

Geração Automatizada de Coroas Dentárias Anteriores com Modelos de Difusão Baseado em Pontos e Reconstrução 3D

Catherine D. P. Benavides Mena^{*¶}, Bárbara E. T. Aguayo^{*§}, Aliane S. Bezerra[†], Lucileide M. D. Silva^{*||},
Patricia S. Calderon[†], Sebastián Ríos[¶], Iván Sipirán[§] and Marcelo A. C. Fernandes^{*‡}

^{*}InovAI Lab, nPITI/IMD, Universidade Federal do Rio Grande do Norte (UFRN), Natal, RN, Brasil.

[†]Departamento de Odontologia, Universidade Federal do Rio Grande do Norte (UFRN), Natal, RN, Brasil.

[‡]Departamento de Engenharia da Computação, Universidade Federal do Rio Grande do Norte (UFRN), Natal, RN, Brasil.

[§]Departamento de Ciência da Computação, Universidad de Chile, Santiago, Chile.

[¶]Departamento de Engenharia industrial, Universidad de Chile, Santiago, Chile.

^{||}Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte, Santa Cruz, RN, Brasil.

Email: catherine.benavides@ug.uchile.cl, barbaraaguayo@ug.uchile.cl, alianebezerra2706@gmail.com,

lucileide.dantas@ifrn.edu.br, patricia.calderon@ufrn.br, sriosdii@uchile.cl, isipiran@dcc.uchile.cl, mfernandes@dca.ufrn.br

Resumo—O presente trabalho apresenta um novo *pipeline* para a geração automatizada de coroas dentárias anteriores, utilizando modelos generativos de difusão e técnicas de reconstrução 3D. A partir do conjunto de dados público Teeth 3DS, aplicou-se um criterioso processo de seleção das amostras para garantir a qualidade e a integridade anatômica dos dados. O dente 21 foi removido de cada escaneamento, e a estrutura restante foi representada como uma nuvem de pontos 3D. A geometria do dente ausente foi então reconstruída por um modelo de difusão treinado com dados nesse formato. Em seguida, foram aplicados métodos de reconstrução para transformar as nuvens de pontos geradas em malhas 3D completas, apropriadas para uso clínico. Os resultados preliminares demonstraram um erro quadrático médio na geração de nuvens de pontos de 0,0827 no conjunto de treinamento e 0,0973 no conjunto de teste. Para a etapa de reconstrução de malhas, a abordagem alcançou uma distância de Hausdorff média de $0,2801 \pm 0,0787$ e consistência de normais de $0,5466 \pm 0,0535$, indicando boa aproximação geométrica da superfície real, embora ainda com limitações em detalhes anatômicos finos. Essa abordagem demonstra o potencial da combinação entre modelos generativos e processamento geométrico para a automação do design de restaurações dentárias.

Index Terms—Modelos generativos, Modelos de difusão, Coroas dentárias, Design automatizado, Reconstrução 3D.

I. INTRODUÇÃO

A restauração de dentes ausentes com coroas protéticas é fundamental para a reabilitação oral, pois permite aos pacientes recuperar a estética e funções essenciais, como a mastigação e a integridade oclusal, que impactam diretamente sua qualidade de vida [1] [2]. Atualmente, as coroas dentárias são projetadas principalmente por meio de ferramentas digitais baseadas em softwares CAD/CAM (*Computer-Aided Design* e *Computer-Aided Manufacturing*, ou projeto e fabricação assistidos por computador), o que tem aumentado a eficiência dos laboratórios de prótese dentária [3]. Esses sistemas possibilitam a geração de coroas a partir de bibliotecas pré-definidas e auxiliam os técnicos em prótese na personalização

de cada caso [4]. No entanto, apesar de suas vantagens, essa abordagem ainda depende de intervenção manual especializada, sendo suscetível a erros e exigindo uma quantidade considerável de tempo de trabalho, especialmente devido à complexidade do sistema mastigatório humano [5].

Nesse cenário, a inteligência artificial (IA) tem se consolidado como uma alternativa promissora para superar essas limitações. Sua crescente integração na área médica tem demonstrado sua capacidade de automatizar tarefas administrativas repetitivas e de auxiliar em processos clínicos complexos, como a análise de imagens diagnósticas e o planejamento de tratamentos [6] [7]. Nesse contexto, o aprendizado profundo tem se destacado como uma tecnologia-chave por permitir que sistemas computacionais aprendam diretamente a partir dos dados, sem a necessidade de programação explícita, ampliando sua aplicabilidade em contextos clínicos complexos e diversos [8] [9]. Métodos baseados em aprendizado profundo têm impulsionado avanços importantes no design automatizado de implantes cranianos [10]. De forma semelhante, os modelos de difusão têm se mostrado eficazes na geração de estruturas complexas, como implantes cranianos, equilibrando eficiência computacional, preservação de detalhes anatômicos e adaptabilidade clínica [11].

Atualmente, soluções comerciais baseadas em aprendizado profundo já são utilizadas nos mercados odontológicos do Brasil e do Chile. Um exemplo notável é o Exocad [12], que oferece módulos com recursos de IA para personalização de próteses. No entanto, o custo elevado dessas ferramentas ainda representa uma barreira à sua ampla adoção. Além disso, a maioria das abordagens existentes ainda depende de representações intermediárias (como imagens 2D ou modelos CAD), o que pode comprometer a fidelidade anatômica das reconstruções.

Diante desse contexto, torna-se relevante explorar modelos generativos de difusão capazes de atuar diretamente sobre

nuvens de pontos 3D. Essa estratégia elimina etapas intermediárias e preserva a geometria original das estruturas dentárias, representando um avanço metodológico na área de design automatizado de próteses.

Este trabalho propõe um pipeline automatizado para o projeto de coroas dentárias anteriores, utilizando um modelo generativo de difusão treinado com nuvens de pontos e técnicas de reconstrução 3D para obtenção de superfícies anatômicas completas, compatíveis com avaliação clínica. As principais contribuições deste estudo são:

- 1) A adaptação de um modelo de difusão originalmente desenvolvido para implantes crânicos à geração de coroas dentárias;
- 2) A aplicação direta sobre nuvens de pontos 3D sem necessidade de projeções ou representações intermediárias;
- 3) A reconstrução final da malha por meio de um modelo baseado em *Shape as Points*, capaz de gerar superfícies contínuas e compatíveis com uso clínico;

II. REFERENCIAL TEÓRICO

Uma das primeiras propostas para a automação do design de coroas dentárias utilizando inteligência artificial envolve o uso de redes generativas adversariais condicionais (cGANs). Esses modelos aprendem a mapear a geometria da preparação dentária para uma superfície oclusal que segue a distribuição estatística de superfícies naturais projetadas por especialistas da área [13]. Nessa abordagem, a geometria 3D é inicialmente convertida em imagens de profundidade 2D, que são então utilizadas para reconstruir a superfície oclusal em 3D. O objetivo do trabalho é demonstrar que essa técnica pode gerar restaurações funcionais e anatomicamente plausíveis. No entanto, uma limitação dessa abordagem é a perda de informação inerente ao processo de transformação para 2D. Além disso, o modelo pode apresentar dificuldades em generalizar para variações anatômicas complexas, devido à limitada diversidade dos dados de treinamento.

O estudo de [14] expande a proposta original de [13], ao introduzir melhorias na arquitetura do modelo, incluindo filtragem de sulcos e perdas perceptuais, com o objetivo de refinar detalhes anatômicos críticos. Também são introduzidas melhorias nos mecanismos de alinhamento funcional com o dente antagonista, visando garantir uma oclusão adequada. No entanto, essa abordagem ainda depende da construção de conjuntos de dados 2D a partir de projeções ortogonais de modelos 3D, mantendo a limitação de representação indireta das superfícies.

Em contrapartida, surgiram métodos que operam diretamente no espaço 3D, como os modelos de difusão aplicados a nuvens de pontos [11]. Esses modelos permitem a geração de geometrias completas a partir de dados parciais, eliminando etapas intermediárias e preservando melhor os detalhes anatômicos. Por essa razão, têm ganhado destaque em tarefas de reconstrução e geração 3D, devido à sua capacidade de recuperar formas complexas mesmo a partir de observações incompletas [15].

No campo da reconstrução a partir de nuvens de pontos, diversas estratégias vêm sendo exploradas. Modelos como a família *PointNet* [16] [17] se destacam por processar nuvens de pontos diretamente, sem necessidade de voxelização. Autoencoders, por sua vez, permitem compressão e posterior reconstrução da nuvem, viabilizando a geração eficiente de malhas [18]. Métodos baseados em deformação adaptam uma malha-base à nuvem de pontos, enquanto técnicas de otimização por movimentação de pontos ajustam iterativamente a superfície final [19].

Estudos comparativos recentes indicam que não existe uma abordagem universalmente superior, pois o desempenho dos métodos varia significativamente conforme o tipo de dado, a complexidade geométrica e os objetivos clínicos ou industriais [20]. Observa-se também uma tendência crescente de integração entre técnicas clássicas, como a *Poisson Surface Reconstruction*, e abordagens baseadas em aprendizado profundo. Um exemplo disso é o modelo *Shape as Points* [21], que utiliza funções de distância para reconstruir representações implícitas de forma precisa.

Apesar dos avanços, a aplicação de modelos de difusão diretamente sobre nuvens de pontos no contexto de coroas dentárias anteriores ainda é escassa na literatura. Este estudo propõe um *pipeline* que integra um modelo generativo de difusão, adaptado a partir de estudos com implantes crânicos, à reconstrução de superfícies por otimização hierárquica. Diferentemente de abordagens baseadas em imagens 2D ou malhas predefinidas, a proposta apresentada atua diretamente sobre dados 3D em formato de nuvem de pontos, permitindo maior fidelidade anatômica e eliminando etapas de conversão geométrica. Essa combinação se apresenta como uma solução para o design automatizado de próteses dentárias com potencial de aplicação clínica.

III. METODOLOGIA

Este trabalho emprega um modelo generativo baseado em difusão, combinado com técnicas de reconstrução 3D, para a geração automatizada de coroas dentárias. Utiliza-se o conjunto de dados público *Teeth 3DS* [22], que contém malhas dentárias previamente segmentadas e possibilita a simulação da ausência do dente 21, conforme a nomenclatura da Federação Dentária Internacional (FDI), na maxila superior dos pacientes selecionados.

Para cada paciente, foram geradas duas nuvens de pontos: uma contendo o dente 21 (denotada como $PC_{complete}$) e outra com esse dente removido (denotada como $PC_{incomplete}$). A nuvem $PC_{incomplete}$, representando a ausência do dente, foi utilizada como entrada para o modelo de difusão, que atuou iterativamente na geração dos pontos ausentes, refinando progressivamente a estrutura incompleta. Os pontos gerados foram comparados com a nuvem $PC_{complete}$, visando garantir a convergência do modelo.

Com o objetivo de viabilizar o desenvolvimento paralelo das etapas, a reconstrução da malha 3D foi realizada a partir das nuvens de pontos originais (pré-geração). Essa abordagem modular possibilita, em fases futuras do trabalho, a integração

entre os dois processos em um *pipeline* automatizado de geração de malhas 3D.

A Figura 1 apresenta um resumo esquemático da metodologia proposta, detalhada nas subseções a seguir.

A. Conjunto de Dados

O conjunto de dados utilizado neste estudo é o *Teeth 3DS*, preparado para o desafio *3D Teeth Scan Segmentation and Labeling Challenge* em 2022 [23]. Ele compreende 1.800 escaneamentos intraorais de 900 pacientes, obtidos por meio de protocolos clínicos padronizados.

B. Seleção de Dados

Apesar de sua abrangência, o dataset *Teeth 3DS* apresentou alguns desafios relevantes, como dentes ausentes, estruturas danificadas, falhas nas superfícies dentárias e presença de aparelhos ortodônticos. Estes fatores poderiam introduzir ruídos e afetar a acurácia do modelo.

Assim, durante a etapa de Seleção de Dados (ver Figura 1), foi conduzido um processo rigoroso de depuração para eliminar escaneamentos que apresentavam essas anomalias. Essa filtragem contou com o suporte essencial de profissionais da ortodontia, que auxiliaram na identificação e validação das inconsistências. Como resultado, o número de pacientes incluídos na análise foi reduzido de 900 para 102.

C. Pré-processamento dos Dados

Com os dados selecionados, iniciou-se o pré-processamento. O dente de número 21 foi removido de cada escaneamento intraoral. Essa escolha deve-se à sua alta prevalência no conjunto e à sua relevância morfológica na região anterior da arcada dentária, essencial para a estética e oclusão.

Após a remoção, cada escaneamento foi convertido em uma nuvem de pontos 3D, preservando as informações geométricas da arcada remanescente. Essas nuvens, denotadas como $PC_{incomplete}$, foram utilizadas como entrada para o modelo de difusão, responsável por gerar a geometria da coroa ausente.

D. Modelo Generativo Baseado em Difusão

O modelo generativo baseado em difusão utilizado foi originalmente desenvolvido para reconstrução de implantes cranianos [22]. Ele utiliza a rede neural *PCDiff* (*Point Cloud Diffusion*), capaz de gerar estruturas 3D a partir de observações parciais. Isso ocorre por meio da introdução progressiva de ruído na nuvem de pontos e posterior remoção, permitindo ao modelo de difusão reconstruir os pontos ausentes com base em padrões espaciais aprendidos.

Para adaptação ao contexto odontológico, ajustaram-se os parâmetros de entrada, espaço de trabalho e número de etapas de difusão, visando atender às especificidades geométricas da anatomia dentária. O modelo foi treinado com as nuvens de pontos pré-processadas, utilizando-se $PC_{complete}$ como referência de *ground truth*.

E. Modelo de Reconstrução de Malha a partir da Nuvem de Pontos

Para que as estruturas geradas possam ser utilizadas clinicamente, é necessário transformá-las em superfícies (malhas) 3D. Embora o objetivo final deste trabalho seja aplicar essa reconstrução diretamente à saída do modelo de difusão, nesta fase inicial a avaliação foi feita com base nas nuvens de pontos originais.

Adotou-se uma variante do framework *Shape as Points* (SAP) [21], por sua compatibilidade com entradas em nuvem de pontos e pela flexibilidade no controle dos processos de deformação e refinamento.

A reconstrução inicia-se com uma malha base de baixa resolução (como uma esfera), que é iterativamente deformada para se ajustar à nuvem de entrada. O processo é orientado por uma função de perda com dois termos principais: a *Chamfer Distance Loss*, que promove a aproximação geométrica entre as nuvens de pontos prevista e real, e a *Laplacian Smoothness Loss*, que favorece a regularidade local da superfície. A função objetivo total é definida por:

$$\mathcal{L}_{total} = \lambda_{cd} \cdot \mathcal{L}_{Chamfer} + \lambda_{lap} \cdot \mathcal{L}_{Laplacian} \quad (1)$$

em que λ_{cd} e λ_{lap} são coeficientes que ajustam a influência da contribuição de cada termo. Após convergência em uma resolução inicial, a malha é refinada para resoluções superiores, capturando detalhes geométricos mais precisos. Essa otimização hierárquica é realizada em múltiplos estágios, favorecendo uma reconstrução estável e precisa das características mais globais até os detalhes anatômicos mais refinados.

A avaliação experimental foi conduzida com nuvens de pontos completas extraídas do *Teeth 3DS*. Seis malhas base distintas foram otimizadas individualmente e comparadas com as superfícies reais, possibilitando uma análise controlada da acurácia e da fidelidade superficial da técnica.

Espera-se, em etapas futuras, aplicar esse mesmo método à saída do modelo de difusão, completando o *pipeline* automatizado para a geração de coroas dentárias realistas e clinicamente viáveis.

IV. RESULTADOS

Esta seção descreve a configuração experimental, as métricas de avaliação utilizadas e os resultados obtidos a partir da aplicação das etapas do pipeline proposto para o projeto automatizado de coroas dentárias. Apresentam-se resultados preliminares com foco na fidelidade anatômica das estruturas geradas e em sua viabilidade clínica. Para isso, as nuvens de pontos geradas foram avaliadas por meio do Erro Quadrático Médio (MSE), enquanto as malhas reconstruídas foram analisadas utilizando o Coeficiente de Similaridade de Dice. Adicionalmente, a qualidade das superfícies reconstruídas foi mensurada com base na Distância de Hausdorff e na Consistência de Normais, permitindo uma avaliação detalhada tanto da acurácia geométrica quanto da regularidade superficial das malhas resultantes.




Figura 1. Sequência de etapas da metodologia proposta. Foi realizada uma etapa de seleção de dados para eliminar escaneamentos que apresentavam anomalias. Em seguida, o processo incluiu a geração de nuvens de pontos com e sem o dente 21, a aplicação do modelo generativo de difusão para preenchimento da ausência dentária e, paralelamente, a reconstrução 3D.

A. Resultados Preliminares da Reconstrução Geométrica com Nuvens de Pontos pelo Modelo PC-Diff

Para a geração de nuvens de pontos com a arquitetura PC-Diff, foi utilizada a seguinte configuração experimental: o modelo foi treinado por 300 épocas, com nuvens de pontos contendo 8.704 pontos, dos quais 512 correspondiam ao dente gerado e 8.192 às estruturas adjacentes, incluindo dentes vizinhos e gengiva. Foi aplicada uma taxa de *dropout* de 10% para reduzir o *overfitting*, e a taxa de aprendizado foi fixada em 2×10^{-5} , sem aplicação de *weight decay* nesta etapa preliminar. O Erro Quadrático Médio (MSE) foi utilizado como função de perda para a otimização da rede neural.

Conforme mostrado na curva de treinamento apresentado na Figura 2, o MSE converge rapidamente para um valor próximo de 0,8. Com base nessa observação, o treinamento foi mantido até 300 épocas, já que não foram observadas melhorias significativas após esse ponto.

A Figura 3 ilustra a evolução progressiva da estrutura gerada ao longo das épocas de treinamento, enquanto a Figura 4 mostra a boa correspondência visual entre a estrutura gerada e os dados reais de um paciente do conjunto de teste.

Conforme apresentado na Tabela I, o modelo alcançou um MSE de 0,0827 no conjunto de treinamento, indicando boa aproximação da estrutura dentária ausente pelos pontos gerados. O valor corresponde no conjunto de teste é de 0,0973 no conjunto de teste, indicando uma boa capacidade de generalização do modelo.

B. Resultados Iniciais da Reconstrução Geométrica com Malhas 3D pelo Método Shape as Points

Como etapa complementar do pipeline de projeto de coroas dentárias, foi utilizado um modelo de reconstrução de forma para converter as nuvens de pontos geradas em superfícies




Figura 2. Curva da função de perda durante o treinamento do modelo de difusão para nuvens de pontos

Tabela I
ERRO QUADRÁTICO MÉDIO (MSE) NAS ETAPAS DE TREINAMENTO E TESTE PARA GERAÇÃO DE NUVENS DE PONTOS

Conjunto	MSE
Treinamento	0,0827
Teste	0,0973

3D contínuas. Experimentos iniciais foram conduzidos utilizando o framework *Shape as Points*, baseado em otimização hierárquica. O modelo foi treinado por 800 épocas com duas resoluções diferentes de grade de Poisson: 32 e 64. Utilizou-se uma política progressiva de taxa de aprendizado, iniciando




Figura 3. Evolução da geração de nuvens de pontos pelo modelo PC-Diff ao longo do treinamento: (a) época 0, (b) época 5, (c) época 50 e (d) época 300. As regiões destacadas em azul claro indicam os pontos gerados da estrutura dentária ausente.




Figura 4. Comparação entre a nuvem de pontos de referência (a) e a nuvem gerada (b) pelo modelo de difusão PC-Diff no conjunto de teste, após 300 épocas de treinamento.

em 0,01 e reduzindo até 0,001 ao longo do treinamento. Além disso, a reamostragem de pontos foi realizada a cada 400 épocas, para o refinamento contínuo da superfície.




Figura 5. Curva de perda do modelo de otimização Shape as Points (SAP) ao longo de 800 épocas para a resolução 32.

Como observado nas Figuras 5 e 6, ambas as curvas apresentam uma tendência decrescente consistente, indicando que o modelo aprende efetivamente a aproximar a nuvem




Figura 6. Curva de perda do modelo de otimização Shape as Points (SAP) ao longo de 800 épocas para a resolução 64.

de pontos objetivo ao longo do treinamento. Para a resolução 32, a otimização inicia com um valor de perda mais elevado, de aproximadamente 0,24, que diminui de forma estável. Já na resolução 64, a curva começa com uma perda significativamente menor, de aproximadamente 0,064. Esse comportamento é típico de pipelines hierárquicos, nos quais os estágios posteriores aproveitam o aprendizado acumulado nas etapas anteriores. Com isso, o modelo inicia o treinamento com estimativas mais precisas e alcança convergência mais rapidamente.

Um aspecto notável na curva apresentada na Figura 6 é o aumento abrupto da perda na época 400. Esse pico corresponde ao evento de reamostragem configurado para ocorrer a cada 400 épocas. Durante o reamostragem, a grade de otimização é atualizada para se adaptar melhor à geometria atual, o que momentaneamente aumenta o erro de reconstrução. No entanto, isso é rapidamente compensado conforme o treinamento prossegue, e a perda volta a decrescer suavemente.

Tabela II
MÉTRICAS DE RECONSTRUÇÃO DAS MALHAS GERADAS PELO MÉTODO SAP

Métrica	Média	Desvio Padrão
Distância de Hausdorff	0,2801	0,0787
Consistência de Normais	0,5466	0,0535

A Figura 7 ilustra a progressão do processo de otimização hierárquica do SAP. Partindo de uma esfera inicial, a malha é gradualmente modificada até se alinhar com a nuvem de pontos objetivo. Embora a reconstrução melhore com o avanço do treinamento e se aproxime da anatomia dentária, a malha final permanece grosseira e com poucos detalhes finos, indicando a necessidade de refinamento adicional.

Para avaliar a acurácia geométrica das superfícies reconstruídas a partir das nuvens de pontos do conjunto *Teeth 3DS*, foram computadas a Distância de Hausdorff (HD) e a Consistência de Normais (NC) em seis casos de pacientes. Conforme apresentado na Tabela II, o método alcançou uma HD média de 0,2801, indicando que as malhas reconstruídas




Figura 7. Resultados da reconstrução de malhas na resolução 64 para diferentes épocas de treinamento: (a) época 0, (b) época 300, (c) época 500 e (d) época 800

capturam a morfologia geral das estruturas dentárias com precisão razoável. No entanto, o valor médio de NC igual a 0,5466 revela limitações na qualidade da orientação superficial. Vetores normais inconsistentes podem comprometer o ajuste oclusal ou a precisão na fabricação via impressão 3D. Um dos principais fatores contribuintes para esse desempenho é a presença de fragmentação superficial, particularmente na região gengival, que introduz descontinuidades e ruído geométrico, degradando a consistência dos vetores normais.

V. CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho apresentou um pipeline automatizado para o projeto de coroas dentárias anteriores, combinando um modelo generativo baseado em difusão, adaptado do contexto de implantes cranianos, com técnicas de reconstrução de malhas 3D orientadas por otimização hierárquica. A proposta atua diretamente sobre nuvens de pontos, eliminando etapas intermediárias e preservando a fidelidade anatômica das estruturas dentárias.

As etapas de geração da coroa e reconstrução da malha foram conduzidas de forma separada nesta fase inicial, o que permitiu o desenvolvimento paralelo dos módulos por diferentes equipes, otimizando o processo de pesquisa e validação. Ressalta-se, no entanto, que a reconstrução de malha foi realizada a partir das nuvens de pontos originais, ainda sem integração direta com a saída do modelo generativo.

Os resultados preliminares indicam que o modelo PC-Diff foi capaz de gerar nuvens de pontos que se aproximam da estrutura ausente com um Erro Quadrático Médio (MSE) de 0,0827 no conjunto de treinamento 0,0973. A análise qualitativa também revelou boa coerência visual entre os dados gerados e as referências reais. Na etapa de reconstrução de superfície, o método *Shape as Points* demonstrou ser eficaz na modificação progressiva de uma malha base até a forma

dentária-alvo, com valores médios de Distância de Hausdorff e Consistência de Normais compatíveis com os requisitos clínicos iniciais, embora ainda existam limitações na suavidade e continuidade da superfície final.

O processo de geração automatizada de coroas dentárias com modelos de difusão e reconstrução 3D, embora promissor, ainda demanda refinamentos para alcançar níveis mais elevados de detalhe e fidelidade anatômica. Como trabalhos futuros, destacam-se:

- Aplicar o modelo de reconstrução diretamente às nuvens de pontos geradas pelo modelo de difusão, consolidando um *pipeline end-to-end* mais próximo da aplicação clínica;
- Aplicar técnicas de remoção de *outliers* nas nuvens de pontos para reduzir ruído geométrico e melhorar a consistência dos vetores normais;
- Aumentar a resolução das malhas finais e incorporar técnicas de suavização no pós-processamento;
- Avaliar outros modelos de reconstrução para malhas, a fim de identificar a arquitetura mais adequada ao domínio odontológico;
- Ampliar a base de dados utilizada nos experimentos;
- Executar o método *Shape as Points* com um maior número de indivíduos para avaliação estatística mais robusta da reconstrução;
- Incluir avaliações qualitativas conduzidas por especialistas da área.
- Analisar a qualidade das coroas geradas com base em métricas específicas da odontologia, considerando aspectos como oclusão, adaptação marginal e estética;
- Avaliar o desempenho do pipeline em outros conjuntos de dados clínicos, visando a generalização do modelo proposto.

Os resultados obtidos até o momento reforçam o potencial das abordagens baseadas em aprendizado profundo para automatizar tarefas complexas de reabilitação oral, representando um avanço metodológico em direção à integração da inteligência artificial nos fluxos clínicos odontológicos.

VI. AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro concedido a este trabalho. Agradecem, também, ao programa CAPES Move La América, cuja colaboração possibilitou a visita das pesquisadoras chilenas ao Laboratório InovAI da UFRN, fortalecendo e enriquecendo as atividades de pesquisa conjunta. Por fim, expressam reconhecimento ao Núcleo de Processamento de Alto Desempenho da UFRN (NPAD/UFRN) pelo suporte computacional disponibilizado.

REFERÊNCIAS

- [1] K. Schnitzhofer, A. Rauch, M. Schmidt, and T. Rosentrit, "Impact of the occlusal contact pattern and occlusal adjustment on the wear and stability of crowns," *Journal of Dentistry*, vol. 128, pp. 1–6, 2023.
- [2] J. Calderon, Rehabilitación oral con prótesis fija para una mejor calidad de la salud bucal, reporte de caso clínico. Universidad Peruana Los Andes, 2022. Available: <https://hdl.handle.net/20.500.12848/4580>

- [3] C. Caparros and J. Duque, "Cerámicas y sistemas para restauraciones CAD-CAM: una revisión," *Rev. Fac. Odontol. Univ. Antioquia*, vol. 22, no. 1, pp. 88–108, 2010. [Online]. Available: http://www.scielo.org.co/scielo.php?pid=s0121-246x2010000200011&script=sci_arttext
- [4] Cho JH, Yi Y, Choi J, Ahn J, Yoon HI, Yilmaz B. "Time efficiency, occlusal morphology, and internal fit of anatomic contour crowns designed by dental software powered by generative adversarial network: a comparative study," *Journal of Dentistry*, vol. 138, pp. 1–9, 2023.
- [5] H. J. Kong and Y. L. Kim, "Application of artificial intelligence in dental crown prosthesis: a scoping review," *BMC Oral Health*, vol. 24, pp. 1–10, 2024.
- [6] O. Panahi, "AI ushering in a new era of digital dental-medicine," *Acta Scientific Medical Sciences*, vol. 8, no. 8, pp. 132–134, Aug. 2024.
- [7] M. Vodanović, M. Subašić, D. Milošević, and I. Savić Pavičin, "Artificial intelligence in medicine and dentistry," *Acta Stomatologica Croatica*, vol. 57, no. 1, pp. 70–84, Mar. 2023.
- [8] R. C. W. Chau, M. Chong, K. M. Thu, N. S. P. Chu, M. K. Moghadam, R. T. C. Hsung, et al., "Artificial intelligence-designed single molar dental prostheses: a protocol of prospective experimental study," *PLoS One*, vol. 17, no. 6, pp. 1–14, 2022.
- [9] J. J. Hwang, Y. H. Jung, B. H. Cho, and M. S. Heo, "An overview of deep learning in the field of dentistry," *Imaging Sci. Dent.*, vol. 49, pp. 1–7, 2019.
- [10] J. Li and D. Ellis, "Towards clinical applicability and computational efficiency in automatic cranial implant design: An overview of the AutoImplant 2021 cranial implant design challenge," *Med. Image Anal.*, vol. 88, Art. no. 102865, 2023.
- [11] P. Friedrich, J. Wolleb, F. Bieder, F. Thieringer, and P. Cattin, "Point cloud diffusion models for automatic implant generation," Dept. of Biomedical Engineering, University of Basel and Dept. of Oral and Cranio-Maxillofacial Surgery, University Hospital Basel, Switzerland, 2023.
- [12] exocad GmbH, 2025. Available: <https://exocad.com/>
- [13] Y. Zhang, X. Jing, Z. He, Y. He, Z. Shu, T. Tan, and J. Li, "Personalized design technique for the dental occlusal surface based on conditional generative adversarial networks," *Computer Methods and Programs in Biomedicine*, vol. 241, Art. no. 107638, 2023.
- [14] F. Yuan, N. Dai, S. Tian, et al., "Personalized design technique for the dental occlusal surface based on conditional generative adversarial networks," *Int. J. Numer. Meth. Biomed. Eng.*, vol. 36, no. 6, Art. no. e3321, 2020.
- [15] H. Zhou, Y. Cao, W. Chu, J. Zhu, T. Lu, Y. Tai, and C. Wang, "SeedFormer: Patch seeds based point cloud completion with upsampling transformer," Laboratory for Novel Software Technology, Nanjing University and YouTu Lab, Tencent, 2022.
- [16] C. R. Qi, H. Su, K. Mo, and L. J. Guibas, "PointNet: Deep learning on point sets for 3D classification and segmentation," *arXiv preprint arXiv:1612.00593*, 2017. [Online]. Available: <https://arxiv.org/abs/1612.00593>
- [17] C. R. Qi, L. Yi, H. Su, and L. J. Guibas, "PointNet++: Deep hierarchical feature learning on point sets in a metric space," *arXiv preprint arXiv:1706.02413*, 2017. [Online]. Available: <https://arxiv.org/abs/1706.02413>
- [18] T. Groueix, M. Fisher, V. G. Kim, B. C. Russell, and M. Aubry, "AtlasNet: A papier-mâché approach to learning 3D surface generation," *arXiv preprint arXiv:1802.05384*, 2018. [Online]. Available: <https://arxiv.org/abs/1802.05384>
- [19] S. Miyauchi, K. Morooka, and R. Kurazume, "Isomorphic mesh generation from point clouds with multilayer perceptrons," *arXiv preprint arXiv:2210.14157*, 2022. [Online]. Available: <https://arxiv.org/abs/2210.14157>
- [20] F. Z. Iguenfer, A. Hsain, H. Amissa, and Y. Chtouki, "Point Cloud to Mesh Reconstruction: A Focus on Key Learning-Based Paradigms," *arXiv preprint arXiv:2412.10977*, Dec. 2024. Available: <https://arxiv.org/abs/2412.10977>
- [21] S. Peng, C. Max Jiang, Y. Liao, M. Niemeyer, M. Pollefeys and A. Geiger, "Shape As Points: A Differentiable Poisson Solver," *arXiv preprint arXiv:2106.03452*, 2021. Available: <https://arxiv.org/abs/2106.03452>
- [22] A. Ben-Hamadou, M. Mahjoub, F. Mahmoudi, D. Rebai, A. Douik, and M. A. Mahjoub, "Teeth3DS+: An Extended Benchmark for Intraoral 3D Scans Analysis," 2022. Available: <https://crns-smartvision.github.io/teeth3ds/>
- [23] Teeth Scan Segmentation and Labeling Challenge MICCAI2022, Grand Challenge, [Online]. Available: <https://3dteethseg.grand-challenge.org/>. [Accessed: May 19, 2025]