionais, como o método de penalização de material isotrópico sólido (SIMP), especialmente em problemas de otimização estrutural de alta resolução. A metodologia aplicada consiste em uma rede neural de camada única, utilizando a função de ativação sigmoide e a função de descrição topológica (TDF) como entrada. A TDF é convertida diretamente em pesos da rede, permitindo a otimização por métodos baseados em gradiente. O método foi testado em

problemas de minimização de conformidade, utilizando exemplos bidimensionais e tridimensionais, e comparado com o SIMP tradicional. Os objetos de estudo incluem estruturas 2D, como feixes MBB, cantilever e Michell, e 3D, como uma ponte de um pilar. O método TDF-NN demonstrou uma eficiência computacional até 10 vezes maior do que o SIMP, com uma redução significativa do número de iterações necessárias para alcançar uma solução estável. Adicionalmente, a TDF-NN eliminou o efeito de padrão de xadrez, uma limitação comum nas otimizações topológicas de alta resolução realizadas pelo SIMP. Uma das principais vantagens da TDF-NN é a sua capacidade de gerar várias soluções viáveis, permitindo a obtenção de múltiplos designs ótimos que atendem aos mesmos critérios de conformidade estrutural. Isso confere aos engenheiros a flexibilidade de escolher entre diferentes configurações de design, otimizadas para diferentes restrições ou preferências. Além disso, a TDF-NN mostrou-se robusta na adaptação a diversas condições de fronteira, geometrias complexas e diferentes tipos de carregamento. Em termos de precisão, a TDF-NN foi capaz de reproduzir com maior detalhe as características geométricas finas das estruturas otimizadas, resultando em maior eficiência de material sem comprometer a resistência estrutural. A interpolação baseada no método Kriging melhorou a precisão das previsões, especialmente em problemas tridimensionais mais complexos.

Limitações

As limitações identificadas referem-se à dependência da qualidade das soluções em relação à distribuição dos nós utilizados na otimização. A aplicação do método em problemas com geometrias mais complexas e maiores níveis de detalhe requer investigações adicionais. Além disso, é necessário explorar como a metodologia se comporta quando aplicada a problemas práticos que envolvem múltiplos materiais e outras restrições de engenharia, como cargas dinâmicas.

Perspetivas Futuras

Em termos de perspectivas futuras, o artigo sugere que a combinação da TDF-NN com técnicas de design arquitetónico automatizado poderia expandir as aplicações da metodologia. O estudo também recomenda a exploração de restrições adicionais, como pavimentos ou janelas, para integrar a TDF-NN em problemas práticos de engenharia civil e design arquitetónico.

- O estudo realizado por Teixeira et al. (2018) tem como objetivo propor um método metaheurístico chamado Evolutionary Quick Artificial Bee Colony (EQABC). Esta abordagem combina a estratégia de colónia de abelhas artificiais (ABC) com estratégias evolutivas (ES), visando aumentar a robustez do algoritmo e melhorar a qualidade das soluções em problemas de otimização estrutural com restrições. A metodologia aplicada no EQABC integra as capacidades de busca global da

ABC com operadores de mutação e reprodução das estratégias evolutivas. O algoritmo introduz melhorias na fase de busca das abelhas empregadas e observadoras, além de implementar novas formas de busca local e global para superar limitações da ABC tradicional. O EQABC foi testado em diversos problemas de engenharia estrutural com restrições, incluindo a otimização do projeto de vasos de pressão, vigas soldadas e molas de tração/compressão. Os objetos de estudo incluíram quatro problemas clássicos de design de engenharia: o design de um vaso de pressão, o problema da viga soldada, o problema da mola de tração/compressão e o design de um redutor de velocidade. Os resultados mostraram que o EQABC superou outras versões da ABC e algoritmos similares, como o ABC+ES, em termos de precisão das soluções e robustez. Para o problema do vaso de pressão, o EQABC alcançou a melhor solução de 5804.40957, evidenciando sua eficácia em encontrar soluções globais.

Limitações

As limitações identificadas na implementação do EQABC incluem a necessidade de definir múltiplos parâmetros, como o número de ciclos máximos e o fator de amortecimento, que podem influenciar o desempenho do algoritmo. Além disso, o tempo computacional pode aumentar com o tamanho dos problemas, o que sugere a necessidade de mais testes em problemas de maior escala. **Perspectivas**

Futuras

Em termos de perspectivas futuras, os autores recomendam que pesquisas adicionais se concentrem na expansão da aplicação do EQABC para problemas mais complexos, como a otimização de redes neurais e outras funções de otimização não lineares. A paralelização do algoritmo também é uma possibilidade a ser explorada, visando melhorar a eficiência computacional.

- O estudo realizado por Pham e Becker (2023) centra-se na aplicação de métodos de design inverso para estruturas isoladas, utilizando variáveis de decisão estimadas pela metodologia FEMA P-58. O objetivo é desenvolver um processo que permita aos engenheiros projetar estruturas com desempenho superior e otimização de custos, evitando análises dinâmicas extensas e demoradas, através da aplicação de modelos de machine learning. A metodologia implementada envolveu diversos modelos de machine learning, incluindo a classificação por processo Gaussiano (GPC) para prever a probabilidade de impacto da estrutura contra a parede do fosso, e regressão por vetores de suporte (SVR) e regressão de crista com núcleo (KR) para estimar os custos de reparação e o tempo de inatividade. A base de dados foi gerada a partir de 400 simulações de um edifício com sistema de isolamento de pêndulo de fricção tripla (TFP), incluindo variáveis como o coeficiente de atrito e o raio de curvatura dos deslizadores. Os objetos de estudo foram edifícios isolados com sistemas TFP. Os resultados mostraram que o modelo de classificação Gaussiana alcançou

uma precisão de 90% na previsão da probabilidade de impacto. Além disso, os modelos SVR e KR revelaram que um aumento do período de isolamento (TM) e uma redução da razão de amortecimento (M) estão associados a menores custos de reparação e tempos de inatividade. Comparado a um design típico conforme o código, o design inverso proposto conseguiu reduzir o custo de reparação em até 50% e o tempo de inatividade em 48,9%.

Limitações

Entre as limitações identificadas, destaca-se a dependência da qualidade dos dados de treino e a possibilidade de dificuldades ao lidar com variações significativas nos parâmetros de design não explorados na base de dados. Adicionalmente, a abordagem não considera diretamente o colapso estrutural, podendo necessitar de ajustes para aplicações em larga escala.

Perspetivas Futuras

Em termos de perspectivas futuras, os autores propõem a expansão do processo de design inverso para incluir mais variáveis de desempenho, como o risco de colapso e perdas específicas de componentes. Além disso, recomenda-se a integração de modelos mais sofisticados de custos iniciais e a melhoria da precisão dos modelos preditivos para aplicações práticas em edifícios com diferentes configurações de isolamento.

- O estudo realizado por Liang et al. (2023) propõe o desenvolvimento de um modelo de substituição baseado em NGBoost para prever a resistência ao corte por punção em lajes planas reforçadas com fibras de polímero(FRP). O principal objetivo é a otimização multi-objetivo do design dessas lajes, considerando tanto a resistência ao corte por punção quanto o custo do material. O artigo explora a aplicação de algoritmos genéticos não-dominados, especificamente o NSGA-II, para resolver problemas de otimização multi-objetivo na engenharia estrutural. A metodologia implementada utiliza o NGBoost (Natural Gradient Boosting), que se destaca por maximizar a precisão da previsão da resistência ao corte por punção das lajes. Complementarmente, o método explicativo SHAP (Shapley Additive Explanations) é utilizado para identificar os parâmetros mais influentes na previsão. A otimização do design é realizada através do algoritmo NSGA-II, permitindo a simultânea otimização da resistência e do custo. Os resultados demonstram que o modelo NGBoost apresenta maior precisão na previsão da resistência ao corte por punção em comparação com outros modelos da aprendizagem automática e com modelos teóricos, como os códigos de design ACI e JSCE. A análise de sensibilidade, utilizando SHAP, revelou que a profundidade efetiva da laje é o fator mais influente para a resistência ao corte por punção. A otimização multi-objetivo resultou na geração de um conjunto de soluções Pareto-ótimas, onde se conseguiu equilibrar a maximização

da resistência ao corte por punção e a minimização do custo dos materiais. A aplicação prática do método foi validada com dados experimentais.

Limitações

Entre as limitações identificadas, destaca-se a dependência do modelo em um conjunto de dados experimentais relativamente pequeno (154 amostras), o que pode comprometer a capacidade de generalização dos resultados. Além disso, o custo computacional associado ao algoritmo NSGA-II, em conjunto com a análise de um grande volume de dados, pode ser elevado em casos de otimização de estruturas mais complexas.

Perspetivas Futuras

Em termos de perspectivas futuras, os autores sugerem que futuras investigações devem explorar a aplicação do modelo em estruturas mais complexas e diversificadas. Ademais, propõem o uso de outros algoritmos da aprendizagem automática para aprimorar a eficiência do processo de otimização e a utilização de conjuntos de dados mais amplos, visando aumentar a precisão das previsões.

- O estudo realizado por Hong, Le, et al. (2023) apresenta um algoritmo de otimização baseado em redes neurais artificiais (ANN) e no método dos multiplicadores de Lagrange, focado no design de colunas circulares de betão armado (RC). O principal objetivo é minimizar simultaneamente três funções objetivas: custo, emissões de CO₂ e peso das colunas, proporcionando aos engenheiros um conjunto de soluções de compromisso entre esses parâmetros, conhecido como fronteira de Pareto. A metodologia implementada utiliza uma rede neuronal artificial combinada com o método dos multiplicadores de Lagrange para resolver problemas de otimização com múltiplos objetivos. A função global de Lagrange é empregada para agregar as funções objetivas, e as condições de Karush-Kuhn-Tucker (KKT) são resolvidas através do método iterativo de Newton-Raphson. O modelo ANN é treinado com um conjunto de dados que relaciona os parâmetros de design com as funções objetivas, permitindo a otimização simultânea dos três critérios. Os resultados obtidos demonstram a eficácia do algoritmo proposto na obtenção de soluções ótimas para o design de colunas circulares de betão armado. O algoritmo de otimização baseado em ANN e Lagrange apresentou uma melhor convergência em comparação com o algoritmo genético NSGA-II, evidenciando uma fronteira de Pareto mais suave e uniforme. A otimização resultou em um conjunto de soluções ótimas, permitindo aos engenheiros tomar decisões informadas entre as funções objetivas, como a redução de custo ou minimização das emissões de CO₂, conforme as prioridades do projeto.

Limitações

Entre as limitações identificadas, destaca-se a dependência dos valores iniciais dos vetores de entrada no método de Newton-Raphson, que pode influenciar a convergência para soluções globais ótimas. Além disso, o modelo requer um número significativo de iterações para garantir uma cobertura completa da fronteira de Pareto, o que pode ser computacionalmente dispendioso.

Perspetivas Futuras

Em termos de perspectivas futuras, os autores sugerem que o método pode ser expandido para incluir outros tipos de elementos estruturais, além das colunas circulares de betão armado. A investigação futura também pode focar na integração de outras técnicas da aprendizagem automática para melhorar a eficiência do algoritmo, bem como na exploração de diferentes combinações de funções objetivas e condições de restrição.

- O estudo realizado por Dehkordi et al. (2023) apresenta uma variante adaptativa e híbrida do algoritmo Marine Predators (MPA) voltada para a otimização de estruturas de treliça de larga escala. O principal objetivo é superar as limitações dos algoritmos MPA tradicionais, como a baixa exploração e a tendência a ficar preso em ótimos locais, proporcionando um método mais eficaz para a otimização de formas e tamanhos em problemas complexos de engenharia estrutural. A metodologia aplicada enquadra-se na categoria de técnicas de otimização meta-heurísticas, que são inspiradas em fenômenos naturais e utilizadas para resolver problemas de otimização onde as soluções ideais são difíceis de encontrar por métodos convencionais. O Marine Predators Algorithm (MPA) é combinado com técnicas de hill climbing e valores caóticos, resultando em duas variantes híbridas: HNMPA (Hybrid Nonlinear Marine Predator Algorithm) e HNCMPA (Hybrid Nonlinear-Chaotic Marine Predator Algorithm). Essas versões melhoram a eficiência e a capacidade de exploração do espaço de soluções, minimizando o risco de ficar preso em ótimos locais, e são aplicadas especificamente para otimizar o peso de estruturas de treliça com restrições dinâmicas e geométricas. Os resultados obtidos demonstram que os algoritmos HNMPA e HNCMPA superaram diversas meta-heurísticas de ponta, como Dragonfly Algorithm (DA), Salp Swarm Algorithm (SSA) e Generalized Normal Distribution Optimization (GNDO). Em particular, para a otimização de estruturas de treliça com 260, 314 e 345 barras, o algoritmo HNCMPA melhorou a eficiência em mais de 65% nas estruturas com 260 e 314 barras, e cerca de 25% na estrutura com 340 barras. O estudo também revelou que os novos algoritmos alcançaram melhor desempenho em termos de taxa de convergência e precisão em comparação com outras técnicas de otimização.

Limitações

Entre as limitações identificadas, destaca-se o elevado custo computacional, resultante do grande número de avaliações de função necessárias para encontrar soluções ótimas em problemas de grande escala. Apesar das melhorias significativas, o algoritmo ainda requer um processo iterativo extenso para garantir a obtenção de soluções globais.

Perspetivas Futuras

As perspectivas futuras propostas pelos autores incluem a expansão da aplicação dos algoritmos híbridos para outros tipos de problemas estruturais e de engenharia. Futuras investigações poderão focar na melhoria da eficiência computacional, reduzindo o número de iterações necessárias sem comprometer a qualidade das soluções. A integração de métodos baseados em aprendizagem automática para aprimorar o processo de predição durante a otimização também foi sugerida como uma direção promissora para investigação.

5.3 Análise e Detecção de Falhas Estruturais

As primeiras tentativas de detecção de falhas estruturais estavam ligadas a métodos de inspeção visual e ensaios de carga. A teoria da elasticidade começou a ser formalizada, permitindo uma melhor compreensão das tensões em estruturas Bendsøe e Kikuchi (1988). O desenvolvimento de métodos de cálculo, como a análise por elementos finitos, proporcionou uma base sólida para a análise estrutural.

Durante o período de 1960 à 1980, emergiram técnicas de inspeção não destrutiva (NDT), como ultrassonografia e radiografia, que permitiram a detecção de falhas internas sem danificar as estruturas Ghaboussi e M. (1991). O monitorização estrutural começou a ganhar importância, com sensores utilizados para medir deformações e vibrações.

Com o avanço da tecnologia da informação, no período de 1990 à 2000, sistemas de monitorização em tempo real tornaram-se viáveis. A modelação computacional e a simulação foram fundamentais para prever o comportamento estrutural e identificar potenciais falhas. O uso de análise de dados melhorou a detecção de anomalias, permitindo a tomada de decisões mais informadas Deb e K. (2002).

A partir de 2000, técnicas de inteligência artificial e aprendizagem automática têm transformado a detecção de falhas. Algoritmos são capazes de processar grandes volumes de dados e identificar padrões que indicam potenciais falhas X.-G. Zhou, Hou e J. Peng (2023). A integração de dados de múltiplas fontes, através de sistemas baseados em IA, tem permitido uma detecção de anomalias mais precisa.

5.3.1 Análise dos Estudos:

- O estudo realizado por Amezcua-Sanchez et al. (2016) apresenta uma revisão das aplicações recentes de redes neurais artificiais (ANNs) na engenharia civil, com um foco específico na identificação de sistemas estruturais, monitorização da saúde estrutural, controlo de vibrações, optimização de projeto e previsões. O objetivo principal é destacar as técnicas de ANN mais comuns, bem como discutir métodos híbridos inovadores, como redes neuro-fuzzy e redes neurais baseadas em wavelets, aplicadas em infraestruturas civis. O método de inteligência artificial utilizado no estudo centra-se em várias técnicas de machine learning, com ênfase no uso de ANNs. Os modelos analisados incluem redes neurais feedforward, redes neurais com retropropagação, redes neurais de base radial (RBF) e redes neurais recorrentes (RNN). Adicionalmente, o estudo revisa técnicas híbridas mais recentes, como o sistema de inferência neuro-fuzzy e as redes neurais baseadas em wavelets, que têm sido aplicadas em problemas de optimização, monitorização da saúde estrutural e controlo de vibrações. Os resultados obtidos demonstram que as ANNs são eficazes na previsão de falhas estruturais e no controlo de vibrações em infraestruturas civis. O artigo sublinha a

aplicação bem-sucedida de ANNs na identificação de sistemas estruturais, apresentando resultados significativos em termos de precisão na detecção de falhas e no controle de danos em estruturas durante eventos sísmicos. Técnicas híbridas, como as redes neuro-fuzzy e as redes baseadas em wavelets, mostraram-se promissoras para o controle de vibrações em grandes estruturas, como edifícios altos e pontes.

Limitações

Uma limitação importante das ANNs no campo da engenharia civil é a necessidade de grandes quantidades de dados para o treino dos modelos. Além disso, os modelos podem ser sensíveis ao ruído nos dados e podem enfrentar dificuldades na generalização para novas estruturas ou condições. Outro desafio observado foi a alta complexidade computacional necessária para implementar alguns dos modelos mais avançados, como o sistema de inferência neuro-fuzzy e as redes de wavelets.

Perspetivas Futuras

Os autores recomendam a continuação da investigação no desenvolvimento de modelos híbridos mais avançados, que combinem redes neurais com outras técnicas de inteligência artificial, como lógica fuzzy e algoritmos genéticos. Outra perspectiva futura é a aplicação de técnicas da aprendizagem profunda para melhorar a precisão e a eficiência na identificação de falhas estruturais e controle de vibrações em grandes infraestruturas civis. A integração de redes neurais em sistemas de monitorização em tempo real também é sugerida como uma área promissora.

- O estudo realizado por P. Liu (2023) centra-se na aplicação de inteligência artificial (IA) no monitorização de saúde estrutural (SHM) para prever e identificar falhas em estruturas de grande escala, como pontes e edifícios. O objetivo principal do estudo foi analisar a aplicação de redes de sensores sem fio (WSN) e técnicas de IA no monitorização da integridade estrutural em projetos de engenharia civil. O estudo compara a eficiência de sistemas tradicionais de monitorização por sensores com redes sem fio avançadas e explora como a IA, particularmente o aprendizagem automática (ML), pode melhorar a precisão e eficiência na detecção de falhas estruturais e na previsão de ciclos de manutenção. O método de IA aplicado foi o machine learning, com foco em três tipos principais de algoritmos: aprendizagem supervisionada, não supervisionada e aprendizagem por reforço. Estes algoritmos foram utilizados para prever comportamentos estruturais e classificar os dados obtidos a partir de sensores. A aplicação de redes neurais artificiais (ANN) e aprendizagem profunda também foi abordada como uma solução para analisar grandes volumes de dados, melhorando a detecção de danos e a previsão de vida útil restante das estruturas. Os resultados obtidos demonstraram que a IA, especialmente as redes de sensores sem

fio integradas com algoritmos de machine learning, oferece uma solução mais eficiente e de menor custo em comparação com os métodos tradicionais de monitorização por sensores com fio. As WSN permitem uma instalação mais rápida, manutenção facilitada e monitorização contínua em tempo real. As técnicas de IA aplicadas resultaram em previsões precisas de falhas estruturais e melhorias na capacidade de planeamento de manutenção preventiva, com ênfase na deteção precoce de fissuras e desgaste em infraestruturas como pontes e edifícios.

Limitações

Uma das principais limitações do estudo é a dependência de redes sem fio alimentadas por baterias, o que pode limitar o tempo de operação contínua dos sensores. Além disso, a sensibilidade dos sensores sem fio a interferências ambientais, como interferências eletromagnéticas, pode comprometer a qualidade dos dados. O estudo também apontou a falta de padronização nas práticas de monitorização e a dificuldade de adaptação das técnicas de IA a diferentes tipos de estruturas e materiais.

Perspetivas Futuras

O estudo sugere que futuras investigações devem focar-se no desenvolvimento de sistemas híbridos que combinem sensores sem fio com fontes de energia renovável para prolongar a duração operacional dos sistemas de monitorização. Além disso, recomenda-se a criação de protocolos padronizados para garantir a consistência na aplicação de IA no monitorização de saúde estrutural, assim como a expansão do uso da aprendizagem profunda para melhorar a precisão na análise de grandes volumes de dados estruturais.

- O estudo realizado por Lins e Givigi (2016) centra-se na utilização de técnicas de visão computacional para a deteção e medição automática de fissuras em estruturas civis. O objetivo principal deste estudo foi desenvolver um sistema que utilize uma única câmara para captar imagens e estimar as dimensões das fissuras, com o intuito de automatizar o processo de medição e aumentar a eficiência e a precisão das inspeções estruturais. O método de IA aplicado baseia-se em filtros de partículas combinados com técnicas de visão computacional. O filtro de partículas é utilizado para reconhecer automaticamente fissuras nas imagens captadas pela câmara, enquanto a medição das fissuras é realizada através da análise da largura e comprimento utilizando algoritmos de visão computacional. O sistema processa uma sequência de imagens para identificar e medir as fissuras em tempo real. Os resultados obtidos demonstraram que o sistema foi capaz de identificar e medir fissuras com elevada precisão em várias estruturas reais e em ambientes controlados. O erro médio na medição da largura das fissuras foi de aproximadamente 7,51%, enquanto o erro médio na medição do comprimento foi de 8,59%. Comparado a métodos manuais e outras

abordagens automáticas, o sistema apresentou melhores resultados em termos de precisão e tempo de processamento, com uma média de 6 segundos por imagem.

Limitações

Uma das limitações do estudo é a dependência da resolução da câmara para a precisão das medições. Além disso, o método enfrenta dificuldades na medição de fissuras com geometrias complexas, como fissuras curvas, que foram excluídas do estudo. O sistema também pode ser sensível a condições de iluminação variáveis, o que pode impactar a qualidade das imagens processadas.

Perspetivas Futuras

Futuros trabalhos poderão focar-se no desenvolvimento de algoritmos mais robustos para lidar com fissuras de geometrias complexas, bem como na melhoria da precisão das medições através do uso de câmaras de maior resolução. A integração do sistema com plataformas robóticas e a utilização de processadores dedicados, como DSPs ou FPGAs, poderão aumentar ainda mais a eficiência do sistema e permitir a sua utilização em campo para inspeções automáticas.

- O estudo realizado por Bhuiyan et al. (2015) foca na eficiência de redes de sensores sem fio (WSN) aplicadas ao monitorização de estruturas, com particular ênfase na recolha de dados de vibração para deteção de danos. O principal objetivo do estudo foi desenvolver um algoritmo eficiente de recolha de dados de vibração em sistemas ciberfísicos (CPS), com base em WSN, para monitorização da integridade estrutural. O estudo procurou superar as limitações de comunicação e de energia associadas a esses sistemas, otimizando a recolha de dados para aumentar a vida útil dos sensores. O método aplicado baseia-se em técnicas colaborativas de sensores e no uso do algoritmo Goertzel, juntamente com modulação por amplitude em quadratura (QAM), para melhorar a eficiência da recolha de dados de vibração em WSN. Este método permitiu reduzir significativamente a quantidade de dados transmitidos sem comprometer a precisão na deteção de danos nas estruturas monitorizadas. Os resultados obtidos demonstraram que o sistema CPS proposto, utilizando o algoritmo Goertzel e QAM, conseguiu prolongar a vida útil do sistema de monitorização em 40% a 60%, comparado com abordagens baseadas em transformada rápida de Fourier (FFT). Além disso, o sistema foi capaz de identificar com precisão alterações nas frequências de vibração que indicavam a presença de danos estruturais, reduzindo a necessidade de transmissão contínua de dados para o ponto central de processamento.

Limitações

O estudo identificou que o desempenho do sistema de sensores sem fio pode ser afetado por interferências de comunicação e pelo consumo de energia em ambientes de grande escala. Além disso, a técnica

proposta ainda depende de hardware especializado, o que pode limitar a sua aplicabilidade em situações onde recursos computacionais ou energéticos são escassos.

Perspetivas Futuras

Futuros estudos deverão explorar a integração de novos algoritmos de compressão de dados e técnicas de inteligência artificial para otimizar ainda mais a transmissão de dados e melhorar a precisão na deteção de falhas em sistemas de grande escala. A aplicação do método a diferentes tipos de estruturas e a adaptação a sensores de diferentes capacidades são outras áreas sugeridas para investigação.

- O estudo realizado por Sarma e Mallikarachchi (2022) foca na medição de deformação tridimensional (3D) de campo completo em estruturas, utilizando visão estéreo. O objetivo principal do artigo é desenvolver uma técnica económica e precisa para a medição de deformações 3D, utilizando câmaras digitais comuns e ferramentas de processamento de imagem do MATLAB. Esta técnica visa substituir os sistemas tradicionais dispendiosos, fornecendo uma alternativa viável para aplicações em engenharia civil, tanto na fase de construção como na fase operacional das estruturas. A metodologia baseia-se na aplicação da técnica de correlação de imagens digitais (Digital Image Correlation - DIC), que é uma técnica óptica não intrusiva para medir as deformações estruturais de campo completo. O processamento das imagens capturadas é realizado através de algoritmos de visão computacional disponibilizados pelo MATLAB, envolvendo várias fases, como calibração das câmaras estéreo, estimativa da disparidade, reconstrução tridimensional, deteção de características locais e cálculo dos deslocamentos e deformações. Os resultados obtidos demonstraram a validação do sistema em diferentes ensaios experimentais de engenharia civil. Ensaios com cubos e cilindros de betão mostraram a capacidade de reconstruir superfícies tridimensionais, incluindo superfícies curvas. O sistema também conseguiu identificar padrões de fissuras em ensaios de compressão e capturar o alongamento de amostras metálicas em testes de tração uniaxial até à rutura. Adicionalmente, a técnica foi utilizada para detetar fissuras de retração em argamassa com câmaras de telemóveis de alta resolução.

Limitações Entre as principais limitações, destaca-se a dificuldade em medir deformações fora do plano, que depende da profundidade de campo das câmaras utilizadas. O tempo de processamento é relativamente elevado em comparação com métodos de medição por contacto, especialmente quando se monitoriza um número limitado de pontos. Além disso, até ao momento, a técnica apenas foi validada em ensaios laboratoriais, carecendo de validação extensiva em campo.

Perspetivas Futuras Os autores indicam que estão a explorar técnicas de verificação mais precisas, como o uso de transdutores laser, com o intuito de melhorar a precisão da medição. Existe também a intenção

de expandir o leque de aplicações da técnica e superar as suas limitações atuais, aumentando a robustez e a aplicabilidade em cenários práticos de engenharia civil.

- O estudo realizado por Song et al. (2022) insere-se na área da Análise e Detecção de Falhas Estruturais, focando na medição de deslocamento estrutural através de métodos baseados em visão computacional que demonstram robustez a variações de iluminação e possibilitam medições simultâneas em múltiplos pontos. O objetivo principal do estudo foi desenvolver um método baseado em visão computacional para monitorar deslocamentos estruturais de forma resistente a variações de iluminação, utilizando técnicas avançadas de segmentação de imagens e correlação de imagem digital (DIC). Este método visa superar as limitações dos sensores físicos tradicionais, como a sensibilidade a ruídos e os altos custos de implementação, ao mesmo tempo que melhora a precisão das medições em condições de iluminação desfavoráveis. A metodologia aplicada combina Redes Neurais Convolucionais Completamente Conectadas (Fully Convolutional Networks - FCN) com Campos Aleatórios Condicionais (CRF) para segmentar a estrutura do fundo da imagem. A DIC é utilizada para medir os deslocamentos estruturais, com a FCN realizando a segmentação pixel a pixel e o CRF ajustando inconsistências espaciais, garantindo precisão mesmo em condições de iluminação variáveis. Os resultados experimentais demonstraram que o método proposto é significativamente mais robusto a variações de iluminação em comparação com métodos tradicionais de medição de deslocamento, como SURF e FlowNet2. O sistema possibilitou medições simultâneas em múltiplos pontos e apresentou elevada precisão, com um erro quadrático médio (RMSE) de 0,0499 mm e um coeficiente de determinação (R^2) de 0,9815. O método demonstrou capacidade de medir deslocamentos sob diferentes condições de iluminação com pequenas flutuações na precisão.

Limitações

Uma das limitações do método proposto é a dependência das características de textura das superfícies medidas, o que pode restringir sua aplicabilidade em superfícies com baixa textura. Além disso, a precisão das medições pode ser influenciada pela qualidade do vídeo e pela resolução das imagens capturadas.

Perspetivas Futuras

Os autores sugerem que futuros trabalhos devem concentrar-se no desenvolvimento de métodos de medição de deslocamento baseados em vídeo que sejam invariantes às variações de iluminação. A integração de métodos de fluxo óptico contínuo pode também contribuir para melhorar a robustez das medições em diversas condições ambientais.

- O estudo realizado por Bhuiyan et al. (2015) centra-se na recolha eficiente de dados de vibração em sistemas ciber-físicos (CPS), utilizando redes de sensores sem fios (WSN) para monitorizar a saúde estrutural (SHM). O objetivo principal deste estudo foi propor um algoritmo eficiente para a recolha de dados de vibração, visando a monitorização da saúde estrutural em sistemas ciber-físicos. A proposta busca otimizar a utilização de redes de sensores sem fios, reduzindo a quantidade de dados transmitidos e, consequentemente, prolongando a vida útil dos sistemas de sensores, sem comprometer a precisão da monitorização. A metodologia aplicada envolve técnicas de processamento de sinais, como a transformada de Fourier e o algoritmo de Goertzel, e destaca a aplicação de técnicas colaborativas entre sensores para detetar e transmitir apenas dados relevantes. A arquitetura proposta inclui algoritmos de compressão e filtragem, otimizando assim a aquisição e transmissão de dados. Além disso, são implementados mecanismos para identificar parâmetros sensíveis a danos estruturais, permitindo que os sensores decidam localmente se os dados devem ser enviados para um nó central. Os resultados obtidos demonstraram que o algoritmo proposto conseguiu aumentar a vida útil do sistema em 40% a 60% em comparação com métodos tradicionais baseados na transformada rápida de Fourier (FFT). A abordagem provou ser eficaz na redução da quantidade de dados transmitidos, mantendo a qualidade da monitorização estrutural, mesmo em estruturas complexas e de grande escala. As experiências realizadas com sensores Imote2 confirmaram que o sistema é capaz de monitorizar grandes estruturas com uma quantidade significativamente reduzida de transmissões de dados.

Limitações

Uma limitação identificada no estudo é a dependência da comunicação sem fios, que pode ser afetada por interferências e limitações de largura de banda, reduzindo a eficácia em ambientes ruidosos ou a grandes distâncias. Além disso, a abordagem proposta requer que os sensores disponham de capacidade de processamento suficiente para realizar a filtragem e compressão de dados localmente.

Perspetivas Futuras

Os autores sugerem que futuros estudos devem explorar a aplicação desta abordagem em ambientes de monitorização de saúde estrutural em larga escala, utilizando redes de sensores ainda mais densas. A integração com técnicas da aprendizagem automática também é recomendada para melhorar a precisão na deteção de danos estruturais e otimizar o consumo de energia.

- O estudo realizado por Siam, Ezzeldin e El-Dakhakhni (2019) foca na aplicação de algoritmos da aprendizagem automática para a previsão do desempenho de paredes de alvenaria armada sujeitas a cargas sísmicas. O objetivo principal deste estudo foi introduzir uma framework baseada

em aprendizagem automática para prever e classificar o desempenho estrutural de componentes, utilizando um conjunto de dados que inclui 97 paredes de alvenaria armada. A investigação visa melhorar a classificação e a previsão dos modos de falha, como cisalhamento e flexão, através da aplicação de algoritmos da aprendizagem supervisionada e não supervisionada. A metodologia aplicada incluiu tanto algoritmos da aprendizagem supervisionada quanto não supervisionado (UL). O método da aprendizagem não supervisionada utilizou a análise de componentes principais (PCA) para reduzir a dimensionalidade dos dados e identificar padrões nos modos de falha das paredes. Por outro lado, o aprendizagem supervisionada fez uso do Partial Least Squares (PLS) para prever o deslocamento lateral máximo das paredes com base nas suas características geométricas e mecânicas. Os resultados obtidos demonstraram que a framework baseada em aprendizagem automática foi capaz de prever com precisão o deslocamento lateral máximo das paredes de alvenaria armada, classificando-as em diferentes modos de falha, como cisalhamento, flexão ou uma combinação de ambos. O algoritmo PLS apresentou resultados consistentes com os dados experimentais, mostrando a sua eficácia na previsão dos valores de deslocamento. Além disso, a abordagem baseada em PCA revelou-se útil para a identificação de clusters de paredes com características semelhantes.

Limitações

As limitações identificadas incluem a necessidade de grandes volumes de dados experimentais para treinar os modelos de forma mais precisa, bem como a complexidade de ajustar adequadamente os modelos da aprendizagem automática para prever diferentes cenários de falha. Adicionalmente, a framework proposta foi validada apenas para um conjunto específico de paredes, o que pode restringir a sua aplicabilidade a outros tipos de estruturas.

Perspetivas Futuras

Os autores sugerem a aplicação futura desta framework baseada em aprendizagem automática a outros tipos de componentes estruturais, como colunas, vigas e lajes, em diferentes cenários de carga, como explosões ou ventos. Também recomendam a utilização desta framework como complemento às técnicas tradicionais de simulação, como o método dos elementos finitos.

- O estudo realizado por Karaçay (2022) centra-se na deteção de fissuras em estruturas de betão, utilizando técnicas da aprendizagem profunda. O principal objetivo deste estudo foi desenvolver um sistema autónomo para a deteção de fissuras em estruturas de betão, recorrendo à visão computacional e a redes neurais convolucionais (CNN). A deteção rápida e precisa de fissuras é crucial para a avaliação precoce de danos estruturais, facilitando assim uma manutenção eficaz

e prolongando a vida útil das infraestruturas. A metodologia aplicada baseou-se na arquitetura U-Net, uma rede neural convolucional projetada para a segmentação de imagens. O estudo utilizou diferentes conjuntos de dados, que incluíam imagens de fissuras e regiões sem fissuras em estruturas de betão. O modelo foi treinado para segmentar as áreas danificadas nas imagens, sendo ajustado para aumentar a precisão na deteção, mesmo em cenários com grande ruído e variações de iluminação. Os resultados obtidos demonstraram que a arquitetura U-Net conseguiu uma elevada precisão na deteção de fissuras em imagens de estruturas de betão. A inclusão de imagens de regiões sem fissuras no conjunto de dados contribuiu para melhorar a robustez do modelo, que atingiu uma precisão de deteção superior a 96%. O modelo revelou-se eficaz na deteção de fissuras em diferentes cenários e com variados níveis de ruído.

Limitações

As limitações identificadas incluem a necessidade de uma base de dados maior, com maior diversidade de tipos de fissuras e condições de iluminação. Adicionalmente, a redução do tamanho das imagens para 256x256 pixels, de modo a se ajustar às limitações computacionais, pode ter resultando em perda de informação relevante, especialmente em fissuras de pequena dimensão.

Perspetivas Futuras

Futuras investigações poderão focar na melhoria da resolução das imagens de entrada e no aumento do conjunto de dados para treinar modelos mais robustos. O estudo sugere também a integração de sistemas autónomos com drones para a inspeção de grandes infraestruturas, permitindo a deteção de fissuras em tempo real com o suporte de IA.

- O estudo realizado por H. Cheng et al. (2024) tem como objetivo desenvolver e demonstrar uma plataforma denominada Random Bridge Generator (RBG), projetada para criar ambientes sintéticos e gerar conjuntos de dados destinados à inspeção estrutural automatizada de pontes, utilizando algoritmos de visão computacional. A meta principal é permitir a criação de imagens realistas e anotadas de componentes estruturais de pontes, visando melhorar a eficiência e a automação dos processos de inspeção visual. A plataforma RBG cria automaticamente seis tipos diferentes de pontes, incluindo pontes de laje, viga, treliça, arco, estaiadas e suspensas, em conformidade com normas de design estrutural. O ambiente gerado facilita o uso de algoritmos de visão computacional e aprendizagem profunda, como redes convolucionais profundas (CNNs), para a segmentação semântica de componentes estruturais a partir de imagens sintéticas. Esta técnica é aplicada para identificar e rotular automaticamente componentes maiores e menores, como vigas, tabuleiros, cabos e outros elementos estruturais das pontes. Os objetos de estudo consistem nos

seis tipos de pontes geradas com diferentes geometrias e texturas, simulando cenários de inspeção visual realistas. A plataforma produziu um conjunto de dados de 10.753 imagens, com anotações pixelizadas dos componentes estruturais. O uso deste conjunto de dados possibilitou o treinamento de um algoritmo de segmentação semântica, com 101 camadas convolucionais, que demonstrou eficácia na identificação de componentes estruturais principais e secundários, alcançando uma precisão superior a 75% na métrica Intersection over Union (IoU) para classes como colunas e tabuleiros.

Limitações

O estudo reconhece que, apesar da eficácia da plataforma RBG na geração de ambientes sintéticos, a transição dos dados sintéticos para o mundo real ainda enfrenta desafios. Estas dificuldades incluem a discrepância entre os padrões de segmentação em ambientes simulados e em imagens reais. Além disso, existem limitações na criação de ambientes complexos que representem com total fidelidade as condições reais de campo.

Perspetivas Futuras

O artigo sugere que futuras investigações devem focar-se na adaptação não supervisionada de domínios (UDA), com o objetivo de melhorar o desempenho de algoritmos treinados em dados sintéticos quando aplicados a imagens reais. A expansão da plataforma para incluir segmentação 3D e detecção de danos estruturais também é destacada como uma área promissora para desenvolvimento.

- O estudo realizado por X. Liu et al. (2022) tem como principal objetivo desenvolver um método de monitorização de deformações baseado em técnicas de segmentação adaptativa e correspondência de correlação. O sistema proposto visa fornecer medições de alta precisão e em tempo real de deformações e deslocamentos em edifícios e pontes, superando as limitações dos métodos tradicionais, que dependem de medições manuais e são sensíveis a condições climáticas e de iluminação. O método utiliza câmaras industriais de alta resolução combinadas com técnicas de visão computacional para detetar e monitorizar o deslocamento de alvos em estruturas. O algoritmo de correspondência de correlação normalizada (NCC) é aplicado para calcular o deslocamento a partir de imagens capturadas em tempo real. A segmentação adaptativa ajusta automaticamente os parâmetros conforme as condições de iluminação mudam, sendo desenvolvido em C++ com a biblioteca OpenCV. Os objetos de estudo foram pontes e edifícios monitorizados para medir deformações. O sistema demonstrou a capacidade de medir deslocamentos com precisão de até 0,1 mm, mantendo um erro inferior a 10% em condições variáveis de iluminação. Comparado com o método tradicional NCC e o método RNCC, o novo sistema apresentou melhor robustez em

cenários com variações extremas de luz, proporcionando medições mais estáveis e precisas.

Limitações

As principais limitações incluem a dependência da qualidade das imagens capturadas e a necessidade de ajustes específicos em ambientes com variações extremas de luz ou alvos de baixa visibilidade. O desempenho do sistema também é condicionado pela capacidade das câmaras de manter uma resolução adequada em distâncias maiores.

Perspetivas Futuras

O artigo sugere que futuras investigações explorem o uso de sensores 3D para melhorar a precisão e robustez do sistema em diferentes condições ambientais. A integração com técnicas da aprendizagem automática é recomendada para aumentar a capacidade de adaptação a cenários de monitorização mais complexos.

- O estudo realizado por Jaziri et al. (2024) tem como objetivo desenvolver um sistema híbrido de redes neurais capaz de segmentar fissuras em superfícies de betão, utilizando dados simulados baseados em fractais e dados reais. O sistema visa superar as dificuldades de generalização dos modelos de visão computacional, que frequentemente são afetados pela variabilidade nas superfícies de betão, nas condições de iluminação e na sobreposição de diferentes defeitos estruturais. Para tal, o artigo propõe um simulador de alta fidelidade, denominado Cracktal, que gera dados anotados complementados por um modelo neural que integra normalização de instâncias adaptativas e informação mútua ponto a ponto. O método de IA aplicado é o CAP-Net, um sistema híbrido que combina a normalização de instâncias adaptativas (Adaptive Instance Normalization, AdaIN) e a informação mútua ponto a ponto (Pointwise Mutual Information, PMI). O modelo é treinado com dados gerados pelo simulador Cracktal, que utiliza um algoritmo baseado em fractais para criar imagens de fissuras em superfícies de betão, incluindo mapas de profundidade e normais da superfície. O CAP-Net consiste em duas redes U-Net que são ajustadas para realizar a segmentação de fissuras em dados reais, utilizando inicialmente imagens simuladas. Os objetos de estudo incluem imagens simuladas de superfícies de betão fissuradas geradas pelo simulador Cracktal, bem como imagens reais do conjunto de dados CODEBRIM, que abrange pontes de betão com diversos níveis de deterioração. O modelo CAP-Net demonstrou uma melhoria significativa na segmentação de fissuras, superando outros modelos ao apresentar um aumento de 7% na métrica F1 em relação à U-Net convencional. A utilização de mapas de profundidade e informações de textura contribuiu para a capacidade do modelo em identificar fissuras em superfícies complexas.

Limitações

Uma das principais limitações do estudo é a dependência de dados simulados, que, embora detalhados, podem não refletir perfeitamente as condições do mundo real. O método exige ajustes adicionais para lidar com novos tipos de superfícies e defeitos estruturais que não estão representados no conjunto de dados inicial.

Perspetivas Futuras

Os autores sugerem que futuras investigações devem explorar a aplicação do simulador Cracktal em outros contextos de engenharia civil, além da integração com métodos de transferência de estilo para aumentar a diversidade dos dados de treino. Também é recomendada a aplicação de técnicas de paralelização para melhorar a eficiência do treinamento em cenários de larga escala.

- O estudo realizado por Hsu, T.-W. Chang e C.-M. Chang (2021) tem como objetivo apresentar um método baseado em aprendizagem profunda para a segmentação e detecção de fissuras em superfícies de betão. Este método utiliza visão computacional para identificar a presença de fissuras e realizar a sua segmentação, proporcionando uma abordagem não intrusiva para a monitorização da integridade estrutural de infraestruturas de betão. Adicionalmente, o estudo busca comparar a eficácia de dois modelos da aprendizagem profunda — Mask R-CNN e DeepLabv3+ — na tarefa de segmentação de fissuras. No que diz respeito ao método de IA aplicado, os autores implementaram ambos os modelos da aprendizagem profunda para a segmentação de fissuras em superfícies de betão. O Mask R-CNN, que realiza segmentação de instâncias, foi utilizado com a arquitetura ResNet101, combinada com Feature Pyramid Networks (FPN), a fim de melhorar a detecção de objetos pequenos. O DeepLabv3+, por sua vez, foi implementado também com ResNet101, realizando segmentação semântica. Ambos os modelos foram treinados utilizando técnicas da aprendizagem por transferência, com imagens de fissuras de betão previamente etiquetadas. A performance dos modelos foi avaliada através da métrica "mean intersection-over-union" (mIoU). Os resultados obtidos indicam que ambos os modelos mostraram-se eficazes na identificação de fissuras em superfícies de betão. Contudo, o DeepLabv3+ destacou-se com um melhor desempenho geral em termos de mIoU durante a fase de validação. Em contrapartida, o Mask R-CNN revelou ser mais robusto na identificação de fissuras em ambientes de teste, onde o desempenho do DeepLabv3+ foi inferior. O Mask R-CNN mostrou-se particularmente eficiente em conjuntos de dados com etiquetas baseadas em polígonos, enquanto o DeepLabv3+ teve um desempenho superior em dados com etiquetas de segmentação pixel a pixel. Ambos os modelos conseguiram segmentar com precisão fissuras em diferentes tipos de superfícies de betão, permitindo a extração de propriedades geométricas, como a largura e o comprimento das fissuras.

Limitações

Uma limitação significativa mencionada no estudo é a dificuldade dos modelos em generalizar para diferentes tipos de superfícies de betão que não estavam presentes no conjunto de treino. A precisão dos modelos foi impactada pela variação nas características dos dados de treino e teste. Além disso, os autores destacaram que o desempenho do modelo depende fortemente do tipo de etiquetas utilizadas, sendo o Mask R-CNN mais adequado para etiquetas poligonais e o DeepLabv3+ para etiquetas baseadas em pixels.

Perspetivas Futuras

Os autores sugerem que futuras investigações devem explorar a utilização de conjuntos de dados mais amplos e variados, bem como a integração de técnicas de ensemble learning para combinar as forças de ambos os modelos (Mask R-CNN e DeepLabv3+) em um único sistema. Outra direção sugerida é o desenvolvimento de métodos que possam melhorar a generalização dos modelos para diferentes tipos de superfícies de betão e cenários de teste.

- O estudo realizado por Honarjoo e Darvishan (2024) tem como principal objetivo desenvolver uma arquitetura leve de rede neuronal convolucional (CNN) para a deteção e classificação de fissuras em estruturas de betão. O estudo visa otimizar o tempo de execução e reduzir os custos computacionais associados à monitorização não destrutiva da saúde estrutural, fornecendo uma solução rápida e eficiente para a detecção automática de fissuras. Relativamente ao método de IA aplicado, a abordagem consiste na utilização de uma rede neuronal convolucional (CNN) rasa, com um número reduzido de camadas, destinada à classificação de fissuras em imagens de estruturas de betão. A arquitetura proposta é composta por blocos que incluem camadas de convolução, normalização por lotes (batch normalization) e a função de ativação Leaky ReLU, seguidos por camadas de pooling máximo. A função Softmax é empregada para a classificação final. O treinamento da rede foi realizado com um conjunto de dados padrão, cujas imagens foram convertidas para escala de cinza e redimensionadas, a fim de otimizar o tempo de processamento. Os resultados obtidos demonstram que o modelo alcançou uma precisão de 99,53% na classificação de fissuras em duas classes (presença e ausência de fissuras) e 91,56% na classificação em múltiplas classes (fissuras pequenas, grandes e ausência de fissuras). O modelo destacou-se em comparação com outras arquiteturas tradicionais de CNN, como o MobileNetV2 e VGG16, tanto em termos de precisão como de tempo de execução. O melhor desempenho foi atingido ao utilizar o otimizador Adam, que resultou em maior precisão e menor tempo de execução em comparação com outros otimizadores.

Limitações

Uma limitação relevante do estudo é a dependência de um conjunto de dados específico para o treino do modelo, o que pode restringir a sua capacidade de generalização a outros tipos de fissuras ou a diferentes condições ambientais. Além disso, o modelo não foi testado com dados em tempo real, o que é crucial para as aplicações práticas de monitorização da saúde estrutural.

Os autores sugerem que investigações futuras devem centrar-se na expansão do conjunto de dados, incluindo imagens de estruturas de betão sob diversas condições e com vários níveis de severidade de danos. É também recomendada a exploração de outras modalidades, como imagens térmicas e nuvens de pontos 3D, para proporcionar uma avaliação mais abrangente das condições estruturais.

- O estudo realizado por Khemapech, Sansrimahachai e Toahchoodee (2017) tem como principal objetivo apresentar o desenvolvimento do sistema SPANNeT (An Enhanced Structural Health Monitoring System Using Stream Processing and Artificial Neural Network Techniques), projetado para a monitorização em tempo real da saúde estrutural de pontes. O sistema visa melhorar a deteção de danos e a comunicação de dados em tempo real através de uma rede de sensores sem fio, processamento de fluxos de dados e redes neuronais artificiais. O SPANNeT permite a deteção de deformações estruturais críticas e a emissão de alertas antecipados, contribuindo para a prevenção de falhas estruturais. No que diz respeito ao método de IA aplicado, o SPANNeT combina uma rede de sensores sem fio (WSN) com técnicas de processamento de fluxos de dados em tempo real e redes neuronais artificiais (ANN) para detetar e reportar deformações em elementos estruturais, como vigas de pontes. A deteção de danos é realizada através da comparação dos valores de deformação medidos com limiares pré-definidos, que são baseados em simulações e nas especificações de design da AASHTO (American Association of State Highway and Transportation Officials). A arquitetura do sistema inclui algoritmos de detecção baseados em gráficos ponderados de ataques (WAG) para monitorizar o estado estrutural e emitir alertas quando os limites de segurança são ultrapassados. Os resultados obtidos indicam que o sistema SPANNeT foi testado em ambientes laboratoriais e reais, mostrando elevada precisão na monitorização de deformações em pontes. A máxima deformação observada durante operações normais variou entre 25 a 30 microstrains, o que se encontra dentro da zona de segurança. O sistema apresentou uma fiabilidade de comunicação de 90% na transmissão de dados entre os sensores e a estação base. Além disso, os testes de campo e simulações demonstraram que o SPANNeT foi capaz de detetar com precisão níveis críticos de deformação e emitir alertas oportunos para prevenir falhas estruturais.

Limitações

Uma das limitações do sistema SPANNeT é a necessidade de uma linha de visão clara entre os sensores e a estação base, o que pode comprometer a fiabilidade da comunicação em ambientes complexos ou durante desastres naturais. Adicionalmente, o sistema foi predominantemente testado em pontes com características específicas, sendo necessário validar o SPANNeT em outros tipos de estruturas e materiais, como vigas de aço ou híbridas.

Perspetivas Futuras

Os autores sugerem que futuras melhorias no SPANNeT devem incluir a integração de sensores adicionais, como acelerómetros e transdutores de deslocamento, para proporcionar uma avaliação mais abrangente das condições estruturais. Também é proposta a incorporação de novas políticas de alerta baseadas em características adicionais, como os tipos de suporte e as propriedades do material. O uso do sistema em estruturas localizadas em áreas rurais e em situações extremas, como terremotos, é igualmente sugerido como uma área de investigação futura.

5.4 Simulação e Modelação Estrutural Avançada

A simulação e modelação estrutural avançada têm evoluído significativamente, refletindo a crescente necessidade de analisar comportamentos complexos em estruturas de engenharia. Inicialmente, as simulações eram limitadas a modelos lineares e a abordagens simplificadas, onde a análise das estruturas era feita com base em princípios clássicos da mecânica dos sólidos. A introdução do Método dos Elementos Finitos (FEA) na década de 1960, como apresentado por Bendsøe e Kikuchi (1988), permitiu a modelação mais precisa de estruturas complexas, ao dividir um corpo em elementos menores e interligados. Nos anos 1980, com o aumento da capacidade computacional, surgiram novas técnicas que possibilitaram a modelação não linear e a simulação dinâmica. Isto permitiu que os engenheiros analisassem não apenas o estado de equilíbrio estático das estruturas, mas também como estas respondiam a cargas dinâmicas, como sismos ou ventos fortes. As técnicas de otimização, como os algoritmos genéticos, começaram a ser integradas, sendo que Deb e K. (2002) demonstraram a eficácia de algoritmos multi-objetivo na busca por soluções ideais em design estrutural. Na década de 1990, o uso de redes neuronais para otimização de estruturas, conforme explorado por Ghaboussi e M. (1991), abriu novos caminhos na simulação e modelação, permitindo uma abordagem mais adaptativa e eficiente. Recentemente, com a ascensão de técnicas da aprendizagem automática e inteligência artificial, a análise preditiva e a deteção de falhas em tempo real tornaram-se cada vez mais viáveis. A pesquisa de Xiao e C. (2019) exemplifica como modelos da aprendizagem profunda podem ser utilizados para prever a resistência à compressão do betão, ilustrando a aplicação prática dessas tecnologias. A modelação paramétrica também emergiu como uma ferramenta poderosa, permitindo que os engenheiros explorem rapidamente diferentes cenários e configurações de design. A combinação de simulações avançadas com big data tem o potencial de revolucionar a forma como as estruturas são projetadas e mantidas, ao fornecer insights valiosos baseados em grandes volumes de dados históricos e operacionais. Um exemplo é o trabalho de X.-G. Zhou, Hou e J. Peng (2023), que utilizou otimização híbrida e redes neuronais para prever a resistência ao corte de vigas de betão armado, mostrando a eficácia das abordagens integradas na modelação estrutural.

5.4.1 Análise dos Estudos

- O estudo realizado por Shi et al. (2022) tem como principal objetivo desenvolver uma abordagem híbrida que combina análise experimental, análise de elementos finitos (FEA) e técnicas da aprendizagem automática (ML) para prever o gradiente vertical de temperatura (GVT) em vias-férreas sem lastro, causado pela radiação solar. O GVT é um fator crucial na conceção, manutenção e controlo de danos dessas infraestruturas, uma vez que a variação térmica afeta diretamente a sua integridade e desempenho. O estudo procura melhorar a precisão das previsões de GVT,

considerando as condições ambientais complexas e variáveis que influenciam as vias-férreas. Os resultados indicam que, de entre as seis técnicas da aprendizagem automática testadas, regressão linear múltipla (MLR), regressão polinomial (PR), regressão por vetores de suporte (SVR), floresta aleatória (RF), XGBOOST e CATBOOST, a abordagem baseada no CATBOOST foi a que demonstrou maior precisão na previsão do GVT. Especificamente, o modelo CATBOOST apresentou um coeficiente de determinação (R^2) de 0,97, um erro médio absoluto (MAE) de 1,46 °C/m e um erro percentual absoluto médio (MAPE) de 6,52%. Estes resultados superaram significativamente os obtidos pelas outras técnicas da aprendizagem automática. Além disso, o estudo revelou que as variáveis mais importantes para a previsão do GVT são as temperaturas máximas e mínimas do ar, a latitude e a velocidade média do vento.

Limitações

As principais limitações do estudo prendem-se com a dependência de dados experimentais obtidos em condições específicas de um local geográfico particular (Tibete, China). Embora os modelos da aprendizagem automática tenham demonstrado bom desempenho nas previsões, a sua generalização para outras regiões ou para condições climáticas extremas diferentes ainda necessita de investigação adicional. Além disso, o modelo de elementos finitos (FEA) simplificou alguns aspetos estruturais, como a exclusão do impacto dos trilhos e blocos de suporte, o que pode influenciar os resultados em casos práticos.

Perspetivas Futuras

Os autores indicam que estudos futuros devem focar-se na realização de testes de campo em diversas regiões geográficas e em diferentes tipos de estruturas, para melhorar a abordagem híbrida proposta. A continuidade deste trabalho incluirá o desenvolvimento de modelos mais robustos que possam aglomerar variadíssimos fatores ambientais e estruturais, otimizando a concepção de vias-férreas sem lastro e aprimorando a previsão de gradientes térmicos em diversas condições. A implementação de uma abordagem mais abrangente, que tenha em consideração os efeitos de longo prazo e a resistência dos materiais, é um potencial para melhoria da precisão das previsões e eficiência das soluções.

- O estudo realizado por Alhusban, Alhusban e Alkhawaldeh (2024b) tem como principal objetivo avaliar a eficiência do uso de várias técnicas da aprendizagem automática (ML) na previsão do comportamento de membros de betão armado reforçados com fibras de polímero (FRP). Através da análise de 96 artigos publicados entre 2016 e 2023, os autores procuram identificar lacunas no conhecimento existente e sugerir soluções para melhorar a precisão das previsões e a eficiência no uso de FRP no reforço de estruturas. O estudo foca na aplicação de ML para prever a resistência de vigas, colunas e ligações FRP-betão, propondo um quadro abrangente para a utilização

dessas tecnologias na engenharia estrutural. Os resultados obtidos mostram que os algoritmos da aprendizagem automática, especialmente os da aprendizagem supervisionada, aumentaram significativamente a precisão das previsões de resistência em comparação com os métodos empíricos tradicionais. Em termos percentuais, 32% dos estudos focaram no reforço à flexão e corte de vigas de betão armado, 32% na resistência à compressão de colunas e 22% na resistência de ligação entre FRP e betão. Entre os modelos mais eficazes estão o Random Forest, o Extreme Gradient Boosting (XGBoost) e o CATBOOST, todos mostrando melhorias no desempenho preditivo. Estes resultados reforçam a eficácia dos métodos de ML na modelação estrutural complexa.

Limitações

As principais limitações identificadas no estudo incluem a dependência de bases de dados específicas, o que pode afetar a capacidade de generalização dos modelos de ML. Outro desafio é a escolha do algoritmo mais adequado para cada aplicação, pois diferentes algoritmos baseiam-se em princípios e metodologias distintas. O estudo também sublinha que a qualidade e a distribuição dos dados utilizados para treinar os modelos têm um impacto significativo no seu desempenho e, portanto, na precisão das previsões.

Perspetivas Futuras

Os autores sugerem que futuras pesquisas devem expandir as bases de dados experimentais para reforçar a robustez e a precisão dos modelos de ML. Também propõem a combinação de técnicas de ML com modelos numéricos, como análises de elementos finitos (FEA), para melhorar a previsão de resistência estrutural. A utilização de algoritmos híbridos, que combinem técnicas de ML com métodos de otimização, é considerada uma perspectiva promissora para aumentar ainda mais a eficiência do reforço estrutural com FRP. Esta abordagem pode ser aplicada não apenas no contexto atual, mas também em novos cenários de engenharia estrutural.

- O estudo realizado por G. Zhang et al. (2022) foca na previsão da resistência ao corte de vigas de betão armado profundo através de um modelo híbrido de AA. O principal objetivo deste estudo foi desenvolver um modelo híbrido da aprendizagem automática que combina a regressão por vetores de suporte (Support Vector Regression - SVR) com um algoritmo genético (GA), para prever com precisão a capacidade de resistência ao corte de vigas de betão armado profundo. O estudo visa superar as limitações dos modelos clássicos, aplicando técnicas de inteligência artificial para melhorar a precisão das previsões de resistência ao corte. A técnica da aprendizagem automática utilizada foi a regressão por vetores de suporte (SVR), otimizada por um algoritmo genético (GA), formando o modelo híbrido SVR-GA. O GA foi empregado para ajustar os hiperparâmetros do modelo SVR, melhorando a sua capacidade de generalização e evitando o problema de overfitting.

Este modelo foi comparado com outras técnicas, como redes neurais artificiais (ANN) e árvores de decisão com boosting (GBDT), sendo validado com uma base de dados de 217 amostras de testes experimentais de vigas de betão armado profundo. Os resultados mostraram que o modelo SVR-GA superou os outros modelos comparados, alcançando um coeficiente de determinação (R^2) de 0,958, enquanto os modelos ANN e GBDT apresentaram valores inferiores de R^2 (0,884 e 0,935, respetivamente). O modelo SVR-GA demonstrou uma excelente capacidade preditiva durante a fase de teste, com erros médios absolutos (MAE) e erros quadráticos médios (RMSE) significativamente mais baixos do que os outros modelos.

Limitações

Uma limitação do estudo é a necessidade de dados experimentais extensivos e variados para garantir a generalização do modelo em diferentes contextos. Além disso, o desempenho do modelo SVR depende fortemente da seleção apropriada dos hiperparâmetros, o que pode ser computacionalmente intensivo. Apesar da eficácia do modelo SVR-GA, o ajuste fino desses parâmetros é complexo e exige uma abordagem de otimização robusta.

Perspetivas Futuras

Os autores sugerem que futuros estudos explorem a aplicação do modelo SVR-GA em outros tipos de estruturas e materiais, como vigas de betão armado reforçadas com fibras (FRP). Recomenda-se também a integração de novos algoritmos de otimização bio-inspirados para melhorar ainda mais a precisão e a eficiência dos modelos preditivos em engenharia estrutural. Outra perspetiva é a implementação deste modelo em software de análise estrutural comercial, auxiliando os engenheiros na previsão de falhas estruturais em tempo real.

- O estudo realizado por Kuo et al. (2024) tem como objetivo principal desenvolver um modelo de fusão inovador que combina redes neurais gráficas (GNN) e redes de memória de longo prazo (LSTM) para prever as respostas dinâmicas de estruturas resistentes a momentos em aço (SMRF) sujeitas a movimentos sísmicos. O modelo foi concebido para superar as limitações dos modelos da aprendizagem profunda existentes, que frequentemente se limitam a previsões para configurações estruturais específicas. A técnica de IA utilizada é uma combinação de redes neurais gráficas (GNN) e redes de memória de longo prazo (LSTM). As GNNs modelam a geometria e as propriedades dinâmicas das estruturas através de uma representação gráfica dos elementos estruturais. O modelo LSTM é aplicado para capturar características temporais, como as respostas não-lineares ao movimento do solo. Além disso, o modelo utiliza estratégias otimizadas da aprendizagem LSTM para reduzir os custos de treino, incluindo a estratégia de "packing padded sequences" (PPS) e

a estratégia de compressão de sequências (SC). O modelo de fusão GNN-LSTM demonstrou uma elevada precisão na previsão das respostas dinâmicas de estruturas SMRF com quatro a sete andares, superando os modelos existentes em termos de capacidade preditiva. As métricas de desempenho incluíram erros médios quadráticos normalizados (NMSE) e o coeficiente de determinação (R^2), com o modelo alcançando valores de R^2 próximos a 0,95 para as previsões de aceleração e deslocamento. As estratégias otimizadas de LSTM reduziram significativamente os custos de treino, sem comprometer a precisão do modelo.

Limitações

As principais limitações do estudo incluem o fato de os dados de treino e validação serem gerados apenas através de simulações numéricas, o que pode não captar todas as complexidades de cenários do mundo real, como a presença de pulsações nos movimentos do solo. Além disso, o modelo foi desenvolvido apenas para estruturas de aço com determinadas propriedades geométricas e materiais, limitando a sua aplicabilidade a outras geometrias ou tipos de estruturas.

Perspetivas Futuras

Os autores sugerem que futuros estudos explorem a aplicação do modelo de fusão GNN-LSTM em outros tipos de estruturas e cenários de carregamento, como edificações com geometrias complexas e movimentos sísmicos com características pulsantes. Recomenda-se o uso de dados experimentais em vez de apenas simulações numéricas para melhorar a aplicabilidade prática do modelo. A integração com novos métodos de otimização e aprendizagem por reforço é vista como uma área promissora para melhorar ainda mais a capacidade preditiva.

- O estudo realizado por Singh (2023) tem como objetivo principal explorar as tendências emergentes e aplicações recentes das redes neurais artificiais (ANN) no campo da engenharia civil. O foco do estudo está em demonstrar como as ANN podem ser aplicadas em várias subáreas, como a engenharia de transportes, gestão de recursos hídricos, geotecnia e engenharia estrutural, para melhorar a precisão preditiva e a eficiência em projetos de engenharia civil. A técnica de IA utilizada são as redes neurais artificiais (ANN), incluindo várias formas, como as redes neurais convolucionais (CNN), redes feed-forward (FFNN), redes recorrentes (RNN) e redes modulares. O estudo revisa as aplicações de cada tipo de rede neural em diferentes ramos da engenharia civil, abordando o uso dessas redes para previsão de falhas, otimização de projetos e monitorização da integridade estrutural. Os resultados obtidos demonstram que as ANN têm mostrado excelentes resultados em várias subáreas da engenharia civil, como a previsão de fissuras em pavimentos de betão, gestão de recursos hídricos e a previsão de falhas em sistemas estruturais. A utilização de

ANN em problemas de otimização de topologia estrutural e monitorização da saúde estrutural também provou ser promissora, com melhorias significativas na precisão e eficiência dos processos.

Limitações

Uma das limitações destacadas no estudo é a falta de familiaridade entre engenheiros civis tradicionais com o uso de ANN, o que dificulta a sua aplicação prática em larga escala. Além disso, a complexidade dos algoritmos de ANN e a necessidade de grandes conjuntos de dados de alta qualidade para treino são desafios que devem ser superados para uma implementação mais abrangente.

Perspetivas Futuras

O estudo recomenda que as universidades e instituições de ensino incorporem cursos relacionados com ANN no currículo de engenharia civil, preparando os engenheiros para o uso de tecnologias avançadas. Além disso, futuras pesquisas devem focar-se na aplicação de ANN em áreas menos exploradas, como a engenharia de recursos hídricos e a gestão de projetos de construção.

- O estudo realizado por Lee et al. (2018) tem como objetivo principal investigar as técnicas da aprendizagem profunda aplicáveis à análise estrutural. O artigo discute a evolução das redes neurais artificiais (ANN) e como os avanços em hardware e algoritmos, como as redes de crença profunda (DBN), funções de ativação como a ReLU, e métodos para lidar com overfitting, podem ser utilizados para resolver problemas estruturais complexos. O estudo exemplifica isso com o problema clássico de uma treliça de 10 barras. O método de IA aplicado inclui redes neurais profundas, com foco em feedforward neural networks (FNN) e técnicas como backpropagation para otimizar a estrutura de camadas e a performance dos modelos. Foram aplicadas várias funções de ativação, como sigmoid, tangente hiperbólica (tanh), softplus e ReLU, para analisar a eficiência e precisão em modelos de otimização estrutural. Os resultados mostraram que o uso de redes profundas, especialmente com a função de ativação ReLU, proporcionou a melhor convergência e precisão para a análise estrutural de uma treliça de 10 barras. O modelo com arquitetura (10-20-2) alcançou um erro quadrático médio (MSE) de 0,245 com a função ReLU após 10.000 épocas. Outras funções de ativação, como softplus e tanh, também mostraram resultados promissores, mas com uma convergência ligeiramente mais lenta.

Limitações

Uma das limitações mencionadas no estudo foi a alta demanda computacional das redes profundas para problemas estruturais complexos, especialmente ao lidar com múltiplas camadas ocultas e grandes conjuntos de dados. Além disso, a seleção do número ideal de neurónios em cada camada ainda representa um desafio, uma vez que impacta diretamente a precisão e eficiência do modelo.

Perspetivas Futuras Os autores sugerem que futuros trabalhos explorem o uso de redes neurais em otimização estrutural em problemas de maior escala, com foco em reduzir a complexidade computacional. Também é recomendado o desenvolvimento de novas técnicas para lidar com problemas de overfitting e melhorar a capacidade de generalização dos modelos para diferentes tipos de estruturas.

- O estudo realizado por Vu, Truong e Thai (2021) tem como objetivo principal desenvolver uma estrutura preditiva eficiente para prever a resistência de colunas CFST (Concrete Filled Steel Tubes) sob carga concêntrica, utilizando o algoritmo de Gradient Tree Boosting (GTB). O artigo visa superar as limitações dos métodos de design tradicionais, empregando uma base de dados extensa de mais de 1.000 testes em colunas CFST para treinar e testar o modelo preditivo. O método aplicado foi o Gradient Tree Boosting (GTB), um dos algoritmos da aprendizagem automática mais robustos e precisos para desenvolver modelos preditivos. Além do GTB, o estudo comparou o desempenho de outros algoritmos, como Random Forest (RF), Support Vector Machines (SVM), Decision Tree (DT) e aprendizagem profunda. A eficiência do modelo foi avaliada utilizando métricas como o erro quadrático médio (MSE) e o coeficiente de determinação (R^2). Os resultados demonstraram que o modelo baseado em GTB apresentou o melhor desempenho preditivo, com um MSE significativamente menor e um R^2 superior em comparação com os outros algoritmos testados. O modelo GTB foi considerado mais rápido e preciso, alcançando uma precisão de 69,59% para um erro de 5% nos dados de teste. A sensibilidade ao diâmetro externo do tubo de aço foi identificada como o parâmetro mais crítico para a previsão da resistência das colunas CFST.

Limitações

Uma das limitações do estudo foi a dependência de uma base de dados experimental extensa para treinar os modelos, o que pode restringir a aplicabilidade do modelo a outras geometrias ou tipos de materiais estruturais que não estão suficientemente representados na base de dados.

Perspetivas Futuras

Futuros trabalhos deverão expandir o uso do algoritmo GTB para prever o comportamento de colunas CFST em condições mais complexas, como carga excêntrica ou momentos de flexão. É também recomendada a aplicação de novos algoritmos da aprendizagem automática para melhorar a eficiência computacional e a precisão dos modelos preditivos.

- O estudo realizado por S. Wang et al. (2024) foca na previsão de resistência e modos de falha em juntas coladas de aço-CFRP, utilizando métodos da aprendizagem automática e redes geradoras adversariais condicionais (CTGAN). O principal objetivo deste estudo foi desenvolver modelos preditivos baseados em aprendizagem automática para estimar a resistência e modos de falha de

juntas coladas de CFRP e aço. Para superar a limitação de dados experimentais disponíveis, o método CTGAN foi utilizado para gerar dados sintéticos, permitindo a construção de modelos robustos. O estudo compara quatro algoritmos amplamente utilizados: Support Vector Machines (SVM), K-Nearest Neighbours (KNN), Decision Trees (DT) e Artificial Neural Networks (ANN). A técnica aplicada foi o Conditional Tabular Generative Adversarial Network (CTGAN), utilizada para aumentar a quantidade de dados disponíveis ao gerar um conjunto de dados sintéticos a partir de 178 amostras reais de testes de cisalhamento de juntas. Os modelos da aprendizagem automática foram então treinados com este conjunto de dados ampliado. Além disso, o método SHAP (SHapley Additive exPlanations) foi empregado para interpretar a importância das características dos dados nos modelos preditivos. Os resultados mostraram que o modelo ANN obteve o melhor desempenho preditivo para a resistência das juntas, com um coeficiente de determinação (R^2) de 0,95. O modelo SVM foi o mais eficaz na previsão dos modos de falha, alcançando uma precisão de 92,3% ou superior. A análise SHAP indicou que o módulo de elasticidade do adesivo é o fator mais importante para a previsão da resistência da junta, enquanto a resistência à tração do adesivo foi a mais significativa para os modos de falha.

Limitações

A principal limitação mencionada no estudo foi a necessidade de validação adicional com mais dados experimentais. Embora o CTGAN tenha ampliado significativamente o conjunto de dados, a precisão dos modelos ainda depende da qualidade dos dados de entrada. Além disso, variáveis como o tipo de adesivo utilizado não foram incluídas devido à falta de informações detalhadas nos dados experimentais.

Perspetivas Futuras

O estudo sugere que, à medida que mais dados experimentais forem coletados, os modelos desenvolvidos podem ser aprimorados e validados para garantir maior robustez. Futuras pesquisas também podem explorar mais detalhadamente os modos de falha e outras variáveis não abordadas neste estudo, como diferentes tipos de adesivo.

- O estudo realizado por Sheikh Khozani et al. (2020) tem como objetivo principal prever a distribuição de tensões de cisalhamento em canais compostos prismáticos através de diferentes métodos da aprendizagem automática e compará-los com modelos analíticos conhecidos, como o Método de Shiono e Knight (SKM) e o modelo de Shannon. Os autores realizaram experimentos em canais com diferentes larguras de planície de inundação e profundidades de fluxo, tanto em condições subcríticas como supercríticas. Foram aplicados cinco modelos da aprendizagem automática e mineração de dados, nomeadamente Random Forest (RF), M5P, Random Committee

(RC), KStar e Additive Regression (AR), para prever a distribuição de tensões de cisalhamento. Entre esses modelos, o Random Forest (RF) apresentou o melhor desempenho preditivo, com um coeficiente de determinação (R^2) de 0,9. Os resultados mostraram que o Random Forest foi o modelo que apresentou os resultados mais precisos, superando tanto o modelo de SKM quanto o modelo de Shannon. O modelo RF obteve um coeficiente de determinação (R^2) de 0,9003 e um RMSE de 0,0971. As previsões de tensões de cisalhamento nas paredes e no leito do canal foram mais precisas em comparação com os outros métodos. No entanto, o modelo SKM foi mais eficaz na previsão da tensão de cisalhamento no leito do canal principal, enquanto o modelo Shannon demonstrou melhor precisão nas previsões das tensões de cisalhamento nas paredes

. Limitações

Uma limitação identificada foi a dificuldade e o tempo necessário para medir diretamente as tensões de cisalhamento. Além disso, a precisão dos modelos depende da qualidade dos dados experimentais e das condições específicas do canal. Outra limitação é que o modelo SKM não consegue prever a distribuição de tensões nas paredes do canal.

Perspetivas Futuras

Os autores sugerem a aplicação de modelos da aprendizagem automática para prever a distribuição de tensões de cisalhamento em diferentes tipos de canais, incluindo canais não prismáticos. O uso de métodos bayesianos também é proposto para melhorar as previsões dos modelos de regressão e lidar com incertezas nos dados.

- O estudo realizado por Cabrera, Ninic e Tizani (2023) tem como objetivo principal desenvolver um modelo robusto para prever o comportamento de ligações de aço do tipo extended hollo-bolt (EHB), combinando dados experimentais limitados com um extenso conjunto de dados sintéticos gerados por simulações em elementos finitos (FE). O estudo propõe dois métodos híbridos da aprendizagem automática para melhorar a precisão das previsões de resistência, rigidez e deslocamento da face da coluna. A técnica de IA aplicada inclui dois métodos principais de AA: o primeiro é a Data Fusion (DF) com otimização por enxame de partículas (PSO) para combinar dados experimentais e sintéticos antes do treino dos modelos. O segundo é o uso de Artificial Neural Networks (ANN) com fusão de modelos, onde os dados experimentais e sintéticos são utilizados em modelos separados, e suas previsões são posteriormente combinadas. Os resultados mostraram que o modelo de Data Fusion (DF) apresentou o melhor desempenho, com valores de erro quadrático médio (RMSE) de 8% para a resistência da ligação, 6% para a rigidez e 8% para o deslocamento da face da coluna. O modelo baseado em ANN também apresentou resultados promissores, mas

a precisão foi inferior ao modelo DF. A combinação de dados experimentais limitados com um grande conjunto de dados sintéticos mostrou-se eficaz para melhorar a precisão das previsões.

Limitações

Uma das limitações identificadas no estudo foi a dependência dos dados sintéticos gerados por simulações de elementos finitos, que podem introduzir erros numéricos. Além disso, a quantidade limitada de dados experimentais afetou a capacidade de generalização dos modelos, especialmente no método de fusão de modelos.

Perspetivas Futuras

Os autores sugerem que futuros estudos devem expandir o número de dados experimentais para validar e melhorar ainda mais os modelos desenvolvidos. A aplicação de técnicas híbridas pode ser estendida para outros tipos de ligações estruturais e condições de carga.

- O estudo realizado por Gallet et al. (2022) tem como objetivo principal explorar a utilização de metodologias de problemas inversos em diversas subáreas da engenharia estrutural, como a monitorização da saúde estrutural e a avaliação não destrutiva. O artigo visa destacar como as técnicas de problemas inversos podem contribuir para uma análise mais precisa e eficiente de estruturas, permitindo a deteção de falhas e a otimização de projetos. O método de IA aplicado inclui Redes Neurais Profundas (DNNs) e métodos probabilísticos para resolver problemas inversos na engenharia estrutural. Além disso, são aplicadas técnicas como regularização e aproximação de soluções não lineares para lidar com a instabilidade e não unicidade dos problemas inversos. Os resultados indicam que o uso de metodologias de problemas inversos pode fornecer previsões mais robustas sobre o comportamento estrutural, especialmente em contextos de avaliação de falhas. A combinação de técnicas da aprendizagem automática com abordagens tradicionais de engenharia resultou numa maior capacidade de análise de estruturas complexas.

Limitações

As limitações identificadas incluem a complexidade computacional envolvida na resolução de problemas inversos em larga escala, bem como a dificuldade em obter medições precisas e a necessidade de modelos numéricos eficientes para lidar com dados ruidosos ou incompletos.

Perspetivas Futuras

Os autores sugerem que o futuro das metodologias de problemas inversos na engenharia estrutural está fortemente ligado ao desenvolvimento da IA e da aprendizagem automática. A integração dessas tecnologias pode melhorar a capacidade de prever falhas e otimizar projetos estruturais.

- O estudo realizado por Thisovithan et al. (2023) tem como objetivo principal prever o período fundamental de vibração (T) de estruturas de betão armado com preenchimento em alvenaria, utilizando quatro modelos diferentes de AA: Artificial Neural Network (ANN), Support Vector Regression (SVR), K-Nearest Neighbors (KNN) e Random Forest (RF). O estudo também explora o uso de técnicas de inteligência artificial explicável (XAI) para interpretar os modelos e as suas previsões, fornecendo explicações detalhadas sobre a importância das variáveis e as interações entre elas. Foram utilizados quatro modelos de machine learning: ANN, SVR, KNN e RF, combinados com métodos explicáveis de IA, como SHAP (Shapley Additive Explanations), LIME (Local Interpretable Model-Agnostic Explanations) e Partial Dependency Plots (PDP). Estes métodos foram empregados para interpretar os resultados e identificar as variáveis mais importantes nas previsões de T. Os resultados mostraram que todos os modelos previram com precisão o valor de T, destacando-se o Random Forest (RF), que apresentou a maior precisão, com um coeficiente de determinação (R^2) de 0,989. A análise XAI revelou que o número de andares foi a variável mais influente no cálculo de T, seguido pela razão de abertura e pela rigidez das paredes de alvenaria. O estudo também demonstrou que o uso de explicações pós-modelo, como SHAP e LIME, pode aumentar a confiança dos utilizadores nas previsões dos modelos.

Limitações

O estudo identificou que os métodos explicáveis, como LIME e SHAP, podem gerar discrepâncias nas suas explicações, o que sugere a necessidade de mais investigação para melhorar a confiabilidade desses métodos. Além disso, a ausência de parâmetros do solo e outros fatores complexos no conjunto de dados pode limitar a precisão das previsões em condições geotécnicas variáveis.

Perspetivas Futuras

O estudo sugere que futuros trabalhos explorem o uso de métodos da aprendizagem automática mais avançados e a inclusão de mais variáveis no conjunto de dados, como parâmetros geotécnicos, para melhorar a precisão das previsões de T. Além disso, a expansão do uso de XAI em outras áreas da engenharia estrutural é vista como uma área promissora de investigação.

- O estudo realizado por D. Wang et al. (2023) tem como objetivo principal desenvolver um método de pesquisa de arquitetura neural, denominado HKNAS, para a classificação de imagens hiperespectrais (HSI). O estudo propõe a utilização de hyper kernels para gerar parâmetros estruturais e reduzir a complexidade de otimização, melhorando o desempenho da rede em tarefas de classificação a nível de pixel e imagem. A técnica aplicada foi a Neural Architecture Search (NAS), especificamente o método Hyper Kernel NAS (HKNAS). Este método transforma

o problema de otimização de dois níveis, presente em métodos tradicionais de NAS, em um problema de otimização de um nível ao utilizar hyper kernels para gerar os parâmetros estruturais das redes neurais. Foram desenvolvidas três arquiteturas de rede: 1-D HK-CLS, 3-D HK-CLS e 3-D HK-SEG, para classificação de HSI a nível de pixel e imagem, utilizando convoluções 1-D e 3-D. Os resultados mostraram que o método HKNAS superou outros métodos avançados de NAS na tarefa de classificação de HSI, apresentando precisão superior em seis conjuntos de dados públicos. A arquitetura 3-D HK-CLS obteve precisão superior na classificação a nível de pixel, enquanto a 3-D HK-SEG apresentou resultados competitivos na classificação a nível de imagem, com menores tempos de busca e menor complexidade computacional.

Limitações

Uma das limitações do estudo é que, apesar da eficiência do HKNAS em termos de complexidade de pesquisa e precisão, a técnica requer um conjunto de dados significativo para obter modelos robustos. A implementação do método em contextos com poucos dados pode apresentar desafios relacionados à generalização.

Perspetivas Futuras

Os autores sugerem que o método HKNAS pode ser expandido para outras áreas de classificação de imagens e aplicado a redes neurais mais complexas. Além disso, melhorias no uso de hyper kernels podem permitir a integração de outras técnicas de NAS para otimizar a eficiência e precisão em diferentes tipos de dados.

- O estudo realizado por Qiang, Chenyue e Dezhi (2024) tem como objetivo principal desenvolver um modelo baseado em Least Square Support Vector Regression (LSSVR), otimizado por três algoritmos meta-heurísticos — Tunicate Swarm Algorithm (TSA), Equilibrium Optimization (EO) e Turbulent Flow of Water-based Optimization (TFWO) — para prever com precisão a resistência ao cisalhamento não drenado (USS) do solo. O estudo visa superar as limitações dos métodos tradicionais de previsão ao aumentar a precisão e a eficiência computacional. O método aplicado foi o LSSVR combinado com os algoritmos meta-heurísticos TSA, EO e TFWO. Estes métodos foram utilizados para otimizar os parâmetros de entrada que influenciam a USS, como o peso de sobrecarga (OBW), a fricção da luva (SF), o limite líquido (LL) e o limite plástico (PL). A avaliação dos modelos foi feita utilizando métricas estatísticas como RMSE, R^2 , RSR, MDAPE e SMAPE. Os resultados mostraram que o modelo combinado LSSVR + TSA obteve os melhores resultados, com um R^2 de 0,998 e um RMSE de 34,28 no conjunto de treino, superando os outros modelos (LSSVR + EO e LSSVR + TFWO) tanto em precisão quanto em eficiência. A análise

indicou que o modelo LSTS (LSSVR com TSA) tem o menor erro em comparação com os outros modelos, tornando-o o mais eficaz na previsão da USS.

Limitações

As principais limitações incluem a dependência de dados experimentais e a complexidade computacional dos algoritmos de otimização meta-heurística, o que pode afetar a aplicabilidade do modelo em cenários de grande escala ou com dados limitados. Além disso, a precisão dos resultados depende da qualidade dos dados de entrada, que podem variar significativamente.

Perspectivas Futuras

O estudo sugere a aplicação de técnicas híbridas de otimização e IA para melhorar ainda mais a precisão dos modelos em diferentes cenários geotécnicos. Futuros trabalhos também devem explorar a inclusão de mais variáveis para melhorar a capacidade preditiva em condições de solo mais complexas.

- O estudo realizado por M. Naser e Teymori Gharah Tapeh (2023) tem como objetivo principal destacar a importância da descoberta causal e da inferência causal na engenharia civil e estrutural, fornecendo uma estrutura teórica para o uso de algoritmos da aprendizagem automática baseados em causalidade. O estudo visa contrastar a abordagem causal com métodos tradicionais de previsão estatística e apresentar casos práticos de como a causalidade pode ser aplicada em projetos de engenharia. Os métodos de IA aplicados incluem algoritmos de descoberta causal, como o algoritmo de Peter-Clark (PC) e o Fast Greedy Equivalence Search (FGES), que são utilizados para identificar estruturas causais em conjuntos de dados observacionais. Estes algoritmos ajudam a criar grafos acíclicos direcionados (DAGs) para descrever a relação entre variáveis. Além disso, são aplicados métodos de inferência causal para prever os efeitos de intervenções em sistemas estruturais, como o do-calculus de Judea Pearl. Os resultados indicam que a descoberta causal pode ser aplicada com sucesso na engenharia estrutural para identificar estruturas de dados geradores e prever o comportamento de sistemas sob diferentes condições. A aplicação de DAGs e modelos de inferência causal melhorou a compreensão dos mecanismos subjacentes em cenários de falhas estruturais e ajudou a otimizar intervenções. Por exemplo, em um dos casos práticos, foi possível inferir o impacto de um novo sistema de reforço em vigas de betão armado.

Limitações

As principais limitações envolvem a complexidade computacional dos algoritmos de descoberta causal, especialmente quando aplicados a grandes conjuntos de dados ou sistemas estruturais complexos. Além disso, os modelos requerem conhecimento prévio significativo sobre os sistemas analisados para garantir a validade das inferências causais.

Perspetivas Futuras

Futuros estudos devem explorar a integração de causalidade com modelos da aprendizagem automática mais avançados, especialmente para a previsão de falhas estruturais em sistemas complexos. Os autores também sugerem a aplicação de métodos causais em uma ampla gama de problemas de engenharia, como a monitorização da saúde estrutural e a análise de impacto de desastres naturais em infraestruturas.

- O estudo realizado por Y. Zhou et al. (2024) tem como objetivo principal desenvolver um sistema automatizado de ponta a ponta, denominado StructDiffusion, que utiliza modelos de difusão para gerar layouts de paredes de corte com base em plantas arquitetónicas e condições de design textuais. O sistema visa melhorar a eficiência do design estrutural, minimizando a intervenção humana e otimizando o processo de criação de layouts para paredes de corte em edifícios altos. O método aplicado foi um modelo de difusão, que permite a geração de imagens de layouts estruturais condicionadas por imagens arquitetónicas e parâmetros de design, como altura do edifício e intensidade sísmica. O modelo utiliza ControlNet para controlar o processo de geração com base em entradas textuais e LoRA (Low-Rank Adaptation) para melhorar a eficiência do treino com dados limitados. A arquitetura inclui o uso do modelo UNet para capturar detalhes locais e contextos globais durante a geração das imagens. Os resultados experimentais demonstraram que o StructDiffusion supera abordagens baseadas em GANs (Generative Adversarial Networks), gerando layouts que são visualmente e estruturalmente mais válidos. O sistema conseguiu produzir layouts de paredes de corte que atendem aos requisitos de código de design estrutural, com uma relação de erro relativa em torno de 2% a 9% em comparação com designs humanos. O modelo também apresentou melhorias significativas em termos de eficiência computacional, reduzindo o tempo de treino em até 80

Limitações

As limitações identificadas incluem a capacidade limitada de fornecer controlos detalhados sobre o layout gerado, uma vez que as condições textuais usadas são relativamente simples (por exemplo, altura do edifício e intensidade sísmica). Além disso, o sistema ainda depende de conjuntos de dados limitados para treino, o que pode restringir a sua generalização em condições mais complexas.

Perspetivas Futuras

Os autores sugerem que estudos futuros devem explorar a integração de condições de design mais complexas e detalhadas, bem como expandir a utilização do StructDiffusion para outros tipos de projetos estruturais. A inclusão de controlos textuais mais avançados permitirá uma personalização mais precisa dos layouts gerados.

- O estudo realizado por G. Zhang et al. (2022) tem como objetivo principal desenvolver um modelo híbrido de inteligência artificial que combina Support Vector Regression (SVR) com um algoritmo genético (GA) para prever a resistência ao corte de vigas profundas de betão armado. O estudo visa melhorar a precisão da previsão utilizando parâmetros dimensionais, mecânicos e de material. O método aplicado foi a regressão por vetores de suporte (SVR), combinada com um algoritmo genético (GA), para otimizar a seleção de parâmetros e aumentar a precisão do modelo preditivo. Além disso, o estudo compara o desempenho deste modelo híbrido com outros modelos de IA clássicos, como redes neurais artificiais (ANN) e árvores de decisão com aumento de gradiente (GBDTs). Os resultados mostraram que o modelo híbrido SVR-GA superou outros modelos comparativos, obtendo um coeficiente de determinação (R^2) de 0,958 durante a fase de teste, em comparação com valores entre 0,884 e 0,941 para os outros modelos. O SVR-GA apresentou a melhor capacidade preditiva, mostrando resultados próximos dos experimentais, e demonstrou ser uma ferramenta robusta para a previsão da resistência ao corte de vigas de betão armado.

Limitações

O estudo identifica que, apesar da precisão do modelo SVR-GA, a complexidade dos cálculos e a necessidade de otimização contínua dos parâmetros podem limitar a sua aplicação em contextos práticos de grande escala. Além disso, a precisão do modelo depende da qualidade e da quantidade dos dados de entrada disponíveis.

Perspetivas Futuras

Os autores sugerem que futuras pesquisas devem explorar a integração de outros algoritmos bio-inspirados com métodos de inteligência artificial, bem como a aplicação desta metodologia a outros tipos de estruturas e parâmetros mecânicos para melhorar ainda mais a precisão e a eficiência das previsões.

- O estudo realizado por Kazemi, Shafighfard e Yoo (2024) tem como objetivo fornecer uma revisão crítica das técnicas da aprendizagem automática aplicadas à modelação das propriedades mecânicas do betão armado com fibras (FRC). O artigo discute as diversas propriedades mecânicas do FRC, como a resistência à compressão, à flexão e à tração, e analisa as técnicas de inteligência artificial que foram utilizadas para prever essas propriedades com maior precisão, comparando diferentes algoritmos. O método de IA aplicado no artigo revisa o uso de múltiplos algoritmos da aprendizagem automática para prever as propriedades mecânicas do FRC. Entre os métodos revisados estão Redes Neurais Artificiais (RNA), Support Vector Regression (SVR), Random Forest (RF), Gradient Boosting Machine (GBM) e XGBoost. O estudo também discute o uso de técnicas como otimização de hiperparâmetros e análise de sensibilidade para melhorar a precisão

dos modelos preditivos. Os resultados da revisão indicam que técnicas baseadas em Redes Neurais e Árvores de Decisão (como RF e XGBoost) são altamente eficazes na previsão das propriedades mecânicas do FRC. Em particular, a combinação de RNA com algoritmos de otimização, como o Algoritmo Genético (GA), apresentou excelentes resultados na modelação de resistência à compressão e à flexão, com coeficientes de determinação (R^2) que variam de 0,91 a 0,98 em diferentes estudos. O estudo também identifica que a adição de fibras, como as de aço, vidro e polipropileno, tem impactos significativos nas previsões das propriedades mecânicas.

Limitações

As principais limitações incluem a disponibilidade limitada de grandes conjuntos de dados experimentais para treinar os modelos de machine learning, o que pode afetar a generalização dos resultados. Além disso, a complexidade de ajustar e otimizar os modelos para diferentes tipos de FRC representa um desafio significativo.

Perspetivas Futuras

O artigo sugere que futuras pesquisas devem focar-se em expandir o uso de métodos híbridos que combinem diferentes técnicas da aprendizagem automática com métodos baseados em física, para melhorar ainda mais a precisão e aplicabilidade dos modelos. Além disso, a integração de mais variáveis relacionadas à composição do FRC e ao ambiente de cura pode aumentar a robustez dos modelos preditivos.

- O estudo realizado por Málaga-Chuquitaype (2022) tem como objetivo realizar uma revisão crítica sobre as técnicas da aprendizagem automática aplicadas ao design estrutural. O artigo discute os desafios enfrentados na aplicação de inteligência artificial (IA) e aprendizagem automática para a automação e otimização do design de estruturas, propondo soluções mais eficientes e explorando alternativas criativas no espaço de design. O método de IA aplicado no estudo abrange uma vasta gama de técnicas de machine learning, incluindo redes neurais artificiais (RNA), algoritmos de otimização e aprendizagem por reforço. Estas metodologias são utilizadas para otimizar diferentes aspectos do design estrutural. O artigo enfatiza a capacidade das redes neurais de processar dados complexos e encontrar padrões, permitindo a automação de tarefas de design que antes dependiam da intuição e julgamento humanos. Os resultados obtidos revelam que os algoritmos da aprendizagem automática são eficazes na exploração de espaços de design complexos, descobrindo relações subjacentes entre variáveis de entrada e saídas desejadas que seriam difíceis de detectar pelos humanos. Além disso, o aprendizagem automática permite a diversificação das soluções propostas, indo além das limitações do design tradicional. Contudo, são necessários grandes

volumes de dados de treino para garantir a eficácia dos modelos.

Limitações

As principais limitações incluem a necessidade de grandes quantidades de dados para treinar os modelos de machine learning, o que nem sempre está disponível no campo da engenharia estrutural. Além disso, o desafio da interpretabilidade dos modelos de IA, especialmente quando as decisões não são facilmente explicáveis, representa uma barreira para a sua adoção ampla.

Perspetivas Futuras

O autor sugere que, no futuro, as soluções de design assistidas por IA podem colaborar com os engenheiros, permitindo uma combinação entre intuição humana e análise automatizada. O estudo também destaca a necessidade de melhoria dos modelos da aprendizagem automática e de compartilhar bases de dados de designs reais para facilitar o treino de algoritmos mais robustos.

- O estudo realizado por Rezasefat e Hogan (2023) tem como objetivo desenvolver um modelo de substituição baseado em elementos finitos e redes neurais convolucionais (FE-CNN) para prever a distribuição de tensões em torno de inclusões arbitrárias em materiais. Este trabalho visa facilitar a análise de concentrações de tensões e o comportamento de materiais em cenários de inclusão complexa. O método de IA aplicado no estudo utiliza uma arquitetura de rede neural convolucional chamada U-Net. A CNN foi treinada com um conjunto de dados gerado a partir de simulações de elementos finitos, permitindo a previsão da distribuição de tensões em campo completo, sem a necessidade de converter os dados de tensão em formato de imagem. Esta abordagem oferece uma representação direta e eficiente dos dados de entrada. Os resultados obtidos mostram que o modelo FE-CNN foi capaz de prever com precisão a concentração de tensões ao redor de inclusões de várias formas e tamanhos. O aumento do tamanho do conjunto de dados levou a uma melhoria significativa na precisão do modelo, com análises de sensibilidade indicando que maiores resoluções resultaram em previsões mais precisas, com valores de correlação acima de 0,95. Além disso, o tempo de previsão foi significativamente reduzido em comparação com simulações tradicionais de elementos finitos.

Perspetivas Futuras

As limitações identificadas incluem a dificuldade do modelo em generalizar para dados fora do intervalo de treino, especialmente em cenários com inclusões múltiplas ou com características não consideradas no conjunto de treino. Foi observada uma maior margem de erro nas fronteiras das inclusões, onde ocorrem concentrações de tensões mais elevadas.

Limitações

Os autores sugerem que futuras pesquisas explorem a aplicação do modelo FE-CNN em outros contextos de análise estrutural, incluindo materiais fabricados por manufatura aditiva e ensaios não destrutivos. O desenvolvimento de modelos que consigam extrapolar para estruturas mais complexas, como inclusões múltiplas, é também uma área promissora para estudos futuros.

- O estudo realizado por Feng e Wei (2023) tem como objetivo desenvolver um modelo baseado em Redes Neurais Informadas por Dados Físicos (PINN) para resolver problemas de encurvadura em estruturas de paredes finas. A abordagem proposta visa superar a dependência de métodos numéricos tradicionais, como o Método dos Elementos Finitos (FEA), que exigem uma malha computacional detalhada para o domínio de cálculo. O método de IA aplicado utiliza as Redes Neurais Informadas por Física (PINNs), que integram o conhecimento físico dos problemas de encurvadura não linear com redes neurais profundas. O modelo de PINN é empregado para resolver equações diferenciais parciais (PDEs) que descrevem os problemas de encurvadura e foi otimizado com técnicas como a função de ativação auto-adaptativa e o método do comprimento de arco para controle iterativo. Os resultados obtidos mostram que o método de PINN foi eficaz na análise de modos de encurvadura e pós-encurvadura de estruturas de paredes finas, incluindo comparações com o método de elementos finitos (FEA). Embora o PINN tenha demonstrado precisão comparável ao FEA, a convergência foi mais lenta, mas o método ofereceu a vantagem de não requerer malha de domínio pré-processada.

Limitações

As limitações incluem o tempo de convergência mais lento em comparação com métodos maduros, como o FEA, e a necessidade de melhorias na eficiência computacional. Além disso, a abordagem ainda está na fase inicial de aplicação prática em grandes sistemas estruturais.

Perspetivas Futuras

Futuras investigações sugerem a aplicação de PINNs em problemas mais complexos de encurvadura e pós-encurvadura, com melhorias na eficiência computacional e integração de dados de sensores estruturais para aplicações em tempo real.

- O estudo realizado por Hussein, Mohammed e Elwi (2022) tem como objetivo analisar a eficácia da estrutura de um edifício alto, com 19 andares, sob a presença ou ausência de paredes de corte para resistir a cargas dinâmicas, como vento e sismos. A investigação procura determinar a melhor configuração das paredes de corte em termos de forma e localização, avaliando momentos, forças laterais, cargas verticais e momentos de torção em diferentes pisos. O método de IA aplicado consiste na otimização do design estrutural utilizando o software SAP2000 para analisar a resposta

da estrutura às cargas dinâmicas. Uma Rede Neural Artificial (ANN) foi utilizada para melhorar o design da estrutura de betão armado, otimizando parâmetros como profundidade, largura e área de reforço de aço, de acordo com o Código ACI-318-08. Foram criados quatro modelos diferentes da estrutura, variando a localização das paredes de corte para testar a sua eficácia sob diferentes zonas sísmicas (UBC-97). Os resultados obtidos demonstraram que, quando as paredes de corte foram colocadas próximas ao centro geométrico da estrutura, houve uma diminuição significativa no deslocamento máximo, momento fletor, forças horizontais e momentos de torção. A redistribuição das paredes de corte ao longo das faces do edifício também resultou em melhor desempenho, embora menos eficaz do que a localização central. O estudo conclui que as paredes de corte oferecem um aumento na rigidez estrutural, diminuindo os deslocamentos em até seis vezes, dependendo da zona sísmica.

Limitações

As limitações incluem o foco em uma única tipologia de edifício e a dependência do software SAP2000 para a modelação, que pode não capturar todas as variações comportamentais possíveis. Além disso, a análise é limitada à rigidez e resistência a cargas dinâmicas em edifícios altos, não explorando outros fatores, como o impacto de cargas térmicas ou variações no tipo de material.

Perspetivas Futuras

Sugere-se que investigações futuras expandam o estudo para incluir uma maior variedade de tipologias de edifícios e cargas, como cargas térmicas. A integração de outros métodos de IA, como redes neurais profundas, poderia ser explorada para melhorar a precisão das previsões de desempenho estrutural sob cargas dinâmicas complexas.

- O estudo realizado por Pan et al. (2024) tem como objetivo apresentar uma nova abordagem de extração de atributos de edifícios utilizando grandes modelos de visão e linguagem, como CLIP e SAM, em um workflow zero-shot. A intenção é eliminar a necessidade de rotulação humanas, essenciais nos métodos supervisionados, para extrair atributos como número de andares, tipo de telhado e outros elementos estruturais a partir de imagens de satélite e street view. O método de IA aplicado utiliza dois grandes modelos da aprendizagem automática: CLIP, para associar imagens a texto, e SAM, para a segmentação de imagens. O workflow zero-shot desenvolvido combina a legenda de nível de imagem com a legenda de nível de segmento, permitindo uma descrição precisa dos atributos dos edifícios. O modelo é capaz de generalizar para novas áreas e tipos de edifícios sem necessitar de anotações manuais, o que aumenta a sua eficiência e escalabilidade. Os resultados obtidos demonstram que a abordagem zero-shot proposta é robusta e versátil, permitindo

uma extração eficiente de atributos de edifícios em áreas e estilos de construção não previamente treinados. Comparado com métodos anteriores que dependem de anotações manuais extensivas, o modelo proposto mostra-se mais eficiente e escalável, embora com uma ligeira perda de precisão em relação a métodos supervisionados, especialmente em tarefas específicas como a classificação de tipo de telhado.

Limitações

Apesar do sucesso da abordagem zero-shot, existe uma ligeira diferença de precisão em relação a modelos supervisionados em tarefas de classificação, como a de tipos de telhado. Além disso, a extração de atributos em edifícios mais complexos ou de tipologias menos comuns pode apresentar desafios adicionais que exigem melhorias futuras nos modelos.

Perspetivas Futuras

O artigo sugere que futuros trabalhos devem focar-se em melhorar a generalização dos modelos em edifícios com tipologias únicas ou regiões não vistas durante o treino. O desenvolvimento de modelos especializados para áreas de engenharia estrutural também pode ser um caminho promissor para melhorar a precisão da extração de atributos.

- O estudo realizado por Pizarro, Massone, et al. (2021) tem como objetivo propor o uso de redes neurais convolucionais (CNNs) para automatizar o design conceptual de edifícios com paredes de cisalhamento. A principal intenção é reduzir o tempo e o esforço exigidos na interação entre arquitetos e engenheiros estruturais ao prever automaticamente a espessura, comprimento e localização das paredes estruturais baseadas em dados arquitetónicos. O método de IA aplicado envolve o desenvolvimento de dois modelos de CNN para prever os parâmetros de engenharia das paredes e gerar uma planta estrutural de engenharia a partir de uma planta arquitetónica. Um dos modelos prevê a espessura, o comprimento e a translação das paredes, enquanto o outro gera imagens prováveis da planta final com base em dados arquitetónicos. Ambos os modelos são combinados para criar uma planta de engenharia que propõe novos elementos estruturais e otimiza a distribuição das paredes. Os resultados obtidos incluem a análise de 165 projetos de edifícios residenciais chilenos. O modelo previu com precisão a espessura e o comprimento das paredes, com coeficientes de determinação (R^2) de 0,994 e 0,995, respetivamente. A interseção sobre a união (IoU) média foi de 0,627, sugerindo uma boa correspondência entre as plantas arquitetónicas e as plantas estruturais geradas. A principal vantagem foi a capacidade do modelo de sugerir novos elementos estruturais, melhorando a eficiência e reduzindo o tempo de interação entre as equipas de design.

Limitações

A limitação principal é que os modelos foram treinados com dados de edifícios chilenos, o que pode restringir a sua aplicação em outros contextos. Além disso, a qualidade dos resultados depende da precisão das imagens fornecidas e dos dados de treino. O modelo pode necessitar de ajustes adicionais ao lidar com configurações estruturais mais complexas ou diferentes materiais.

Perspetivas Futuras

Sugere-se que futuros estudos expandam a base de dados para incluir diferentes tipos de edifícios e restrições arquitectónicas. A integração da técnica com software de projeto estrutural pode aumentar a sua aplicabilidade na indústria da construção. O impacto dos novos elementos sugeridos no comportamento estrutural, especialmente em termos de resistência sísmica, também deve ser explorado.

- O estudo realizado por Kareem (2020) tem como objetivo apresentar os avanços recentes em casos de ações do vento, implementando as novas tecnologias computacionais, incluindo dinâmica de fluidos computacional (CFD), modelação estocástica e aprendizagem automática. O artigo aborda as complexidades dos efeitos do vento em estruturas, que incluem fenómenos não-lineares, não-Gaussianos e não-estacionários, utilizando novas ferramentas computacionais para melhorar a segurança e o desempenho das infraestruturas civis. O método de IA aplicado destaca o uso da aprendizagem automática e redes neurais Bayesianas para analisar dados de tempo e prever comportamentos dinâmicos de estruturas sob cargas de vento. Técnicas como a decomposição dinâmica de modos (DMD) são utilizadas para capturar padrões e modelos a partir dos dados gerados pelos ventos. Adicionalmente, técnicas de análise de séries temporais, como "shapelets", são introduzidas para a classificação de sinais de vento. Os resultados obtidos demonstram que a combinação de técnicas computacionais avançadas com aprendizagem automática pode melhorar significativamente a precisão das previsões dos efeitos do vento em estruturas, superando métodos convencionais. As simulações apresentadas mostraram ser eficazes na previsão de pressões dinâmicas e comportamentos aerodinâmicos complexos em estruturas expostas a ventos extremos.

Limitações

O estudo reconhece as limitações associadas aos elevados requisitos computacionais para implementar CFD e outras técnicas de simulação de alta fidelidade, como a modelação de grandes redemoinhos (LES). Além disso, a disponibilidade limitada de dados experimentais para validação dos modelos também é uma limitação significativa.

Perspetivas Futuras

O artigo sugere que futuras investigações devem explorar a integração da aprendizagem automática com simulações numéricas de alta fidelidade para reduzir a carga computacional e melhorar a eficiência dos modelos preditivos. O uso de sistemas ciberfísicos para monitorização em tempo real de estruturas expostas ao vento é outro campo promissor a ser desenvolvido.

- O estudo realizado por Roh et al. (2024) tem como objetivo desenvolver um modelo de gêmeo digital para prever a capacidade última de resistência ao corte e a capacidade de deformação de conectores de corte de pinos em estruturas compósitas. A proposta visa superar as limitações dos códigos de design tradicionais, que frequentemente se baseiam em equações empíricas, proporcionando uma solução mais precisa e eficiente para a conceção estrutural, ao incorporar previsões de força última e deslocamento com base em parâmetros geométricos e materiais. O método de IA aplicado consiste em um modelo AutoML, desenvolvido através da biblioteca PyCaret, que automatiza o processo de seleção e otimização de modelos de machine learning. Este modelo utiliza uma combinação de dados experimentais e resultados de simulações de elementos finitos para prever a resistência ao corte. Foram implementados modelos de árvores de decisão, como CatBoost, XGBoost, Random Forest e LightGBM, com o objetivo de prever a força última dos conectores de corte. Para reduzir o sobreajuste e melhorar a precisão, foi adotado um mecanismo de votação entre os melhores modelos. Os resultados obtidos demonstraram que o modelo baseado em AutoML foi capaz de prever com precisão a resistência ao corte e o deslizamento último dos conectores de corte. O modelo CatBoost apresentou o melhor desempenho, alcançando uma precisão de $R^2 = 0.987$ no conjunto de treino e $R^2 = 0.948$ no conjunto de teste. A utilização de dados aumentados através da integração com a FEA melhorou a capacidade preditiva do modelo em cenários com dados limitados ou tendenciosos. As análises de SHAP indicaram que o diâmetro dos pinos e a espessura da laje de betão foram os fatores mais influentes para a previsão de resistência ao corte.

Limitações

O estudo destaca a necessidade de conjuntos de dados mais amplos e diversificados para melhorar a capacidade de generalização do modelo, especialmente em relação a materiais de alta resistência e pinos de diâmetro maior. Outro desafio está relacionado à quantidade de dados necessários para treinar os modelos da aprendizagem automática de forma eficaz, sendo a coleta de dados experimentais um processo dispendioso e moroso. Além disso, a aplicabilidade prática do modelo ainda requer validação adicional em cenários de engenharia real.

Perspetivas Futuras

Os autores sugerem que o modelo pode ser expandido para outras aplicações de engenharia estrutural, incluindo a previsão de falhas em diferentes tipos de ligações estruturais. Futuras investigações também devem focar na integração de dados de monitorização de campo em tempo real no modelo de gêmeo digital, permitindo uma atualização contínua das previsões à medida que novos dados são recolhidos.

- O estudo realizado por Uddin et al. (2023) tem como objetivo explorar a aplicação de redes neuronais informadas por física (PINNs) com funções de ativação baseadas em wavelets para a solução de equações diferenciais não lineares, abordando especificamente problemas em dinâmica de fluidos, como o famoso problema de Blasius. O método de IA aplicado consiste na utilização de PINNs, que integram o conhecimento físico na função de perda da rede neural, garantindo que a solução respeite as leis físicas governantes. Este artigo distingue-se por empregar três funções wavelet (Morlet, chapéu mexicano e Gaussian) como funções de ativação nas PINNs. Foram investigadas variações no número de camadas ocultas, neurónios e pontos de colocação para determinar a configuração ideal da rede, utilizando a técnica Adam para otimização e inicialização Xavier para os parâmetros da rede. Os resultados demonstraram que as PINNs com ativação baseada em wavelets superaram as redes que utilizam funções de ativação convencionais. A wavelet chapéu mexicano apresentou os melhores resultados em termos de erro L^2 relativo para a equação de Blasius, enquanto a wavelet Gaussiana mostrou-se mais eficiente na resolução de equações diferenciais acopladas. O estudo concluiu que o uso de wavelets melhorou a generalização e a precisão da rede em comparação com métodos existentes, como o método Galerkin de wavelets.

Limitações

O artigo ressalta que, apesar das melhorias na precisão proporcionadas pelas funções de ativação baseadas em wavelets, a complexidade computacional aumentou, especialmente em problemas de equações diferenciais acopladas. A abordagem ainda necessita de validação em problemas mais complexos com um maior número de variáveis físicas.

Perspetivas Futuras

Os autores sugerem que futuros trabalhos devem focar na aplicação das PINNs com wavelets a problemas de transferência de calor e massa em contextos industriais, além de explorar novas funções de ativação para melhorar o desempenho das redes neuronais em cenários mais complexos. Outra linha de pesquisa indicada é a combinação de PINNs com outros métodos da aprendizagem automática para aumentar a eficiência do processo de treino e previsão.

5.5 Avaliação de Risco e Segurança Estrutural

A avaliação de risco e a segurança estrutural têm sido uma preocupação central na engenharia civil, especialmente no contexto de infraestruturas críticas, como pontes, edifícios altos, barragens e redes de transporte. Tradicionalmente, a avaliação de risco estrutural baseava-se em métodos probabilísticos clássicos, como a Teoria de Fiabilidade e a Análise de Árvores de Falhas. Estas técnicas permitiam avaliar a probabilidade de falhas estruturais, considerando incertezas nos parâmetros de projeto, como resistência dos materiais, cargas aplicadas e fatores ambientais. No entanto, à medida que as infraestruturas se tornaram mais complexas e os riscos associados ao seu desempenho aumentaram, essas abordagens tradicionais mostraram-se limitadas na capacidade de capturar a variabilidade e a complexidade das condições reais.

Nos anos 1990, surgiram novas técnicas baseadas em simulação, como a Simulação de Monte Carlo, que permitiram melhorar a avaliação de risco, ao gerar cenários aleatórios de carga e resistência e avaliar o desempenho estrutural com base nesses cenários. No entanto, o elevado custo computacional dessas técnicas, especialmente em grandes infraestruturas, continuou a ser uma limitação significativa.

A partir da década de 2000, o uso de inteligência artificial (IA) e aprendizagem automática (ML) começou a emergir como uma alternativa promissora para melhorar a avaliação de risco e segurança estrutural. Melchers (1999) foi um dos primeiros a sugerir a utilização de redes neurais artificiais (RNA) para prever o desempenho estrutural sob condições de incerteza, integrando dados de sensores e monitorização contínua em modelos probabilísticos. Esse trabalho pioneiro abriu caminho para a aplicação mais ampla de IA na avaliação de risco, permitindo que engenheiros modelassem cenários complexos de risco e desenvolvessem estratégias de mitigação com base em dados reais.

Durante a última década, a proliferação de sensores inteligentes instalados em infraestruturas permitiu que grandes volumes de dados fossem recolhidos em tempo real, fornecendo uma nova fonte de informação para a avaliação de risco. Esses dados têm sido integrados com técnicas de IA, como redes neurais profundas (DNN) e algoritmos da aprendizagem reforçada, para prever falhas estruturais e desenvolver modelos baseados em fiabilidade que permitem avaliações de risco mais precisas e dinâmicas. Huang e Lu (2016) foram pioneiros no uso de IA para integrar dados de monitorização sísmica em avaliações probabilísticas de risco estrutural, criando modelos de risco que podiam ser ajustados em tempo real com base nas condições ambientais e estruturais.

5.5.1 Análise dos Estudos

- O estudo realizado por Hason et al. (2022) tem como objetivo desenvolver novos modelos para prever a aceleração máxima do solo (PGA) utilizando duas técnicas de otimização meta-heurísticas: redes neurais artificiais (ANN) combinadas com o Algoritmo de Busca Gravitacional (GSA) e a Metodologia de Superfície de Resposta (RSM). O artigo foca na necessidade de previsões precisas de PGA para a avaliação sísmica na região tectônica do Iraque, sendo o primeiro estudo desse tipo na área. O método de IA aplicado envolve uma combinação de ANN e GSA para prever a PGA, baseado em um conjunto de dados que inclui 187 registros de movimentos sísmicos. A ANN é utilizada para modelar as relações complexas entre os parâmetros sísmicos e a PGA, enquanto o GSA otimiza a seleção dos parâmetros das ANN, melhorando a precisão das previsões. A RSM foi aplicada como método comparativo para analisar a interação entre os parâmetros e a PGA. Os resultados demonstraram que o modelo ANN-GSA teve um desempenho superior em relação ao RSM, apresentando menores coeficientes de variância e erros absolutos, com uma alta correlação com os valores reais de PGA. O modelo ANN-GSA obteve uma precisão elevada, com um erro percentual médio inferior a 10%, enquanto a RSM apresentou uma precisão ligeiramente inferior.

Limitações

As principais limitações incluem a necessidade de grandes volumes de dados para treinar adequadamente o modelo ANN-GSA, e a sensibilidade do modelo à qualidade dos dados sísmicos disponíveis, o que pode limitar sua aplicabilidade em áreas com poucos dados históricos.

Perspetivas Futuras

Os autores sugerem que futuros estudos devem desenvolver modelos mais robustos que integrem diferentes técnicas de otimização e aprendizagem de máquina para melhorar ainda mais a precisão das previsões. Também recomendam a aplicação da metodologia em outras regiões sísmicas para validar a generalização dos modelos.

- O estudo realizado por S.-Z. Chen et al. (2022) tem como objetivo investigar o uso do algoritmo Natural Gradient Boosting (NGBoost) para prever respostas estruturais e infraestruturais, considerando a incerteza nos dados de treino e teste. O foco é melhorar as capacidades preditivas dos modelos de machine learning, proporcionando previsões probabilísticas e quantificando a incerteza, o que é essencial para a avaliação de riscos e a concepção de estruturas baseadas na performance. O método de IA aplicado foi o Natural Gradient Boosting (NGBoost), que é uma variante do gradient boosting tradicional, projetada para gerar previsões probabilísticas em vez de valores determinísticos. O NGBoost substitui o gradiente numérico convencional pelo gradiente natural,

permitindo a produção de distribuições de probabilidade para as previsões. O estudo aplicou este método em dois cenários: (1) previsão de resistência de paredes de cisalhamento de betão armado (RC squat) e (2) classificação dos níveis de dano sísmico em pontes. Os resultados mostraram que o NGBoost oferece uma precisão de previsão comparável a outros algoritmos de machine learning, enquanto fornece uma estimativa robusta da incerteza. No caso da previsão de resistência de paredes de cisalhamento, o modelo NGBoost atingiu um coeficiente de determinação (R^2) superior a 0,99 no conjunto de treino e 0,96 no conjunto de teste, com um erro médio quadrático (RMSE) de até 120 kN no teste. Na classificação de danos em pontes, o NGBoost obteve uma precisão de 81% no conjunto de teste, demonstrando sua eficácia em prever níveis de dano sísmico.

Limitações

Uma das limitações do estudo foi a complexidade adicional introduzida pela necessidade de seleccionar a distribuição de probabilidade adequada para cada tipo de previsão. Além disso, a implementação do NGBoost requer um processamento computacional mais elevado devido à optimização de múltiplos parâmetros e à complexidade dos cálculos probabilísticos.

Perspetivas Futuras

Os autores sugerem que o NGBoost pode ser aplicado a outros problemas de engenharia estrutural e infraestrutural, com ênfase em cenários onde a quantificação da incerteza é crucial. A integração do NGBoost com outras técnicas da aprendizagem automática e sua aplicação em escala regional para a avaliação de riscos e danos são áreas promissoras para investigações futuras.

- O estudo realizado por Lamouri, El Mkhalet e Lamdouar (2024b) tem como objetivo aplicar a simulação de Monte Carlo para modelar a resistência de secções transversais de betão armado e realizar uma análise de confiabilidade estrutural de vigas de pontes de betão, em conformidade com a norma EUROCODE 2. O trabalho explora a aplicação da simulação de Monte Carlo para lidar com as incertezas presentes nas propriedades geométricas e dos materiais de construção. O método utilizado foi a Simulação de Monte Carlo, que emprega amostragem aleatória para modelar as distribuições probabilísticas das variáveis geométricas e dos materiais. A simulação foi realizada para calcular as resistências ao momento fletor e ao esforço cortante, considerando as variáveis tratadas como determinísticas e aleatórias. O estudo também menciona a integração da simulação de Monte Carlo com redes neurais artificiais em contextos de análise de confiabilidade estrutural, sugerindo a ligação entre aprendizagem automática e simulações probabilísticas. Os resultados da simulação de Monte Carlo indicaram que a resistência ao momento fletor apresenta uma distribuição normal com um valor médio de 146,27 kN.m e um desvio padrão de 11,25. A

resistência ao esforço cortante segue uma distribuição lognormal, com uma média de 284,66 kN.m e um desvio padrão de 50,49. A probabilidade de falha estrutural foi estimada em aproximadamente 62% para o exemplo de viga analisado, demonstrando a eficácia da simulação na quantificação da confiabilidade estrutural.

Limitações

As principais limitações deste estudo estão relacionadas ao custo computacional elevado da simulação de Monte Carlo, especialmente para um número grande de iterações, e à dependência de modelos probabilísticos adequados para representar as variáveis envolvidas. A precisão dos resultados depende da quantidade de simulações realizadas e da escolha correta das distribuições probabilísticas.

Perspetivas Futuras

Os autores sugerem o uso de técnicas complementares, como algoritmos genéticos e lógica fuzzy, para melhorar a eficiência da simulação e otimizar o processo de design estrutural com base na confiabilidade. Além disso, a aplicação da simulação de Monte Carlo em outros tipos de estruturas e cenários de carregamento dinâmico é recomendada como um campo promissor para futuras investigações.

- O estudo realizado por Vasugi, Santhi e Malathi (2024) tem como objetivo principal desenvolver e aplicar técnicas da aprendizagem automática para avaliar o risco sísmico e os danos em edifícios de betão armado (RC) de vários andares. A análise concentra-se na utilização de dados de respostas dinâmicas, como o deslocamento e o cisalhamento na base, para classificar os níveis de danos sísmicos e otimizar o projeto estrutural com base nas características de capacidade e demanda dos edifícios. O método utilizado incluiu algoritmos simples da aprendizagem automática para classificar os níveis de danos sísmicos, baseando-se em índices de fiabilidade e parâmetros de resposta estrutural. As técnicas de ML foram aplicadas a dados gerados por análises modais e de time-history usando o software ETABS, com dados sísmicos do terramoto de El Centro escalados de 0,1 a 1,0 g. Os resultados mostraram que o uso de ML foi eficaz para classificar os estados de danos sísmicos, variando de operacional a colapso parcial ou total, com base em índices de fiabilidade e na resposta estrutural. O estudo concluiu que o edifício de 9 andares modelado poderia suportar um sismo com uma PGA (aceleração de pico no solo) de até 0,4 g com segurança. A análise de pushover indicou que cerca de 75% das articulações formadas estavam dentro da faixa elástica, e 0,5% estavam além do estado de prevenção de colapso, sugerindo a necessidade de reforçar os andares inferiores.

Limitações As limitações do estudo incluem a dependência de análises numéricas e modelos simplificados, que podem não capturar todas as nuances do comportamento estrutural em condições reais. Além disso, a

precisão das previsões depende da qualidade dos dados de entrada utilizados no treino dos algoritmos de machine learning.

Perspetivas Futuras

Os autores recomendam expandir a metodologia de avaliação de danos sísmicos usando ML para outros tipos de estruturas e edifícios existentes. Futuras investigações também podem explorar algoritmos de aprendizagem automática mais avançados e o uso de grandes bases de dados para melhorar a precisão e a robustez das previsões de danos.

- O estudo realizado por Lamouri, El Mkhalet e Lamdouar (2024a) tem como objetivo principal desenvolver um modelo baseado em redes neuronais artificiais para prever a probabilidade de falha de vigas de pontes de betão pré-esforçado, com foco na avaliação da confiabilidade estrutural. A abordagem combina técnicas de RNA com o Método de Confiabilidade de Primeira Ordem (FORM) para estimar o risco de falhas estruturais, concentrando-se no critério de falha por flexão. O método utilizado foi uma Rede Neural Artificial (RNA), que previu as tensões de flexão das vigas e avaliou a confiabilidade através do Método de Confiabilidade de Primeira Ordem (FORM). A rede neural foi treinada com dados de projetos de pontes obtidos de escritórios técnicos e empresas de construção em Marrocos. Além disso, foram empregadas técnicas de simulação, como a simulação de Monte Carlo, para aumentar a base de dados e melhorar a precisão do modelo preditivo. Os resultados mostraram que o modelo baseado em RNA conseguiu prever as tensões de flexão com um coeficiente de determinação (R^2) de 0,9604. A aplicação do FORM indicou uma convergência do índice de confiabilidade de 6,53, correspondendo a uma probabilidade de falha de $3,3327e-11$. Esses resultados sugerem que o dimensionamento das vigas se encontra dentro do domínio de segurança, apresentando uma baixa probabilidade de falha segundo o critério de tensões admissíveis.

Limitações

As limitações do estudo incluem a necessidade de grandes volumes de dados de projeto para treinar a RNA com precisão, o que pode ser desafiador devido à confidencialidade dos dados. Além disso, o ajuste da arquitetura da rede neural pode ser demorado, exigindo várias iterações para minimizar o erro quadrático médio e obter um ajuste adequado aos dados.

Perspetivas Futuras

Os autores sugerem que o modelo de RNA pode ser aplicado em conjunto com algoritmos genéticos para otimização do design estrutural, visando melhorar ainda mais a confiabilidade com base no critério de falha preditiva. Futuras pesquisas devem explorar a integração de mais variáveis e cenários de carga para

aumentar a robustez do modelo.

- O estudo realizado por X. Wang et al. (2022) tem como objetivo principal realizar uma revisão abrangente das metodologias da aprendizagem automática aplicadas à avaliação de risco e resiliência de infraestruturas estruturais. O artigo examina o estado da arte, os desafios atuais e os avanços no uso de técnicas da aprendizagem automática para avaliar o desempenho de edifícios, pontes, pipelines e sistemas de energia elétrica em face de eventos de risco. O método aplicado abrange uma variedade de técnicas de machine learning, incluindo redes neurais artificiais (ANN), florestas aleatórias (RF), redes neurais profundas (DNN) e redes de reforço profundo (deep reinforcement learning - DRL). Estas técnicas foram utilizadas em diferentes módulos da avaliação de risco e resiliência, como a previsão de resposta, modelação de capacidade e avaliação de fragilidade e danos. Os resultados destacam que o uso da aprendizagem automática pode melhorar significativamente a precisão e eficiência na avaliação de risco e resiliência em infraestruturas estruturais. Os modelos baseados em machine learning, especialmente os de boosting e aprendizagem profunda, mostraram-se superiores a métodos tradicionais em termos de precisão preditiva e capacidade de lidar com grandes volumes de dados complexos. O estudo identifica também que a implementação da aprendizagem automática em estruturas regionais ou urbanas é promissora, particularmente em relação à análise de redes interdependentes de infraestruturas.

Limitações

As principais limitações do estudo incluem a falta de dados consistentes e padronizados em grande escala, necessários para treinar adequadamente os modelos de machine learning. Além disso, a complexidade de implementar aprendizagem automática em avaliações de resiliência de sistemas integrados, como redes elétricas e de transporte, representa um desafio significativo.

Perspetivas Futuras

Os autores sugerem que futuras pesquisas devem focar na integração de dados de monitorização de saúde estrutural (SHM) com aprendizagem automática para melhorar a previsão de falhas e danos em tempo real. A aplicação da aprendizagem automática a nível de comunidades ou cidades inteiras é recomendada, com o objetivo de otimizar as respostas a eventos extremos e os planos de recuperação pós-desastre.

- O estudo realizado por Kondo et al. (2018) tem como objetivo principal desenvolver métodos bayesianos de seleção de subconjuntos para determinar os valores característicos de resistência de materiais, especificamente na indústria de madeira. O objetivo é substituir os métodos tradicionais da ASTM, que apresentam limitações, por abordagens mais robustas que garantam a integridade estrutural do produto com uma elevada probabilidade de exceder o valor especificado. O método de

inteligência artificial aplicado inclui três métodos de seleção de subconjuntos, sendo dois baseados em abordagens bayesianas: o Bayes empírico-não paramétrico e o Bayes semiparamétrico, além de um método clássico baseado em Rizvi-Sobel. Os métodos bayesianos utilizam processos de Dirichlet para modelar a incerteza nos parâmetros de resistência, permitindo maior flexibilidade em relação a distribuições paramétricas. Os resultados obtidos indicam que os métodos bayesianos propostos superaram o método tradicional da ASTM em termos de robustez e estabilidade, especialmente no tratamento de subpopulações heterogêneas de madeira. O método semiparamétrico demonstrou ser o mais eficiente quando as amostras são grandes, enquanto o método empírico-não paramétrico se destacou em amostras pequenas. Ambos os métodos resultaram em seleções de subconjuntos menores e mais estáveis em comparação ao método da ASTM.

Limitações

As limitações do estudo incluem a necessidade de um volume significativo de cálculos para implementar os métodos bayesianos, o que pode ser desafiador em termos computacionais. Adicionalmente, os métodos dependem da escolha de prioridades adequadas, que podem ser difíceis de determinar em aplicações práticas.

Perspetivas Futuras

Os autores sugerem que futuros estudos devem explorar a aplicação dos métodos propostos em outras indústrias além da madeira, onde a seleção de subconjuntos é crítica para garantir a segurança estrutural. A integração desses métodos em normas de segurança estrutural pode trazer melhorias significativas na precisão e confiabilidade dos valores de design.

- O estudo realizado por Pomponi et al. (2021) tem como principal objetivo desenvolver uma ferramenta que facilite a estimativa de carbono incorporado ao longo do ciclo de vida de estruturas de edifícios, utilizando modelos de machine learning. O foco está em melhorar a precisão e a usabilidade das ferramentas de estimativa de carbono, substituindo métodos tradicionais, como a análise por elementos finitos (FEA), que são computacionalmente exigentes. A ferramenta pretende apoiar decisões durante a fase inicial de projeto, considerando diferentes materiais estruturais, como aço, betão armado e madeira. O método de inteligência artificial aplicado incluiu três modelos de machine learning, nomeadamente Redes Neurais Artificiais (ANN), Random Forest (RF) e Suporte a Vetores de Regressão (SVR). Estes modelos foram treinados com um conjunto de dados gerados a partir de simulações anteriores, visando prever a massa estrutural e, subsequentemente, calcular o carbono incorporado de forma eficiente. O modelo Random Forest destacou-se ao apresentar os melhores resultados em termos de desempenho e precisão. Os

resultados demonstraram que os modelos da aprendizagem automática foram eficazes na previsão das emissões de carbono incorporados em estruturas de aço, betão armado e madeira engenheirada, substituindo os cálculos tradicionais por FEA. A implementação do modelo Random Forest reduziu significativamente o tempo de cálculo, permitindo a geração de resultados em tempo real. As previsões foram validadas com resultados de software comerciais de FEA, apresentando uma boa correlação e níveis de precisão adequados para a fase inicial do projeto. Adicionalmente, a ferramenta foi integrada ao software Trimble SketchUp, tornando-a acessível a arquitetos e engenheiros.

Limitações

Entre as limitações do estudo, destaca-se a dependência da qualidade dos dados de entrada, uma vez que erros nos dados podem comprometer as previsões. Além disso, o modelo foi treinado com base num conjunto de dados gerado a partir de simulações por FEA, o que pode introduzir uma margem de erro nas previsões. Outra limitação mencionada pelos autores é que o modelo RF, embora preciso, requer uma quantidade significativa de armazenamento computacional.

Perspetivas Futuras

Os autores sugerem que futuras investigações devem concentrar-se na integração de outros materiais e tipologias estruturais na ferramenta, além de melhorar a interface gráfica do utilizador para torná-la ainda mais acessível. Também há planos para expandir a aplicação da ferramenta para fases mais avançadas do design estrutural, permitindo otimizações mais detalhadas do ciclo de vida do carbono incorporad

6

Conclusão

A dissertação debruça-se sobre o impacto revolucionário da aplicação de Inteligência Artificial (IA) e Aprendizagem Automática (AA) no cálculo estrutural, oferecendo uma análise sistemática das áreas em que estas tecnologias estão a transformar a engenharia civil. Ao longo deste trabalho, verificou-se que a IA e a AA, através de métodos como redes neuronais, algoritmos genéticos e sistemas de otimização, têm melhorado significativamente a precisão e a eficiência das análises estruturais. Estas tecnologias, que anteriormente eram mais comuns em campos da informática, agora desempenham um papel central na modelação e simulação de estruturas complexas

Os resultados obtidos ao longo da pesquisa revelam que as técnicas de IA são eficazes na previsão de comportamento estrutural, otimização de projetos e deteção de falhas, proporcionando novas soluções para os desafios enfrentados pelos engenheiros civis. Um dos principais avanços foi observado na capacidade da IA em lidar com grandes volumes de dados e cenários de incerteza, permitindo prever o desempenho estrutural com maior precisão e em menor tempo comparativamente aos métodos tradicionais, como o Método dos Elementos Finitos (FEM).

Contudo, apesar dos benefícios identificados, existem algumas limitações a serem superadas. Entre elas, destaca-se a dependência de grandes volumes de dados de alta qualidade para treinar modelos preditivos e a dificuldade na interpretação dos resultados fornecidos por técnicas avançadas, como redes neuronais profundas. A complexidade computacional associada à IA, sobretudo em aplicações com dados em tempo real, continua a ser um desafio que impede a sua plena adoção.

As perspetivas futuras para a utilização de IA e AA no cálculo estrutural sugerem uma expansão destas técnicas para áreas ainda pouco exploradas, como o design generativo e a otimização de ciclo de vida de infraestruturas. Recomenda-se o desenvolvimento de modelos híbridos, que combinem métodos tradicionais com algoritmos de IA, a fim de superar as limitações atuais e melhorar a generalização dos resultados.

7 Anexo-A1

TITLE-ABS-KEY("3D printing" AND "structural engineering") OR TITLE-ABS-KEY("adaptive learning" AND "structural engineering") OR TITLE-ABS-KEY("additive manufacturing" AND "structural engineering") OR TITLE-ABS-KEY("ad-hoc techniques" AND "structural engineering") OR TITLE-ABS-KEY("algorithms" AND "structural engineering") OR TITLE-ABS-KEY("ant colony optimization" AND "structural engineering") OR TITLE-ABS-KEY("augmented intelligence" AND "structural engineering") OR TITLE-ABS-KEY("augmented reality" AND "structural engineering") OR TITLE-ABS-KEY("automated" AND "structural engineering") OR TITLE-ABS-KEY("automation" AND "structural engineering") OR TITLE-ABS-KEY("autonomous systems" AND "structural engineering") OR TITLE-ABS-KEY("Bayesian belief networks" AND "structural engineering") OR TITLE-ABS-KEY("Bayesian methods" AND "structural engineering") OR TITLE-ABS-KEY("big data" AND "structural engineering") OR TITLE-ABS-KEY("blockchain" AND "structural engineering") OR TITLE-ABS-KEY("clustering" AND "structural engineering") OR TITLE-ABS-KEY("collaborative filtering" AND "structural engineering") OR TITLE-ABS-KEY("computer vision" AND "structural engineering") OR TITLE-ABS-KEY("convolutional neural network" AND "structural engineering") OR TITLE-ABS-KEY("cyber-physical systems" AND "structural engineering") OR TITLE-ABS-KEY("data mining" AND "structural engineering") OR TITLE-ABS-KEY("decision trees" AND "structural engineering") OR TITLE-ABS-KEY("deep learning" AND "structural engineering") OR TITLE-ABS-KEY("deep multilayer perceptron" AND "structural engineering") OR TITLE-ABS-KEY("deep reinforcement learning" AND "structural engineering") OR TITLE-ABS-KEY("digital fabrication" AND "structural engineering") OR TITLE-ABS-KEY("digital twin" AND "structural engineering") OR TITLE-ABS-KEY("discriminant analysis" AND "structural engineering") OR TITLE-ABS-KEY("dynamic programming" AND "structural engineering") OR TITLE-ABS-KEY("ensemble methods" AND "structural engineering") OR

TITLE-ABS-KEY("evolutionary algorithms" AND "structural engineering") OR TITLE-ABS-KEY("evolutionary computation" AND "structural engineering") OR TITLE-ABS-KEY("expert systems" AND "structural engineering") OR TITLE-ABS-KEY("fuzzy logic" AND "structural engineering") OR TITLE-ABS-KEY("gaussian mixture" AND "structural engineering") OR TITLE-ABS-KEY("gaussian process regression" AND "structural engineering") OR TITLE-ABS-KEY("generative AI" AND "structural engineering") OR TITLE-ABS-KEY("graph theory" AND "structural engineering") OR TITLE-ABS-KEY("hidden Markov model" AND "structural engineering") OR TITLE-ABS-KEY("hierarchical clustering" AND "structural engineering") OR TITLE-ABS-KEY("IoT" AND "structural engineering") OR TITLE-ABS-KEY("Internet of Things" AND "structural engineering") OR TITLE-ABS-KEY("k-nearest neighbor" AND "structural engineering") OR TITLE-ABS-KEY("linear discriminant analysis" AND "structural engineering") OR TITLE-ABS-KEY("linear regression" AND "structural engineering") OR TITLE-ABS-KEY("machine learning" AND "structural engineering") OR TITLE-ABS-KEY("machine vision" AND "structural engineering") OR TITLE-ABS-KEY("markov decision processes" AND "structural engineering") OR TITLE-ABS-KEY("metric learning" AND "structural engineering") OR TITLE-ABS-KEY("models" AND "structural engineering") OR TITLE-ABS-KEY("naive Bayes" AND "structural engineering") OR TITLE-ABS-KEY("natural language processing" AND "structural engineering") OR TITLE-ABS-KEY("neural network" AND "structural engineering") OR TITLE-ABS-KEY("nonlinear regression" AND "structural engineering") OR TITLE-ABS-KEY("optimization" AND "structural engineering") OR TITLE-ABS-KEY("particle swarm optimization" AND "structural engineering") OR TITLE-ABS-KEY("partitional clustering" AND "structural engineering") OR TITLE-ABS-KEY("pattern recognition" AND "structural engineering") OR TITLE-ABS-KEY("perception" AND "structural engineering") OR TITLE-ABS-KEY("principal component analysis" AND "structural engineering") OR TITLE-ABS-KEY("probability theory" AND "structural engineering") OR TITLE-ABS-KEY("random forest" AND "structural engineering") OR TITLE-ABS-KEY("recurrent neural network" AND "structural engineering") OR TITLE-ABS-KEY("reinforcement learning" AND "structural engineering") OR TITLE-ABS-KEY("robotics" AND "structural engineering") OR TITLE-ABS-KEY("semi-supervised learning" AND "structural engineering") OR TITLE-ABS-KEY("smart cities" AND "structural engineering") OR TITLE-ABS-KEY("spectral clustering" AND "structural engineering") OR TITLE-ABS-KEY("structural health monitoring"

AND "structural engineering") OR TITLE-ABS-KEY("structural identification" AND "structural engineering") OR TITLE-ABS-KEY("support vector machines" AND "structural engineering") OR TITLE-ABS-KEY("support vector regression" AND "structural engineering") OR TITLE-ABS-KEY("swarm intelligence" AND "structural engineering") OR TITLE-ABS-KEY("swarm optimization" AND "structural engineering") OR TITLE-ABS-KEY("sustainable design" AND "structural engineering") OR TITLE-ABS-KEY("support vector machines" AND "structural engineering") OR TITLE-ABS-KEY("temporal difference learning" AND "structural engineering") OR TITLE-ABS-KEY("unsupervised learning" AND "structural engineering") OR TITLE-ABS-KEY("virtual reality" AND "structural engineering") OR TITLE-ABS-KEY("vision-based" AND "structural engineering")

Bibliography

- Abuodeh, O., J. A. Abdalla e R. A. Hawileh (2019). “Predicting the Shear Capacity of FRP in Shear Strengthened RC Beams using ANN and NID”. In: *Proceedings of the 2019 IEEE International Conference on Artificial Intelligence and Computing Applications (ICAICA)*, pp. 1–6. DOI: [10.1109/ICAICA.2019.000XX](https://doi.org/10.1109/ICAICA.2019.000XX).
- Adeli, H. e S. Kumar (1995). “Distributed Genetic Algorithm for structural optimization”. In: *Journal of Aerospace Engineering* 8, pp. 156–163. DOI: [10.1061/\(ASCE\)0893-1321\(1995\)8:3\(156\)](https://doi.org/10.1061/(ASCE)0893-1321(1995)8:3(156)).
- Adeli, H. e C. J. Yeh (1989). “Perceptron learning in engineering design”. In: *Computers Structures* 31.5, pp. 869–879. DOI: [10.1111/j.1467-8667.1989.tb00026.x](https://doi.org/10.1111/j.1467-8667.1989.tb00026.x).
- Alagundi, S. e T. Palanisamy (2022). “ANN Model for Joint Shear Strength of RC Interior Beam-Column Joint”. In: *CIGOS 2021, Emerging Technologies and Applications for Green Infrastructure*. Vol. 203. Lecture Notes in Civil Engineering. Springer, pp. 1091–1101. DOI: [10.1007/978-981-16-7160-9_125](https://doi.org/10.1007/978-981-16-7160-9_125).
- Alhusban, M., M. Alhusban e A. A. Alkhawaldeh (2024a). “The Efficiency of Using Machine Learning Techniques in Fiber-Reinforced-Polymer Applications in Structural Engineering”. In: *Sustainability* 16.1, p. 11. DOI: [10.3390/su16010011](https://doi.org/10.3390/su16010011).
- (2024b). “The Efficiency of Using Machine Learning Techniques in Fiber-Reinforced-Polymer Applications in Structural Engineering”. In: *Sustainability* 16.1, p. 11. DOI: [10.3390/su16010011](https://doi.org/10.3390/su16010011).
- Amezquita-Sanchez, J. P. et al. (2016). “Neurocomputing in Civil Infrastructure”. In: *Scientia Iranica* 23.6, pp. 2417–2428. DOI: [10.24200/sci.2016.3927](https://doi.org/10.24200/sci.2016.3927).
- Ampanavos, S., M. Nourbakhsh e C. Y. Cheng (2022). “Structural Design Recommendations in the Early Design Phase Using Machine Learning”. In: *Communications in Computer and Information Science*. Springer Science and Business Media Deutschland GmbH, pp. 190–202.

- DOI: [10.1007/978-981-19-1280-1_12](https://doi.org/10.1007/978-981-19-1280-1_12). URL: https://link.springer.com/content/pdf/10.1007/978-981-19-1280-1_12.pdf.
- Bekdaş, G., M. Yücel e S. M. Nigdeli (2021). “Estimation of optimum design of structural systems via machine learning”. In: *Frontiers of Structural and Civil Engineering* 15.6, pp. 1441–1452. DOI: [10.1007/s11709-021-0774-0](https://doi.org/10.1007/s11709-021-0774-0). URL: <https://link.springer.com/content/pdf/10.1007/s11709-021-0774-0.pdf>.
- Bendsøe, Martin Philip e Noboru Kikuchi (1988). “Generating optimal topologies in structural design using a homogenization method”. In: *Computer Methods in Applied Mechanics and Engineering* 71.2, pp. 197–224. ISSN: 0045-7825. DOI: [https://doi.org/10.1016/0045-7825\(88\)90086-2](https://doi.org/10.1016/0045-7825(88)90086-2). URL: <https://www.sciencedirect.com/science/article/pii/0045782588900862>.
- Berradia, M. et al. (2023). “A GMDH-based estimation model for axial load capacity of GFRP-RC circular columns”. In: *Steel and Composite Structures* 49.2, pp. 161–180. DOI: [10.12989/scs.2023.49.2.161](https://doi.org/10.12989/scs.2023.49.2.161).
- Bhuiyan, M. Z. A. et al. (2015). “Resource-Efficient Vibration Data Collection in Cyber-Physical Systems”. In: *ICA3PP 2015: Algorithms and Architectures for Parallel Processing*. Vol. 9529. Lecture Notes in Computer Science. Springer, Cham, pp. 134–147. DOI: [10.1007/978-3-319-27137-8_11](https://doi.org/10.1007/978-3-319-27137-8_11).
- Cabrera, M., J. Ninic e W. Tizani (2023). “Fusion of experimental and synthetic data for reliable prediction of steel connection behaviour using machine learning”. In: *Engineering with Computers* 39, pp. 3993–4011. DOI: [10.1007/s00366-023-01864-1](https://doi.org/10.1007/s00366-023-01864-1).
- Cascone, Francesco et al. (2021). “A Structural Grammar Approach for the Generative Design of Diagrid-Like Structures”. In: *Buildings* 11.3, p. 90. DOI: <https://doi.org/10.3390/buildings11030090>.
- Çevik, A. et al. (2015). “Support Vector Machines in Structural Engineering: A Review”. In: *Journal of Civil Engineering and Management* 21.3, pp. 261–281. DOI: [10.3846/13923730.2015.1005021](https://doi.org/10.3846/13923730.2015.1005021).
- Charalampakis, A. E. e G. C. Tsiatas (2019). “Critical evaluation of metaheuristic algorithms for weight minimization of truss structures”. In: *Frontiers in Built Environment* 5, p. 113. DOI: <https://doi.org/10.3389/fbuil.2019.00113>.

- Chen, G. e Y. Liu (2020). “Hybrid artificial intelligence and finite element analysis approach for predicting structural behavior”. In: *Renewable Energy* 145, pp. 2426–2434. DOI: [10.1016/j.renene.2019.07.166](https://doi.org/10.1016/j.renene.2019.07.166).
- Chen, S.-Z. et al. (2022). “Probabilistic Machine-Learning Methods for Performance Prediction of Structure and Infrastructures through Natural Gradient Boosting”. In: *Journal of Structural Engineering* 148.8, p. 04022096. DOI: [10.1061/\(ASCE\)ST.1943-541X.0003401](https://doi.org/10.1061/(ASCE)ST.1943-541X.0003401).
- Cheng, H. et al. (2024). “Random Bridge Generator as a Platform for Developing Computer Vision-Based Structural Inspection Algorithms”. In: vol. 3, p. 100098. DOI: [10.1016/j.iintel.2024.100098](https://doi.org/10.1016/j.iintel.2024.100098).
- Coello, Carlos A. e A. D. Christiansen (2000). “Multiobjective optimization of trusses using genetic algorithms”. In: *Computers & Structures* 75.6, pp. 647–660. DOI: [10.1016/S0045-7949\(99\)00110-8](https://doi.org/10.1016/S0045-7949(99)00110-8).
- Deb, K. e T. A. K. (2002). “A fast and elitist multi-objective genetic algorithm: NSGA-II”. In: *IEEE Transactions on Evolutionary Computation* 6.2, pp. 182–197. DOI: [10.1109/4235.996017](https://doi.org/10.1109/4235.996017).
- Dehkordi, A. A. et al. (2023). “Adaptive Chaotic Marine Predators Hill Climbing Algorithm for Large-Scale Design Optimizations”. In: *IEEE Access* 11, pp. 39269–39290. DOI: [10.1109/ACCESS.2023.3266991](https://doi.org/10.1109/ACCESS.2023.3266991).
- Deng, C., R. Zhang e X. Xue (2022). “Application of Group Method of Data Handling on the Ultimate Conditions’ Prediction of FRP-Confined Concrete Cylinders”. In: *Polymers* 14.17. DOI: [10.3390/polym14173615](https://doi.org/10.3390/polym14173615). URL: https://mdpi-res.com/d_attachment/polymers/polymers-14-03615/article_deploy/polymers-14-03615.pdf?version=1662029007.
- Dhakal, N. et al. (2023). “Machine Learning-Based Prediction of Compressive Performance in Circular Concrete Columns Confined with FRP”. In: *2023 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)*. IEEE. DOI: [10.1109/3ICT60104.2023.10391832](https://doi.org/10.1109/3ICT60104.2023.10391832).
- Di, B. et al. (2023). “Investigation of the Shear Behavior of Concrete Beams Reinforced with FRP Rebars and Stirrups Using ANN Hybridized with Genetic Algorithm”. In: *Polymers* 15.13. DOI: [10.3390/polym15132857](https://doi.org/10.3390/polym15132857). URL: https://mdpi-res.com/d_attachment/

[polymers/polymers-15-02857/article_deploy/polymers-15-02857.pdf?version=1687949489](https://doi.org/10.1007/s41939-023-00231-3).

Ding, X. (2024). “Employing adaptive neural fuzzy inference system model via meta-heuristic algorithms for predicting undrained shear strength”. In: *Multiscale and Multidisciplinary Modeling, Experiments and Design* 7, pp. 689–703. DOI: <https://doi.org/10.1007/s41939-023-00231-3>.

Ding, Z. et al. (2024). “Neighborhood Component Analysis-based Feature Selection in Machine Learning to Predict Tendon Ultimate Stress of Unbonded Prestressed Concrete Beams”. In: *Case Studies in Construction Materials* 21, e03428. DOI: [10.1016/j.cscm.2024.e03428](https://doi.org/10.1016/j.cscm.2024.e03428).

Elhishi, S., A. M. Elashry e S. El-Metwally (2023). “Unboxing Machine Learning Models for Concrete Strength Prediction Using XAI”. In: *Scientific Reports* 13, p. 19892. DOI: [10.1038/s41598-023-47169-7](https://doi.org/10.1038/s41598-023-47169-7).

Feng, T. e L. Wei (2023). “The Buckling Analysis of Thin-Walled Structures Based on Physics-Informed Neural Networks”. In: *Chinese Journal of Theoretical and Applied Mechanics* 55.11, pp. 2539–2553. DOI: [10.6052/0459-1879-23-277](https://doi.org/10.6052/0459-1879-23-277).

Fujino, T. e F. C. Hadipriono (1994). “New gate operations of fuzzy fault tree analysis”. In: *Proceedings of 1994 IEEE 3rd International Fuzzy Systems Conference*. Vol. 2. Orlando, FL, USA, pp. 1246–1251. DOI: [10.1109/FUZZY.1994.343643](https://doi.org/10.1109/FUZZY.1994.343643).

Gad, Ahmed G. (2022). “Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review”. In: *Archives of Computational Methods in Engineering* 29.1, pp. 2531–2561. DOI: <https://doi.org/10.1007/s11831-021-09694-4>.

Gallet, A. et al. (2022). “Structural engineering from an inverse problems perspective”. In: *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 478.2261, p. 20210526. DOI: [10.1098/rspa.2021.0526](https://doi.org/10.1098/rspa.2021.0526).

Ghaboussi, J. e D. B. M. (1991). “Neural network for optimization of structures”. In: *Computers Structures* 38.3, pp. 471–477. DOI: [10.1016/0045-7949\(91\)90105-3](https://doi.org/10.1016/0045-7949(91)90105-3).

Guerlement, G., R. Targowski, W. Gutkowski, et al. (2001). “Discrete minimum weight design of steel structures using EC3 code”. In: *Structural and Multidisciplinary Optimization* 22, pp. 322–327. DOI: <https://doi.org/10.1007/s00158-001-0152-4>.

- Guler, O. et al. (2023). “Predicting Shear Capacity of RC Beams Strengthened with NSM FRP Using Neural Networks”. In: *2023 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)*, pp. 57–64. DOI: [10.1109/3ICT60104.2023.10391555](https://doi.org/10.1109/3ICT60104.2023.10391555).
- Guo, J., L. Wang e J. Shan (2023). “Data-driven Modeling and Prediction on Hysteresis Behavior of Flexure RC Columns Using Deep Learning Networks”. In: *Structural Design of Tall and Special Buildings* 32.11-12, e2039. DOI: [10.1002/tal.2039](https://doi.org/10.1002/tal.2039).
- Guo, Y. et al. (2007). “A novel cellular automata based approach to storm sewer design”. In: *Engineering Optimization* 39.3, pp. 345–364. DOI: <https://doi.org/10.1080/03052150601128261>.
- Hakim, S. J. S. et al. (2024). “A Pioneering Approach to Predicting the Shear Strength of RC Beams by Employing Artificial Intelligence Techniques”. In: *Civil Engineering and Architecture* 12.1, pp. 218–230. DOI: [10.13189/cea.2024.120118](https://doi.org/10.13189/cea.2024.120118).
- Hanoon, A. N., A. W. Al Zand e Z. M. Yaseen (2022). “Designing new hybrid artificial intelligence model for CFST beam flexural performance prediction”. In: *Engineering with Computers* 38.4, pp. 3109–3135. DOI: [10.1007/s00366-021-01325-7](https://doi.org/10.1007/s00366-021-01325-7). URL: <https://link.springer.com/content/pdf/10.1007/s00366-021-01325-7.pdf>.
- Haroon, M. et al. (2021). “Torsional Behavior Evaluation of Reinforced Concrete Beams Using Artificial Neural Network”. In: *Applied Sciences* 11.10, p. 4465. DOI: [10.3390/app11104465](https://doi.org/10.3390/app11104465).
- Hason, M. M. et al. (2022). “Peak Ground Acceleration Models Predictions Utilizing Two Metaheuristic Optimization Techniques”. In: *Latin American Journal of Solids and Structures* 19.3, e447. DOI: [10.1590/1679-78256940](https://doi.org/10.1590/1679-78256940).
- Hassan, S. I. et al. (2023). “Systematic Literature Review on the Application of Machine Learning for the Prediction of Properties of Different Types of Concrete”. In: *PeerJ Computer Science* 9, e1853. DOI: [10.7717/peerj-cs.1853](https://doi.org/10.7717/peerj-cs.1853).
- He, Zhili, Yu-Hsing Wang e Jian Zhang (2023). *Generative Structural Design Integrating BIM and Diffusion Model*. arXiv: [2311.04052](https://arxiv.org/abs/2311.04052) [cs.LG]. URL: <https://arxiv.org/abs/2311.04052>.

- Höll, Simon e Christoph Humer (2023). “Deep predictions and transfer learning for simulation-driven structural health monitoring based on guided waves”. In: *Expert Systems with Applications* 212, p. 122133. DOI: <https://doi.org/10.1016/j.eswa.2023.122133>.
- Honarjoo, A. e E. Darvishan (2024). “A shallow 2D-CNN network for crack detection in concrete structures”. In: *International Journal of Structural Integrity* 15.3, pp. 461–474. DOI: [10.1108/IJSI-08-2023-0082](https://doi.org/10.1108/IJSI-08-2023-0082).
- Hong, W. K., T. A. Le, et al. (2023). “ANN-based Lagrange optimization for RC circular columns having multiobjective functions”. In: *Journal of Asian Architecture and Building Engineering* 22.2, pp. 961–976. DOI: [10.1080/13467581.2022.2064864](https://doi.org/10.1080/13467581.2022.2064864).
- Hong, W. K. e D. H. Nguyen (2023). “Pareto frontier for steel-reinforced concrete beam developed based on ANN-based Hong-Lagrange algorithm”. In: *Journal of Asian Architecture and Building Engineering* 22.6, pp. 3535–3551. DOI: [10.1080/13467581.2023.2193621](https://doi.org/10.1080/13467581.2023.2193621). URL: <https://www.tandfonline.com/doi/pdf/10.1080/13467581.2023.2193621>.
- Hou, C. e X. G. Zhou (2022). “Strength prediction of circular CFST columns through advanced machine learning methods”. In: *Journal of Building Engineering* 51. DOI: [10.1016/j.jobbe.2022.104289](https://doi.org/10.1016/j.jobbe.2022.104289). URL: <https://www.sciencedirect.com/science/article/pii/S2352710222003023?via%3Dihub>.
- Hsu, S.-H., T.-W. Chang e C.-M. Chang (2021). “Concrete Surface Crack Segmentation Based on Deep Learning”. In: *EWSHM 2020, Lecture Notes in Civil Engineering*. Vol. 128. Springer, Cham, pp. 24–34. DOI: [10.1007/978-3-030-64908-1_3](https://doi.org/10.1007/978-3-030-64908-1_3).
- Hussein, W. G. A., A. S. Mohammed e M. Elwi (2022). “The Effect of Dynamic Load on Tall Building”. In: *Periodicals of Engineering and Natural Sciences* 10.3, pp. 286–299. DOI: [10.21533/pen.v10i3.3088](https://doi.org/10.21533/pen.v10i3.3088).
- Islam, Naimul et al. (2024). “Prediction of high-performance concrete compressive strength using deep learning techniques”. In: *Asian Journal of Civil Engineering* 25, pp. 327–341. DOI: [10.1007/s42107-023-00778-z](https://doi.org/10.1007/s42107-023-00778-z). URL: <https://doi.org/10.1007/s42107-023-00778-z>.
- Jaziri, A. et al. (2024). “Designing a Hybrid Neural System to Learn Real-world Crack Segmentation from Fractal-based Simulation”. In: *2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, pp. 8621–8631. DOI: [10.1109/WACV57701.2024.00844](https://doi.org/10.1109/WACV57701.2024.00844).

- Kallioras, N. A. e N. D. Lagaros (2020). “DL-Scale: Deep Learning for model upgrading in topology optimization”. In: *Procedia Manufacturing*, pp. 433–440. DOI: [10.1016/j.promfg.2020.02.273](https://doi.org/10.1016/j.promfg.2020.02.273). URL: <https://www.sciencedirect.com/science/article/pii/S235197892030860X?via%3Dihub>.
- Kalooop, M. R. et al. (2020). “Compressive Strength Prediction of High-Performance Concrete Using Gradient Tree Boosting Machine”. In: *Construction and Building Materials* 264, p. 120198. DOI: [10.1016/j.conbuildmat.2020.120198](https://doi.org/10.1016/j.conbuildmat.2020.120198).
- Karaçay, T. (2022). “Autonomous Crack Detection in Concrete Structures with Deep Learning”. In: *El-Cezerî Journal of Science and Engineering* 9.2, pp. 607–624. DOI: [10.31202/ecjse.983908](https://doi.org/10.31202/ecjse.983908).
- Kashani, A. R. et al. (2022). “Population-Based Optimization in Structural Engineering: A Review”. In: *Artificial Intelligence Review* 55.1, pp. 345–452. DOI: <https://doi.org/10.1007/s10462-021-10036-w>.
- Katlav, M. e F. Ergen (2024). “Data-driven moment-carrying capacity prediction of hybrid beams consisting of UHPC-NSC using machine learning-based models”. In: *Structures* 59. DOI: [10.1016/j.istruc.2023.105733](https://doi.org/10.1016/j.istruc.2023.105733). URL: <https://www.sciencedirect.com/science/article/pii/S2352012423018210?via%3Dihub>.
- Kazemi, F., T. Shafighfard e D.-Y. Yoo (2024). “Data-Driven Modeling of Mechanical Properties of Fiber-Reinforced Concrete: A Critical Review”. In: *Archives of Computational Methods in Engineering* 31, pp. 2049–2078. DOI: [10.1007/s11831-023-10043-w](https://doi.org/10.1007/s11831-023-10043-w).
- Khemapech, I., W. Sansrimahachai e M. Toahchoodee (2017). “Leveraging data stream processing and weighted attack graph for real-time bridge structural monitoring and warning”. In: *Proceedings of an unspecified conference*. Sem DOI disponível.
- Kicingier, R., T. Arciszewski e K. A. De Jong (2005). “Generative design in structural engineering”. In: *Proceedings of the 2005 ASCE International Conference on Computing in Civil Engineering*. Cancun, Mexico: American Society of Civil Engineers Press. URL: <https://hdl.handle.net/1920/622>.
- Kondo, Y. et al. (2018). “Bayesian Subset Selection Methods for Finding Engineering Design Values: An Application to Lumber Strength”. In: *Sankhya: The Indian Journal of Statistics* 80-A.S1, pp. 146–172. DOI: [10.1007/s13171-018-00157-w](https://doi.org/10.1007/s13171-018-00157-w).

- Kuo, P.-C. et al. (2024). “GNN-LSTM-based fusion model for structural dynamic responses prediction”. In: *Engineering Structures* 306, p. 117733. DOI: [10.1016/j.engstruct.2024.117733](https://doi.org/10.1016/j.engstruct.2024.117733).
- Lamouri, H., M. El Mkhalel e N. Lamdouar (2024a). “Failure Predictability Model Based on Reliability Assessment of Prestressed Concrete Bridge Beams Using Artificial Neural Networks”. In: *Civil Engineering and Architecture* 12.3A, pp. 2263–2278. DOI: [10.13189/cea.2024.121323](https://doi.org/10.13189/cea.2024.121323).
- (2024b). “Probabilistic Modeling and Structural Reliability based Monte Carlo Simulation: A Case Study”. In: *International Journal of Engineering Trends and Technology* 72.5, pp. 321–331. DOI: [10.14445/22315381/IJETT-V72I5P133](https://doi.org/10.14445/22315381/IJETT-V72I5P133).
- Lee, S. et al. (2018). “Background Information of Deep Learning for Structural Engineering”. In: *Archives of Computational Methods in Engineering* 25.1, pp. 121–129. DOI: [10.1007/s11831-017-9237-0](https://doi.org/10.1007/s11831-017-9237-0).
- Li, C., M. Zhang e X. Zhang (2023). “Enhancing Concrete Creep Prediction With Deep Learning: A Soft-Sorted One-Dimensional CNN Approach”. In: *IEEE Access* 11, pp. 139314–139325. DOI: [10.1109/ACCESS.2023.3340425](https://doi.org/10.1109/ACCESS.2023.3340425).
- Li, H. et al. (2024). “A study on improving energy flexibility in building engineering through generalized prediction models: Enhancing local bearing capacity of concrete for engineering structures”. In: *Engineering Structures* 303, p. 117051. DOI: [10.1016/j.engstruct.2023.117051](https://doi.org/10.1016/j.engstruct.2023.117051).
- Li, J. et al. (2019). “Fiberglass-Reinforced Polyester Composites Fatigue Prediction Using Novel Data-Intelligence Model”. In: *Arabian Journal for Science and Engineering* 44, pp. 3343–3356. DOI: [10.1007/s13369-018-3508-4](https://doi.org/10.1007/s13369-018-3508-4).
- Liang, S. et al. (2023). “Multi-Objective Optimization Design of FRP Reinforced Flat Slabs under Punching Shear by Using NGBoost-Based Surrogate Model”. In: *Buildings* 13.11. DOI: [10.3390/buildings13112727](https://doi.org/10.3390/buildings13112727). URL: https://mdpi-res.com/d_attachment/buildings/buildings-13-02727/article_deploy/buildings-13-02727-v2.pdf?version=1698642944.
- Lin, Y. e A. A. Ibraheem (2024). “Machine learning method as a tool to estimate the vibrations of the concrete structures reinforced by advanced nanocomposites”. In: *Mechanics of Advanced*

- Materials and Structures*. DOI: [10.1080/15376494.2024.2355517](https://doi.org/10.1080/15376494.2024.2355517). URL: <https://www.tandfonline.com/doi/pdf/10.1080/15376494.2024.2355517>.
- Lins, R. G. e S. N. Givigi (2016). “Automatic Crack Detection and Measurement Based on Image Analysis”. In: *IEEE Transactions on Instrumentation and Measurement* 65.3, pp. 583–590. DOI: [10.1109/TIM.2015.2509278](https://doi.org/10.1109/TIM.2015.2509278).
- Liu, Hui, Zixing Cai e Yong Wang (2010). “Hybridizing particle swarm optimization with differential evolution for constrained numerical and engineering optimization”. In: *Applied Soft Computing* 10.2, pp. 629–640. ISSN: 1568-4946. DOI: <https://doi.org/10.1016/j.asoc.2009.08.031>. URL: <https://www.sciencedirect.com/science/article/pii/S1568494609001550>.
- Liu, P. (2023). “Study on Structural Health Monitoring Practice Using Artificial Intelligence”. In: *2023 IEEE International Conference on Electrical, Automation and Computer Engineering (ICEACE)*, pp. 804–809. DOI: [10.1109/ICEACE60673.2023.10441957](https://doi.org/10.1109/ICEACE60673.2023.10441957).
- Liu, X. et al. (2022). “Deformation Monitoring Method Based on Adaptive Segmentation and Correlation Matching”. In: *Proceedings of the 2022 IEEE 5th International Conference on Electronic Information and Communication Technology (ICEICT)*, pp. 438–443. DOI: [10.1109/ICEICT55736.2022.9909256](https://doi.org/10.1109/ICEICT55736.2022.9909256).
- Luo, X. et al. (2021). “A Deep Learning Prediction Model for Structural Deformation Based on Temporal Convolutional Networks”. In: *Computational Intelligence and Neuroscience* 2021, pp. 1–12. DOI: [10.1155/2021/8829639](https://doi.org/10.1155/2021/8829639).
- Málaga-Chuquitaype, C. (2022). “Machine Learning in Structural Design: An Opinionated Review”. In: *Frontiers in Built Environment* 8, p. 815717. DOI: [10.3389/fbuil.2022.815717](https://doi.org/10.3389/fbuil.2022.815717).
- Megahed, K., N. S. Mahmoud e S. E. M. Abd-Rabou (2024). “Prediction of the axial compression capacity of stub CFST columns using machine learning techniques”. In: *Scientific Reports* 14, p. 2885. DOI: [10.1038/s41598-024-53352-1](https://doi.org/10.1038/s41598-024-53352-1).
- Milad, A. et al. (2022). “Development of ensemble machine learning approaches for designing fiber-reinforced polymer composite strain prediction model”. In: *Engineering with Computers* 38, pp. 3625–3637. DOI: [10.1007/s00366-021-01398-4](https://doi.org/10.1007/s00366-021-01398-4).
- Narang, A., R. Kumar e A. Dhiman (2023). “Machine Learning Applications to Predict the Axial Compression Capacity of Concrete-Filled Steel Tubular Columns: A Systematic Review”. In:

- Multidiscipline Modeling in Materials and Structures* 19.2, pp. 197–225. DOI: [10.1108/MMMS-09-2022-0195](https://doi.org/10.1108/MMMS-09-2022-0195).
- Naser, M. Z. (2020). “Autonomous Fire Resistance Evaluation”. In: *ASCE Journal of Structural Engineering* 146.4, p. 04020103. DOI: [https://doi.org/10.1061/\(ASCE\)ST.1943-541X.0002641](https://doi.org/10.1061/(ASCE)ST.1943-541X.0002641).
- Naser, M.Z. e A. Teymori Gharah Tapeh (2023). “Causality, causal discovery, causal inference and counterfactuals in Civil Engineering: Causal machine learning and case studies for knowledge discovery”. In: *Computers and Concrete* 31.4, pp. 277–292. DOI: [10.12989/cac.2023.31.4.277](https://doi.org/10.12989/cac.2023.31.4.277).
- Negi, B. S., A. Bhatt e N. Negi (2024). “Advanced Predictive Modeling for Enhancing Manufacturing Efficiency in Concrete Structures: A Novel Hybrid Approach”. In: *Proceedings on Engineering Sciences* 6.1, pp. 407–418. DOI: [10.24874/PES.SI.24.02.023](https://doi.org/10.24874/PES.SI.24.02.023). URL: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85188436312&doi=10.24874%2fPES.SI.24.02.023&partnerID=40&md5=176e15f5c4757b738f8814ae49e441f9>.
- Nguyen, T.-A., K. L. Nguyen e H.-B. Ly (2024). “Universal Boosting ML Approaches to Predict the Ultimate Load Capacity of CFST Columns”. In: *Structural Design of Tall and Special Buildings* 33.2, e2071. DOI: [10.1002/tal.2071](https://doi.org/10.1002/tal.2071).
- Ni, Xiangyong et al. (2022). “Deep HystereticNet to predict hysteretic performance of RC columns against cyclic loading”. In: *Engineering Structures* 273, p. 115103. DOI: <https://doi.org/10.1016/j.engstruct.2022.115103>. URL: <https://www.sciencedirect.com/science/article/pii/S0141029622011798>.
- Pak, H. e S. G. Paal (2022). “Evaluation of transfer learning models for predicting the lateral strength of reinforced concrete columns”. In: *Engineering Structures* 266. DOI: [10.1016/j.engstruct.2022.114579](https://doi.org/10.1016/j.engstruct.2022.114579). URL: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85133235263&doi=10.1016%2fj.engstruct.2022.114579&partnerID=40&md5=d1e647afd86abbff18d5b62f011fdd17>.
- Pan, F. et al. (2024). “Zero-shot Building Attribute Extraction from Large-Scale Vision and Language Models”. In: *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*. DOI: [10.1109/WACV57701.2024.00845](https://doi.org/10.1109/WACV57701.2024.00845).

- Peng, C. et al. (2024). “Application of Fuzzy-ISM-MICMAC in the risk analysis affecting swivel bridge construction spanning existing railway lines: A case study”. In: *Buildings* 14.1, p. 52. DOI: <https://doi.org/10.3390/buildings14010052>.
- Pham, H. G. e T. C. Becker (2023). “Inverse design of isolated structures using predicted FEMA P-58 decision variables”. In: *Life-Cycle of Structures and Infrastructure Systems - Proceedings of the 8th International Symposium on Life-Cycle Civil Engineering, IALCCE 2023*. CRC Press/Balkema, pp. 1481–1488. DOI: [10.1201/9781003323020-182](https://doi.org/10.1201/9781003323020-182). URL: <https://s3-euw1-ap-pe-df-pch-content-store-p.s3.eu-west-1.amazonaws.com/9781003323020/12afb023-302c-4972-8445-2baf499347cb/chapters/chapter206.pdf>.
- Pizarro, P. N. e L. M. Massone (2021). “Structural design of reinforced concrete buildings based on deep neural networks”. In: *Engineering Structures* 241. DOI: [10.1016/j.engstruct.2021.112377](https://doi.org/10.1016/j.engstruct.2021.112377). URL: <https://www.sciencedirect.com/science/article/pii/S0141029621005277?via%3Dihub>.
- Pizarro, P. N., L. M. Massone, et al. (2021). “Use of Convolutional Networks in the Conceptual Structural Design of Shear Wall Buildings Layout”. In: *Engineering Structures* 239, p. 112311. DOI: [10.1016/j.engstruct.2021.112311](https://doi.org/10.1016/j.engstruct.2021.112311).
- Pomponi, F. et al. (2021). “Enhancing the practicality of tools to estimate the whole life embodied carbon of building structures via machine learning models”. In: *Frontiers in Built Environment* 7, p. 745598. DOI: [10.3389/fbuil.2021.745598](https://doi.org/10.3389/fbuil.2021.745598).
- Qian, W., Y. Xu e H. Li (2022). “A topology description function-enhanced neural network for topology optimization”. In: *Computer-Aided Civil and Infrastructure Engineering* 38.8, pp. 1020–1040. DOI: [10.1111/mice.12933](https://doi.org/10.1111/mice.12933). URL: <https://onlinelibrary.wiley.com/doi/pdfdirect/10.1111/mice.12933?download=true>.
- Qiang, S., M. Chenyue e K. Dezhi (2024). “The implementation of a least square support vector regression model utilizing meta-heuristic algorithms for predicting undrained shear strength”. In: *Multiscale and Multidisciplinary Modeling, Experiments and Design* 7, pp. 1843–1856. DOI: [10.1007/s41939-023-00299-x](https://doi.org/10.1007/s41939-023-00299-x).
- Ravikumar, P. e D. Rajkumar (2023). “Machine Learning Prediction of Structural Response for Slabs Subjected to Blast Loading”. In: *Proceedings of the 9th World Congress on Machine*

- Vision and Machine Learning (MLMV'23)*. London, UK, pp. 1–5. DOI: [10.11159/mvml23.121](https://doi.org/10.11159/mvml23.121).
- Regenwetter, Lyle, Amin Heyrani Nobari e Faez Ahmed (2022). *Deep Generative Models in Engineering Design: A Review*. arXiv: [2110.10863](https://arxiv.org/abs/2110.10863) [cs.LG]. URL: <https://arxiv.org/abs/2110.10863>.
- Rezasefat, M. e J. D. Hogan (2023). “A finite element-convolutional neural network model (FE-CNN) for stress field analysis around arbitrary inclusions”. In: *Machine Learning: Science and Technology* 4, p. 045052. DOI: [10.1088/2632-2153/ad134a](https://doi.org/10.1088/2632-2153/ad134a).
- Rodrigues, Miguel et al. (2023). “Machine learning and cointegration for structural health monitoring of a model under environmental effects”. In: *Expert Systems with Applications* 211, p. 121739. DOI: <https://doi.org/10.1016/j.eswa.2023.121739>.
- Roh, G. T. et al. (2024). “Augmented Data-Driven Machine Learning for Digital Twin of Stud Shear Connections”. In: *Buildings* 14.2. DOI: [10.3390/buildings14020328](https://doi.org/10.3390/buildings14020328). URL: https://mdpi-res.com/d_attachment/buildings/buildings-14-00328/article_deploy/buildings-14-00328.pdf?version=1706098428.
- Sahu, S. et al. (2016). “A fuzzy logic based finite element analysis for structural design of a 6-axis industrial robot”. In: *Computational Intelligence in Data Mining*. Springer, pp. 173–182. DOI: https://doi.org/10.1007/978-81-322-2731-1_18.
- Salih, B. H. H. e F. S. Hamad (2024). “ANN and Gradient Boosting-Based Predictive Techniques for Punching Shear Capacity of Concrete Slabs Reinforced with FRP Bars”. In: *Iranian Journal of Science and Technology - Transactions of Civil Engineering*. DOI: [10.1007/s40996-024-01353-5](https://doi.org/10.1007/s40996-024-01353-5). URL: <https://link.springer.com/content/pdf/10.1007/s40996-024-01353-5.pdf>.
- Sarir, P. et al. (2021). “Developing GEP tree-based, neuro-swarm, and whale optimization models for evaluation of bearing capacity of concrete-filled steel tube columns”. In: *Engineering with Computers* 37.1, pp. 1–19. DOI: [10.1007/s00366-019-00808-y](https://doi.org/10.1007/s00366-019-00808-y).
- Sarma, L. S. e C. Mallikarachchi (2022). “Medição de deformação 3D de campo completo utilizando visão estéreo”. In: *Moratuwa Engineering Research Conference (MERCon)*. Moratuwa, Sri Lanka: IEEE. DOI: [10.1109/MERCon55799.2022.9906211](https://doi.org/10.1109/MERCon55799.2022.9906211).

- Sheikh Khozani, Z. et al. (2020). “Shear stress distribution prediction in symmetric compound channels using data mining and machine learning models”. In: *Frontiers of Structural and Civil Engineering* 14.5, pp. 1097–1109. DOI: [10.1007/s11709-020-0634-3](https://doi.org/10.1007/s11709-020-0634-3).
- Shi, T. et al. (2022). “A hybrid approach to predict vertical temperature gradient of ballastless track caused by solar radiation”. In: *Construction and Building Materials* 352, p. 129063. DOI: [10.1016/j.conbuildmat.2022.129063](https://doi.org/10.1016/j.conbuildmat.2022.129063).
- Siam, A., M. Ezzeldin e W. El-Dakhakhni (2019). “Machine learning algorithms for structural performance classifications and predictions: Application to reinforced masonry shear walls”. In: *Structures* 22, pp. 252–265. DOI: [10.1016/j.istruc.2019.06.017](https://doi.org/10.1016/j.istruc.2019.06.017).
- Simwanda, L. e B. D. Ikotun (2024). “Prediction of Torque Capacity in Circular Concrete-Filled Double-Skin Tubular Members under Pure Torsion via Machine Learning and Shapley Additive Explanations Interpretation”. In: *Buildings* 14.4, p. 1040. DOI: [10.3390/buildings14041040](https://doi.org/10.3390/buildings14041040).
- Singh, A. (2023). “The Recent Trend of Artificial Neural Network in the Field of Civil Engineering”. In: *ICO 2023: Intelligent Computing and Optimization*. Ed. by P. Vasant, I. Zelinka e G. W. Weber. Springer, Cham, pp. 324–333. DOI: [10.1007/978-3-031-50158-6_32](https://doi.org/10.1007/978-3-031-50158-6_32).
- Song, Q. et al. (2022). “Computer vision-based illumination-robust and multi-point simultaneous structural displacement measuring method”. In: *Mechanical Systems and Signal Processing* 170, p. 108822. DOI: [10.1016/j.ymssp.2022.108822](https://doi.org/10.1016/j.ymssp.2022.108822).
- Teixeira, O. N. et al. (2018). “Evolutionary Quick Artificial Bee Colony for Constrained Engineering Design Problems”. In: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. Springer Verlag, pp. 603–615. DOI: [10.1007/978-3-319-91262-2_53](https://doi.org/10.1007/978-3-319-91262-2_53). URL: https://link.springer.com/content/pdf/10.1007/978-3-319-91262-2_53.pdf.
- Thisovithan, P. et al. (2023). “A novel explainable AI-based approach to estimate the natural period of vibration of masonry infill reinforced concrete frame structures using different machine learning techniques”. In: *Results in Engineering* 19, p. 101388. DOI: [10.1016/j.rineng.2023.101388](https://doi.org/10.1016/j.rineng.2023.101388).
- Uddin, Z. et al. (2023). “Wavelets based physics informed neural networks to solve non-linear differential equations”. In: *Scientific Reports* 13, p. 2882. DOI: [10.1038/s41598-023-29806-3](https://doi.org/10.1038/s41598-023-29806-3).

- Vasugi, V., M. Helen Santhi e G. Malathi (2024). “Global seismic damage assessment of RC framed buildings using machine learning techniques”. In: *Artificial Intelligence Applications for Sustainable Construction*. Elsevier. DOI: [10.1016/B978-0-443-13191-2.00011-0](https://doi.org/10.1016/B978-0-443-13191-2.00011-0). URL: <https://www.sciencedirect.com/science/article/pii/B9780443131912000110?via%3Dihub>.
- Vu, Q.-V., V.-H. Truong e H.-T. Thai (2021). “Machine learning-based prediction of CFST columns using gradient tree boosting algorithm”. In: *Composite Structures* 259, p. 113505. DOI: [10.1016/j.compstruct.2020.113505](https://doi.org/10.1016/j.compstruct.2020.113505).
- Wakjira, T. G. et al. (2022). “FAI: Fast, accurate, and intelligent approach and prediction tool for flexural capacity of FRP-RC beams based on super-learner machine learning model”. In: *Materials Today Communications* 33. DOI: [10.1016/j.mtcomm.2022.104461](https://doi.org/10.1016/j.mtcomm.2022.104461). URL: <https://www.sciencedirect.com/science/article/pii/S2352492822013022?via%3Dihub>.
- Wan, W. e M. Xu (2024). “The Implementation of a Multi-layer Perceptron Model Using Meta-heuristic Algorithms for Predicting Undrained Shear Strength”. In: *Multiscale and Multidisciplinary Modeling, Experiments and Design*. DOI: [10.1007/s41939-024-00435-1](https://doi.org/10.1007/s41939-024-00435-1).
- Wang, D. et al. (2023). “HKNAS: Classification of Hyperspectral Imagery Based on Hyper Kernel Neural Architecture Search”. In: *IEEE Transactions on Neural Networks and Learning Systems*, pp. 1–12. DOI: [10.1109/TNNLS.2023.3270369](https://doi.org/10.1109/TNNLS.2023.3270369).
- Wang, S. et al. (2024). “Data-driven estimates of the strength and failure modes of CFRP-steel bonded joints by implementing the CTGAN method”. In: *Engineering Fracture Mechanics* 299, p. 109962. DOI: [10.1016/j.engfracmech.2024.109962](https://doi.org/10.1016/j.engfracmech.2024.109962).
- Wang, X. et al. (2022). “Machine Learning for Risk and Resilience Assessment in Structural Engineering: Progress and Future Trends”. In: *Journal of Structural Engineering* 148.8, p. 03122003. DOI: [10.1061/\(ASCE\)ST.1943-541X.0003392](https://doi.org/10.1061/(ASCE)ST.1943-541X.0003392).
- Xiao, J. e H. C. (2019). “A deep learning model for predicting the compressive strength of concrete”. In: *Journal of Building Engineering* 24, pp. 100–105. DOI: [10.1016/j.jobeb.2019.100105](https://doi.org/10.1016/j.jobeb.2019.100105).
- Yeh, Anthony Gar-On e Xia Li (2002). “Urban Simulation Using Neural Networks and Cellular Automata for Land Use Planning”. In: *Advances in Spatial Data Handling*. Ed. by

- D. E. Richardson et al. Springer-Verlag Berlin Heidelberg, pp. 441–454. ISBN: 978-3-642-56094-1. DOI: https://doi.org/10.1007/978-3-642-56094-1_33.
- Yücel, M., G. Bekdaş e S. M. Nigdeli (2023). “Evaluation of Performance of Different Machine Learning Techniques for Structural Models”. In: *Lecture Notes in Networks and Systems*. Springer Science and Business Media Deutschland GmbH, pp. 243–251. DOI: [10.1007/978-3-031-36246-0_23](https://doi.org/10.1007/978-3-031-36246-0_23). URL: https://link.springer.com/content/pdf/10.1007/978-3-031-36246-0_23.pdf.
- Yücel, M., S. M. Nigdeli e G. Bekdaş (2023). “Estimation Models for Optimum Design of Structural Engineering Problems via Swarm-Intelligence Based Algorithms and Artificial Neural Networks”. In: *Studies in Computational Intelligence*. Vol. 1054. Springer Science and Business Media Deutschland GmbH. DOI: [10.1007/978-3-031-09835-2_14](https://doi.org/10.1007/978-3-031-09835-2_14). URL: https://link.springer.com/content/pdf/10.1007/978-3-031-09835-2_14.pdf.
- Zhang, G. et al. (2022). “Reinforced concrete deep beam shear strength capacity modelling using an integrative bio-inspired algorithm with an artificial intelligence model”. In: *Engineering with Computers* 38, S15–S28. DOI: [10.1007/s00366-020-01137-1](https://doi.org/10.1007/s00366-020-01137-1).
- Zhou, X.-G., C. Hou e J. Peng (2023). “Active learning methods for strength assessment of circular CFST under coupled long-term axial loading and random localized corrosion”. In: *Thin-Walled Structures* 193, p. 111254. DOI: [10.1016/j.tws.2023.111254](https://doi.org/10.1016/j.tws.2023.111254).
- Zhou, Y. et al. (2024). “StructDiffusion: End-to-end intelligent shear wall structure layout generation and analysis using diffusion model”. In: *Engineering Structures* 309, p. 118068. DOI: [10.1016/j.engstruct.2024.118068](https://doi.org/10.1016/j.engstruct.2024.118068).
- Zhu, X.Q. e S.S. Law (2015). “Structural Health Monitoring Based on Vehicle-Bridge Interaction: Accomplishments and Challenges”. In: *Advances in Structural Engineering* 18.12, pp. 1999–2015. DOI: [10.1260/1369-4332.18.12.1999](https://doi.org/10.1260/1369-4332.18.12.1999).
- Zienkiewicz, O. C., R. L. Taylor e J. Z. Zhu (2005). *The Finite Element Method: Its Basis and Fundamentals*. 6th. Amsterdam: Elsevier Butterworth-Heinemann. ISBN: 9780750664318. URL: https://archive.org/details/finiteelementmet0000zien_q2q0.