

Aplicação de IA Generativa na Modelagem 3D: Um Estudo para Apoio a Linhas de Pesquisa

Gustavo Vieira de Mattos (CTI)^{1,2}, Leonardo M. R. Machado (CTI)¹, Pedro Y. Noritomi (CTI)¹

{gvmattos, leonardo.machado, pedro.noritomi}@cti.gov.br

**¹Laboratório aberto de impressão 3D – LAPRINT
CTI/MCTI Renato Archer – Campinas/SP**

**²Faculdade de Engenharia Mecânica
Universidade Estadual de Campinas – Campinas/SP**

Abstract. *This article discusses the potential of generative artificial intelligence (AI) for creating three-dimensional (3D) anatomical models in surgical planning and research. Using a mandibular model previously developed in Rhinoceros software as reference, the study analyzes how techniques such as generative adversarial networks and multimodal transformers can accelerate and automate the modeling process. Generative AI offers significant gains in speed, scalability, and reproducibility, but challenges remain regarding geometric fidelity, clinical validation, and integration with medical systems.*

Resumo. *Este artigo discute o potencial da inteligência artificial (IA) generativa na criação de modelos anatômicos tridimensionais (3D) para planejamento cirúrgico e pesquisa. Utilizando como referência um modelo de mandíbula previamente desenvolvido no software Rhinoceros, o estudo analisa como técnicas como redes adversariais generativas e transformadores multimodais podem acelerar e automatizar o processo de modelagem. A IA generativa oferece ganhos relevantes em rapidez, escalabilidade e reprodutibilidade, mas ainda enfrenta desafios relacionados à fidelidade geométrica, validação clínica e integração com sistemas médicos.*

1. Introdução

A modelagem tridimensional tornou-se uma ferramenta essencial para pesquisas laboratoriais e estudos aplicados em anatomia, devido à sua capacidade de representar estruturas biológicas com precisão e realismo. Modelos digitais de ossos e órgãos permitem análises detalhadas e simulações biomecânicas, oferecendo um suporte decisivo tanto para a pesquisa quanto para a prática médica.

Com o aumento da demanda por precisão e velocidade em ambientes clínicos e acadêmicos, a modelagem tradicional baseada em softwares CAD e técnicas manuais revela limitações como a demora e a complexidade de uso do software, que exige alto grau de especialização e que nem sempre consegue atender às necessidades de tempo real impostas por procedimentos cirúrgicos ou por experimentações em laboratório.

Nesse cenário, a Inteligência Artificial (IA) generativa surge como uma inovação promissora, oferecendo ferramentas capazes de automatizar etapas críticas da criação de

modelos 3D. Entre as abordagens mais relevantes, destacam-se as Redes Adversariais Generativas (GANs), que utilizam a interação entre um gerador e um discriminador para produzir geometrias cada vez mais realistas e já demonstraram grande potencial na reconstrução de estruturas anatômicas a partir de exames médicos, mesmo em situações em que os dados de imagem estão incompletos ou apresentam ruído. Outra linha importante são os Autoencoders Variacionais (VAEs), que permitem representar informações complexas em um espaço latente e, a partir dele, gerar variações morfológicas de uma mesma estrutura anatômica, preservando características essenciais e possibilitando análises comparativas em diferentes cenários clínicos. Mais recentemente, os transformadores multimodais têm ampliado as possibilidades ao integrar dados de múltiplas fontes, como imagens médicas, descrições textuais e bancos de anatomia, resultando em modelos 3D mais completos e contextualizados.

Essas tecnologias trazem ganhos significativos em agilidade, permitindo que modelos anatômicos complexos sejam produzidos em menos tempo e com maior nível de detalhe, além de possibilitar a criação de múltiplos cenários anatômicos de forma automatizada, ampliando o potencial para pesquisas, treinamentos e simulações cirúrgicas. Ainda assim, permanecem desafios como garantir a fidelidade geométrica, a validação clínica e a integração com sistemas já utilizados em ambientes hospitalares e laboratoriais. Assim, a IA generativa se consolida como um campo em rápida evolução, que combina inovação tecnológica com a crescente demanda por precisão e velocidade na modelagem anatômica digital.

Diante disso, o presente artigo tem como objetivo discutir a aplicação da IA generativa na modelagem 3D de estruturas anatômicas, com ênfase em seu uso para pesquisas laboratoriais e estudos que exigem alta precisão e rapidez. O trabalho não tem caráter experimental, mas busca consolidar as evidências existentes e oferecer uma base teórica para apoiar linhas de pesquisa futuras que explorem a integração dessas tecnologias na prática científica.

2. Metodologia

A metodologia deste trabalho foi organizada em duas etapas complementares: (i) a descrição do biomodelo manual construído no software Rhinoceros 3D, utilizado como base de referência visual e conceitual, e (ii) a análise teórica das novas abordagens baseadas em Inteligência Artificial (IA) generativa, com potencial de substituir ou complementar os métodos tradicionais de modelagem em pesquisas futuras.

2.1 O modelo no software Rhinoceros 3D

Este estudo toma como referência um modelo anatômico manual da mandíbula, construído no software Rhinoceros 3D, inspirado nos protocolos Biocad [1]. O biomodelo inclui as principais estruturas anatômicas relevantes para simulações e análises biomecânicas: osso cortical, osso trabecular, ligamento periodontal e dentes, todas representadas individualmente de modo a possibilitar maior detalhamento.

Embora este trabalho não aborde a construção de novos modelos práticos utilizando a IA generativa, o biomodelo existente serve como parâmetro de comparação, ilustrando o tempo, a complexidade e os desafios envolvidos em abordagens manuais de modelagem 3D.

2.1.1 O cortical e o trabecular

O osso cortical, constitui a camada externa densa da mandíbula, responsável por sua resistência e rigidez, suportando grandes cargas mastigatórias. Já o osso trabecular, localizado no interior, apresenta estrutura esponjosa que auxilia na dissipação de tensões e impactos. A diferenciação entre essas duas regiões é fundamental para análises biomecânicas, visto que suas propriedades mecânicas são distintas. Na prática proposta, o osso cortical pode ser obtido por meio de operações de *offset* aplicadas às superfícies externas, enquanto o trabecular é definido pelo volume interno resultante.




Figura 1. Representação das duas estruturas em conjunto

2.1.2 Dentina

A dentina, localizada abaixo do esmalte, constitui a maior parte estrutural dos dentes e atua no suporte mecânico durante a mastigação. O ligamento periodontal, por sua vez, é um tecido fibroso que conecta a raiz ao osso alveolar, funcionando como amortecedor das cargas mastigatórias e protegendo tanto os dentes quanto os ossos adjacentes.

No modelo manual, essas estruturas foram representadas a partir da segmentação das raízes dentárias e do espaço periodontal, posteriormente preenchidos com volumes paramétricos no software CAD. Essa representação é fundamental para análises de mobilidade dentária e para o estudo do impacto das forças em simulações ortodônticas e cirúrgicas.

Sob a ótica da IA generativa, propõe-se avaliar como redes neurais de reconstrução volumétrica e técnicas de geração condicional 3D podem automatizar a representação dessas microestruturas, permitindo maior precisão anatômica e reduzindo a necessidade de ajustes manuais em softwares de CAD.




Figura 2. Dentes modelados manualmente no software Rhinoceros 7

2.1.3 O Modelo Completo

A mandíbula pode ser subdividida em quatro regiões principais — osso cortical, osso trabecular, dentes e ligamento periodontal — cada qual com propriedades mecânicas específicas e relevantes para simulações biomecânicas. Essa subdivisão é essencial para a correta seleção de parâmetros nos estudos de planejamento cirúrgico e ortodôntico.

Na abordagem manual, essas partes foram organizadas em camadas distintas no Rhinoceros 3D, com atribuição de materiais baseados em valores de literatura, garantindo consistência estrutural e comparabilidade entre diferentes modelos. O processo, entretanto, é altamente trabalhoso: a criação exige a definição de um grande número de curvas de referência, a reconstrução de superfícies complexas que respeitem as variações anatômicas, o alinhamento de diferentes elementos dentários, além da parametrização cuidadosa de espessuras e volumes, como no caso do ligamento periodontal. Esses passos tornam a modelagem manual precisa, mas consomem tempo e demandam grande experiência do operador, representando um gargalo significativo para pesquisas que necessitam de múltiplos modelos ou variações anatômicas.

É justamente nesse ponto que a Inteligência Artificial generativa se mostra como solução promissora. Enquanto no Rhinoceros cada curva, superfície e camada precisa ser desenhada manualmente, abordagens baseadas em grandes bases de dados anatômicos permitem treinar modelos capazes de realizar segmentações automáticas, reconstruir superfícies complexas de forma realista e até atribuir propriedades materiais de maneira integrada. Dessa forma, a IA não apenas acelera o processo, mas também reduz erros humanos e amplia a escalabilidade da modelagem. Além disso, fluxos híbridos já começam a ser explorados, combinando ferramentas como Grasshopper para ajustes paramétricos com algoritmos de IA para geração automática de geometrias complexas, apontando para um futuro em que a modelagem manual servirá mais como etapa de refinamento do que como tarefa central.




Figura 3. Modelo CAD subdividido em regiões anatômicas

2.2 A IA Generativa na criação de biomodelos 3D

A aplicação de Inteligência Artificial (IA) generativa na criação de biomodelos tridimensionais tem se consolidado como uma área de pesquisa em rápido crescimento, oferecendo alternativas promissoras à modelagem manual em softwares CAD tradicionais. Do ponto de vista técnico, essas abordagens baseiam-se em arquiteturas como redes adversariais generativas (GANs), autoencoders variacionais (VAEs) e modelos baseados em transformadores multimodais. As GANs utilizam um gerador, que cria amostras sintéticas, e um discriminador, que avalia sua fidelidade, permitindo a

geração de volumes anatômicos de alta resolução [3]. Os VAEs, por sua vez, são capazes de mapear dados anatômicos para um espaço latente contínuo, possibilitando a criação de variações morfológicas realistas úteis em cenários de comparação clínica [4]. Modelos mais recentes, baseados em transformadores multimodais, permitem condicionar a geração 3D a partir de diferentes tipos de entrada, como imagens médicas, segmentações prévias ou descrições textuais, ampliando as possibilidades de controle sobre características anatômicas e detalhamento estrutural [5].

Essas tecnologias oferecem ganhos significativos em termos de agilidade, reduzindo etapas manuais como segmentação e reparo de malhas, além de permitir maior padronização e reprodutibilidade dos resultados. A geração de múltiplos cenários anatômicos também se torna mais acessível, o que beneficia o treinamento de profissionais de saúde, a realização de simulações cirúrgicas e o desenvolvimento de próteses personalizadas. Porém, persistem desafios relevantes, como a garantia de fidelidade geométrica e anatômica em relação às variações reais do corpo humano, a necessidade de validação clínica rigorosa para assegurar aplicabilidade, e a dificuldade de integração com sistemas em ambientes hospitalares e laboratoriais.

Alguns estudos recentes já exploraram a aplicação prática dessas técnicas no contexto biomédico. O modelo Shap-MeD (2025), por exemplo, adaptou a tecnologia Shap-E da OpenAI para geração de modelos biomédicos 3D a partir de texto, alcançando maior acurácia estrutural em comparação ao modelo original [6]. Outro trabalho relevante utilizou uma adaptação do StyleGANv2 para a geração de volumes do círculo de Willis a partir de ressonâncias magnéticas angiográficas, demonstrando que é possível sintetizar estruturas vasculares complexas com alta fidelidade [7]. Na mesma direção, pesquisas com HR-pQCT mostraram que GANs podem preservar a microarquitetura óssea em imagens sintéticas, fornecendo dados úteis para análises biomecânicas e ortopédicas [8]. Outras arquiteturas híbridas, como a 3DGAUnet, combinam GANs e U-Nets para gerar modelos sintéticos de tumores pancreáticos e tecidos circundantes, evidenciando o potencial clínico em diferentes domínios anatômicos [9].

No campo das ferramentas, algumas plataformas comerciais e de código aberto já oferecem recursos que se aproximam dessas possibilidades. Softwares como o Materialise Mimics permitem segmentação avançada de imagens médicas e reconstrução tridimensional [10]. Além disso, a iniciativa recente da Autodesk chamado de: Projeto Bernini, explora a geração de modelos tridimensionais a partir de descrições textuais, ainda que em aplicações gerais, indicando uma tendência crescente de mercado na direção da automação inteligente da modelagem [11].

A partir dessas inovações, torna-se evidente que a IA generativa pode complementar ou até substituir a modelagem manual em cenários de pesquisa e planejamento cirúrgico. A integração dessas abordagens com fluxos CAD tradicionais, como o utilizado na construção manual da mandíbula no Rhinoceros, aponta para um futuro em que a criação de modelos anatômicos será acelerada, padronizada e mais acessível, sem abrir mão da precisão necessária para aplicações científicas e médicas. Assim, a IA generativa se configura como uma tecnologia de transição entre a prática artesanal da modelagem

manual e um cenário em que modelos digitais complexos possam ser obtidos de forma automática, precisa e integrada a sistemas clínicos e laboratoriais.

3. Resultados e discussão

A partir das inovações discutidas, a IA generativa mostra que pode complementar ou até substituir a modelagem manual em cenários de pesquisa e planejamento cirúrgico. A integração dessas abordagens com fluxos CAD tradicionais, como o utilizado na construção manual da mandíbula no Rhinoceros, aponta para um futuro em que a criação de modelos anatômicos será acelerada, padronizada e mais acessível, sem abrir mão da precisão necessária para aplicações científicas e médicas. Nesse sentido, a IA generativa configura-se como uma tecnologia de transição entre a prática artesanal da modelagem manual e um cenário em que modelos digitais complexos possam ser obtidos de forma automática, precisa e integrada a sistemas clínicos e laboratoriais.

Entre os principais avanços possibilitados por essa tecnologia, destacam-se a redução do tempo de produção de biomodelos, a eliminação de etapas manuais repetitivas como segmentação e reparo de malhas, além da padronização de resultados, o que contribui para maior reprodutibilidade em pesquisas e treinamentos.

Apesar desses benefícios, a implementação em ambientes clínicos ainda enfrenta desafios significativos. A fidelidade geométrica e anatômica em relação às variações reais do corpo humano precisa ser continuamente validada, e a integração dessas soluções com softwares já consolidados em hospitais e laboratórios permanece como barreira prática. Questões regulatórias e a necessidade de validação clínica rigorosa também se apresentam como entraves à adoção em larga escala.

No cenário ideal, a criação de modelos 3D a partir de prompts textuais desponta como a etapa mais avançada dessa transformação. Um sistema capaz de compreender descrições médicas detalhadas e gerar modelos anatômicos completos, prontos para ajustes finos ou integração direta em softwares de planejamento cirúrgico, representaria o ponto máximo de automação e acessibilidade. Tal abordagem permitiria que profissionais de saúde sem conhecimento avançado em modelagem 3D pudessem criar modelos personalizados de forma rápida, segura e com aplicabilidade clínica imediata.

Dessa forma, embora ainda em fase de desenvolvimento e validação, a IA generativa já se mostra como uma ferramenta estratégica para a evolução dos biomodelos tridimensionais, aproximando a prática médica de um futuro em que a inteligência artificial será elemento central na personalização e na eficiência do cuidado em saúde.

4. Referências

- [1] IKUNO, Isabelle M. et al. Modelagem tridimensional da mandíbula mesodivergente utilizando a abordagem ortodôntica de nivelamento da curva de Spee.
- [2] MATTOS, Gustavo Vieira et al. Avaliação de técnica de modelagem e simulação computacional aplicados na mandíbula.
- [3] GOODFELLOW, Ian J. et al. Generative adversarial nets. *Advances in neural information processing systems*, v. 27, 2014.
- [4] KINGMA, Diederik P.; WELING, Max. Auto-encoding variational bayes. *arXiv preprint arXiv:1312.6114*, 2013.
- [5] RAMESH, Aditya et al. Hierarchical text-conditional image generation with clip latents. *arXiv preprint arXiv:2204.06125*, v. 1, n. 2, p. 3, 2022.
- [6] LAVERDE, Nicolás; ROBLES, Melissa; RODRÍGUEZ, Johan. Shap-MeD. *arXiv preprint arXiv:2503.15562*, 2025.
- [7] AYDIN, Orhun Utku et al. Generative modeling of the Circle of Willis using 3D-StyleGAN. *NeuroImage*, v. 304, p. 120936, 2024.
- [8] ANGERMANN, Christoph et al. Three-Dimensional Bone-Image Synthesis with Generative Adversarial Networks. *Journal of Imaging*, v. 10, n. 12, p. 318, 2024.
- [9] SHI, Yu et al. 3DGAUnet: 3D generative adversarial networks with a 3D U-net based generator to achieve the accurate and effective synthesis of clinical tumor image data for pancreatic cancer. **Cancers**, v. 15, n. 23, p. 5496, 2023.
- [10] MATERIALISE. Mimics Innovation Suite. 2023. Disponível em: <https://www.materialise.com/en/healthcare/mimics-innovation-suite>. Acesso em: 15 set. 2025.
- [11] AUTODESK. Projeto Bernini: AI-generated 3D models. 2024. Disponível em: <https://www.axios.com/2024/05/08/autodesk-ai-3d-models-bernini>. Acesso em: 15 set. 2025.