

Detecção Automática de Pontos Cefalométricos em Teleradiografias Laterais Digitalizadas

Felipe Coelho de Andrade
Pós Graduação em Computação Aplicada (PGCA)
Universidade Estadual de Feira de Santana – UEFS
Feira de Santana, Brasil
Email: andrade.felipecoelho@gmail.com

Michele Fúlvia Angelo
Departamento de Tecnologia – DTEC
Universidade Estadual de Feira de Santana – UEFS
Feira de Santana, Brasil
Email: mfangelo@ecomp.uefs.br

Abstract—This paper objective the automatic detection of cephalometric points, seeking help orthodontists in the achievement of cephalometric analysis. The algorithm under development will involve digital image processing techniques, pattern recognition and computational intelligence. This paper present the methodology used and the obtained preliminary results until the completion of this task.

Keywords—Cephalometric analysis, Cephalometric landmarks, Automatic detection, image processing.

Resumo—Esse trabalho tem como objetivo a detecção automática de pontos cefalométricos, buscando auxiliar os ortodontistas na realização das análises cefalométricas. O algoritmo que está sendo desenvolvido envolverá técnicas de processamento de imagens digitais, reconhecimento de padrões e inteligência computacional. Este artigo apresenta o processo empregado, junto há resultados preliminares encontrados até o momento para realização desta tarefa.

Palavras-chave—Análise cefalométrica, Pontos cefalométricos, Detecção automática, processamento de imagens.

I. INTRODUÇÃO

As análises cefalométricas ou traçados cefalométricos são considerados ferramentas vitais para descrever a morfologia, diagnosticar anomalias, planejar e avaliar o tratamento ortodôntico [1]. Estas análises são tradicionalmente realizadas por meio de traçados sobre as teleradiografias laterais da face, os quais são resultado da ligação de pontos de referência, também chamados de pontos cefalométricos.

Os pontos cefalométricos foram determinados por diferentes autores, sendo localizados em acidentes anatômicos, ou em posições geométricas [2]. A ortodontia possui um total de 90 pontos cefalométricos, mas destes apenas 30 são comumente utilizados [3].

Uma grande dificuldade para a realização da análise cefalométrica é a identificação dos pontos cefalométricos, e a determinação destes pontos tem se mostrado não reprodutível se comparado por diversos observadores. Segundo Houston [4], essa não reprodutibilidade é consequência da falta de precisão na determinação dos pontos cefalométricos, bem como erros de medidas por instrumentos manuais.

Estes erros, por sua vez, possuem um importante significado, pois segundo pesquisadores da área, a má localização dos pontos pode mudar significativamente o diagnóstico e o planejamento do tratamento ortodôntico. [5], [6].

Assim, buscando auxiliar na tarefa de detecção dos pontos cefalométricos, vários trabalhos vêm sendo realizados com o objetivo de automatizar esse processo [7]–[13]. No entanto, muitos destes apresentam taxas de acerto baixas para vários pontos cefalométricos e algumas técnicas só apresentam resultados considerados bons para um pequeno conjunto de pontos. Diante disso, este trabalho tem como objetivo desenvolver um algoritmo para a detecção automática de pontos cefalométricos em uma escala considera ideal pelos especialistas da área de ortodontia.

II. TRABALHOS RELACIONADOS

Os trabalhos voltados para a detecção automática de pontos cefalométricos podem ser divididos em três abordagens: a) Baseada em Modelos; b) Baseada em Computação Flexível; c) Híbridas. Abaixo são apresentados alguns dos trabalhos encontrados na literatura, seguindo a divisão apresentada.

A. Baseada em Modelos

Vučinić, Predrag, e Ivana [7] utilizaram Active Appearance Models (AAM) para a detecção automática de 17 pontos cefalométricos. Para tanto foram utilizados 60 cefalogramas, sendo 55 utilizados na fase de treinamento, e 5 na fase de teste. Como resultado obtiveram 28% dos pontos detectados com erro até 1mm, 61% até 2mm e 95% com erro até 5mm.

Ningrun, Harjoko e Mudjosemedi [8] utilizaram 55 imagens para detectar 10 pontos cefalométricos. Os autores desenvolveram uma técnica que utiliza 10 templates, um por ponto, com o intuito de encontrar a região de interesse de cada um, em seguida foi aplicado o algoritmo Project Principal-Edge Distribution (PPED) para a identificação dos pontos. Os resultados foram obtidos em amostras de 10 e 20 imagens, com taxas de acerto variando entre 14% e 86%, e 17% e 80% respectivamente.

B. Baseada em Computação Flexível

El-Feghi, Maher e Majid [9] utilizaram uma rede neural do tipo Perceptron Multicamadas (PMC) como um aproximador funcional para localizar automaticamente 20 pontos cefalométricos. Dois experimentos foram realizados usando um conjunto de 210 imagens, sendo 105 para treinamento e 105 para teste. Os resultados demonstraram que foi possível

localizar mais de 81% dos 20 pontos em todas as imagens com uma precisão menor ou igual a 2mm.

Um dataset com 100 imagens foi utilizado por Vandaeli et al. [10] para detectar 19 pontos cefalométricos. Eles aplicaram uma técnica baseada em árvores extremamente aleatórias, junto ao que chamaram de características simples das imagens. Com esta técnica obtiveram resultados médios de 75,37%, 91,84% dos pontos foram encontrados dentro da taxa da precisão de 2mm e 4mm respectivamente, com uma distância euclidiana média de -1.83mm a 1.81mm

C. Híbrida

Pouyan e Farshbaf [11] utilizaram 63 cefalogramas para detectar 3 pontos cefalométricos. No experimento foi utilizado o descritor HOG (Histogram of Oriented Gradients) e uma rede neural em que seu treinamento foi composto por 62 imagens e seu teste por 1. Como resultado foi apresentado um erro maior que 2mm.

Kaur e Singh [12] utilizaram o método dos momentos de Zernike para detectar 18 pontos cefalométricos. Para tanto utilizaram 135 radiografias, 134 para teste e uma para o treinamento. Os autores propuseram a utilização de um módulo online com a tarefa principal de calcular as características relativas ao descritor, junto a divisão da imagem em seis estruturas craniofaciais, cada uma contendo 3 pontos cefalométricos, e outro off-line, inicialmente responsável por reconhecer as sub-imagens. Em seguida foi feito um processo que busca identificar, detectar e refinar a localização de cada ponto. Os resultados foram considerados expressivos, visto que 89,5% dos pontos foram localizados em uma janela de ± 2 mm com erro médio de 1.84mm.

III. METODOLOGIA

Este trabalho tem como objetivo principal o desenvolvimento de um algoritmo para a detecção automática de pontos cefalométricos e para o seu desenvolvimento serão seguidas as seguintes etapas:

A. Ampliação do Dataset

As radiografias utilizadas neste trabalho fazem parte do banco de imagens cefalométricas criado por Santana et al. [13]. Esta base contém 52 radiografias e está disponível através da Internet (<http://www2.uefs.br:8081/bic/web/home.xhtml>), com download disponível somente para usuários com a aprovação do administrador.

Considerando que esse número não é tão expressivo, novas radiografias serão inseridas nesse banco de imagens. Essas novas radiografias serão obtidas através da Clínica de Odontopediatria da Universidade Estadual de Feira de Santana e em seguida serão inseridas no banco de imagens [13].

B. Seleção dos Pontos Cefalométricos que Serão Detectados pelo Algoritmo

Conforme mencionado anteriormente, existem diversos pontos cefalométricos localizados em posições geométricas e em acidentias anatômicas, na Figura 1 é possível visualizar 27

pontos utilizados na análise cefalométrica padrão UNESP Araraquara [14].

A escolha dos pontos a serem detectados se dará através da estratégia de encontrar, em primeira instância, os pontos presentes no tecido mole, a exemplo dos pontos: Pró-Nasal (Pn), Columela (Cm), Subnasal (Sn) e Lábio Superior (Ls), junto aos pontos localizados no tecido duro na parte mais exterior da face como os pontos mentoniano (Me), gnátio (Gn), e pogônio (Pg) que estão localizados no queixo. Em seguida serão detectados os pontos mais posteriores como o sela (S), ponto B (B), ponto pório (Po).

Após a análise do dataset foi observado que as imagens possuem estruturas anatômicas [13] presente em regiões de baixo contraste, e de alto contraste, respectivamente consideradas mais e menos complexas para extração de informação. Num primeiro momento, serão utilizadas as regiões consideradas menos complexas, e depois, num segundo momento de desenvolvimento deste projeto, serão utilizadas as demais regiões.

C. Pré-Processamento de Imagens

Considerada uma etapa importante deste projeto, pois envolve melhorar a qualidade das imagens a fim de ressaltar características chave das estruturas anatômicas, nas quais serão detectados os pontos cefalométricos.

Para realizar este objetivo serão aplicados algoritmos para melhorar o contraste das imagens como o CLAHE (Contrast Limited Adaptive Histogram Equalization) [15], junto a aplicação dos filtros da gaussiana e mediana para a diminuição de ruídos e suavização das áreas de interesse. Além destas técnicas, outros algoritmos que possam auxiliar na identificação das regiões de interesse (onde os pontos deverão ser marcados) serão desenvolvidos e implementados.

D. Detectar Automaticamente Pontos Cefalométricos

Na literatura existem três categorias de técnicas utilizadas para detectar pontos cefalométricos automaticamente. A primeira categoria segue uma estratégia similar a usada pelos técnicos de ortodontia e emprega uma combinação de técnicas de processamento de imagens para extrair os contornos importantes e localizar os pontos cefalométricos. Já a segunda, emprega sistemas de detecção de contornos para reduzir as áreas de procura e encontrar a localização exata dos pontos. Uma terceira categoria, bastante estudada atualmente, utiliza técnicas de Inteligência Artificial.

Este projeto busca detectar a maior quantidade de pontos com a melhor precisão possível, para isso será incorporado ao algoritmo o melhor de cada técnica levando em consideração a localização do ponto, pois a depender da região que este se encontra é mais interessante utilizar por exemplo uma rede neural com um descritor de forma, ao invés de um detector de borda junto a descrição da localização do ponto, assim como o inverso também pode vir a ocorrer.

E. Validação e Levantamento de Erros.

Essa etapa consiste na comparação dos resultados obtidos usando o algoritmo proposto com a marcação dos pontos




Fig. 1. Pontos Cefalométricos

cefalométricos feita por um especialista da área de ortodontia, buscando estabelecer a margem de erro na detecção de cada ponto cefalométrico. Para isso será desenvolvido um programa que permita o especialista marcar os pontos cefalométricos, e estas informações serão armazenadas em um banco de dados.

O resultado gerado pelo algoritmo também será armazenado em um banco de dados e em seguida será comparado com o do especialista utilizando a fórmula de distância entre dois pontos. O resultado dessa operação definirá o erro do algoritmo e se ele está de acordo com a necessidade clínica, que define um erro inferior a 2mm como correto, menor que 4mm aceitável, acima de 4 mm é considerado incorreto [3].

IV. RESULTADOS PRELIMINARES

Até o presente momento as etapas de “Seleção dos Pontos Cefalométricos que Serão Detectados pelo Algoritmo”, “Pré-Processamento de Imagens” e “Detectar Automaticamente Pontos Cefalométricos” estão em desenvolvimento. A etapa de “Ampliação do Dataset” ainda não foi inicializada e a etapa de “Validação e Levantamento de erros” foi iniciada para validar as técnicas que já foram implementadas até o presente momento.

A seguir serão apresentados os resultados preliminares obtidos com as etapas de “Seleção dos Pontos Cefalométricos que Serão Detectados pelo Algoritmo”, “Pré-Processamento de Imagens” e de “Detectar Automaticamente Pontos Cefalométricos”.




Fig. 2. Processo de segmentação

A. Seleção dos Pontos Cefalométricos que serão detectados pelo algoritmo

No primeiro momento foram escolhidos pontos com fácil entendimento sobre sua descrição de localização. Outro critério adotado foi o de presença em regiões anatômicas que possam servir de apoio a localização de regiões para outros pontos, que serão utilizados na segunda fase do projeto.

Levando em consideração estes critérios foram selecionados para a primeira etapa os seguintes pontos: N, Pn, Cm, Sn, Ls, St, Pg', B, Pg, E, Gn, Me (que podem ser observados na Figura 1). Estes 11 pontos estão distribuídos em 4 regiões diferentes (nariz, lábios, queixo, e násio).

B. Pré-Processamento de Imagens

Seguindo a ideia de Jain [16], essa etapa foi subdividida em duas atividades, a primeira foi responsável por identificar regiões de interesse no cefalograma, enquanto a segunda buscou aprimorar a qualidade desta região a fim de facilitar a etapa de marcação dos pontos cefalométricos. Estas duas atividades são apresentadas a seguir:

1) *Localização das regiões de interesse:* Nesta etapa são localizadas as regiões do nariz, lábio superior e queixo. A partir de um conhecimento prévio do crânio humano foi possível definir um segmento em que a região deve estar presente, esta foi chamada de macrorregião (Figura 2c), no entanto, essa ainda é considerada grande e pode englobar outras estruturas que podem afetar a etapa de marcação dos pontos.

Para melhorar a qualidade da macrorregião foi utilizado o algoritmo CLAHE para maximizar o contraste e a visibilidade das estruturas de interesse [15]. Em seguida foi aplicado nesse segmento uma técnica de template matching, utilizando três templates diferentes (Figura 2b), todos segmentos de imagens presentes no dataset [11]. A necessidade de utilizar três templates se deu devido a variabilidade da anatomia humana, encontrar um padrão específico para essas estruturas torna-se uma missão difícil, pois, podem variar pela forma ou tamanho dentre os pacientes.

A aplicação de cada template resultou em 4 tipos de coordenadas que representam os cantos: superior esquerdo, superior direito, inferior esquerdo e inferior direito. A relação desses pontos resulta no segmento da macrorregião que corresponde ao padrão aplicado (Figura 3a). As 12 coordenadas encontradas geralmente são diferentes, pois os templates escolhidos diferem pelo tamanho e formato da região.

Para mensurar as coordenadas de cada template aplicado foi desenvolvido um algoritmo de junção de templates (Figura 3b) que processa essas coordenadas, e de acordo com a relação de sua disposição na macrorregião, seleciona ou calcula a melhor opção para cada tipo de coordenada gerando assim uma microrregião (Figura 3c).

2) *Aprimorar a qualidade da imagem:* Na microrregião foi feito um processo de binarização local utilizando o método de Otsu [17], em seguida foi aplicado o filtro da mediana para suavizar a imagem e diminuir o ruído.




Fig. 3. Etapas de identificação da região de interesse

A parte final do processo desta etapa foi a busca por um ponto de corte para eliminar ruídos, por exemplo, na região do nariz tem muito ruído na direita da imagem, então foi feita uma busca no histograma da imagem que possibilitasse um corte na tentativa de eliminar esse ruído, e formar a região de interesse (Figura 2e).

C. Detectar Automaticamente Pontos Cefalométricos

Essa etapa foi subdividida em duas atividades, aplicação do detector de bordas e detecção do ponto. A seguir cada uma destas atividades são apresentadas.

1) *Aplicação do Detector de Bordas:* Após a binarização da microrregião foi necessário aplicar o detector de bordas. Com base no trabalho desenvolvido por Jain [13], o algoritmo Canny foi o escolhido (Figura 4a).


2) *Detecção dos pontos cefalométricos:* Cada ponto cefalométrico possui uma descrição sobre sua localização, por exemplo, o ponto pró-nasal (PN) é o ponto mais anterior do nariz, sendo localizado na ponta do nariz [14].

Na figura 4a é possível observar a microrregião após a aplicação do detector de bordas, já na figura 4b é possível visualizar a marcação do ponto PN em azul.

3) *Validação e levantamento de erros:* Até o presente momento, a única técnica que foi validada foi a de localização das regiões de interesse (nariz, queixo e lábios). A técnica utilizada, apresentada na subseção “Pré-Processamento de Imagens” da seção de “Resultados Preliminares”, apresentou uma precisão de 100%, 93%, 90% para as regiões do nariz, queixo e lábios, respectivamente. Esse resultado foi obtido através da aplicação do algoritmo de junção de templates, que analisa as coordenadas de cada vértice resultante e faz uma mensuração baseada na distância entre os vértices do mesmo grupo (superior direito, superior esquerdo, inferior direito, inferior esquerdo).

Este algoritmo permite localizar a região de interesse mesmo que nenhum dos templates associados acerte 100% a localização. Para tanto foi utilizado um dataset composto por 44 cefalogramas, sendo 10 utilizados para a escolha dos templates e treinamento do algoritmo, e 34 para a fase de teste.

Após a localização da região de interesse do nariz foi possível marcar o ponto cefalométrico Pn, conforme apresentado na figura 4b. O ponto Pn está marcado em azul.



(a) Aplicação do Canny (b) Ponto Pn

Fig. 4. Marcação do Ponto Pn

V. CONCLUSÃO

O presente trabalho encontra-se no início, mas já é possível localizar as regiões de interesse nariz, queixo e lábios, onde estão localizados um bom número de pontos. A localização do ponto Pn já está implementada, e as rotinas de localização dos pontos Cm, Ls, Gn, Me, E, Pg e N também encontram-se em desenvolvimento.

Para detectar os pontos citados anteriormente também estão sendo desenvolvidas rotinas de varredura nas imagens buscando eliminar ruídos que se mostram comum nas imagens analisadas.

Dando continuidade ao trabalho, outras técnicas, como redes neurais serão utilizadas a fim de que se possa detectar uma maior quantidade de pontos com a melhor precisão possível.

REFERÊNCIAS

- [1] S. Shahidi, M. Oshagh, F. Gozin, P. Salehi, and S. Danaei, “Accuracy of computerized automatic identification of cephalometric landmarks by a designed software,” *Dentomaxillofacial Radiology*, vol. 42, no. 1, pp. 20 110 187–20 110 187, 2013.
- [2] T. B. B. Cléber Bidegain Pereira, Carlos Alberto Mundstock, *Introdução à Cefalometria Radiográfica 3ª ed.*, E. D. U. D. R. G. D. SUL, Ed. Pancast, 1998.
- [3] W. Yue, D. Yin, C. Li, G. Wang, and T. Xu, “Automated 2-d cephalometric analysis on x-ray images by a model-based approach,” *Biomedical Engineering, IEEE Transactions on*, vol. 53, no. 8, pp. 1615–1623, 2006.
- [4] W. Houston, “A comparison of the reliability of measurement of cephalometric radiographs by tracings and direct digitization,” *Swedish dental journal. Supplement*, vol. 15, p. 99, 1982.
- [5] M. Amad Neto, “Estudo da padronização para a determinação de pontos cefalométricos utilizados na cefalometria radiológica,” Ph.D. dissertation, Universidade de São Paulo, 2004.
- [6] A. N. Mustaphá, “Avaliação da variação nas grandezas cefalométricas obtidas pelo método manual comparada com dois métodos digitais indiretos da análise de mc namara,” Ph.D. dissertation, Universidade de São Paulo, Faculdade de Odontologia, 1999.
- [7] P. Vučinić, Ž. Trpovski, and I. Šćepan, “Automatic landmarking of cephalograms using active appearance models,” *The European Journal of Orthodontics*, vol. 32, no. 3, pp. 233–241, 2010.
- [8] I. P. Ningrum, A. Harjoko, and M. Mudjosemedi, “Robust cephalometric landmark identification on cephalometric downs analysis,” *International Journal of Computer & Electrical Engineering*, vol. 6, no. 2, 2014.
- [9] I. El-Feghi, M. A. Sid-Ahmed, and M. Ahmadi, “Automatic localization of craniofacial landmarks for assisted cephalometry,” *Pattern Recognition*, vol. 37, no. 3, pp. 609–621, 2004.
- [10] R. Vandaele, R. Marée, S. Jodogne, and P. Geurts, “Automatic cephalometric x-ray landmark detection challenge 2014: A machine learning tree-based approach.”
- [11] A. A. Pouyan and M. Farshbaf, “Cephalometric landmarks localization based on histograms of oriented gradients,” in *Signal and Image Processing (ICSIP), 2010 International Conference on*. IEEE, 2010, pp. 1–6.

- [12] A. Kaur and C. Singh, "Automatic cephalometric landmark detection using zernike moments and template matching," *Signal, Image and Video Processing*, vol. 9, no. 1, pp. 117–132, 2013.
- [13] B. Santana, F. Oliveira, I. Bastos, L. Souza, and M. Angelo, "Criação de um banco de imagens cefalométricas on-line."
- [14] L. G. Gandini Jr, A. dos Santos-Pinto, D. B. Raveli, M. T. Sakima, and L. Parsekian, "Análise cefalométrica padrão unesp araraquara," *R Dental Press Ortodon Ortop Facial*, vol. 10, pp. 139–57, 2005.
- [15] K. Zuiderveld, "Contrast limited adaptive histogram equalization," in *Graphics gems IV*. Academic Press Professional, Inc., 1994, pp. 474–485.
- [16] A. Jain, T. Mondal, and H. Sardana, "A novel strategy for automatic localization of cephalometric landmarks," in *Computer Engineering and Technology (ICCET), 2010 2nd International Conference on*, vol. 3. IEEE, 2010, pp. V3–284.
- [17] N. Otsu, "A threshold selection method from gray-level histograms," *Automatica*, vol. 11, no. 285-296, pp. 23–27, 1975.