

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA

VITÓRIA BUENO GUEDES

**Avaliação do Uso de Inteligência Artificial na Área de Biomateriais: Contexto Atual e
Futuras Tendências**

Uberlândia/MG

2024

VITÓRIA BUENO GUEDES

**Avaliação do Uso de Inteligência Artificial na Área de Biomateriais: Contexto Atual e
Futuras Tendências**

Trabalho de Conclusão de Curso apresentado à
Faculdade de Engenharia Elétrica da
Universidade Federal de Uberlândia como
requisito parcial para obtenção do título de
bacharel em Engenharia Biomédica.

Orientador: Adriano Alves Pereira

Coorientadora: Márcia Mayumi Omi Simbara

Uberlândia/MG

2024

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

G924 2024	Guedes, Vitória Bueno, 2000- Avaliação do Uso de Inteligência Artificial na Área de Biomateriais [recurso eletrônico] : Contexto Atual e Futuras Tendências / Vitória Bueno Guedes. - 2024. Orientador: Adriano Alves Pereira. Coorientadora: Márcia Mayumi Omi Simbara. Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Uberlândia, Graduação em Engenharia Biomédica. Modo de acesso: Internet. Inclui bibliografia. 1. Engenharia biomédica. I. Pereira, Adriano Alves, 1964-, (Orient.). II. Simbara, Márcia Mayumi Omi, 1991-, (Coorient.). III. Universidade Federal de Uberlândia. Graduação em Engenharia Biomédica. IV. Título. CDU: 62:61
--------------	--

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074

VITÓRIA BUENO GUEDES

**Avaliação do Uso de Inteligência Artificial na Área de Biomateriais: Contexto Atual e
Futuras Tendências**

Trabalho de Conclusão de Curso apresentado à
Faculdade de Engenharia Elétrica da
Universidade Federal de Uberlândia como
requisito parcial para obtenção do título de
bacharel em Engenharia Biomédica.

Uberlândia, 05 de novembro de 2024.

Banca Examinadora:

Adriano Alves Pereira – Professor Doutor (FEELT/UFU)

Márcia Mayumi Omi Simbara – Professora Doutora (FEELT/UFU)

Gabriella Lelis Silva – Professora Doutora (FEELT/UFU)

Pedro Cunha Carneiro – Professor Doutor (FEELT/UFU)

AGRADECIMENTOS

Gostaria de agradecer em primeiro lugar meus pais, Marília e José, e meus irmãos, Rodrigo e Rafaela, por sempre me apoiarem e me darem todo carinho que podiam a distância, não me deixando desistir e me aconselhando diante de decisões sobre meu futuro acadêmico e profissional. Agradecer também toda minha família, em especial minhas tias, Elisângela, Inez, Irene e Zélia, minha avó Terezinha, meus primos Vinícius e Natália e minha amiga Natália, que me ajudaram a chegar até aqui, que torcem para meu sucesso e sempre me incentivaram a ir além. Sem eles eu não estaria aqui hoje, meus sinceros obrigada, essa conquista tem um pedaço de cada um.

Um agradecimento à professora Márcia Mayumi Omi Simbara, que sempre foi muito profissional e amorosa em sua mentoria. Durante toda a execução deste trabalho se mostrou dedicada e disposta a me ajudar com qualquer das minhas dificuldades. Também ao professor Adriano Alves Pereira que aceitou me ajudar no final, quando a professora Márcia precisou se ausentar. Aos demais professores com quem tive a oportunidade de ter aula, obrigada por todo conhecimento compartilhado, pelo incentivo, motivação e orientação nesta caminhada acadêmica.

Aos meus amigos que pude fazer, pelos momentos de aprendizado, de lazer e desafiadores ao longo de toda essa trajetória. Em especial minhas amigas Luma e Laura, que estiveram comigo o tempo todo, sempre apoiando umas às outras a correrem atrás de nossos sonhos, acreditando que eles serão alcançados. E ao meu amigo Igor, por nunca ter deixado de acreditar em mim e por compartilhar comigo minhas conquistas, dúvidas e batalhas.

RESUMO

Embora os biomateriais já sejam amplamente utilizados com sucesso em tratamentos médicos, a aplicação da Inteligência Artificial (IA) nessa área representa uma inovação recente com grande potencial para melhora. Este estudo teve como objetivo avaliar o uso da IA no setor de biomateriais, compreendendo onde e como está sendo utilizada e quais as futuras tendências para o mercado em questão. Para isso, foi realizada uma revisão narrativa, a partir do levantamento de artigos encontrados por buscas em bases de pesquisa. Os resultados revelaram que ainda não existem artigos publicados na América Latina, sendo a América do Norte, Europa e Ásia os líderes nas pesquisas. A análise também mostrou que o uso de IA ainda está em fase inicial nessa área e há uma predominância de estudos voltados para a medicina regenerativa, especialmente com o uso de polímeros. Sobre o modelo de *Machine Learning* (ML), os resultados mostraram que as Redes Neurais Artificiais (RNAs) são bem mais utilizadas comparadas com os demais. Foi possível concluir que o uso de IA nos biomateriais, embora ainda pouco explorado, apresenta um futuro promissor, especialmente na otimização de processos de fabricação e na correlação de propriedades. Além de que, oferece vantagens como a redução de custos e minimização de desperdícios de material, uma vez que permite previsões precisas antes de testes experimentais. A tendência é que os processos de fabricação sejam otimizados e o uso de RNAs continue a crescer, permitindo previsões mais precisas e eficientes, e que a pesquisa se expanda para novos tipos de biomateriais, diversificando suas aplicações para além da medicina regenerativa.

Palavras-chave: biomateriais; inteligência artificial; aprendizado de máquina.

ABSTRACT

Although biomaterials are already widely and successfully used in medical treatments, the application of Artificial Intelligence (AI) in this area represents a recent innovation with great potential for improvement. The aim of this study was to evaluate the use of AI in the biomaterials sector, understanding where and how it is being used and what the future trends are for the market in question. To this end, a narrative review was carried out, based on a survey of articles found in research databases. The results revealed that there are still no articles published in Latin America, with North America, Europe and Asia being the leaders in research. The analysis also showed that the use of AI is still in its infancy in this area and there is a predominance of studies focused on regenerative medicine, especially concerning the use of polymers. Regarding the *Machine Learning* (ML) model, the results showed that Artificial Neural Networks (ANNs) are much more commonly applied compared to others. It was possible to conclude that the use of AI in biomaterials, although still little explored, has a promising future, especially in optimizing manufacturing processes and correlating properties. It also offers advantages such as reducing costs and minimizing material waste, since it allows accurate predictions to be made before experimental tests. The trend is for manufacturing processes to be optimized and the use of ANNs to continue to grow, allowing for more accurate and efficient predictions, and for research to expand into new types of biomaterials, diversifying their applications beyond regenerative medicine.

Keywords: biomaterials; artificial intelligence; machine learning.

LISTA DE ILUSTRAÇÕES

Figura 1 - Exemplos de tipos de biomateriais	16
Figura 2 - Esquema de funcionamento da medicina regenerativa	17
Figura 3 - Exemplo esquemático de rede neural artificial	20
Figura 4 - Exemplo esquemático de floresta aleatória.....	21
Figura 5 - Quantidade de publicações por ano	28
Figura 6 - Quantidade de publicações por país.....	29
Figura 7 - Porcentagem de utilização de cada material	30
Figura 8 - Modelos de ML utilizados nos artigos.....	31
Figura 9 - Quantidade de artigos para cada objetivo da IA	33
Figura 10 - Porcentagem de níveis de evidência dos artigos	34

LISTA DE TABELAS

Quadro 1 – Tipos de biomateriais.....	14
Quadro 2 - Estratégia de busca para cada base de dados.....	24

LISTA DE ABREVIATURAS E SIGLAS

CAFe - Comunidade Acadêmica Federada

CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior

DeCS/MeSH - Descritores em Ciências da Saúde/*Medical Subject Headings*

IA - Inteligência Artificial

ML - *Machine Learning*

RNA - Rede Neural Artificial

SUMÁRIO

1 INTRODUÇÃO.....	12
2 OBJETIVOS.....	13
2.1 Gerais	13
2.2 Específicos	13
3 REVISÃO BIBLIOGRÁFICA	14
3.1 Biomateriais e principais utilizações	14
3.2 Inteligência Artificial.....	19
3.2.1. Modelos de ML	19
3.3 Utilização da inteligência artificial na área de biomateriais.....	22
3.3.1. Desafios	22
4 METODOLOGIA.....	24
4.1 Busca pelos artigos.....	24
4.2 Extração de informações dos artigos	25
5 RESULTADOS E DISCUSSÃO	27
5.1 Ano e país da publicação	27
5.2 Tipos de biomateriais estudados nos artigos selecionados	29
5.3 Principais metodologias da ML	30
5.4 Objetivo da IA.....	31
5.5 Níveis de evidência	33
6 CONCLUSÃO.....	35
REFERÊNCIAS.....	37
APÊNDICE A.....	41

1 INTRODUÇÃO

Biomaterial é definido como “um material destinado a fazer interface com sistemas biológicos para avaliar, tratar, aumentar ou substituir qualquer tecido, órgão ou função do corpo” (AGRAWAL et al., 2014). Ao longo da história, os biomateriais têm sido aliados da medicina, auxiliando em diversos tratamentos. Em 2500 a.C. foi registrado o uso de fios de ouro para estabilizar dentes moles, sendo esse um dos primeiros usos de biomateriais registrados (FORSHAW, 2009). Com o passar dos anos sua utilização foi evoluindo significativamente até os avançados biomateriais de hoje, tornando-se essenciais para uma ampla gama de tratamentos e procedimentos (MARIN; BOSCHETTO; PEZZOTTI, 2020).

Com o passar desses anos, as técnicas utilizadas na área de biomateriais também se desenvolveram, e hoje, como em diversas outras áreas, a Inteligência Artificial (IA) é utilizada em alguns processos. A definição de IA ainda não é um consenso, mas, pode-se dizer que se refere como “máquinas que têm a capacidade de imitar as capacidades humanas” (AREVALO; BUEHLER, 2023). A IA é um dos grandes destaques dos últimos tempos, algo evidenciado pelo Prêmio Nobel de Física de 2024, que foi concedido a *John J. Hopfield e Geoffrey E. Hinton* pelas "descobertas fundamentais e invenções que possibilitaram o aprendizado de máquinas com redes neurais artificiais" (ISMERIM, 2024).

No caso de pesquisas envolvendo biomateriais, espera-se que os futuros modelos de IA preditiva possam contribuir para a descoberta de novos materiais, com alto rendimento e baixo custo (AREVALO; BUEHLER, 2023). Porém, embora a IA ofereça grandes benefícios, existem muitos desafios em sua implementação nessa área. Há uma necessidade de um grande volume de dados de alta qualidade para que o resultado a ser obtido seja confiável, e a representação de biomateriais complexos pode ser muito desafiadora, assim como a compilação de dados no geral (MEYER et al., 2023). Logo, sua utilização deve ser feita com muita cautela, pois um banco de dados com informações distorcidas pode fornecer respostas erradas, por isso é muito importante treinar as máquinas cuidadosamente (KRUEGER et al., 2020).

O objetivo do presente trabalho foi estudar como a IA está sendo utilizada na área de biomateriais, avaliando o cenário atual, compreendendo as aplicações e analisando futuras tendências. Para isso, foi realizado um levantamento de artigos em bases de dados como *PubMed*, *Web of Science* e *ScienceDirect*. Ressalta-se que foram avaliados apenas artigos acadêmicos, assim o estudo não fornece informações sobre o panorama industrial do uso de IA.

2 OBJETIVOS

2.1 Gerais

Avaliar o uso da Inteligência Artificial no setor de biomateriais, compreendendo onde e como está sendo utilizada e quais as futuras tendências para o mercado em questão.

2.2 Específicos

- Levantar artigos para analisar dados referentes ao crescimento da utilização da IA na área de biomateriais;
- Compreender onde a IA já está sendo utilizada no setor de biomateriais;
- Verificar possíveis aplicações futuras da IA na área de biomateriais;
- Entender os principais desafios da utilização da IA no setor de biomateriais.

3 REVISÃO BIBLIOGRÁFICA

3.1 Biomateriais e principais utilizações

Diante da definição de biomateriais, sabe-se que eles terão interação com sistemas biológicos, e, para isso, é essencial que apresentem biocompatibilidade, conceito definido como “a habilidade de um material de exercer uma resposta adequada no organismo em uma aplicação específica” (WILLIAMS, 1987). Quanto mais biocompatível o material, menor o risco de inflamações indesejadas e infecções que podem comprometer o tratamento, obtendo um resultado mais perto do desejado (MARIN; BOSCHETTO; PEZZOTTI, 2020; MATEU-SANZ et al., 2024).

Os biomateriais podem ser classificados entre poliméricos, metálicos, cerâmicos e compósitos. O que diferencia essas classes são a estrutura molecular e o tipo de ligação entre os átomos (AGRAWAL et al., 2014). As diferentes composições químicas influenciam as propriedades do material, assim, cada tipo possui um conjunto de características que o torna mais ou menos adequado para cada aplicação (RAHMATI et al., 2020). Para melhor compreensão, foi elaborado o Quadro 1 com os conceitos de cada tipo de biomaterial (WILLIAM, 2020).

Quadro 1 – Tipos de biomateriais

Material	Definição
Polimérico	Compostos de moléculas grandes com base em carbono. Têm baixa densidade, são flexíveis e dúcteis, mas menos rígidos e resistentes que metais e cerâmicas. São isolantes elétricos e podem amolecer com o calor. Suas aplicações na área médica são diversas, sendo amplamente utilizados na medicina regenerativa, e na liberação controlada de fármacos. Exemplos: Ácido hialurônico, colágeno, silicone.
Metálico	Compostos por elementos metálicos e, às vezes, com adição de elementos de liga não metálicos, têm arranjos atômicos ordenados e alta densidade. São rígidos, dúcteis, resistentes e bons condutores de calor e eletricidade. Possuem aparência brilhante e, alguns, propriedades magnéticas. Na área médica, são comumente utilizados na ortopedia. Exemplos: Titânio puro e ligas, ligas de cobalto-cromo, platina.

Cerâmico	Formados por combinações de elementos metálicos e não metálicos (como óxidos e carbetos), são rígidos, resistentes e muito duros, porém frágeis. São bons isolantes térmicos e elétricos, resistentes a altas temperaturas, e podem ser transparentes ou opacos. São comuns na odontologia e na ortopedia, principalmente para a substituição de articulações. Exemplos: Alumina, hidroxiapatita, biovidro.
Compósito	Combinam dois ou mais materiais (metais, cerâmicas, polímeros) para criar propriedades melhores que os materiais individuais. Muitos são sintéticos, mas também existem compósitos naturais como madeira e osso. Exemplos: Fibra de carbono + epóxi (cerâmico + polimérico), resina para restauração dentária (cerâmico + polimérico).

Fonte: (Jr.; Rethwisch, 2020, p. 5-12)


A escolha do biomaterial a ser utilizado irá depender da aplicação, e é preciso analisar quais propriedades são necessárias para obter a resposta desejada. Com base nisso, seleciona-se o material (ou a combinação de materiais) que possui as propriedades que melhor atendem a essa demanda.

Os biomateriais ajudam os pacientes a terem uma melhor qualidade de vida, melhorando os resultados das assistências médicas (MATEU-SANZ et al., 2024). Podem auxiliar por meio de implantes, regeneração de tecidos humanos e em sistemas de *drug-delivery*, por exemplo.

Eles são essenciais para a criação de próteses, órteses e dispositivos implantáveis, como articulações artificiais, válvulas cardíacas e *stents*. Esses dispositivos têm como objetivo substituir ou restaurar a função de órgãos e estruturas comprometidas, proporcionando aos pacientes maior mobilidade, funcionalidade e qualidade de vida (STUART; WATCHORN; GU, 2023a) .

A Figura 1 abaixo ilustra alguns exemplos do uso de biomateriais. O número 1 é o ácido hialurônico sendo aplicado em uma articulação, sendo um polímero usado como líquido sinovial artificial. O número 2 é um *stent* metálico, dispositivo utilizado para manter artérias abertas e restaurar o fluxo sanguíneo, o número 3 é uma prótese de quadril, no qual a parte articular é feita de alumina, um material cerâmico, e o número 4 é a ilustração de um procedimento de resina para restauração dentária, em que se faz uso de material compósito.

Figura 1 - Exemplos de tipos de biomateriais




Fonte: Autoria própria, criado com BioRender.com

Por exemplo, no caso dos *stents* coronários, os polímeros bioabsorvíveis têm se tornado uma alternativa promissora aos *stents* metálicos convencionais. Esses polímeros se degradam gradualmente após a cicatrização do vaso sanguíneo, eliminando a necessidade de uma remoção cirúrgica posterior e reduzindo complicações relacionadas a longo prazo. Por outro lado, os *stents* metálicos, normalmente feitos de aço inoxidável ou ligas de cobalto-cromo, são escolhidos por sua alta resistência e durabilidade imediata após a implantação (ZONG et al., 2022). Assim, a escolha do biomaterial também irá depender de outros fatores, como custo do material, acesso, condição do paciente e outros.

Além dos implantes, os biomateriais desempenham um papel importante na medicina regenerativa, especialmente no desenvolvimento de arcabouços, ou *scaffolds*, tridimensionais que dão suporte para a regeneração tecidual. Esses arcabouços biodegradáveis oferecem uma base para a regeneração de tecidos danificados. Eles permitem que as células se fixem, proliferem e formem um novo tecido, degradando-se naturalmente à medida que o tecido regenerado assume sua função (O'BRIEN, 2011).

A Figura 2 ilustra as principais etapas envolvidas na fabricação de tecidos através da medicina regenerativa.

Figura 2 - Esquema de funcionamento da medicina regenerativa



Fonte: Adaptado de (WIKIPEDIA, 2024)

Dentro ainda da medicina regenerativa, muitos estudos utilizam células-tronco junto de biomateriais. Por serem capazes de se diferenciar em vários tipos celulares, as células-tronco oferecem um enorme potencial para a regeneração de tecidos complexos, como cartilagem, músculo cardíaco e osso. Células-tronco mesenquimais, por exemplo, são frequentemente incorporadas a arcabouços de biomateriais para promover a regeneração óssea e cartilaginosa, enquanto as células-tronco pluripotentes induzidas (iPSCs) têm mostrado grande potencial na regeneração de tecidos mais especializados, como o tecido cardíaco (CAO; DING, 2022).

Para regeneração de ossos e cartilagens, o colágeno e a hidroxiapatita são amplamente utilizados, pois conseguem se aproximar das propriedades mecânicas e bioquímicas do tecido original (AREVALO; BUEHLER, 2023). Esses avanços têm sido acelerados por progressos no *design* de biomateriais que imitam o microambiente celular nativo, facilitando a diferenciação celular e a formação de novos tecidos funcionais (CAO; DING, 2022).

Uma das técnicas utilizadas na medicina regenerativa é a bioimpressão 3D. Esse processo envolve a deposição camada por camada de células vivas e, opcionalmente, biomateriais, para criar órgãos ou tecidos artificiais. Materiais como hidrogéis (polímeros hidrofílicos reticulados) são amplamente utilizados devido à sua biocompatibilidade e capacidade de suportar o crescimento celular durante o processo de impressão (CUI et al., 2017).

Além disso, a bioimpressão 3D oferece um grande potencial para personalizar tratamentos médicos, permitindo a criação de tecidos específicos para cada paciente. A utilização de biomateriais na bioimpressão tem avançado com o desenvolvimento de novos compostos que melhoram a precisão e a funcionalidade das estruturas impressas, como as biotintas derivadas de colágeno ou algas marrons, que oferecem melhor mimetização do microambiente natural do tecido. Esses avanços têm acelerado o desenvolvimento de órgãos artificiais, promovendo inovações em transplantes e na regeneração de tecidos danificados (CAO; DING, 2022).

Há também a utilização de biomateriais em sistemas de *drug delivery*, sistemas que têm revolucionado a administração de medicamentos, permitindo a liberação controlada e direcionada de fármacos, o que aumenta a eficácia do tratamento e minimiza efeitos colaterais (MATEU-SANZ et al., 2024). Os biomateriais nesse caso são moldados em nanopartículas, hidrogéis e outras formas, garantindo a liberação gradual dos medicamentos no local-alvo (STUART; WATCHORN; GU, 2023a).

Recentemente, nanopartículas poliméricas têm se destacado pela capacidade de atravessar barreiras biológicas e entregar medicamentos com precisão, particularmente em tratamentos oncológicos. Além disso, alguns sistemas são projetados para reagir a mudanças no ambiente do corpo, como a acidez ou a temperatura, permitindo que o medicamento seja liberado de forma controlada, no momento certo, por exemplo, hidrogéis que se ajustam ao pH, o que torna o tratamento de doenças mais eficiente e direcionado (CAO; DING, 2022). Esses avanços posicionam os sistemas de *drug delivery* como ferramentas interessantes para terapias mais seguras e eficazes.

Portanto, é possível perceber que o avanço do uso de biomateriais nessas aplicações continua a transformar a assistência médica, oferecendo aos pacientes melhores opções de tratamento e recuperação de funções corporais que antes eram consideradas irreversíveis (CAO; DING, 2022; MEYER et al., 2023).

3.2 Inteligência Artificial

A Inteligência Artificial (IA) é um campo da ciência da computação dedicado ao desenvolvimento de sistemas que imitam a inteligência humana, sendo capazes de realizar tarefas como reconhecimento de fala, interpretação de imagens e tomada de decisões. A IA está se tornando cada vez mais integrada em nosso cotidiano, proporcionando melhorias significativas em diversas áreas, desde saúde até transporte e finanças. Um exemplo do cotidiano são as assistentes virtuais Siri e Alexa, que utilizam IA para entender e responder a comandos de voz, facilitando a vida dos usuários (STUART J. RUSSEL, 2021).

Entre as subáreas mais importantes da IA, destaca-se o *Machine Learning* (ML), em português “aprendizado de máquina”, que permite que os sistemas aprendam automaticamente a partir de grandes volumes de dados, sem serem explicitamente programados para cada situação (SCHMIDHUBER, 2015). É importante distinguir IA de ML, embora a IA seja um campo mais amplo, que envolve a criação de máquinas inteligentes, o ML é uma subárea específica da IA focada no desenvolvimento de algoritmos que melhoram com o tempo e a experiência (GOODFELLOW et al., 2016). Em outras palavras, enquanto a IA abrange qualquer sistema inteligente, o ML concentra-se em como esses sistemas podem aprender a partir de dados.

Além disso, a IA pode ser classificada em abordagens preditivas e generativas, que têm aplicações distintas. A IA preditiva concentra-se em analisar dados históricos para prever resultados futuros, sendo amplamente usada em setores como finanças e saúde, para prever eventos como flutuações de mercado ou o desenvolvimento de doenças. Essa abordagem é uma aplicação comum de ML, onde modelos são treinados para identificar padrões para antecipar possíveis cenários futuros (STUART J. RUSSEL, 2021).

Por outro lado, a IA generativa foca na criação de novos dados com características semelhantes aos dados de treinamento, sendo especialmente útil em tarefas de criação de conteúdo, como geração de imagens, textos ou até simulações de voz. Esse tipo permite que a IA produza conteúdos realistas, expandindo as possibilidades criativas e oferecendo suporte em áreas como *design* e entretenimento (GOODFELLOW et al., 2016). Essas duas abordagens ilustram a versatilidade da IA, que não apenas analisa e prevê, mas também gera novos dados, possibilitando inovações em diversos campos.

3.2.1. Modelos de ML


Diferentes algoritmos de ML são aplicados a diferentes problemas, cada um sendo mais adequado para um tipo de tarefa. Entre os algoritmos mais utilizados no âmbito da IA estão as Redes Neurais Artificiais (RNAs). Elas são inspiradas na estrutura dos neurônios biológicos e se destacam por sua capacidade de aprender padrões complexos e fazer previsões precisas, especialmente em grandes volumes de dados. As RNAs são compostas por neurônios artificiais organizados em camadas. Cada neurônio realiza uma operação matemática sobre os dados que recebe, passando as informações adiante pela rede até gerar uma saída final (GOODFELLOW et al., 2016).

As RNAs são amplamente utilizadas em IA devido à sua flexibilidade e capacidade de generalização superior em comparação a outros algoritmos. Elas são particularmente eficazes em tarefas como reconhecimento de imagem, processamento de linguagem natural e previsão de séries temporais, pois suas várias camadas conseguem identificar características abstratas e complexas nos dados (GOODFELLOW et al., 2016).

Além disso, as RNAs têm se destacado por lidar com dados complexos, sendo aplicadas em uma ampla gama de domínios, como visão computacional, reconhecimento de fala e geração de texto. Com o avanço da capacidade computacional e o aumento dos dados disponíveis, elas superam outros algoritmos e podem ser ajustadas para diferentes tipos de problemas, como classificação, regressão e segmentação de imagens (SCHMIDHUBER, 2015).

Para melhor visualização de como funciona uma RNA, segue abaixo a Figura 3 indicando a camada de entrada de dados, as camadas escondidas e a camada de saída, com o resultado do algoritmo.

Figura 3 - Exemplo esquemático de rede neural artificial



Fonte: Adaptada de (“Ciencia detrás de la magia”, 2023)

Desta forma, a IA oferece uma série de algoritmos eficientes, cada um com suas particularidades e vantagens em diferentes cenários. Enquanto redes neurais têm mostrado ser mais versáteis e eficazes em problemas complexos, como reconhecimento de padrões, as árvores de decisão e as florestas aleatórias são eficientes em tarefas de classificação e regressão, e a U-Net tem mostrado ser eficaz em análise de imagens.

3.3 Utilização da inteligência artificial na área de biomateriais

No geral, a IA na área de biomateriais vem sendo utilizada para otimizar o ciclo de inovação, desde a pesquisa até a aplicação clínica, através de técnicas de ML. Um dos esquemas adotados para treinar a máquina é o *Design-Build-Test-Learn* (DBTL), conforme descrito por (MEYER et al., 2023), que permite uma abordagem cíclica e otimizada para o desenvolvimento de novos biomateriais.

O modelo *Design-Build-Test-Learn* começa com o *design* inicial de um material com base nas características desejadas. Na fase de construção (*Build*), o material é fabricado e em seguida testado na fase de teste (*Test*), onde os dados de desempenho e comportamento do material são coletados. A fase final, de aprendizado (*Learn*), utiliza IA para analisar os dados e realimentar o processo de *design*, criando um ciclo contínuo de melhoria e inovação.

No treinamento de máquinas aplicadas a biomateriais, o aprendizado de máquina permite que grandes volumes de dados sejam usados para prever como diferentes materiais ou combinações de materiais irão se comportar. Estudos têm demonstrado que a IA pode não apenas prever características fundamentais como resposta celular, propriedades mecânicas, e comportamentos biológicos, mas também otimizar o processo de fabricação de novos materiais (MEYER et al., 2023).

3.3.1. Desafios

O uso de IA na área de biomateriais enfrenta diversos desafios, sendo um dos principais a complexidade dos dados que precisam ser usados para treinar as ML. Biomateriais são sistemas extremamente complexos, com interações que envolvem propriedades físicas, químicas e biológicas, além de variações nas respostas individuais dos pacientes. O treinamento de máquinas requer uma grande quantidade de dados de alta qualidade, e a obtenção e organização dessas informações, considerando biomateriais nas bases de dados, pode ser um processo desafiador (MATEU-SANZ et al., 2024).

Outro desafio está relacionado ao desenvolvimento de algoritmos que sejam adequados para os diferentes tipos de problemas apresentados pelos biomateriais. Embora RNAs sejam amplamente utilizadas pela sua capacidade de lidar com dados complexos, ainda há uma necessidade de adaptar essas redes para lidar com o caráter multiescalar dos biomateriais, desde as propriedades moleculares até as interações com sistemas biológicos completos (AREVALO; BUEHLER, 2023).

Além disso, a falta de padronização no processo de fabricação e caracterização de biomateriais pode ser um desafio na replicação de resultados. A diversidade de métodos e materiais também dificulta a criação de modelos universais que possam ser aplicados amplamente em diferentes contextos (STUART; WATCHORN; GU, 2023a).

Por fim, a interpretação dos resultados gerados pela IA também é um desafio. Embora modelos de ML possam gerar previsões precisas, a confiabilidade dos resultados é crucial, especialmente em contextos clínicos, onde a segurança e a eficácia devem ser completamente compreendidas antes de qualquer aplicação prática (MATEU-SANZ et al., 2024).

4 METODOLOGIA

Este trabalho tem como objetivo realizar uma revisão narrativa sobre o uso de IA na área de biomateriais. Para sua execução realizou-se uma busca pelos artigos, definindo a estratégia de busca e os critérios de inclusão e exclusão deles. Diante dos artigos encontrados em cada base de dados, realizou-se breves leituras, e para aqueles mais relevantes ao tema de estudo foi feita a extração de informações.

4.1 Busca pelos artigos

Com os objetivos definidos, pôde-se analisar quais os principais termos deveriam ser utilizados na busca pelos artigos, possibilitando também a busca por descritores de acordo com DeCS/MeSH (Descritores em Ciências da Saúde/*Medical Subject Headings*). Na estratégia de busca foi necessário a utilização dos operadores booleanos OR e AND, o primeiro entre os termos semelhantes, e o segundo para separar aqueles diferentes.

As buscas foram feitas nas bases de dados *PubMed*, *Web of Science* e *ScienceDirect*, por meio do acesso institucional oferecido pelo serviço CAFE (Comunidade Acadêmica Federada) na plataforma Periódicos CAPES. Para cada base de dados a estratégia de busca teve que ser personalizada, como mostra o Quadro 2. Além disso, foi definido os critérios de inclusão e exclusão que estão detalhados na terceira coluna do Quadro 2.

Quadro 2 - Estratégia de busca para cada base de dados

Base de dados	Termos de busca	Critérios de inclusão e exclusão
<i>PubMed</i>	(biomaterial OR biomateriais OR biomaterials OR Materiais Biocompatíveis OR Biocompatible Materials) AND (Artificial Intelligence OR AI OR IA OR Inteligência Artificial OR Machine Learning)	Inclusão: - Publicados entre 2004 e 2024 - Artigos publicados nos idiomas Inglês ou Português - Acesso total ao texto Exclusão: - Artigos do tipo revisão
<i>Web of Science</i>	(ALL=(Biomaterial OR Material Biocompatível OR Biocompatible Materials)) AND ALL=(Artificial	

	Intelligence OR Inteligência Artificial OR Machine Learning)	- Artigos que não tinham aplicações na área de
<i>ScienceDirect</i>	(Biomaterial OR Material Biocompatível OR Biocompatible Materials) AND (Artificial Intelligence OR Inteligência Artificial OR Machine Learning)	biomateriais - Artigos repetidos

Fonte: Autoria própria

A busca pelos artigos de forma clara e organizada é essencial para que sejam encontradas publicações que façam os objetivos do estudo serem atingidos. Para as especificações de busca, o intervalo de tempo das publicações escolhido foi de 2004 até os dias atuais, pois com esses 20 anos é possível realizar uma avaliação do crescimento da Inteligência Artificial na área de Biomateriais, além de analisar como se encontra o cenário atual. O idioma foi especificado para inglês e português, já que a maioria dos estudos são feitos e divulgados em inglês, e o português para que fosse possível analisar como andam essas pesquisas em nosso país. E para que aparecessem apenas as publicações que poderiam ser lidas por completo, foi selecionado a especificação de acesso total ao texto, já que muitos artigos só permitem a leitura total para aqueles que assinam a revista em que foi publicado, impedindo até mesmo que as instituições da CAFE tenham acesso.

Além disso, os artigos do tipo revisão foram excluídos para que os materiais utilizados para estudos fossem focados em pesquisas que utilizaram de fato a IA, evitando também artigos repetidos. E aqueles que não tinham aplicação na área de biomateriais, focados apenas na engenharia de materiais como um todo, foram excluídos para que não tivessem artigos fora do foco do estudo.

4.2 Extração de informações dos artigos

Diante dos artigos encontrados com a estratégia de busca elaborada, primeiro lia-se o título da publicação e, caso se enquadrasse nas buscas de interesse, lia-se o resumo para confirmar se o artigo era mesmo relevante para o estudo. Com isso, foram extraídas as informações consideradas pertinentes, como ano, país, autores, objetivo principal, principais resultados/conclusões, tipo do biomaterial utilizado, principal metodologia da *Machine Learning*, fundamento do treinamento da ML, foco de aplicação do artigo e nível de evidência.

Para isso, foi utilizada a IA Gemini para auxiliar na extração das informações desejadas com o seguinte *prompt*:

“Com base nesse texto, formule uma frase com o objetivo principal do artigo e uma frase com o principal resultado/conclusão desse artigo com foco na ML, me dizendo também qual foi sua utilização (Resposta celular, processo de fabricação, propriedades do material), o tipo de material utilizado (polimérico, metálico ou cerâmico), o nível de evidencia (*in vitro*, *in vivo*, *in silico*, protótipo), o principal método utilizado na ML e por fim, formule uma frase que explique o fundamento de treinamento da *machine learning*, indicando onde é possível verificar a utilidade da IA, como será sua função, que tipo de relação é feita e de onde vem as informações para treinar essa *machine learning*? Dê essa resposta detalhada e em português”

Todas as informações obtidas através dessa ferramenta eram cuidadosamente verificadas quanto à veracidade, sendo a IA apenas uma facilitadora para uma leitura mais focada e objetiva do artigo. Para organizar essas informações de forma sintetizada e para possibilitar uma visualização mais fácil, foi estruturado um quadro que se encontra no Apêndice A.

5 RESULTADOS E DISCUSSÃO

Diante da busca pelos artigos, descrita anteriormente, foram encontrados no total 148 artigos, sendo 23 do *PubMed*, 93 do *Web of Science* e 32 do *ScienceDirect*. Desses, apenas 24 artigos foram selecionados para análise, seguindo os critérios de inclusão e exclusão. Muitas publicações foram excluídas pois não eram estudos com aplicação na área de biomateriais, mas foi uma quantidade suficiente para realizar um levantamento satisfatório.


5.1 Ano e país da publicação

A partir da Figura 5, pode ser observada a quantidade de artigos publicados por ano sobre o tema. Em relação à quantidade total de artigos encontrados, pôde-se perceber que o tema ainda é pouco explorado, visto que foram encontrados apenas 24 artigos nos 20 anos considerados no momento da busca. Vale ressaltar também que entre 2004 e 2015 não houve publicação de nenhum artigo sobre o tema. Em outras revisões literárias sobre outros assuntos, o número de artigos encontrados normalmente é significativamente maior.

O ano de 2023 obteve destaque, com 10 artigos publicados, representando 41,67% do total dos artigos levantados. Já em 2024, houve publicação de apenas 4 artigos, porém como a busca foi feita no meio do ano de 2024, os artigos publicados na segunda metade do ano ficaram de fora desse resultado, o que pode ser uma justificativa para o baixo número de artigos.

Mesmo sendo um número baixo, só a primeira metade de 2024 já teve mais publicações do que outros anos inteiros. Ainda não se pode falar sobre tendências de crescimento de publicações sobre o tema, visto que não se tem dados conclusivos e apenas um ano apresentou um crescimento significativo. Porém, acredita-se que nos próximos anos o número de publicações deve crescer, já que o uso de IA vem crescendo de forma significativa em diversos outros setores, não havendo motivo para a área de biomateriais fugir dessa realidade (RAMOS, 2024).

Figura 5 - Quantidade de publicações por ano




Fonte: Autoria própria

Já na Figura 6, pode-se analisar esses artigos distribuídos por países e região, verificando onde se tem o maior foco desse estudo até os dias de hoje. Com o gráfico, é possível observar que os países com destaque nos últimos 20 anos são os Estados Unidos da América com 10 publicações, e a China e o Reino Unido com 4 publicações cada um. Como em diversas outras publicações relacionadas a IA, os Estados Unidos e a China lideram as pesquisas (FAPESP, 2020).

No momento da busca, houve a inclusão de artigos publicados em português, para que pudesse ser analisado como o Brasil está em relação ao tema. Porém, nenhum artigo foi publicado em português ou teve autor com filiação no Brasil, o que indica que esse tema ainda não é tão explorado no país. Além disso, é interessante observar que não há nenhum país da América Latina, o foco maior está na América do Norte e na Europa.

Figura 6 - Quantidade de publicações por país



Fonte: Autoria própria


5.2 Tipos de biomateriais estudados nos artigos selecionados

Em cada um dos 24 artigos analisados, pôde-se extrair qual o tipo de biomaterial utilizado nos estudos. Pelo gráfico da Figura 7, pode-se observar que os biomateriais mais utilizados foram os poliméricos, depois os metálicos e dois artigos realizaram estudos que abrangeram mais de um tipo de biomaterial, que foi categorizado como diversos, ou seja, a pesquisa não tinha como foco de estudo ou então aplicação um único tipo de biomaterial.

No gráfico da Figura 7, é interessante observar que em nenhum dos artigos foram utilizados exclusivamente biomateriais cerâmicos e compósitos. No entanto, eles poderiam ser incluídos na categoria dos diversos.

Dos artigos levantados, dez artigos tinham como foco de aplicação final a medicina regenerativa, então o alto número de biomateriais poliméricos pode-se dar a isso, já que é a categoria de biomateriais mais utilizada nesta aplicação (FARAG, 2023).

Figura 7 - Porcentagem de utilização de cada material



Fonte: Autoria própria

5.3 Principais metodologias da ML


Com a Figura 8, é possível perceber que a RNA foi a metodologia de ML mais utilizada nos estudos, com um total de 13 artigos dos 24 publicados (54,17%). Vale ressaltar que algumas publicações utilizaram mais de uma metodologia, logo alguns artigos estão em mais de uma contagem no gráfico. Outras metodologias que tiveram destaque foram a árvore de decisão, floresta aleatória e U-Net, cada uma em dois artigos.

A escolha do algoritmo depende muito do objetivo do estudo, de qual papel os pesquisadores querem que a IA exerça. Porém, é possível perceber que para diversas frentes de estudos, a RNA é muito utilizada. Uma das possíveis razões da RNA ter sido o modelo mais utilizado nas pesquisas é por sua capacidade de lidar com um grande volume de dados, incluindo dados complexos. Além disso, ela é flexível e tem uma capacidade de generalização superior aos demais modelos de ML. Esses são pontos facilitadores do uso na área de biomateriais, visto que para se ter um bom treinamento da ML, precisa-se de uma grande base de dados, e os dados utilizados são complexos (SCHMIDHUBER, 2015).

Como dito anteriormente, até mesmo o prêmio Nobel de Física de 2024 evidencia o impacto da IA, sendo que a *Royal Swedish Academy of Sciences*, instituição que realiza a seleção e atribuição do prêmio Nobel, disse em um comunicado que “o aprendizado de máquina baseado em redes neurais artificiais está atualmente revolucionando a ciência, a engenharia e a

vida cotidiana.” (ISMERIM, 2024). Assim, acredita-se que em futuras aplicações da IA em biomateriais, a RNA continuará sendo um algoritmo frequentemente utilizado.

Figura 8 - Modelos de ML utilizados nos artigos



Fonte: Autoria própria

5.4 Objetivo da IA

No levantamento dos artigos, foram criadas três categorias de focos de aplicação, para que pudessem ser analisadas as principais utilizações da IA na área de biomateriais. As categorias que melhor encaixavam os estudos são: resposta celular, propriedades do material e processo de fabricação. Em nenhuma delas foi observada a utilização de IA generativa, apenas IA preditiva.

A primeira categoria engloba os artigos que, com a utilização da IA, buscaram prever resposta celular. Como por exemplo no artigo de *Vermeulen e colegas (2021)*, onde a IA é utilizada para analisar superfícies naturais e identificar características topográficas únicas que podem ser aplicadas em biomateriais, e potencialmente induzindo novas respostas celulares. Ou então, como no estudo *Lan et al. (2022)*, onde a IA é usada para verificar e prever a diferenciação de células.

Já a categoria de propriedades do material engloba estudos que pretendiam prever ou correlacionar alguma propriedade dos biomateriais a partir da IA. Como por exemplo o estudo do grupo do *Raguraman (2024)*, onde o objetivo era utilizar a IA para identificar padrões e

correlações entre as propriedades mecânicas, a resistência a corrosão e a microestrutura das ligas de magnésio biodegradáveis.

E por último, a categoria de processo de fabricação foi destinada para os artigos que visavam utilizar a IA para ajustar parâmetros na fabricação de biomateriais, com base em parâmetros que foram utilizados no treinamento da ML. Como por exemplo no artigo *LIMON et al.* (2023), em que a IA foi utilizada para prever o diâmetro do filamento na técnica de extrusão da impressão 3D, com base nos parâmetros de processamento e na composição do biomaterial. Muitos estudos dessa categoria também foram contabilizados na categoria de propriedades do material, visto que muitos utilizavam as propriedades como parâmetro para fabricação.

Pelo gráfico da Figura 9, é possível observar que a maior parte dos estudos possuem um foco no processo de fabricação, sendo 16 dos 24 artigos analisados, ou seja, um percentual de 66,67%. E apenas oito artigos tiveram como foco analisar a resposta celular do biomaterial, sendo que desses oito, apenas quatro tem como foco único a resposta celular, os outros quatro possuem algum outro foco adicional. Esse baixo foco em resposta celular possivelmente se deve à complexidade do assunto e à compreensão limitada sobre as interações entre biomateriais e o microambiente biológico (RAHMATI et al., 2020).

Desta forma, pode-se dizer que a tendência é que no futuro, muitos biomateriais terão seu processo de fabricação otimizado com a utilização da IA, visto que os estudos atuais vêm apresentando resultados satisfatórios para essa aplicação. Como por exemplo o estudo de *Guan et al.* (2021), onde o objetivo era desenvolver um aprendizado de máquina capaz de compensar os efeitos do espalhamento da luz, que são causados pelas células durante a bioimpressão baseada em processamento digital de luz. O estudo obteve sucesso no resultado, criando um modelo de ML capaz de gerar automaticamente os parâmetros de impressão ideais para compensar esses efeitos, a partir de uma base de dados relativamente pequena. Porém, os autores do artigo afirmam que ainda existem alguns desafios nessa aplicação, como a adaptação da captação de imagens de estruturas 3D multicamadas, visto que o modelo criado trabalhou apenas com modelos de camada única, menos complexos. Com isso, serão gerados dados de tamanho maior, o que pode tornar o treinamento da ML mais desafiador.


Além disso, como muitos dos artigos com foco na fabricação correlacionaram as propriedades do material, também pode-se dizer que essa é uma futura tendência de utilização da IA, já que é uma boa opção para economizar tempo e recursos. Como por exemplo o estudo de *Chen et al.* (2023), que mostrou a eficiência da IA em prever a printabilidade de tintas de

biomateriais, possibilitando a previsão de uma nova formulação de tinta, indicando se será imprimível ou não.

Já sobre o foco em resposta celular, a utilização ainda é baixa comparada com as demais. Ainda não é possível indicar alguma tendência em específico, porém, os estudos analisados também apresentaram resultados satisfatórios. Como por exemplo no estudo do grupo de *Lan* (2022), onde a ML foi capaz de prever a diferenciação osteogênica de células tronco mesenquimais da medula óssea de rato em um estágio inicial, em diferentes substratos de biomateriais. No entanto, o modelo de ML desenvolvido não é capaz de analisar a célula de maneira 3D, ou seja, seu volume celular e esfericidade não são analisados, podendo ocasionar alguma perda de informação.

Para visualização dos demais resultados, o Apêndice A apresenta o resumo dos artigos levantados. Por fim, a Figura 9 mostra a quantidade de artigos para cada foco de aplicação, sendo que alguns se enquadram em mais de uma categoria, e, portanto, foram contabilizados mais de uma vez.

Figura 9 - Quantidade de artigos para cada objetivo da IA



Fonte: Autoria própria

5.5 Níveis de evidência

O levantamento dos níveis de evidência permite analisar o estágio atual das pesquisas, compreendendo melhor os resultados obtidos em cada estudo. Para entender melhor a discussão


dos resultados desse levantamento, segue uma breve explicação dos níveis mapeados nos artigos.

- *In vitro*: Estudo realizado sem a utilização de um organismo vivo, realizado em um ambiente controlado, como por exemplo um vidro;
- *In vivo*: Estudo realizado utilizando um organismo vivo, como por exemplo a utilização de ratos para análise do estudo;
- *In silico*: Estudo realizado por meio de simulações computacionais;
- Protótipo: Estudo utiliza já um modelo inicial para teste da pesquisa.

A Figura 10 mostra que 71% dos estudos são *in vitro*, essa predominância indica que a maior parte dos estudos obtiveram seus resultados a partir de condições controladas de laboratório. O que indica que as pesquisas estão em estágio inicial, já que esse costuma ser o primeiro estágio das pesquisas. O artigo em *in silico* fornece resultados computacionais satisfatórios, contribuindo para a correlação de propriedades dos biomateriais, indicando também um estudo em estágio inicial.

Já os estudos *in vivo* fornecem resultados de uma aplicação em organismo vivo, é um estágio mais avançado do que o *in vitro*, mas são estudos em animais, não foram verificados estudos em humanos ainda. Por fim, para o caso dos protótipos, os estudos já estão no estágio mais próximo da aplicação final, porém só há 3 estudos nesse estágio. Assim, espera-se que no futuro as pesquisas progridam para etapas subsequentes.

Figura 10 - Porcentagem de níveis de evidência dos artigos



Fonte: Autoria própria

6 CONCLUSÃO

O cenário atual do uso da IA preditiva na área de biomateriais mostra que este é um campo de pesquisa ainda pouco explorado, porém promissor. Como visto no levantamento, segundo os critérios de inclusão de estudos, a América Latina ainda não apresenta nenhum estudo relacionado, mas na América do Norte, Ásia e Europa, já se tem mais publicações sobre o tema, podendo ser justificado por serem potências econômicas e terem maior investimento em pesquisas. No entanto, as pesquisas ainda estão em estágios iniciais, como mostrou os resultados dos níveis de evidência.

Os estudos concentram-se majoritariamente na aplicação da IA em biomateriais voltados para a medicina regenerativa, refletindo um foco elevado em polímeros. No entanto, espera-se que no futuro, com o avanço das pesquisas, tenha a expansão do uso da IA para outras finalidades na área, envolvendo mais os outros tipos de biomateriais. Isso não apenas para diversificar os tipos de biomateriais estudados, mas também para abrir novas possibilidades para avanços científicos e inovações tecnológicas, contribuindo para uma medicina cada vez mais moderna.

Além disso, a IA será essencial também na correlação das propriedades de biomateriais, auxiliando não apenas na descoberta de novos materiais, mas também na personalização dos existentes. Sobre a aplicação da IA para análise de respostas celulares, não é possível prever algo, já que é uma área ainda pouco explorada pela compreensão limitada sobre as interações entre biomateriais e microambiente biológico.

Outra futura tendência que se pode esperar é que a utilização das Redes Neurais Artificiais continue a ser frequente, por sua capacidade de trabalhar com base de dados grandes, aprender padrões complexos e realizar previsões precisas. Junto a isso, a IA será muito importante na otimização de muitos processos de fabricação, resultando em biomateriais com características cada vez mais ajustadas às necessidades clínicas específicas.

No geral, o uso da IA preditiva em biomateriais tem um impacto positivo em termos de redução de custos e minimização do desperdício de material, devido à sua capacidade de previsão de resultados antes da fase experimental. Essa economia de recursos é muito importante, pois facilita o acontecimento de novas pesquisas. Portanto, com o estudo feito, foi possível analisar dados referentes ao contexto atual da utilização da IA na área de biomateriais,

bem como entender seus desafios e prever futuras tendências dessas aplicações, mostrando ser um assunto ainda pouco explorado, mas com um futuro promissor.

REFERÊNCIAS

- AKKACHE, A. et al. Machine Learning-Based Prediction of Immunomodulatory Properties of Polymers: Toward a Faster and Easier Development of Anti-Inflammatory Biomaterials. **Advanced NanoBiomed Research**, v. 4, n. 3, 2024.
- AREVALO, S. E.; BUEHLER, M. J. Learning from nature by leveraging integrative biomateriomics modeling toward adaptive and functional materials. **MRS Bulletin**, v. 48, n. 11, p. 1140–1153, 2023.
- CAO, D.; DING, J. Recent advances in regenerative biomaterials. **Regenerative Biomaterials**, v. 9, n. December, 2022.
- CHEN, H. et al. Machine Learning in Predicting Printable Biomaterial Formulations for Direct Ink Writing. **Research**, v. 6, p. 1–11, 2023.
- Ciencia detrás de la magia.** Disponível em: <<https://www.cienciasinseso.com/redes-neuronales/>>.
- COBB, J. S.; SEALE, M. A.; JANORKAR, A. V. Evaluation of machine learning algorithms to predict the hydrodynamic radii and transition temperatures of chemo-biologically synthesized copolymers. **Computers in Biology and Medicine**, v. 128, n. August 2020, p. 104134, 2021.
- DHALIWAL, A. et al. Profiling stem cell states in three-dimensional biomaterial niches using high content image informatics. **Acta Biomaterialia**, v. 45, p. 98–109, 2016.
- DOUEST, Y. et al. Machine learning-guided exploration and experimental assessment of unreported compositions in the quaternary Ti-Zr-Cu-Pd biocompatible metallic glass system. **Acta Biomaterialia**, v. 175, p. 411–421, 2024.
- FARAG, M. M. Recent trends on biomaterials for tissue regeneration applications: review. **Journal of Materials Science**, v. 58, n. 2, p. 527–558, 2023.
- FAPESP (São Paulo). Publicações científicas sobre inteligência artificial. **Pesquisafapesp**, [S. l.], p. 1-2, 19 maio 2020. Disponível em: <https://revistapesquisa.fapesp.br/publicacoes-cientificas-sobre-inteligencia-artificial1/>. Acesso em: 4 out. 2024.
- FORSHAW, R. J. The practice of dentistry in ancient Egypt. **British Dental Journal**, v. 206, n. 9, p. 481–486, 2009.
- GOLBABAEI, M. H. et al. Machine learning-guided morphological property prediction of 2D electrospun scaffolds: the effect of polymer chemical composition and processing parameters. **RSC Advances**, v. 14, n. 22, p. 15178–15199, 2024.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. London, England: [s. n.], 2016.
- GUAN, J. et al. Compensating the cell-induced light scattering effect in light-based bioprinting using deep learning. **Biofabrication**, v. 14, n. 1, 2022.

HAO, H. et al. A paradigm for high-throughput screening of cell-selective surfaces coupling orthogonal gradients and machine learning-based cell recognition. **Bioactive Materials**, v. 28, n. May, p. 1–11, 2023.

INTRODUCTION: Definitions. In: AGRAWAL, C. Mauli; ONG, Joo L.; APPLEFORD, Mark R.; MANI, Gopinath. **Introduction to Biomaterials: Basic Theory with Engineering Applications**. [S. l.: s. n.], 2014.

ISMERIM, Flávio. Entenda o trabalho de IA que recebeu o Nobel de Física deste ano: Um dos ganhadores do prêmio deixou o Google em 2023 para poder falar sobre os perigos da inteligência artificial. **CNN Brasil**, [S. l.], p. 1-2, 8 out. 2024. Disponível em: <https://www.cnnbrasil.com.br/tecnologia/entenda-o-trabalho-de-ia-que-recebeu-o-nobel-de-fisica-deste-ano/>. Acesso em: 19 out. 2024.

IZONIN, I. et al. PNN-SVM Approach of Ti-Based Powder's Properties Evaluation for Biomedical Implants Production. **Computers, Materials and Continua**, v. 71, n. 2, p. 5933–5947, 2022.

JR., William D C. **Ciência e Engenharia de Materiais - Uma Introdução**. 10th ed. Rio de Janeiro: LTC, 2020. E-book. p. 5-12. ISBN 9788521637325. Disponível em: <https://integrada.minhabiblioteca.com.br/reader/books/9788521637325/>. Acesso em: 19 out. 2024.

KRUEGER, C. et al. Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions. **Current Reviews in Musculoskeletal Medicine**, v. 13, n. 1, p. 69–76, 2020.

LAN, Y. et al. Morphology-Based Deep Learning Approach for Predicting Osteogenic Differentiation. **Frontiers in Bioengineering and Biotechnology**, v. 9, n. January, p. 1–13, 2022.

LIMON, S. M. et al. Advancing scaffold porosity through a machine learning framework in extrusion based 3D bioprinting. **Frontiers in Materials**, v. 10, n. February, p. 1–13, 2023.

LOH, W. Y. Fifty years of classification and regression trees. **International Statistical Review**, v. 82, n. 3, p. 329–348, 2014.

MARIN, E.; BOSCHETTO, F.; PEZZOTTI, G. Biomaterials and biocompatibility: An historical overview. **Journal of Biomedical Materials Research - Part A**, v. 108, n. 8, p. 1617–1633, 2020.

MARKOVIĆ, G. et al. Predicting Low-Modulus Biocompatible Titanium Alloys Using Machine Learning. **Materials**, v. 16, n. 19, 2023.

MATEU-SANZ, M. et al. Redefining biomaterial biocompatibility: challenges for artificial intelligence and text mining. **Trends in Biotechnology**, v. 42, n. 4, p. 402–417, 2024.

MEYER, T. A. et al. A User's Guide to Machine Learning for Polymeric Biomaterials. **ACS Polymers Au**, v. 3, n. 2, p. 141–157, 2023.

MICHA, R. 乳鼠心肌提取 HHS Public Access. **Physiology & behavior**, v. 176, n. 1, p. 100–106, 2017.

NAVAB, N. et al. Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015: 18th International Conference Munich, Germany, October 5-9, 2015 proceedings, part III. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, v. 9351, n. Cvd, p. 12–20, 2015.

NGO, T. B. et al. Label-free cleared tissue microscopy and machine learning for 3D histopathology of biomaterial implants. **Journal of Biomedical Materials Research - Part A**, v. 111, n. 6, p. 840–850, 2023.

O'BRIEN, F. J. Biomaterials & scaffolds for tissue engineering. **Materials Today**, v. 14, n. 3, p. 88–95, 2011.

PEEPLS, J. K. et al. Jointly Optimized Spatial Histogram UNET Architecture (JOSHUA) for Adipose Tissue Segmentation. **BME Frontiers**, v. 2022, 2022.

PENG, B. et al. Machine learning-enabled constrained multi-objective design of architected materials. **Nature Communications**, v. 14, n. 1, p. 1–12, 2023.

PROBST, P.; WRIGHT, M. N.; BOULESTEIX, A. L. Hyperparameters and tuning strategies for random forest. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 9, n. 3, p. 1–19, 2019.

RAGURAMAN, S. et al. Machine learning-guided accelerated discovery of structure-property correlations in lean magnesium alloys for biomedical applications. **Journal of Magnesium and Alloys**, v. 12, n. 6, p. 2267–2283, 2024.

RAHMATI, M. et al. Biological responses to physicochemical properties of biomaterial surface. **Chemical Society Reviews**, v. 49, n. 15, p. 5178–5224, 2020.

RAMOS, Marien. Uso de Inteligência Artificial aumenta e alcança 72% das empresas, diz pesquisa: Avanço é significativo comparado aos 55% em 2023. **CNN Brasil**, [S. l.], 8 jun. 2024. Disponível em: <https://www.cnnbrasil.com.br/economia/negocios/uso-de-inteligencia-artificial-aumenta-e-alcanca-72-das-empresas-diz-pesquisa/#:~:text=O%20interesse%20no%20uso%20da,comparado%20aos%2055%25%20em%202023>. Acesso em: 4 out. 2024.

ROSTAM, H. M. et al. Immune-Instructive Polymers Control Macrophage Phenotype and Modulate the Foreign Body Response In Vivo. **Matter**, v. 2, n. 6, p. 1564–1581, 2020.

SCHMIDHUBER, J. Deep Learning in neural networks: An overview. **Neural Networks**, v. 61, p. 85–117, 2015.

SEFIK ILKIN SERENGIL. **How Random Forests Can Keep You From Decision Tree**. Disponível em: <https://sefiks.com/2017/11/19/how-random-forests-can-keep-you-from-decision-tree/>.

STUART J. RUSSEL, P. N. Artificial Intelligence A Modern Approach (fourth edition). **Angewandte Chemie International Edition**, 6(11), 951–952., p. 5–10, 2021.

STUART, S.; WATCHORN, J.; GU, F. X. Sizing up feature descriptors for macromolecular machine learning with polymeric biomaterials. **npj Computational Materials**, v. 9, n. 1, p. 1–10, 2023a.

STUART, S.; WATCHORN, J.; GU, F. X. An interpretable machine learning framework for modelling macromolecular interaction mechanisms with nuclear magnetic resonance. **Digital Discovery**, v. 2, n. 6, p. 1697–1709, 2023b.

SUN, M. et al. Fast extraction of three-dimensional nanofiber orientation from WAXD patterns using machine learning. **IUCrJ**, v. 10, n. Pt 3, p. 297–308, 2023.

TOURLOMOUSIS, F. et al. Machine learning metrology of cell confinement in melt electrowritten three-dimensional biomaterial substrates. **Microsystems and Nanoengineering**, v. 5, n. 1, 2019.

VERHEYEN, C. A. et al. Integrated data-driven modeling and experimental optimization of granular hydrogel matrices. **Matter**, v. 6, n. 3, p. 1015–1036, 2023.

VERMEULEN, S. et al. Expanding Biomaterial Surface Topographical Design Space through Natural Surface Reproduction. **Advanced Materials**, v. 33, n. 31, 2021.

VYAS, N. et al. A quantitative method to measure biofilm removal efficiency from complex biomaterial surfaces using SEM and image analysis. **Scientific Reports**, v. 6, n. August, p. 2–11, 2016.

WANG, Z. et al. Machine learning unifies flexibility and efficiency of spinodal structure generation for stochastic biomaterial design. **Scientific Reports**, v. 13, n. 1, p. 1–15, 2023.

WIKIPEDIA. **Tissue engineering**. Disponível em: <https://en.wikipedia.org/wiki/Tissue_engineering>.

ZONG, J. et al. Advances in the development of biodegradable coronary stents: A translational perspective. **Materials Today Bio**, v. 16, n. July, 2022.

APÊNDICE A – RESUMO DOS ARTIGOS

O quadro abaixo mostra um resumo dos artigos levantados. Para visualização completa do levantamento dos estudos, segue o *link* para acessar a planilha com os todos os campos: Ano; País; Autores; Objetivo; Principais resultados/conclusões; Tipo do material; Principal metodologia da ML; Fundamento do treinamento da ML; Utilização; Nível de evidência.

Link: [Resumo dos artigos.xlsx](#)

Artigo	Objetivo	Principais resultados/conclusões	Fundamento do treinamento da ML
(ROSTAM et al., 2020)	O estudo visa utilizar técnicas de aprendizado de máquina para identificar padrões moleculares em polímeros que permitam prever e modular a resposta imune, visando a criação de novos materiais bioestruturais com inúmeras aplicações clínicas, desde implantes e adjuvantes de vacinas até medicina regenerativa e drug delivery	A identificação de novos polímeros com propriedades imunomoduladoras e a elucidação dos mecanismos moleculares envolvidos oferecem possibilidades interessantes para a criação de novos materiais bioestruturais com inúmeras aplicações clínicas, desde implantes e adjuvantes de vacinas até medicina regenerativa e fornecimento de medicamentos. Abertura de portas de novas perspectivas para o design de biomateriais inteligentes	Identificação de padrões nas relações entre a estrutura química dos polímeros e a resposta imune, permitindo prever como um novo polímero irá interagir com o sistema imune
(HAO et al., 2023)	Criar uma configuração de triagem de alto rendimento para estudar a funcionalização da superfície de biomateriais, integrando a química de superfície de tiol-eno fotocontrolada e a identificação e estatística de células sem rótulos baseadas em aprendizado de máquina	Este trabalho forneceu um método de alto rendimento para investigar o comportamento de células co-cultivadas em superfícies de biomateriais modificadas com moléculas funcionais combinatórias	Combina técnicas de segmentação e classificação de imagens para analisar automaticamente imagens de células em co-cultura, permitindo a identificação e contagem de diferentes tipos celulares sem a necessidade de métodos tradicionais mais demorados e invasivos
(STUART; WATCHORN ; GU, 2023)	Desenvolver um modelo de aprendizado de máquina capaz de prever e interpretar as interações entre polímeros e proteínas, utilizando dados de ressonância magnética nuclear (RMN), beneficiando pesquisadores focados no desenvolvimento de polímeros	O artigo apresentou um modelo de aprendizado de máquina capaz de prever com precisão as interações entre macromoléculas a partir de dados de RMN. A interpretabilidade do modelo permitiu aos pesquisadores identificar os principais fatores que influenciam essas interações	O aprendizado de máquina foi utilizado para prever e interpretar as interações entre macromoléculas, como proteínas e ácidos nucleicos, a partir de dados experimentais de RMN
(SUN et al., 2023)	Desenvolver um método de aprendizado de máquina para extrair rapidamente a orientação tridimensional de nanofibras a partir de padrões de difração de raios X (WAXD)	Aprendizado de máquina capaz de prever com precisão a orientação tridimensional de nanofibras em materiais biológicos a partir de dados de difração de raios X microfocados. Ela é capaz de analisar grandes volumes de dados de forma rápida e automática. A IA é utilizada para estabelecer uma relação entre os padrões de difração e as orientações das nanofibras, auxiliando na análise e compreensão da estrutura desses materiais	O modelo de aprendizado de máquina foi treinado com um grande conjunto de dados simulados, representando diferentes orientações de nanofibras. O modelo aprende a relação entre os padrões de difração e as orientações correspondentes, permitindo a previsão rápida e precisa a partir de novos dados

Fonte: Autoria própria

Artigo	Objetivo	Principais resultados/conclusões	Fundamento do treinamento da ML
(VERHEYEN et al., 2023)	Utilizar ferramentas de inteligência artificial para acelerar e aprimorar o processo de criação de materiais complexos como os hidrogéis granulares	Criação de um pipeline de aprendizado de máquina capaz de prever as propriedades de matrizes de hidrogel granulares, com base em seus parâmetros de composição e processamento. Identificando as melhores combinações de parâmetros para obter as propriedades desejadas	O modelo foi treinado com dados experimentais sobre as relações entre os parâmetros de composição e processamento das matrizes de hidrogel e as propriedades resultantes. Podendo identificar padrões complexos nos dados experimentais e construir modelos preditivos que podem ser utilizados para orientar o processo de fabricação e otimizar as propriedades dos materiais
(RAGURAM AN et al., 2024)	Investigar a relação entre a microestrutura, as propriedades mecânicas e a resistência à corrosão de ligas de magnésio biodegradáveis, utilizando técnicas de aprendizado de máquina para identificar padrões e correlações	A machine learning atuou como uma ferramenta poderosa para extração de insights valiosos dos dados experimentais, permitindo uma compreensão mais profunda da relação entre a microestrutura e as propriedades das ligas de magnésio e, consequentemente, contribuindo para o desenvolvimento de materiais mais eficientes para aplicações biomédicas, podendo identificar relações complexas e prever propriedades	O modelo de LASSO, que seleciona automaticamente as variáveis mais importantes em um modelo de regressão linear, foi treinado utilizando um conjunto de dados que incluía informações sobre a microestrutura, a dureza e a resistência à corrosão das ligas de magnésio
(DOUEST et al., 2024)	Avaliar a capacidade de um modelo de aprendizado de máquina em prever a capacidade de formação de vidro (GFA) de ligas metálicas amorfas (BMGs) à base de titânio com baixo teor de cobre	O modelo de machine learning, embora tenha mostrado potencial para prever a GFA de BMGs, apresentou limitações em relação à precisão das previsões para composições específicas	A ML foi treinada com um conjunto de dados de composições de ligas metálicas, incluindo informações sobre os elementos presentes e as propriedades experimentais associadas à capacidade de formação de vidro (GFA). Permitiu uma exploração eficiente do espaço composicional de ligas metálicas e a identificação de novas
(GOLBABAEI et al., 2024)	Desenvolver um modelo de aprendizado de máquina capaz de prever as propriedades morfológicas de scaffolds (arcabouços) eletrofiados (diâmetro das fibras e condutividade) com base na composição química do polímero e nos parâmetros de processamento	Demonstração da eficácia de um modelo de machine learning na previsão do diâmetro de fibras eletrofiados	As informações para treinar a máquina vieram de um conjunto de dados de scaffolds eletrofiados, onde cada amostra era descrita por sua composição química, parâmetros do processo e propriedades morfológicas. Ela estabelece uma relação entre a estrutura química dos polímeros e as propriedades dos scaffolds eletrofiados, permitindo uma maior compreensão e controle sobre o processo de fabricação

Fonte: Autoria própria

Artigo	Objetivo	Principais resultados/conclusões	Fundamento do treinamento da ML
(LIMON et al., 2024)	Desenvolver um modelo de aprendizado de máquina capaz de prever o diâmetro do filamento em scaffolds impressos em 3D utilizando a técnica de extrusão, com base em diferentes parâmetros de processamento e composição do biomaterial	Criação de um modelo de regressão que consegue prever com precisão o diâmetro do filamento em scaffolds impressos em 3D	O modelo foi treinado com um conjunto de dados de 157 experimentos, utilizando diferentes combinações de parâmetros de processo e composição do biomaterial. A máquina aprendeu a relacionar esses parâmetros com a largura do filamento, permitindo fazer previsões precisas
(GUAN et al., 2021)	Desenvolver um modelo de aprendizado de máquina capaz de compensar os efeitos do espalhamento da luz causados pelas células durante a bioimpressão baseada em processamento digital de luz (DLP), melhorando a precisão do processo e reduzindo a necessidade de ajustes manuais	Criação de um modelo de aprendizado profundo que pode aprender a partir de um pequeno conjunto de dados de impressão e gerar automaticamente os parâmetros de impressão ideais para compensar os efeitos do espalhamento da luz, melhorando a resolução da impressão intra-camada	O método utiliza apenas 32 amostras de impressão como dados de treinamento. Ele é baseado na análise de pares de máscaras digitais e imagens correspondentes das estruturas impressas. O algoritmo aprende a relação entre as máscaras e as estruturas impressas, permitindo gerar máscaras deformadas para compensar o efeito de espalhamento da luz
(VERMEULEN et al., 2021)	Busca expandir as possibilidades de design de superfícies para biomateriais, usando a natureza como inspiração e a inteligência artificial como ferramenta para analisar os resultados, com o objetivo de induzir respostas celulares específicas	Demonstração de que algoritmos de machine learning podem ser utilizados para analisar as superfícies naturais e identificar características topográficas únicas que podem ser transferidas para biomateriais, ampliando o espaço de design e potencialmente induzindo novas respostas celulares	A máquina é treinada com dados sobre as características dimensionais das superfícies naturais e artificiais, bem como com dados sobre a resposta celular a essas superfícies. A IA pode ser usada para identificar padrões nas superfícies naturais e prever como essas superfícies podem afetar o comportamento celular. Ela pode também ajudar a projetar novas superfícies topográficas com propriedades específicas
(PEEPLES et al., 2022)	Desenvolver um algoritmo de aprendizado de máquina para quantificar a deposição de tecido adiposo em locais cirúrgicos como uma função da implantação de biomateriais. A função de implantação de biomateriais é fornecer suporte estrutural ou funcional para tecidos danificados ou perdidos	O estudo apresenta um novo modelo de aprendizado de máquina, chamado JOSHUA+, que é altamente benéfico para a identificação e localização do tecido adiposo em imagens histológicas de implantes de fibroína de seda. O modelo utiliza camadas de histograma espacial para extrair informações de textura estatística e espacial, melhorando assim o desempenho da segmentação	O modelo foi treinado utilizando um conjunto de imagens histológicas rotuladas manualmente. Essas imagens foram usadas para ensinar o modelo a identificar regiões de tecido adiposo e tecido de fundo. O modelo aprende a reconhecer padrões visuais nas imagens, como diferenças de textura, cor e distribuição espacial, para realizar a segmentação. Essa relação entre as características das imagens e as classes de interesse é aprendida durante o treinamento, permitindo que o modelo faça previsões precisas em novas imagens

Fonte: Autoria própria

Artigo	Objetivo	Principais resultados/conclusões	Fundamento do treinamento da ML
(CHEN et al., 2023)	Desenvolver e avaliar algoritmos de aprendizado de máquina para prever a printabilidade de tintas de biomateriais utilizadas na impressão 3D	Demonstração da eficácia de algoritmos de aprendizado de máquina na previsão da printabilidade de tintas de biomateriais. Acelerando significativamente o processo de desenvolvimento de novos materiais para impressão 3D, reduzindo o número de experimentos necessários	Estabelece uma relação entre a composição da tinta e sua printabilidade, possibilitando a previsão de uma nova formulação de tinta, indicando se será imprimível ou não. Esses padrões são aprendidos a partir de um conjunto de dados de tintas que já foram testadas
(TOURLO MOUSIS et al., 2019)	Desenvolver e caracterizar um sistema para controlar a forma e o comportamento de células através da manipulação precisa da arquitetura de substratos tridimensionais feitos de polímero. Os autores buscam estabelecer uma relação direta entre a geometria do material e a resposta celular, abrindo caminho para novas aplicações em engenharia de tecidos e medicina regenerativa	Através da aplicação de técnicas de aprendizado de máquina, os autores demonstraram que é possível classificar com alta precisão os estados de confinamento celular com base em características morfológicas extraídas de imagens de microscopia. A inteligência artificial foi crucial para identificar padrões complexos nas imagens e correlacioná-los com as diferentes arquiteturas dos substratos, revelando a capacidade da ML de extrair informações biológicas relevantes a partir de dados visuais	O treinamento da ML neste estudo consistiu em fornecer à IA um grande conjunto de dados de imagens de células em diferentes ambientes, juntamente com rótulos que indicavam a arquitetura do substrato e o comportamento celular correspondente, permitindo que a IA aprendesse a identificar padrões visuais associados a cada condição experimental
(WANG et al., 2023)	Desenvolver um modelo de aprendizado de máquina capaz de gerar eficientemente estruturas espinodais para biomateriais, substituindo os modelos físicos tradicionais	Criação de uma rede neural convolucional capaz de simular de forma rápida e precisa a decomposição espinodal, permitindo a geração eficiente de estruturas espinodais com diferentes características	Simula a evolução temporal da decomposição espinodal, ou seja, como uma estrutura inicial se transforma ao longo do tempo em uma estrutura porosa complexa, permitindo a criação de materiais com propriedades personalizadas de forma rápida e eficiente. Esse aprendizado é baseado em um grande número de simulações realizadas utilizando um modelo físico de referência (modelo de campo de fase)
(AKKACHE et al., 2024)	Desenvolver um modelo de Machine Learning (ML) para prever as propriedades anti-inflamatórias de polímeros, acelerando assim o desenvolvimento de biomateriais anti-inflamatórios	Demonstrou que a ML pode ser utilizada para prever as propriedades anti-inflamatórias de polímeros com base em um conjunto de dados relativamente pequeno. Sendo uma ferramenta valiosa para acelerar o desenvolvimento de biomateriais anti-inflamatórios, permitindo a seleção mais rápida e eficiente de candidatos promissores	Demonstrou que a ML pode ser utilizada para prever as propriedades anti-inflamatórias de polímeros com base em um conjunto de dados relativamente pequeno. Sendo uma ferramenta valiosa para acelerar o desenvolvimento de biomateriais anti-inflamatórios, permitindo a seleção mais rápida e eficiente de candidatos promissores

Fonte: Autoria própria

Artigo	Objetivo	Principais resultados/conclusões	Fundamento do treinamento da ML
(PENG et al., 2023)	Desenvolver um método eficiente para o projeto multi-objetivo de materiais arquitetônicos 3D-impressos utilizando técnicas de machine learning (ML)	O método proposto foi capaz de projetar arquiteturas heterogêneas de materiais arquitetônicos com propriedades mecânicas superiores aos designs uniformes tradicionais. A máquina é capaz de prever as propriedades de novas estruturas com alta precisão, acelerando significativamente o processo de desenvolvimento de novos materiais	As informações para treinar a máquina vêm das simulações numéricas (FEM). Essas simulações são realizadas em um grande número de estruturas diferentes, gerando um conjunto de dados que relaciona as características geométricas das estruturas com suas propriedades mecânicas. A IA é uma ferramenta poderosa para explorar o espaço de design de materiais arquitetônicos e encontrar soluções inovadoras para problemas complexos
(LAN et al., 2022)	Desenvolver um modelo de aprendizado profundo (deep learning) capaz de prever a diferenciação osteogênica de células tronco mesenquimais da medula óssea de rato (rBMSCs) em um estágio inicial, baseado em imagens de microscopia confocal de varredura a laser (LSCM) de célula única	O modelo de aprendizado profundo desenvolvido, chamado OCN (Osteogenic Convolutional Neural Network), superou outros métodos na previsão da diferenciação osteogênica. O OCN foi capaz de prever a diferenciação em diferentes substratos de biomateriais, primeiro com um recobrimento de titânio, depois com um polimérico. A IA, através do modelo OCN, pode ser utilizada para triagem de drogas e biomateriais com potencial para induzir a diferenciação osteogênica	A função do OCN é classificar imagens de células e prever o estágio de diferenciação osteogênica. A relação feita é entre a morfologia celular (características visuais) e o estágio de diferenciação. As informações para treinar a máquina vêm das imagens de LSCM capturadas em diferentes tempos de diferenciação, juntamente com dados de marcadores bioquímicos convencionais usados para confirmar a diferenciação osteogênica
(IZONIN et al., 2022)	Desenvolver um método inteligente para avaliar as propriedades de pós de titânio utilizados na produção de implantes biomédicos por meio de tecnologias aditivas	O método proposto demonstra uma acurácia significativa na classificação das propriedades dos pós de titânio, alcançando 91%. Isso permite uma avaliação mais eficiente e precisa desses materiais antes do processo de fabricação dos implantes, reduzindo o risco de defeitos e aumentando a qualidade final dos produtos	O treinamento da máquina ocorre com base em um conjunto de dados que contém informações sobre as propriedades dos pós de titânio, incluindo características como tamanho, forma, composição química e distribuição de tamanho de partículas. A IA estabelece relações entre essas características e as classes de qualidade dos pós, aprendendo a prever a qualidade do material final com base nos dados de entrada. Essa capacidade de aprendizado permite a avaliação inteligente das propriedades dos pós, contribuindo para a otimização do processo de fabricação de implantes biomédicos

Fonte: Autoria própria

Artigo	Objetivo	Principais resultados/conclusões	Fundamento do treinamento da ML
(MARKOVIĆ et al., 2023)	Prever a composição de ligas de titânio biocompatíveis com baixo módulo de Young, utilizando técnicas de aprendizado de máquina	O principal resultado do estudo é a identificação do calor específico como o parâmetro mais influente na redução do módulo de Young das ligas de titânio. A técnica de aprendizado de máquina utilizada foi a Regressão Extra Tree, que demonstrou ser eficaz na previsão do módulo de Young a partir da composição da liga	A máquina foi treinada utilizando um banco de dados de ligas de titânio biocompatíveis, contendo informações sobre a composição química, módulo de Young, propriedades mecânicas e térmicas. A IA é capaz de identificar padrões e relações entre essas informações, permitindo prever o módulo de Young de novas ligas com base na sua composição
(VYAS et al., 2016)	Desenvolver e validar um protocolo de análise de imagem para quantificar a remoção de biofilme em superfícies de biomateriais complexos utilizando microscopia eletrônica de varredura (MEV)	Demonstração da eficácia de algoritmos de aprendizado de máquina para segmentar biofilme em imagens de MEV, permitindo uma quantificação precisa da área de biofilme removida	O treinamento da máquina envolveu a seleção de regiões de interesse (ROIs) nas imagens, que foram manualmente classificadas como biofilme ou superfície. A partir dessas amostras, o algoritmo aprendeu a distinguir entre as duas classes, criando um classificador que pode ser aplicado automaticamente para segmentar o restante das imagens
(COBB; SEALE; JANORKA R, 2020)	Desenvolver e avaliar modelos de aprendizado de máquina para prever o raio hidrodinâmico (Rh) e a temperatura de transição (Tt) de copolímeros quimicamente-biologicamente sintetizados	A utilização da ML neste contexto foi fundamental para entender e prever as propriedades físicas dos copolímeros, o que é crucial para seu desenvolvimento e aplicação em diversas áreas, como entrega de fármacos e engenharia de tecidos	O treinamento da máquina envolveu a construção de um conjunto de dados com informações sobre as condições experimentais (concentração de sal, pH, concentração do polímero e tipo de polímero) e os valores correspondentes de Rh e Tt. Esses dados foram utilizados para treinar o modelo de ML, que aprendeu a identificar padrões e relações entre as variáveis de entrada e saída. A utilidade da IA neste caso está em sua capacidade de analisar grandes quantidades de dados e identificar complexas relações entre as variáveis, o que seria difícil ou impossível para um humano fazer manualmente. O modelo treinado pode então ser usado para prever o Rh e Tt de novos copolímeros sob diferentes condições, acelerando o processo de desenvolvimento e otimização desses materiais

Fonte: Autoria própria

Artigo	Objetivo	Principais resultados/conclusões	Fundamento do treinamento da ML
(NGO et al., 2023)	Apresentar um novo método para examinar a interação entre biomateriais e tecidos, utilizando microscopia de folha de luz e aprendizado de máquina para visualizar e contrastar estruturas anatômicas em tecidos transparentes	O estudo demonstrou que a ML pode ser aplicada para segmentar diferentes tipos de tecido e biomateriais no local de implantação. O algoritmo K-Means foi utilizado para classificar os pixels da imagem em diferentes clusters, representando músculo, vaso sanguíneo, espaço intersticial e biomaterial. A IA foi útil para automatizar o processo de segmentação de imagens, permitindo a análise eficiente de grandes volumes de dados	A máquina foi treinada com dados de intensidade, textura e localização dos pixels da imagem. As informações foram utilizadas para classificar os pixels em diferentes categorias, como músculo, vaso sanguíneo, espaço intersticial e biomaterial. A máquina utiliza essas informações para estabelecer relações entre as características dos pixels e as categorias correspondentes, permitindo a classificação de novos pixels de forma automática
(DHALIWA L et al., 2016)	Desenvolver e validar uma nova metodologia para analisar e classificar, de forma precisa e precoce, o estado de diferenciação de células tronco mesenquimais humanas (hMSCs) cultivadas em diferentes tipos de arcabouços tridimensionais, utilizando a organização espacial da proteína SC-35 como biomarcador e ferramentas de aprendizado de máquina	Demonstração de que a análise de imagens tridimensionais da organização da proteína SC-35, combinada com técnicas de aprendizado de máquina, permite a criação de um modelo preditivo capaz de classificar com alta precisão os diferentes estados de diferenciação das hMSCs em scaffolds tridimensionais, mesmo em estágios iniciais do processo	O treinamento da máquina consistiu em alimentar o algoritmo com um grande conjunto de dados de imagens de células em diferentes estados de diferenciação, onde cada imagem era associada à seu respectivo estado. A IA, por meio da árvore de decisão, aprendeu a identificar padrões nas imagens que permitiram a distinção entre as diferentes classes. Dessa forma, a IA é capaz de analisar novas imagens de células e prever seu estado de diferenciação de forma rápida e precisa, auxiliando os pesquisadores a entender como os diferentes scaffolds influenciam o comportamento das células tronco

Fonte: Autoria própria