

Sistema Automatizado para Detecção de Landmarks Cefalométricos Utilizando Deep Learning e Suporte Diagnóstico via Modelos de Linguagem

Gustavo C. Rosa¹, Danielli A. Lima¹, Cícero L. Costa¹

¹Laboratório de Inteligência Computacional, Robótica e Otimização (LICRO)
Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro (IFTM)
Campus Patrocínio – Av. Lúcia Terezinha Lassi Capuano, 255
Bairro Universitário, 38747-792 – Patrocínio – MG – Brasil

`gustavo.caixetar@estudante.iftm.edu.br, {cicero, danielli}@iftm.edu.br`

Abstract. *Cephalometric analysis is important for orthodontic and surgical planning, but manual annotation of anatomical landmarks is time-consuming and subject to variability. This paper proposes an automated cephalometric landmark detection system supported by a natural language model for diagnostic assistance. The method employs region-of-interest extraction and landmark regression using pre-trained deep learning, evaluated on the IEEE ISBI 2015 dataset with 19 anatomical points. The detected angular measurements are sent to a language model via API to generate interpretative reports. The results show performance consistent with the literature, with $\approx 80\%$ of the landmarks within the clinical margin of 2 mm, contributing to preliminary assessments and the modernization of craniofacial diagnostic workflows.*

Resumo. *A análise cefalométrica é importante no planejamento ortodôntico e cirúrgico, mas a marcação manual dos pontos anatômicos é demorada e sujeita a variações. Este artigo propõe um sistema automatizado de detecção de landmarks cefalométricos com apoio diagnóstico por modelo de linguagem natural. O método utiliza extração de regiões de interesse e regressão de landmarks com aprendizado profundo pré-treinado, avaliado no dataset IEEE ISBI 2015 com 19 pontos anatômicos. As medidas angulares detectadas são enviadas a um modelo de linguagem via API para geração de relatórios interpretativos. Os resultados mostram desempenho compatível com a literatura, com $\approx 80\%$ dos landmarks dentro da margem clínica de 2 mm, contribuindo para avaliações preliminares e modernização dos fluxos diagnósticos craniofaciais.*

1. Introdução

A inteligência artificial (IA) tem se consolidado como uma tecnologia transformadora na área da saúde, especialmente na análise de imagens médicas e dados clínicos [Schwendicke et al. 2020]. Na odontologia, aplicações recentes demonstram resultados promissores em tarefas como detecção de cáries, identificação de lesões e análise cefalométrica automatizada [de Queiroz Tavares Borges Mesquita et al. 2023].

A cefalometria consiste na análise quantitativa das relações esqueléticas craniofaciais a partir de radiografias laterais, sendo essencial para o diagnóstico e planejamento de tratamentos ortodônticos e cirúrgicos [Schwendicke et al. 2021]. A

identificação manual de landmarks é um processo demorado e sujeito a variações intra e interobservadores, com divergências superiores a 2 mm mesmo entre especialistas [Lindner et al. 2016, de Queiroz Tavares Borges Mesquita et al. 2023]. Nesse cenário, métodos baseados em deep learning, especialmente redes neurais convolucionais (CNNs), têm se destacado como alternativa para tornar esse processo mais rápido e padronizado, alcançando concordância entre 79% e 90% em relação à marcação manual [Song et al. 2020, de Queiroz Tavares Borges Mesquita et al. 2023].

Trabalhos recentes também exploram o uso de modelos de linguagem de grande porte como suporte ao diagnóstico de má oclusão Classe II a partir de medidas cefalométricas [Zhou et al. 2026]. Esses modelos têm demonstrado potencial para interpretar parâmetros cefalométricos e gerar descrições textuais que auxiliam profissionais na análise inicial de padrões craniofaciais e ortodônticos. Assim, este trabalho propõe um sistema automatizado de auxílio ao diagnóstico com base em landmarks cefalométricos [Bao et al. 2023]. O sistema combina técnicas de visão computacional e aprendizado profundo para localização automática dos pontos anatômicos com a utilização de um modelo de linguagem natural para suporte interpretativo das medidas obtidas.

Apesar dos avanços recentes, a identificação automática de landmarks ainda apresenta limitações relacionadas à variabilidade anatômica, qualidade das radiografias e sobreposição de estruturas ósseas. Por esse motivo, é importante que o profissional revise e corrija landmarks individualmente antes do cálculo das medidas e da geração do pré-diagnóstico, conforme recomendado por [Menezes et al. 2023, Ye et al. 2023]. A validação clínica continua sendo indispensável para garantir confiabilidade e segurança no uso dessas ferramentas em ambientes reais. Nesse contexto, torna-se relevante integrar a detecção automatizada de landmarks cefalométricos a ferramentas de apoio diagnóstico, visando otimizar fluxos de trabalho, reduzir o tempo de análise e auxiliar a tomada de decisão clínica.

2. Materiais e Métodos

A metodologia proposta consiste no desenvolvimento de um sistema automatizado para auxílio ao diagnóstico cefalométrico, estruturado em um fluxo integrado de processamento de imagens médicas e análise computacional, conforme Figura 1. Inicialmente, utiliza-se o dataset público do IEEE ISBI 2015 Grand Challenge, composto por 400 radiografias cefalométricas laterais anotadas por especialistas, contendo 19 landmarks anatômicos relevantes para a análise craniofacial [Wang et al. 2015]. As imagens são particionadas em conjuntos de treinamento, validação e teste, permitindo a avaliação controlada do modelo. A detecção dos landmarks é realizada por meio de uma abordagem baseada em aprendizado profundo, utilizando redes neurais convolucionais (CNNs) com arquitetura derivada da ResNet. O treinamento utiliza função de custo baseada no erro quadrático médio (MSE) e o otimizador Adam, garantindo estabilidade no processo de aprendizagem. Após a identificação automática dos landmarks, o sistema realiza o cálculo das principais medidas cefalométricas angulares utilizadas na prática clínica, como SNA, SNB, ANB, ODI, APDI, FHI, FMA e Wits modificado. Essas medidas são utilizadas para caracterizar relações esqueléticas craniofaciais e auxiliar na identificação de padrões de má oclusão [de Queiroz Tavares Borges Mesquita et al. 2023, Song et al. 2020, Chen et al. 2019].

Como etapa final, as medidas calculadas são organizadas em formato textual e enviadas a um modelo de linguagem de grande porte, responsável pela geração automática

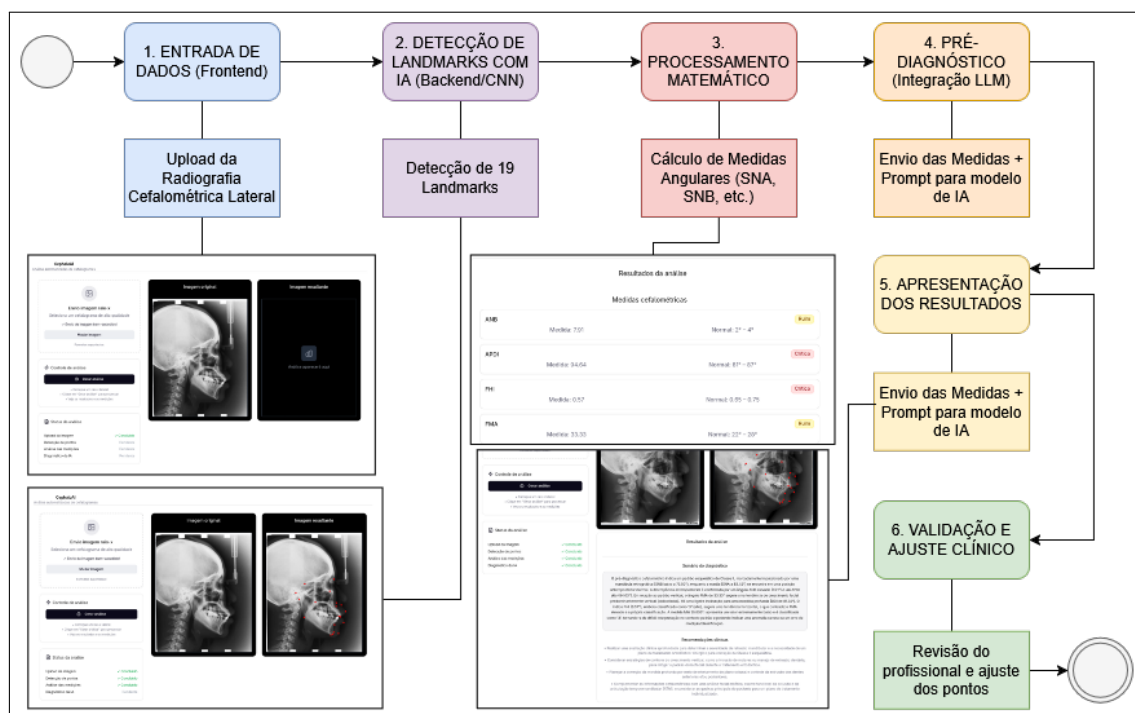


Figura 1. Fluxograma da Proposta.

de um relatório interpretativo em linguagem natural. Os detalhes dessa etapa são apresentados na Subseção 2.1. O sistema completo é implementado em arquitetura modular, com backend de detecção desenvolvido em Python e interface web que permite o envio das radiografias, visualização dos landmarks detectados e acesso ao relatório gerado.

Como requisitos de entrada do sistema, foram utilizadas radiografias cefalométricas laterais provenientes do banco de imagens do IEEE ISBI 2015 Grand Challenge. As imagens originais estão disponibilizadas no formato BMP, com resolução de 1935×2040 pixels.

A etapa de detecção automática foi baseada em arquitetura de redes neurais convolucionais derivada do modelo proposto por Cheng et al. (2019), integrado ao pipeline completo de processamento descrito nesta seção.

2.1. Geração de Relatório com LLM

A geração do relatório textual constitui a etapa final do fluxo, convertendo automaticamente as medidas cefalométricas em uma interpretação em linguagem natural. As medidas, organizadas com valores de referência clínicos, são enviadas via API a um modelo de linguagem para produção de um relatório preliminar. O prompting direto instrui o modelo a sintetizar os resultados em quatro achados diagnósticos principais (padrão esquelético, relação maxilomandibular, direção de crescimento e implicações clínicas). Para favorecer a reprodutibilidade, utilizaram-se configurações determinísticas, sem técnicas adicionais de engenharia de prompt, sendo mecanismos mais avançados de controle e validação considerados como trabalhos futuros.

3. Resultados e Discussão

A análise cefalométrica tradicional envolve um fluxo manual de identificação de landmarks, cálculo de medidas e interpretação diagnóstica, Figura 2, processo demorado e su-

jeito a variabilidade entre observadores. Nesse contexto, técnicas de inteligência artificial têm possibilitado a automação de etapas anteriormente dependentes de intervenção manual. O principal resultado deste trabalho é a transformação desse fluxo em um processo




Figura 2. Fluxo inicial realizado pelo médico.

semiautomático, Figura 3, no qual parte das tarefas é automatizada por deep learning e modelos de linguagem, reduzindo a carga operacional do especialista e aumentando a padronização do processo. O sistema realiza automaticamente a detecção dos landmarks cefalométricos e o cálculo das medidas angulares, enquanto o profissional mantém o papel de supervisão e validação dos resultados.

A detecção automática dos landmarks foi realizada utilizando modelos baseados em redes neurais convolucionais avaliados no dataset público do IEEE ISBI 2015 Grand Challenge, amplamente utilizado como benchmark para essa tarefa. O desempenho foi avaliado por meio do erro radial médio (MRE) e da taxa de detecção bem-sucedida (SDR) em diferentes limiares. Os resultados obtidos apresentam desempenho compatível com o reportado na literatura, com aproximadamente 79–80% de detecção dentro do limiar de 2 mm de erros médios [de Queiroz Tavares Borges Mesquita et al. 2023, Schwendicke et al. 2021].

Após a detecção dos landmarks, o sistema calcula automaticamente medidas cefalométricas angulares, como SNA, SNB e ANB, utilizadas para caracterizar as relações esqueléticas craniofaciais. Diferentemente de abordagens que se concentram apenas na localização dos pontos anatômicos, o presente trabalho integra essa etapa a um módulo de interpretação diagnóstica baseado em modelos de linguagem de grande escala (LLMs). A partir das medidas calculadas, o sistema gera automaticamente um relatório textual com uma interpretação preliminar das relações esqueléticas, classificando padrões como Classe I, Classe II ou Classe III.

Essa integração entre detecção automática, cálculo das medidas e geração de relatório representa uma evolução em relação a estudos anteriores, que geralmente se concentram apenas na acurácia da detecção de landmarks. No sistema proposto, a inteligência artificial automatiza etapas operacionais do processo, enquanto o profissional mantém a supervisão e a possibilidade de revisão dos resultados. Dessa forma, o fluxo de trabalho clínico passa de um processo totalmente manual para um modelo semiautomático, potencialmente mais rápido, padronizado e reprodutível. Como trabalho futuro, pretende-se incorporar mecanismos de edição dos landmarks detectados, permitindo ao profissional ajustar eventuais imprecisões antes da geração das medidas e do relatório final, aumen-




Figura 3. Fluxo semiautomático de auxílio ao diagnóstico.

tando a confiabilidade do sistema em aplicações clínicas.

4. Conclusão

Este trabalho apresentou um sistema computacional para apoio à análise cefalométrica que integra técnicas de visão computacional baseadas em deep learning com modelos de linguagem de grande escala. O sistema desenvolvido é capaz de receber uma radiografia cefalométrica lateral, detectar automaticamente 19 landmarks anatômicos, calcular medidas cefalométricas angulares relevantes e gerar um relatório interpretativo preliminar. Dessa forma, a proposta estabelece um fluxo integrado de processamento que automatiza etapas tradicionalmente realizadas manualmente, contribuindo para tornar o processo de análise mais rápido, padronizado, potencialmente mais reproduzível e menos sujeito à variabilidade entre operadores no contexto clínico.

Os resultados obtidos indicam que o desempenho do sistema na detecção de landmarks é consistente com os valores reportados na literatura. Além disso, a integração com modelos de linguagem permite gerar uma interpretação preliminar das medidas cefalométricas, funcionando como um mecanismo de suporte ao processo diagnóstico. Como principal contribuição, o trabalho demonstra a viabilidade de combinar modelos de detecção automática com ferramentas de interpretação baseadas em IA em um único pipeline semiautomático, no qual a inteligência artificial automatiza etapas operacionais enquanto o profissional mantém a supervisão clínica. Uma limitação do presente trabalho está relacionada ao uso de modelos de linguagem de grande escala na geração automática dos relatórios interpretativos, cujos resultados podem variar em qualidade e eventualmente conter imprecisões, reforçando a necessidade de supervisão clínica humana. Como trabalhos futuros, destacam-se a validação clínica do sistema com especialistas e a ampliação do conjunto de dados e das arquiteturas de deep learning utilizadas, bem como o desenvolvimento de mecanismos de controle e validação da geração textual, visando aumentar a robustez e a aplicabilidade da solução em cenários clínicos reais.

Referências

- Bao, H., Zhang, K., Yu, C., Li, H., Cao, D., Shu, H., Liu, L., and Yan, B. (2023). Evaluating the accuracy of automated cephalometric analysis based on artificial intelligence. *BMC Oral Health*, 23(1):191.
- Chen, R., Ma, Y., Chen, N., Lee, D., and Wang, W. (2019). Cephalometric landmark detection by attentive feature pyramid fusion and regression-voting. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 873–881. Springer.
- de Queiroz Tavares Borges Mesquita, G., Vieira, W. A., Vidigal, M. T. C., Travençolo, B. A. N., Beaini, T. L., Spin-Neto, R., Paranhos, L. R., and de Brito Júnior, R. B. (2023). Artificial intelligence for detecting cephalometric landmarks: a systematic review and meta-analysis. *Journal of digital imaging*, 36(3):1158–1179.
- Lindner, C., Wang, C.-W., Huang, C.-T., Li, C.-H., Chang, S.-W., and Cootes, T. F. (2016). Fully automatic system for accurate localisation and analysis of cephalometric landmarks in lateral cephalograms. *Scientific reports*, 6(1):33581.
- Menezes, L. d. S., Silva, T. P., Lima dos Santos, M. A., Hughes, M. M., Mariano Souza, S. d. R., Leite Ribeiro, P. M., Freitas, P. H. L. d., and Takeshita, W. M. (2023). Assessment of landmark detection in cephalometric radiographs with different conditions of brightness and contrast using the an artificial intelligence software. *Dentomaxillofacial Radiology*, 52(8):20230065.
- Schwendicke, F., Chaurasia, A., Arsiwala, L., Lee, J.-H., Elhennawy, K., Jost-Brinkmann, P.-G., Demarco, F., and Krois, J. (2021). Deep learning for cephalometric landmark detection: systematic review and meta-analysis. *Clinical oral investigations*, 25(7):4299–4309.
- Schwendicke, F. a., Samek, W., and Krois, J. (2020). Artificial intelligence in dentistry: chances and challenges. *Journal of dental research*, 99(7):769–774.
- Song, Y., Qiao, X., Iwamoto, Y., and Chen, Y.-w. (2020). Automatic cephalometric landmark detection on x-ray images using a deep-learning method. *Applied Sciences*, 10(7):2547.
- Wang, C.-W., Huang, C.-T., Hsieh, M.-C., Li, C.-H., Chang, S.-W., Li, W.-C., Vandaele, R., Marée, R., Jodogne, S., Geurts, P., et al. (2015). Evaluation and comparison of anatomical landmark detection methods for cephalometric x-ray images: a grand challenge. *IEEE transactions on medical imaging*, 34(9):1890–1900.
- Ye, H., Cheng, Z., Ungvijanpunya, N., Chen, W., Cao, L., and Gou, Y. (2023). Is automatic cephalometric software using artificial intelligence better than orthodontist experts in landmark identification? *BMC Oral Health*, 23(1):467.
- Zhou, L., Li, Y., and Li, Z. (2026). Large language model-based support for cephalometric analysis in class ii malocclusion diagnosis in stomatology. In *ElCon Conference of Young Researchers in Communication and Networking, Signal Processing & Analysis, Biomedical and Environmental Engineering*. IEEE.