



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ODONTOLOGIA DE PIRACICABA

Giovani Bressan Fogalli

Desenvolvimento de algoritmos para processamento de imagens da microestrutura do esmalte dentário e impressões digitais obtidas a distância.

Development of algorithms for processing of images of tooth enamel microstructure and fingerprints obtained from distance.

Piracicaba
2023

Giovani Bressan Fogalli

Desenvolvimento de algoritmos para processamento de imagens da microestrutura do esmalte dentário e impressões digitais obtidas a distância.

Development of algorithms for processing of images of tooth enamel microstructure and fingerprints obtained from distance.

Tese apresentada à Faculdade de Odontologia de Piracicaba da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Doutor em Biologia Buco-Dental, na Área de Histologia e Embriologia.

Orientador: Prof. Dr. Sérgio Roberto Peres Line

ESTE EXEMPLAR CORRESPONDE À
VERSÃO FINAL DA TESE DEFENDIDA
PELO ALUNO GIOVANI BRESSAN
FOGALLI, E ORIENTADA PELO PROF.
DR. SÉRGIO ROBERTO PERES LINE.

Piracicaba
2023

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Faculdade de Odontologia de Piracicaba
Marilene Girello - CRB 8/6159

Fogalli, Giovani Bressan, 1992-
F687d Desenvolvimento de algoritmos para processamento de imagens da microestrutura do esmalte dentário e impressões digitais a distância / Giovani Bressan Fogalli. – Piracicaba, SP : [s.n.], 2023.

Orientador: Sergio Roberto Peres Line.
Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de Odontologia de Piracicaba.

1. Esmalte dentário. 2. Biometria. 3. Processamento de imagens. 4. Redes neurais (Computação). I. Line, Sergio Roberto Peres, 1963-. II. Universidade Estadual de Campinas. Faculdade de Odontologia de Piracicaba. III. Título.

Informações Complementares

Título em outro idioma: Development of algorithms for processing of images of tooth enamel microstructure and fingerprints obtained from distance

Palavras-chave em inglês:

Dental enamel

Biometry

Image processing

Neural networks (Computer science)

Área de concentração: Histologia e Embriologia

Titulação: Doutor em Biologia Buco-Dental

Banca examinadora:

Sergio Roberto Peres Line [Orientador]

Liza Lima Ramenzoni

Ricardo José Ferrari

Raquel Fernanda Gerlach

Eduardo Daruge Junior

Data de defesa: 28-07-2023

Programa de Pós-Graduação: Biologia Buco-Dental

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0002-8504-3469>

- Currículo Lattes do autor: <http://lattes.cnpq.br/1085034020004395>



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Odontologia de Piracicaba

A Comissão Julgadora dos trabalhos de Defesa de Tese de Doutorado, em sessão pública realizada em 28 de julho de 2023, considerou o candidato GIOVANI BRESSAN FOGALLI aprovado.

PROF. DR. SERGIO ROBERTO PERES LINE

PROF^a. DR^a. LIZA LIMA RAMENZONI

PROF. DR. RICARDO JOSÉ FERRARI

PROF^a. DR^a. RAQUEL FERNANDA GERLACH

PROF. DR. EDUARDO DARUGE JUNIOR

A Ata da defesa, assinada pelos membros da Comissão Examinadora, consta no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Código de Financiamento 001.

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), sob processos de número 2018/23038-7 e 2020/07401-4.

Ao Prof. Dr. Sérgio Roberto Peres Line pela orientação, paciência e amizade durante todos esses anos.

À Faculdade de Odontologia de Piracicaba, na pessoa do seu Diretor Prof. Dr. Flávio Henrique Baggio Aguiar.

Ao Dr. Daniel Baum pela orientação e colaboração em parte do projeto realizado no Zuse Institute Berlin.

À minha esposa Camila Menezes, por todo suporte e companheirismo ao longo desse trajeto.

A todas as pessoas que contribuíram direta ou indiretamente para a realização deste trabalho.

RESUMO

O esmalte dentário é o tecido mais mineralizado do corpo humano sendo caracterizado por camadas de prismas em direções alternadas regularmente. Estas camadas sucessivas formam as Bandas de Hunter-Schreger (HSB) que aparecem como faixas claras e escuras quando vistas com iluminação lateral, assemelhando-se às impressões digitais. Demonstramos anteriormente que o padrão das HSB é altamente variável e único para cada dente. Assim, pode ser um método útil para a identificação pessoal, uma vez que o esmalte pode resistir à degradação pelo tempo e condições ambientais agressivas. Apesar de promissor, a popularização deste método é dificultada por limitações técnicas no processamento das imagens. O objetivo do presente projeto foi desenvolver algoritmos para viabilizar a utilização do método por meio de todas as etapas biométricas: aquisição de imagem, evidenciação das HSB, segmentação da área de interesse, filtro e binarização das HSB, extração de características e comparação biométrica. Haja vista que o padrão das HSB se assemelha às impressões digitais humanas, também adaptamos e testamos o filtro usado nas HSB em imagens de impressões digitais obtidas a distância. Os algoritmos desse processo estão interligados e portanto foram desenvolvidos e aprimorados em conjunto. Resultados da segmentação das HSB de maneira automática para dois métodos diferentes, Segmentação baseada em Anisotropia (ABS) e Rede Neural Convolucional (U-Net), tiveram índice de Jaccard de 0.766 e 0.837, respectivamente. A avaliação do desempenho do filtro e binarização das HSB foi realizada visualmente e indiretamente por meio das etapas subsequentes à segmentação. A extração de características e a comparação biométrica foram criadas a partir de adaptações de técnicas usadas em impressões digitais e revelaram um resultado final de identificação positiva com *Equal Error Rate* (EER) de 0.061, quando iluminação dos dois lados de cada dente são utilizadas em uma amostra com 115 dentes extraídos. De modo geral, embora haja espaço para melhora das técnicas usadas, o novo traço biométrico, nomeado *toothprint*, por meio destes algoritmos criados, já apresenta enorme potencial para uso em larga escala. O teste do filtro adaptado para impressões digitais foi avaliado visualmente e também mostrou potencial para uso, embora ainda seja necessária a verificação de compatibilidade com imagens convencionais obtidas por meio de sensores.

Palavras-chave: Esmalte dentário. Biometria. Processamento de imagens. Redes neurais (Computação).

ABSTRACT

Tooth enamel is the hardest tissue in the human body, formed by prism layers in regularly alternating directions. These prisms form the Hunter-Schreger Bands (HSB) pattern when under side illumination, which is composed of light and dark stripes resembling fingerprints. We have shown in previous works that the HSB pattern is highly variable and unique for each tooth. Therefore, it could be useful for personal identification, since the tooth enamel can withstand degradation through time and under aggressive environmental conditions. Although promising, the popularity of this method is hampered by technical limitations in image processing. The aim of the current project was to develop and enable the use of this method through all biometric steps: image acquisition, HSB enhancement, HSB segmentation, filtering and binarization, feature extraction, and matching. Considering the resemblance of the HSB to the human fingerprint pattern, we also adapted and tested the filter used on HSB to touchless fingerprint images. The algorithms of this process are interconnected and therefore were developed and improved together. Results of automated HSB segmentation for two different methods, Anisotropy-based Segmentation (ABS) and Convolutional Neural Network (U-Net), had a Jaccard index of 0.766 and 0.837, respectively. The evaluation of performance of HSB filtering and binarization was performed visually and indirectly by the following steps after segmentation. The feature extraction and matching algorithms were created upon adaptations from fingerprint techniques and revealed as the final result of matching evaluation an Equal Error Rate (EER) of 0.061, when both enlightened sides of each tooth were used together in a sample of 115 extracted teeth. Generally, even though there is room for improvement of applied techniques, the new biometric trait, named *toothprint*, through these developed algorithms, shows a huge potential for use on a large scale. The adapted filtering step test on fingerprints was assessed visually and also demonstrated potential for usage, however compatibility must still be verified regarding conventional fingerprints obtained by common sensors.

Key words: Dental enamel. Biometry. Image processing. Neural networks (Computer science).

SUMÁRIO

1 INTRODUÇÃO	9
2 METODOLOGIA	13
3 ARTIGO: Segmentation of tooth enamel microstructure images using classical image processing and U-Net approaches	15
4 RESULTADOS	33
5 DISCUSSÃO	42
6 CONCLUSÃO	44
REFERÊNCIAS	45
ANEXOS	
Anexo 1 – Relatório de similaridade	48
Anexo 2 – Comprovante de submissão	50
Anexo 3 – Parecer do comitê de ética em pesquisa	51

1 INTRODUÇÃO

Identificação pessoal

A identificação pessoal está se tornando cada vez mais importante na vida moderna. Ela pode ser necessária em procedimentos simples, como acessar rede de computadores ou em situações mais complexas, como a identificação post-mortem e análise criminal. Ela é geralmente obtida pela utilização de senhas, características físicas, fotografias, padrão da íris, características macroscópicas da dentição, impressão digital e, mais recentemente, a análise de DNA. Entretanto, métodos de identificação post-mortem possuem certas limitações, especialmente em casos onde os corpos investigados sofreram decomposição, fragmentação ou putrefação, como em cadáveres extremamente carbonizados, descobertos vários anos após a morte ou quando são encontrados apenas fragmentos de tecido como em explosões ou outras formas de desastres em massa (Perry et al. 1988). Para identificar um único indivíduo baseando-se em métodos biométricos, as seguintes características são desejáveis: alta unicidade para cada indivíduo, fácil transmissão da característica, fácil obtenção, invariável ao tempo (sem modificações significativas durante um período de tempo), ser passível de ser adquirido com métodos pouco invasivos, e de baixo custo (Weicheng e Tieniu 1999). A impressão digital é um dos mais conhecidos procedimentos biométricos usados para identificação humana. Esta característica é praticamente única para cada indivíduo, sendo bastante precisa para identificação humana (Weicheng e Tieniu 1999). A análise do DNA genômico tem se tornado um método poderoso para identificação humana. Este método, entretanto, requer mão de obra altamente especializada, é laborioso e relativamente dispendioso, e sua análise requer vários dias, impossibilitando a obtenção de resultados imediatos. Além disso, o sucesso da análise do DNA é também altamente dependente da preservação do espécime colhido e da ausência de contaminações. O exame odontológico compara registros ante-mortem (radiografias, odontogramas, e documentos do paciente) com as características post-mortem. Quando esses registros não estão disponíveis ou são insuficientes para a identificação, a análise antropológica é a última alternativa para identificação por meio da estimativa de idade, sexo, raça, entre outras características. Entretanto, a chance de identificação neste estágio é reduzida.

Identificação pela microestrutura do esmalte

O órgão dentário é frequentemente utilizado na identificação humana. O esmalte dentário é o tecido com maior quantidade de mineral no corpo (95%). O alto grau de

mineralização proporciona ao esmalte alta resistência e dureza, permitindo a este tecido suportar condições extremas de degradação, como a exposição a altas temperaturas, umidade e pressão excessivas (Sweet & Sweet 1995, Valenzuela et al. 2000). As características dentais provaram ser particularmente disponíveis para a identificação de vítimas de carbonização em alta temperatura em desastres em massa, quando o reconhecimento visual e a identificação através da impressão digital não são mais possíveis (Valenzuela et al. 2000). Na maior parte das espécies de mamíferos, incluindo humanos, o esmalte é caracterizado por apresentar camadas de prismas dispostas regularmente em direções alternantes formando um ângulo de até aproximadamente 90°. (Koenigswald et al. 1987). Estas camadas sucessivas de prismas formam as Bandas de Hunter-Schreger (HSB) que aparecem como camadas claras e escuras quando observadas sob uma iluminação de baixa potência em uma lupa estereoscópica (Koenigswald 1994). As bandas claras e escuras podem ser invertidas mudando a direção da fonte de iluminação. Este fenômeno óptico ocorre devido ao fato dos prismas funcionarem como fibras ópticas quando expostos sob uma fonte de luz direta (Koenigswald e Rose 2005). Considera-se que as HSB existentes na maior parte das espécies de mamíferos, servem como uma estrutura funcional adaptativa que poderia aumentar a resistência, durabilidade e proteção do esmalte contra a formação e propagação de quebras, trincas e rachaduras (Koenigswald et al. 1987, Stefen 1999, Stefen 2001). A estrutura das HSB pode ser observada em dentes íntegros em mamíferos de até 60 milhões de anos (Line e Begqvist 2003), e em dentes humanos aquecidos a temperatura de 300°C por 1 h (Ramenzoni e Line 2006), fatos que evidenciam a grande resistência destas estruturas aos fatores externos. Quando observadas com iluminação lateral, as faixas claras e escuras das HSB humanas se assemelham a uma impressão digital. Em trabalho utilizando 262 incisivos inferiores humanos extraídos e 30 dentes fotografados *in situ* mostramos que o padrão das HSB pode ser analisado e diferenciado por software de impressão digital (Verifinger, Neurotechnology), permitindo a identificação humana baseada nas HSB (Line e Ramenzoni 2006).

Além da publicação (Ramenzoni e Line 2006) e patenteamento do método, o grande potencial deste achado, especialmente em casos de desastres de destruição em massa fez com que esta descoberta fosse amplamente divulgada nos principais veículos da imprensa leiga nacional (<http://jornalnacional.globo.com/Telejornais/JN/0,,MUL565579-10406,00-IDENTIDADE+NOS+DENTES.html>). No entanto, o desenvolvimento e aprimoramento desta metodologia sofreu pela dificuldade de se obter imagens de boa qualidade, especialmente na

boca de indivíduos (*in situ*). Existem vários obstáculos que precisam ser vencidos para que esta metodologia seja viável para uso em larga escala. Recentemente foi mostrado que o uso de filtro polarizador e impregnação com óleo vegetal podem melhorar substancialmente a qualidade das imagens de HSB obtidas de dentes extraídos e na cavidade bucal de voluntários (Arrieta e Line 2017). Também mostramos o uso de um protocolo para o realce das HSB (Arrieta et al. 2018). No entanto, ainda existem dificuldades no processamento das imagens, sendo os principais desafios:

1. Padronização e controle de qualidade da imagem capturada;
2. Rápida e correta segmentação da região de interesse contendo as HSB;
3. Remoção de ruídos e filtragem das HSB;
4. Comparação biométrica eficaz.

No presente trabalho, o artigo submetido para publicação apresenta abordagens para lidar com o segundo item dos desafios listados. Os demais itens são descritos ao longo da tese.

Tratamento de imagens de impressões digitais fotografadas

Impressões digitais vêm sendo usadas como método de identificação humana há mais de um século, sendo seu uso bastante incrementado no século 21 pelo desenvolvimento de scanners digitais associados a *softwares* que permitem a leitura, extração, e armazenamento em bancos de dados para posterior comparação. O uso de impressões digitais tornou-se parte de nossa rotina. Recentemente a captura de impressões digitais a distância, obtidas sem contato da digital com leitores, tem despertado interesse de pesquisadores (Galbally et al. 2017, Noh et al. 2018) e empresas de biotecnologia (www.technologyreview.com/s/422400/fingerprints-go-the-distance/). A possibilidade de obtenção de imagens de impressões digitais a distância também tem sido fonte de preocupação, haja vista que imagens de impressões digitais podem ser obtidas sem o consentimento (www.theguardian.com/technology/2014/dec/30/hacker-fakes-german-ministers-fingerprints-using-photos-of-her-hands). Neste procedimento não é necessário parar para colocar os dedos em escaneadores e a obtenção da imagem pode ser feita com o usuário em movimento. O padrão das HSB assemelha-se às impressões digitais humanas, pois a obtenção das imagens é feita a distância. Além disso, assim como nas imagens das HSB, a iluminação das impressões digitais feitas a distância pode ser desigual nas extremidades mediais e laterais dos dedos. Neste sentido é possível que algoritmos desenvolvidos para a

melhora das imagens das HSB também possam ser usados na melhora das imagens de impressões digitais feitas a distância. Desta maneira os procedimentos computacionais desenvolvidos para tratamento das imagens para as HSB foram também testados para essa finalidade.

2 METODOLOGIA

Todos os experimentos foram realizados com aprovação do Comitê de Ética em Pesquisa da FOP sob o número CAAE 03596918.2.0000.5418. Fotografias de 127 dentes anteriores extraídos do Biobanco “Ossos, Dentes e Cadáveres Humanos” foram usadas para desenvolver e testar os algoritmos. Destes, 115 dentes apresentaram HSB sob iluminação lateral e foram usados para o desenvolvimento do projeto. A iluminação ambiente foi testada em relação às capturas de imagem e demonstrou não interferir com a qualidade das HSB. Os 12 dentes restantes não puderam ser usados por não apresentarem HSB sob iluminação lateral. A distribuição dos dentes de acordo com o tipo de dente e a condição do elemento dental está representada na Tabela 1, sendo a maioria dos dentes usados incisivos inferiores hígidos. As fotografias foram capturadas com câmera Canon EOS 5D mark iii acoplada a uma objetiva InfiniProbe TS-160 (Infinity Photo-Optical Company, Boulder, Co, EUA). Impressões digitais foram capturadas com câmera fotográfica de *smartphone* de 12 megapixels para adaptação dos algoritmos e testes. A distância de captura variou de 15 a 30 cm. Os algoritmos foram desenvolvidos em Python 3.9.x usando bibliotecas específicas para imagens, como: Numpy, Scikit-Image, OpenCV, Scipy e Tensorflow.

Os algoritmos desenvolvidos seguem um fluxograma que está descrito na Figura 1. O cadastro do dente inicia-se pela fotografia, evidenciação das HSB (Arrieta et al. 2018), segmentação da área utilizável das HSB (artigo submetido: seção 3 ARTIGO), filtro e binarização da região das HSB segmentadas, e extração das características biométricas. Esse procedimento é repetido no mínimo três vezes para cada lado iluminado do dente, e o melhor modelo (*toothprint*) para cada lado iluminado (esquerdo (L) e direito (R)) é escolhido por meio de comparação biométrica entre si, onde o modelo com maior *score* é escolhido como representante do dente para ser inserido no banco de dados. Esse procedimento foi realizado em dois momentos diferentes (1 e 2). As *toothprints* foram armazenadas em bancos de dados distintos: L1, L2, R1 e R2; e depois usadas para o teste de identificação.

Tabela 1. Distribuição da amostra utilizada de 127 dentes de acordo com a condição dos dentes.

	Cariado, restaurado ou fraturado	Hipoplasia, mancha ou desgaste	Hígido	Não utilizado (sem HSB útil)
Canino	4	3	7	3
Incisivo inferior	12	3	56	4
Incisivo superior	15	6	9	5
Total	31	12	72	12

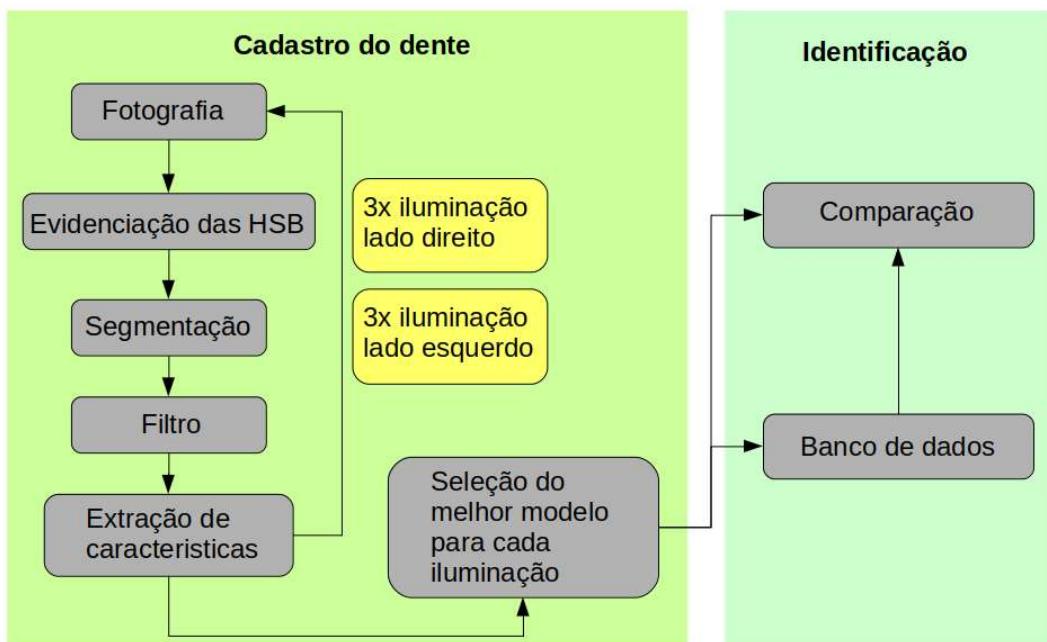


Figura 1. Fluxograma da metodologia para cadastro e identificação de dentes.

3 ARTIGO: Segmentation of tooth enamel microstructure images using classical image processing and U-Net approaches



OPEN ACCESS

EDITED BY

Pankaj K. Sa,
National Institute of Technology Rourkela, India

REVIEWED BY

Alessandro Bruno,
Università IULM, Italy
Subrajeet Mohapatra,
Birla Institute of Technology, Mesra, India

*CORRESPONDENCE

Sérgio Roberto Peres Line
serglin@unicamp.br

RECEIVED 02 May 2023

ACCEPTED 19 July 2023

PUBLISHED 10 August 2023

CITATION

Fogalli GB, Line SRP and Baum D (2023) Segmentation of tooth enamel microstructure images using classical image processing and U-Net approaches. *Front. Imaging.* 2:1215764.
doi: 10.3389/fimag.2023.1215764

COPYRIGHT

© 2023 Fogalli, Line and Baum. This is an open-access article distributed under the terms of the [Creative Commons Attribution License \(CC BY\)](#). The use, distribution or reproduction in other forums is permitted, provided the original author(s) and the copyright owner(s) are credited and that the original publication in this journal is cited, in accordance with accepted academic practice. No use, distribution or reproduction is permitted which does not comply with these terms.

Segmentation of tooth enamel microstructure images using classical image processing and U-Net approaches

Giovani Bressan Fogalli^{1,2}, Sérgio Roberto Peres Line^{1*} and Daniel Baum²

¹Department of Biosciences, Piracicaba Dental School, State University of Campinas, Piracicaba, Brazil

²Department of Visual and Data-Centric Computing, Zuse Institute Berlin, Berlin, Germany

Introduction: Tooth enamel is the hardest tissue in human organism, formed by prism layers in regularly alternating directions. These prisms form the Hunter–Schreger Band (HSB) pattern when under side illumination, which is composed of light and dark stripes resembling fingerprints. We have shown in previous works that HSB pattern is highly variable, seems to be unique for each tooth and can be used as a biometric method for human identification. Since this pattern cannot be acquired with sensors, the HSB region in the digital photograph must be identified and correctly segmented from the rest of the tooth and background. Although these areas can be manually removed, this process is not reliable as excluded areas can vary according to the individual's subjective impression. Therefore, the aim of this work was to develop an algorithm that automatically selects the region of interest (ROI), thus, making the entire biometric process straightforward.

Methods: We used two different approaches: a classical image processing method which we called anisotropy-based segmentation (ABS) and a machine learning method known as U-Net, a fully convolutional neural network. Both approaches were applied to a set of extracted tooth images.

Results: U-Net with some post processing outperformed ABS in the segmentation task with an Intersection Over Union (IOU) of 0.837 against 0.766.

Discussion: Even with a small dataset, U-Net proved to be a potential candidate for fully automated in-mouth application. However, the ABS technique has several parameters which allow a more flexible segmentation with interactive adjustments specific to image properties.

KEYWORDS

image processing, segmentation, fully convolutional neural network, tooth enamel, Hunter–Schreger bands, biometrics

1. Introduction

Tooth enamel is the most highly mineralized tissue (95% of mineral) in an organism and is able to withstand high temperatures, abrasion, aggressive environments (i.e., humidity, pressure), and degradation over time (Sweet and Sweet, 1995; Valenzuela et al., 2000). These characteristics have proved to be beneficial for human identification in massive disasters, such as when victims were carbonized at high temperatures and visual or fingerprint identification was no longer possible (Valenzuela et al., 2000).

Most mammals, including humans, present with tooth enamel composed of layers of prisms regularly arranged in alternating directions nearly perpendicular to each other (von Koenigswald et al., 1987). These prisms act like optic fibers when exposed to

a direct light source (Whittaker and Rothwell, 1984) and form Hunter–Schreger Bands (HSBs), an optical phenomenon that appears as light and dark stripes on the tooth's surface and can be seen with a magnifier when a low-power light is placed to the side of the tooth (Koenigswald, 1994). A thorough analysis of HSBs may provide information regarding a species' life history and taxon identification (Line and Bergqvist, 2005) since it is frequently preserved in tooth fossils dating from thousands to over 60 million years (Koenigswald, 1994), can be used for inferences about diet adaptation (Tseng, 2012), and provide data for biometric identification (Ramenzoni and Line, 2006).

Biometric analysis is the process of personal identification using the biological, physical, or behavioral features of an individual. Currently, there are several biometric methods, including facial, iris, fingerprint, ear, and gait recognition. These methods are applied using automated systems and software that can be used to distinguish individuals reliably. Some desirable characteristics of biometrics data are their being highly unique, easily obtainable, time-invariant (no significant changes over time), easily transmittable, non-intrusively acquirable, and distinguishable by humans without special training (Shen and Tan, 1999). Previous work has shown that a photograph of a tooth with side lighting enhances the HSB appearance (Arrieta and Line, 2017) and that a digital image of HSBs can be treated to highlight the bands (Arrieta et al., 2018). The light and dark patterns formed by the HSBs resemble fingerprints and seem to be unique for each tooth and between individuals (Ramenzoni and Line, 2006). Moreover, tooth image acquisition is non-invasive and practical and can be obtained with a photographic camera using a macro lens.

To be used as a human identification method, as opposed to fingerprints, HSB features cannot be extracted directly from sensors because they are only visible with side illumination. A problem in the image processing of HSBs is the removal of background image areas, including areas of the tooth with poorly defined bands and areas outside of the tooth. These regions can interfere with digital image filtering and produce false HSB patterns. Although these areas can be manually removed, this process is not reliable since the selected areas can vary according to the individual's subjective perception. In addition, it is also a time-consuming procedure. Therefore, the aim of the present project is to develop software that automatically selects the region of interest (ROI), that is, the HSB region whose bands are reliable for biometric comparison, thus making the entire process straightforward.

The workflow for the whole biometric process is illustrated in Figure 1. The segmentation approaches presented here were built to create a proper mask to segment the HSB region, which in turn will be enhanced by an HSB filter and eventually pass through biometric feature extraction for either storage as a template or comparison for personal identification. Note that for real applications, tooth photographs should be taken at the tooth crown level in the mouth. Therefore, anterior teeth are preferred for ease of access. In the present study, we evaluated the techniques for segmentation in extracted teeth but with a similar potential for in-mouth applications.

2. Methods

In this section, we present the methods that were developed to automatically segment the HSBs. The teeth used in this study were provided by the Biobank of Bones, Teeth and Human Corpses of the Department of Biosciences of the Piracicaba Dental School. This study was approved by the research ethics committee of the Piracicaba Dental School under number CAAE 03596918.2.0000.5418. We considered two approaches, classical image processing and a convolutional neural network, for automatic segmentation. The first one is an image processing pipeline based on the anisotropic HSB property. The second one is known as U-Net, a fully convolutional neural network created for medical image segmentation (Ronneberger et al., 2015).

2.1. Anisotropy-based segmentation

The anisotropy-based segmentation (ABS) approach takes advantage of the well-established orientation pattern of HSBs, in addition to their relatively low variation in orientation. Once the tooth photograph is taken with the tooth vertically positioned, its bands consequently will appear horizontally overall. Therefore, it is unnecessary to apply any rotation. The physical property of an object that presents different values according to measures along different axes is called anisotropy. This property arises mainly in the regions of the image containing HSB patterns, and harnessing this characteristic for segmenting the area of interest is possible due to (1) anisotropic features around a tooth are very unlikely to exist, except for the HSBs of its neighboring teeth; (2) the focus of the camera on the HSB pattern of the targeted tooth surface makes other regions blurry; and (3) the HSBs appear only under side lighting, and the residual light effect on neighboring teeth is expected to be weaker. The ABS workflow is shown in Figure 2. A complete description follows. All parameter values chosen were validated across the available data set using the visualization method described by Fogalli et al. (2022).

2.1.1. Smooth and resize

The primary goal of this processing step is to standardize image features before further processing, given the variations present in the input images. Since the initial and enhanced HSB images are noisy, high-resolution images, and the segmentation process do not require these levels of detail; we start the process by smoothing the enhanced HSB image E into E_s such as

$$E_s = W_{(27,27)} \star E, \quad (1)$$

where $W_{(27,27)}$ represents a 27×27 integral kernel (whose sum equals 1) and the star sign (\star) represents a cross-correlation between the kernel and the image E . The expanded version of this expression is demonstrated as follows: Let a be a kernel with size $(2h + 1) \times (2w + 1)$ and B an image; the cross-correlation between

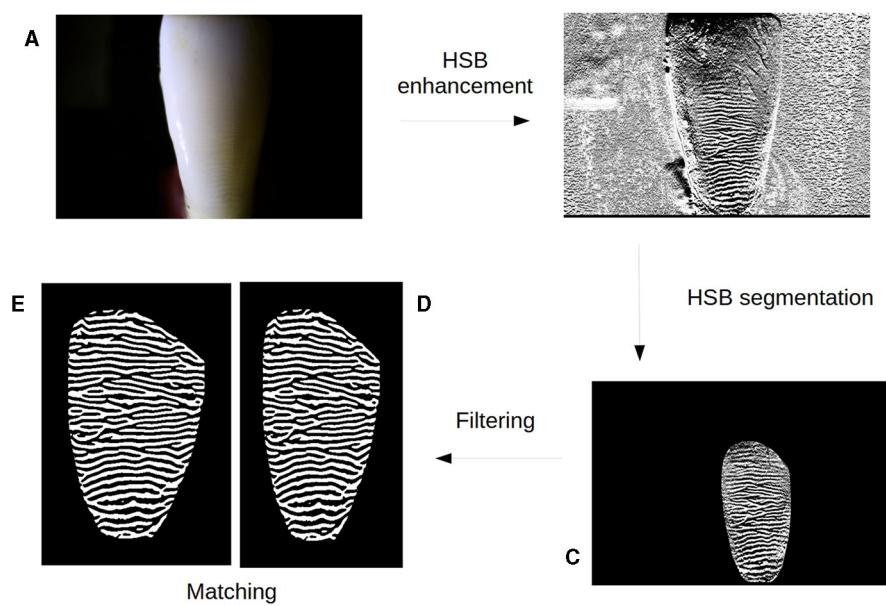


FIGURE 1

Tooth biometrics workflow. The workflow starts with original photography of tooth crown under side lighting (A) that goes through a Hunter-Schreger Band (HSB) enhancement (Arrieta et al., 2018). Then, the reliable enhanced HSB (B) is segmented (C) and filtered into a binary noiseless image representing the tooth HSB pattern (D), which in turn might be stored as template or be compared against tooth templates registered in a database (E) using a matching algorithm.

them can be computed with

$$a \star B(i, j) = \sum_{u=-h}^h \sum_{v=-w}^w a(u, v) \cdot B(u + i, j + v). \quad (2)$$

The ROI seems to follow roughly the shape of the tooth crown. Since anterior teeth are preferable, we assumed its dimensions as default. Consider a front image of an anterior tooth vertically positioned, its frontal surface has a vertical dimension greater than the horizontal dimension at tooth's neck, that is, where the HSBs appear more clearly due to a thinner enamel layer, so the ROI usually is taller vertically and thinner horizontally (Figure 3). Hence, after visual comparisons of the algorithm results using proportions of width over height from 1 (square shape) to $\frac{1}{5}$, the chosen and validated proportion for ROI was set to $\frac{1}{2}$.

In order to maximize performance and standardize the segmentation process, the HSB-enhanced grayscale image E_s with dimensions of M rows and N columns ($M \times N$) is resized to image J of dimensions $P \times Q$ according to the following equations:

$$P = rQ, \quad (3)$$

$$r = \frac{M}{N}, \quad (4)$$

$$Q = \sqrt{\frac{J_{size}}{r}}, \quad (5)$$

$$J_{size} = PQ = k_x k_y u, \quad (6)$$

where parameter u was empirically determined by visually comparing the results for different possible values and validated afterward. It is also proportional to the new desired image size; we used $u = 200$ as default. The scalars $k_x = 61$ and $k_y = 122$ are related to a kernel filter size that will be used later, and their values were chosen accordingly to fit the ROI proportion $\frac{k_x}{k_y} = \frac{1}{2}$. With those settings, the size of image J is fixed at $J_{size} = 1.5 \times 10^6$ pixels. Let image J_b be the blurred version of J , computed as

$$J_b = W_{(3,6)} \star (W_{(3,6)} \star (W_{(3,6)} \star J)), \quad (7)$$

where $W_{(3,6)}$ is a 3×6 integral kernel. Kernel shape and size were selected using the validation approach described previously by Fogalli et al. (2022) for determining other parameters. The horizontally elongated kernel reduces the noise in the background that could mimic HSB edges, mainly in regions of the tooth with artifacts from reflected light, while causing virtually no disturbance to the real HSB.

2.1.2. Edge detection

The HSBs are expected to appear as horizontal stripes. In this processing step, horizontal and vertical edges are detected, hinting at regions containing horizontal stripes (HSBs) or not, respectively. Therefore, after obtaining image J_b , we decompose its features into x and y directions to initially locate the HSB region. Edge detection is performed using horizontal $s_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$ and

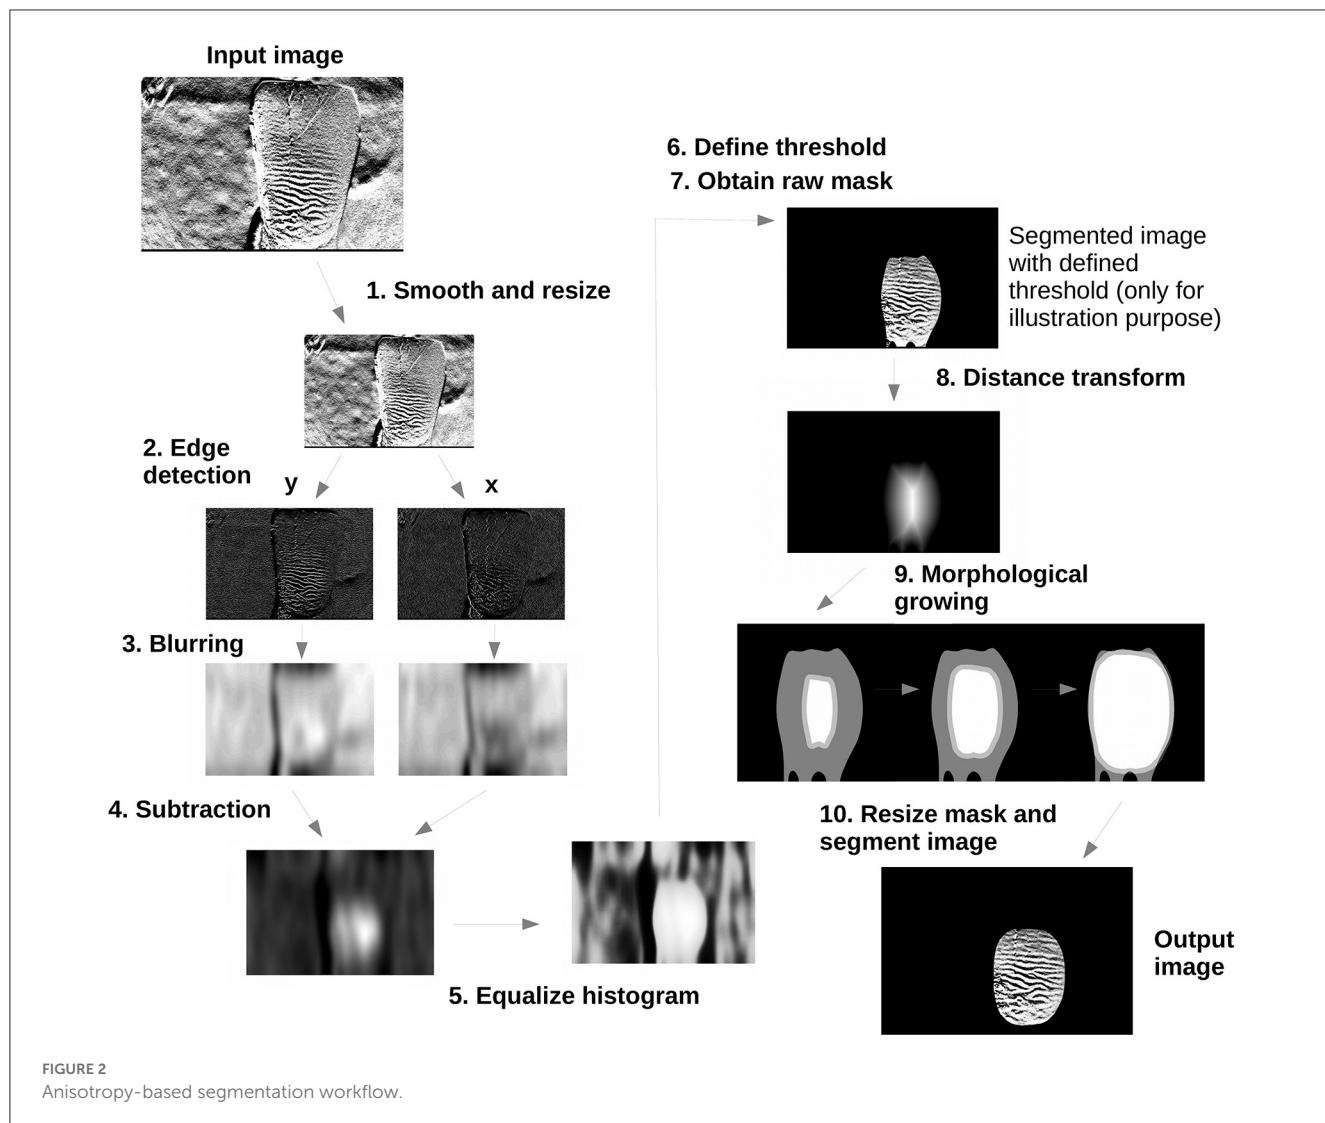
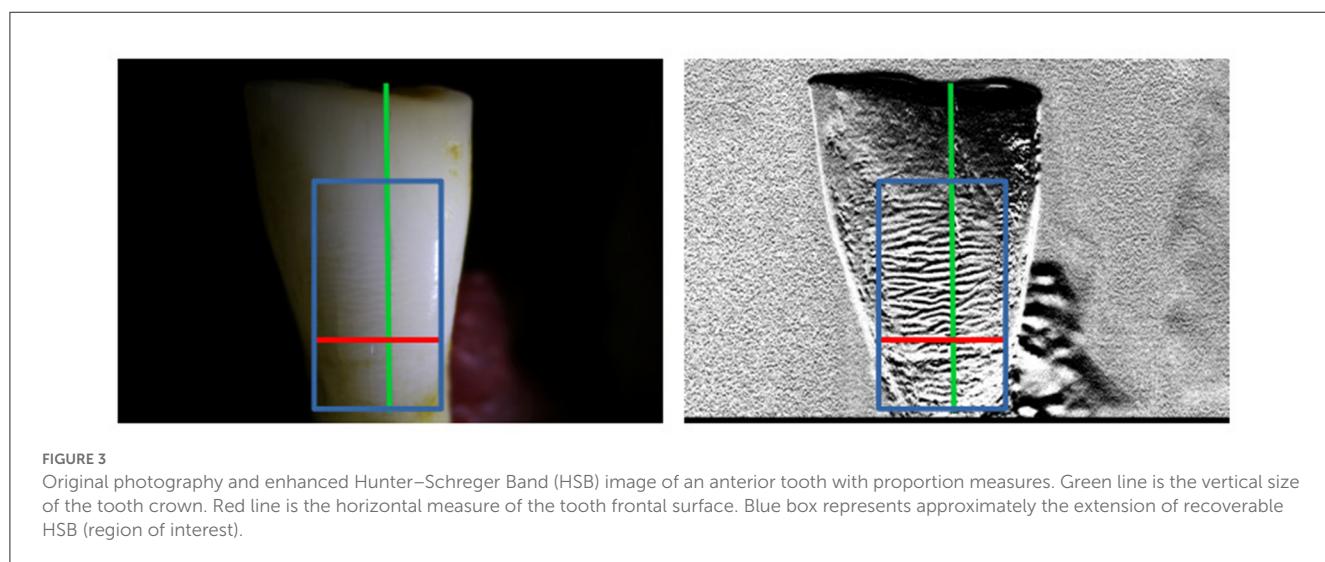


FIGURE 2
Anisotropy-based segmentation workflow.



$$\text{vertical } s_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad \text{Sobel operators:}$$

$$G_x = s_x \star J_b, \quad (8)$$

$$G_y = s_y \star J_b. \quad (9)$$

The filtered image G_y highlights, among other possible undesirable horizontal features, the HSB region. While the filtered image G_x highlights regions where vertical structures are predominant. To remove high-frequency gradients mostly represented by noise and keep values in a standardized range, we clip the edge maps to be in $[0, 255]$, such as

$$G_{x+}(i,j) = \begin{cases} 0 & \text{if } G_x(i,j) < 0 \\ 255 & \text{if } G_x(i,j) > 255, \\ G_x(i,j) & \text{otherwise} \end{cases} \quad (10)$$

$$G_{y+}(i,j) = \begin{cases} 0 & \text{if } G_y(i,j) < 0 \\ 255 & \text{if } G_y(i,j) > 255. \\ G_y(i,j) & \text{otherwise} \end{cases} \quad (11)$$

2.1.3. Blurring

The previous step detected edge intensities locally for orthogonal directions (x and y). The edge blurring applied in this step will allow the detection of larger regions in which a preferred edge orientation is present. The blurring will diffuse the edge magnitude equally to their neighborhood and single strong edges (usually not part of HSBs) are mitigated. Once the edges are detected, after blurring them, the regions with concentrated, stronger edges tend to form blobs, whereas sparse and weak-edged regions tend to disappear. Considering that HSBs are confined to a single region in G_y , after blurring its edges, a few blobs are created, and the most intense values appear near the core of the ROI. To perform this, let K be a unit-integral filter kernel of dimensions $k_y \times k_x$, such as

$$K = \begin{bmatrix} 1_{(1,1)} & \cdots & 1_{(1,k_x)} \\ \vdots & \ddots & \\ 1_{(k_y,1)} & & 1_{(k_y,k_x)} \end{bmatrix} \times \frac{1}{k_y k_x}. \quad (12)$$

Both images G_x and G_y are filtered again by three repeated cross-correlations with K , resulting, respectively, in the blurred images

$$B_x = K \star (K \star (K \star G_{x+})), \quad (13)$$

$$B_y = K \star (K \star (K \star G_{y+})). \quad (14)$$

The shape and size of kernel K are directly related to the level of blurring desired and, consequently, the capture of the details of the ROI shape. A larger K results in heatmaps (described in next section) with more rounded borders, while a smaller K results in more jagged borders (Figure 4). The more cross-correlation

repetitions, the larger and longer the area because the number of rows in K is greater than the number of columns. The number of repetitions, that is, three, was chosen after a visual comparison of the general overlap between the ground truth (ROI) and the automated segmented images among all sets and cannot be replaced by a single cross-correlation with a larger kernel size.

2.1.4. Subtraction

Following the previous step in which regions with preferred edge directions (x and y) were accentuated, subtracting one blurred-edge image from the other will result in a map of anisotropy density. Blurred images B_x and B_y represent blurred-edge maps with gradients for horizontal and vertical features, respectively. Subtracting one from the other creates a heatmap in which isotropic regions have values around zero, high values match the locations of the first-term high values, and low values match the locations of the second-term high values. Therefore, with B_y as the first term, the highest values of the heatmap will indicate the ROI. Let the heatmap H_1 for HSB location at position (i,j) be

$$H_1(i,j) = B_y(i,j) - 2B_x(i,j), \quad (15)$$

where B_x is subtracted twice to compensate for the $J \rightarrow J_b$ (Equation 7), where horizontally detected edges were faded twice as much as vertical ones. Then, from H_1 , we remove negative values as follows:

$$H_2(i,j) = \begin{cases} 0 & \text{if } H_1(i,j) < 0 \\ H_1(i,j) & \text{otherwise} \end{cases}, \quad (16)$$

in which H_2 pixel values are in the interval $\mathbb{R}_p = [0, p]$, where p varies among different images, depending on the extension and intensity of HSBs produced by the lighted tooth.

2.1.5. Equalize histogram

Since the range of gray-level values vary among different H_2 heatmap samples, an equalized heatmap H_3 is created to normalize grayscale values for the automated process. Hence, let the function γ be

$$\gamma(m_b) = \frac{n_b}{J_{size}}, \quad (17)$$

where m_b is the b th gray level and n_b is the number of pixels in heatmap H_2 taking the value m_b . The equalized-histogram heatmap H_3 consists of the transformation mapping $H_3 : \mathbb{R}_p \rightarrow \{0, 255\}$ for all b gray levels in H_2 . So, the equalized-histogram heatmap H_3 at all positions with pixel value m_b can be defined as

$$H_3(m_b) = [255 \sum_{a=0}^b \gamma(m_a)]. \quad (18)$$

2.1.6. Define threshold

Since the image gradient of H_3 tends to increase in the direction of the center of the ROI, descending this gradient leads to its borders (Figure 5A). The threshold for the lower bound determines

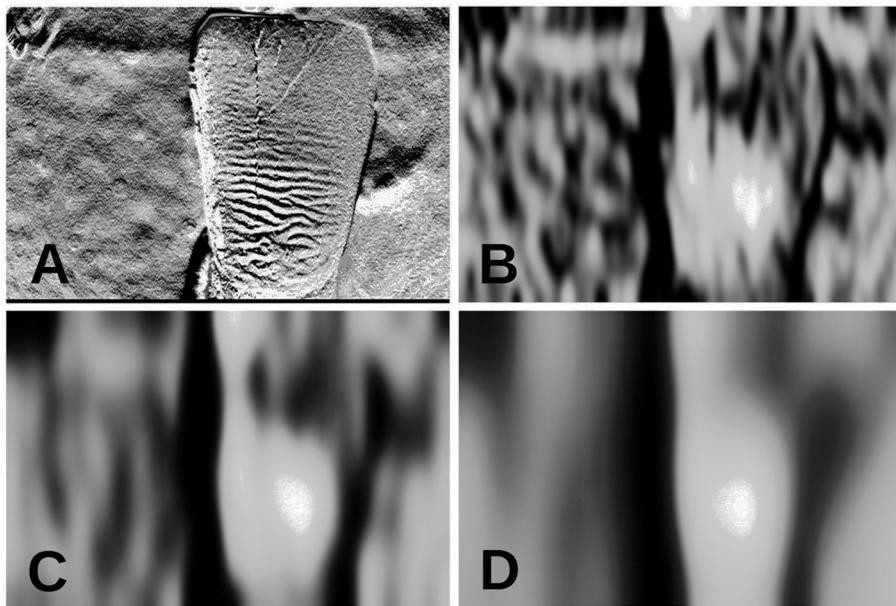


FIGURE 4

Differences on heatmap H_1 according to parameterizations. (A) Resized tooth image J for segmentation. (B) Heatmap with low parameters $k_x = 25$ and $k_y = 75$. (C) Heatmap with intermediate parameters $k_x = 50$ and $k_y = 150$. (D) Heatmap with high parameters $k_x = 100$ and $k_y = 300$. All images have the same size, achieved by maintaining $J_{size} = 1.5 \times 10^6$.

to what extent the HSBs are enclosed. A fixed threshold for enclosing ROI as a foreground mask was tested on a few images without success. Consequently, an adaptive threshold was created based on histogram distribution indexes where large gaps (absence of discrete grayscale values) at high indexes of the histogram are selected as the threshold. To do so, let β be an ordered set of gray levels m_a in H_3 , such that

$$\beta = \{m_a \mid \gamma(m_a) > 0\}. \quad (19)$$

We define the function $f(\cdot)$ as

$$f(b) = \beta_b, \quad (20)$$

where β_b is the b th value in β (Figure 5B). We find the adaptive threshold by looking for the last gap greater than one in the sequence of discrete values of β (Figure 5C). For that, the discrete derivative of $f(b)$ is computed as

$$f'(b) = f(b) - f(b - 1). \quad (21)$$

To prevent the premature selection of a high threshold and consequently the segmentation of a small region by minor gaps among the β highest values, $f'(b)$ is smoothed by the following linear cross-correlation:

$$f'_s(b) = \lfloor \sum_{-\ell}^{\ell} W_{(3)}(\ell) \cdot f'(b + \ell) \rfloor, \quad (22)$$

where $W_{(3)}$ is a linear unit integral kernel of length 3, $\ell = 1$, and $f'_s(b) \in \mathbb{N}$. To solve the threshold decision, let $\{i, \dots, j\}$ be an ordered set of all b that satisfy the inequality

$$f'_s(b) > 1. \quad (23)$$

The final threshold θ to segment H_3 is computed as

$$\theta = f(J + 1). \quad (24)$$

2.1.7. Obtain raw mask

The raw mask M_1 can be defined as

$$M_1(i, j) = \begin{cases} 1 & \text{if } H_3(i, j) \geq \theta \\ 0 & \text{otherwise} \end{cases}. \quad (25)$$

2.1.8. Distance transform

At this point, a segmentation by the M_1 mask might still produce foreground branches that reach outside the ROI. Also, the M_1 mask border might have sharp angles that are not useful for biometric comparisons due to the bands' discontinuity in concave areas. To mitigate this problem, a shrinkage of mask M_1 is performed to remove the branches. Later, a morphological growing is applied to restore its size with a smoother boundary. We first obtain a distance map D using the Euclidean distance transform

$$D(i, j) = \min(\{\sqrt{(i - v)^2 + (j - u)^2} \mid (v, u) \in (V, U)\}), \quad (26)$$

$$(Y, X) = \{(y, x) \mid M_1(i, j) = 1\}, \quad (27)$$

$$(V, U) = \{(v, u) \mid M_1(v, u) = 0\}, \quad (28)$$

where (Y, X) is the set of pairs of the foreground pixel coordinates and (V, U) is the set of pairs of the background pixel coordinates in M_1 .

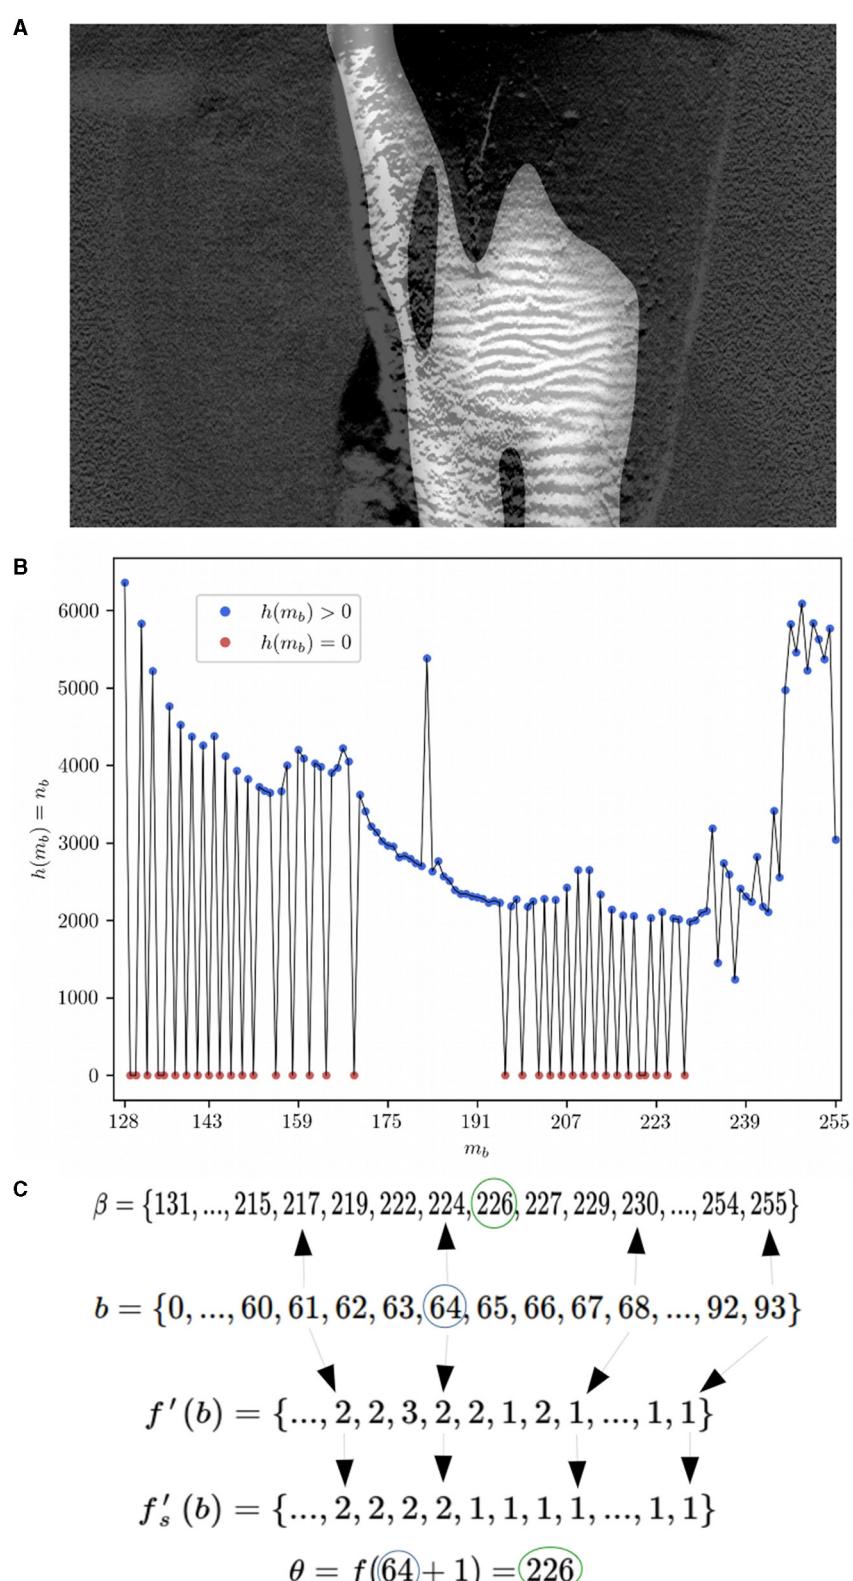
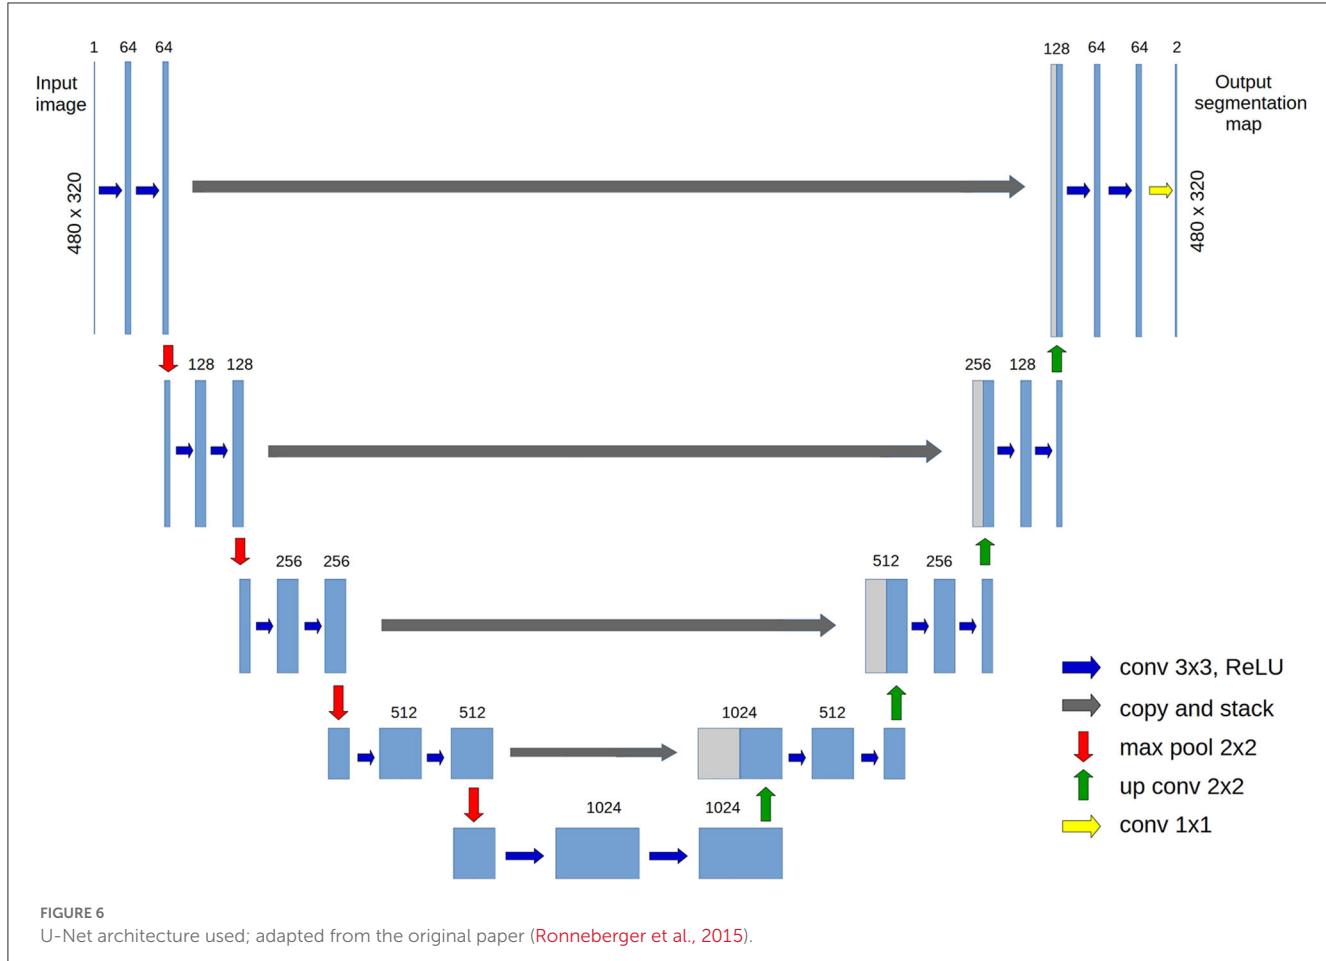


FIGURE 5

Example of adaptive threshold selection for image 10L2. **(A)** Heatmap H_3 overlapping image E (resized to J_{size} for visualization purposes only). Note the higher values of the H_3 heatmap toward the center of the Hunter–Schreger Band region. **(B)** Histogram of H_3 showing values where $m_b > 127$, values above zero (blue dots) compose the ordered set β . **(C)** Illustrated relations between functions and sets to find threshold θ .



2.1.9. Morphological growing

Afterward, a new background removal is performed on D , with threshold $\phi = \max(D) \cdot \alpha$, where α determines the reduction rate of D foreground area based on its maximum pixel value. By default, it was set to $\alpha = 0.6$, resulting in the reduced foreground mask area

$$M_r(i,j) = \begin{cases} 1 & \text{if } D(i,j) > \phi \\ 0 & \text{otherwise} \end{cases}. \quad (29)$$

The M_r is repeatedly dilated by a circle-shaped morphological operator ρ_c of radius $k_x \cdot 0.5$ until eventually resulting in the final mask M_2 when any foreground pixel of M_r overlaps with any background pixel in M_1 . The pseudocode for this process is described in [Algorithm 1](#).

2.1.10. Resize mask and segment image

In the end, the binary mask M_2 is resized back to $\mathbf{M} \times \mathbf{N}$ dimensions, resulting in the M_3 mask, and the final segmented image S_E is defined as

$$S_E(i,j) = \begin{cases} E(i,j) & \text{if } M_3(i,j) > 0 \\ 0 & \text{otherwise} \end{cases}. \quad (30)$$

```

Require:  $M_1, M_r$ 
 $\rho_c \leftarrow$  binary closed disk of radius  $k_x \cdot 0.5$ 
while TRUE do
   $M_2 \leftarrow M_r \oplus \rho_c$ 
  if Any  $M_1(i,j) - M_2(i,j) = -1$  then
    return  $M_2$ 
  end if
   $A_r \leftarrow M_2$ 
end while

```

[Algorithm 1.](#) Morphological growing mask.

2.2. Fully convolutional neural network

The U-Net was initially created for the precise segmentation of medical images and proved to be useful in diverse branches of medical imaging, including magnetic resonance imaging (MRI; Dolz et al., 2019; Li et al., 2019), optical coherence tomography (OCT; Shah et al., 2018), and microscopy (Cai et al., 2020; Pandey et al., 2020). Due to the high efficiency demonstrated by this neural network when applied in several fields of imaging, we harnessed the architecture of the U-Net to automate the segmentation of the HSBs. The U-Net consists of two parts: an encoder and a decoder.

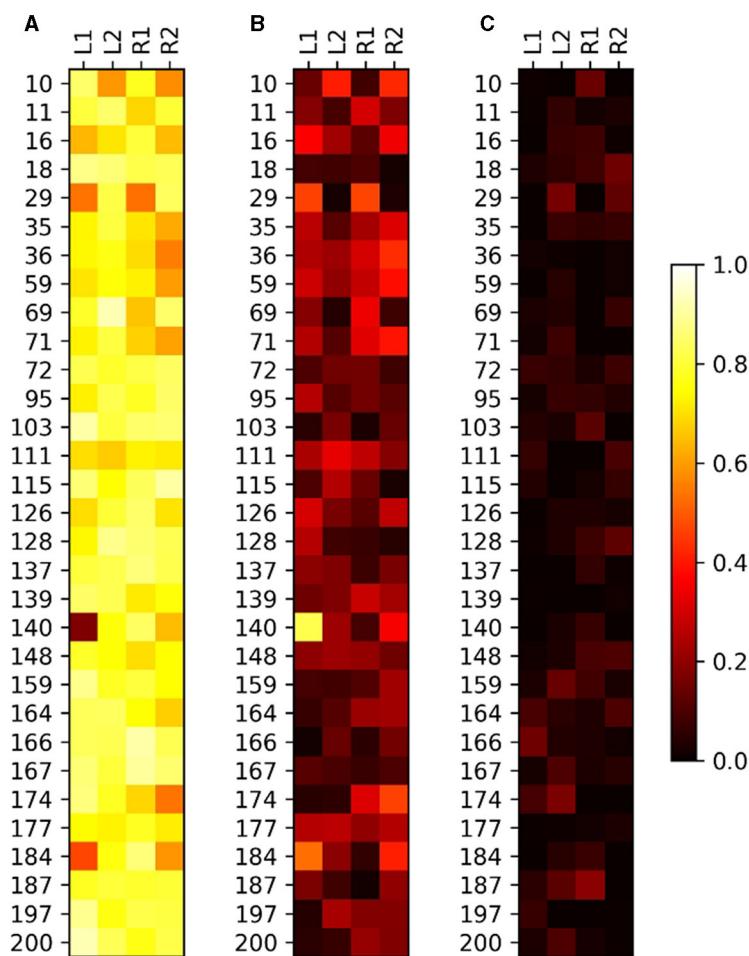


FIGURE 7

Results of the relation between manual and automated segmentation for the four sets of images of 31 teeth. **(A)** Intersection Over Union (IOU). **(B)** Exclusive Manual-Segmentation Region Over Union (EMSOU). **(C)** Exclusive Automate-Segmented Region Over Union (EASOU). Note that $\text{IOU}_{ij} + \text{EMSOU}_{ij} + \text{EASOU}_{ij} = 1$, for $(i, j) \in \mathbb{N}^2$.

The encoder has four blocks, each one composed of two consecutive convolutions and one max-pooling function. The decoder also has four blocks, each one composed of a deconvolution (up-conv), a concatenation with the intermediate output (copy and stack) from the respective encoder block, followed by two convolutions. The encoder and decoder parts are connected by a “bridge” consisting of two convolutions (Figure 6). Our architecture differs only by image padding, which is the same throughout the network, instead of decreasing; there is no cropping, and the initial image size is a single-channel gray scale of 480×320 pixels.

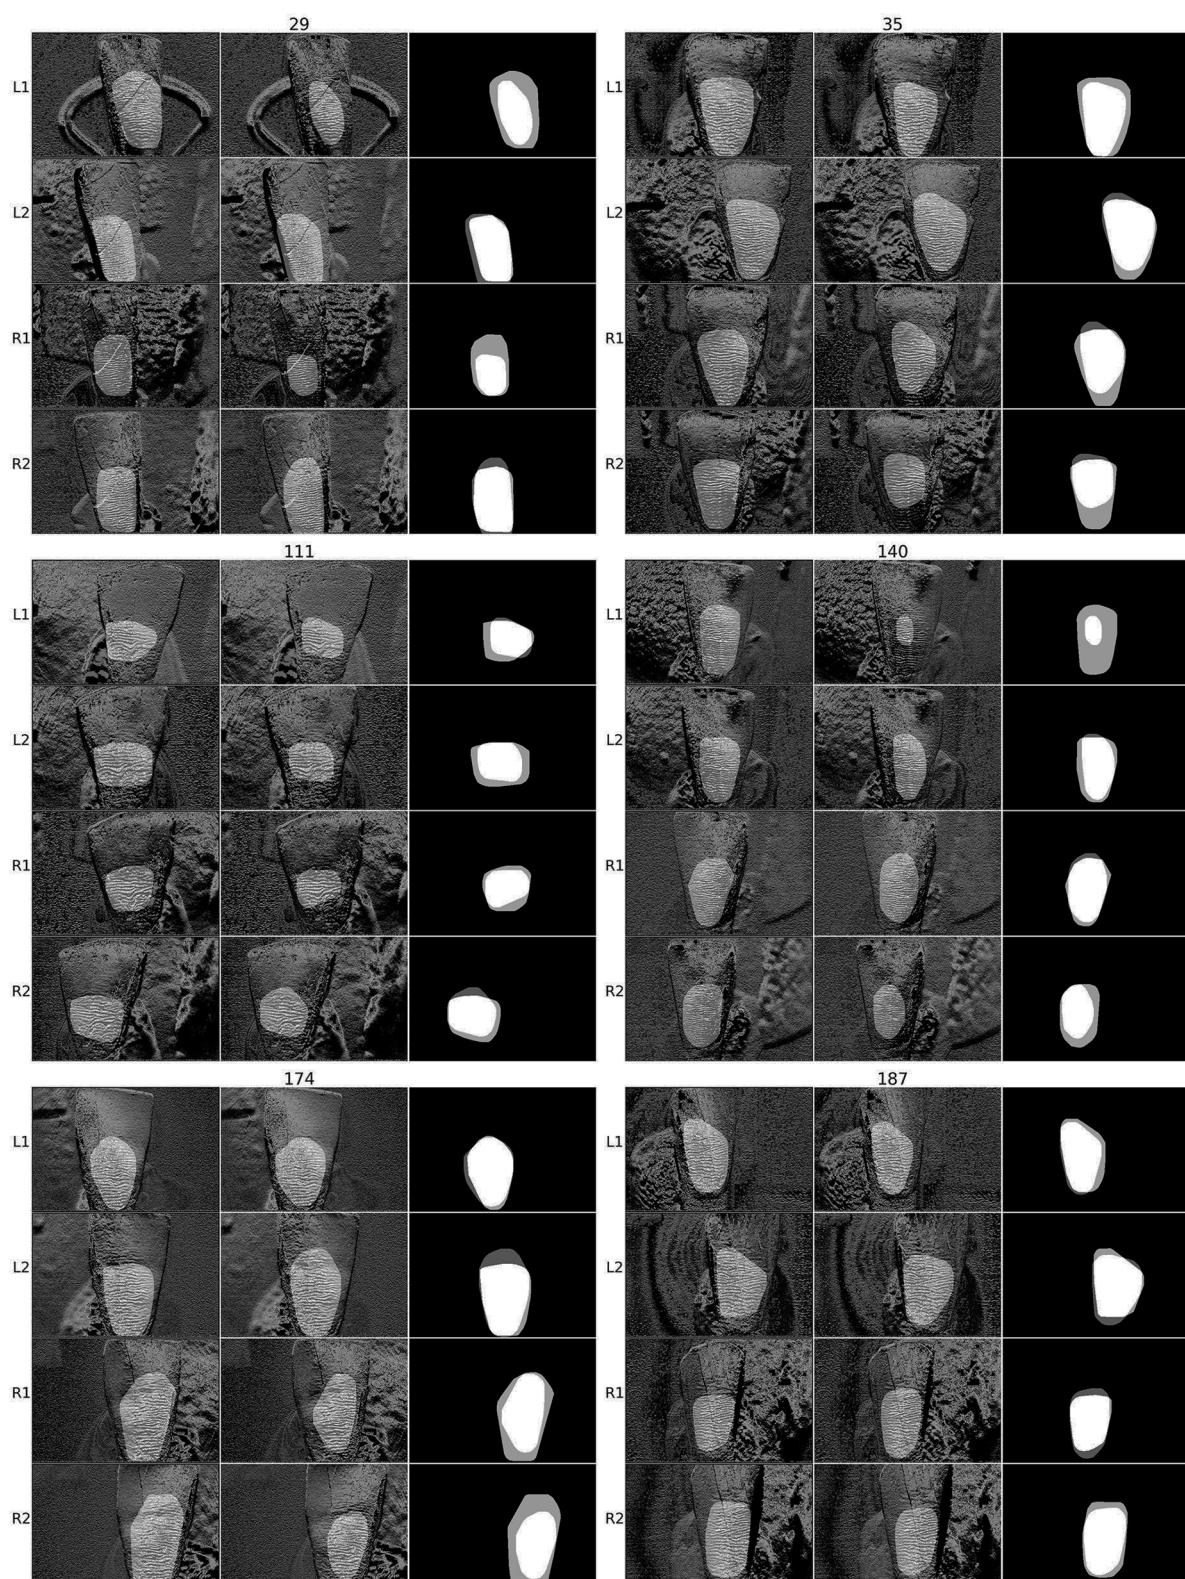
The whole data set was divided into three groups: training, validation, and test groups (15, 6, and 10 teeth, that is, 60, 24, and 40 images, respectively). To avoid result bias by the network seeing different images from the same tooth in the training and test groups, we sorted the image such that all four images per tooth went into the same group. The teeth were randomly assigned to each one of the three groups. Regarding the limited data set size for such a deep network, data augmentation during training was performed to maximize variability, creating five variations from each image for training and one variation for the validation group. These

augmented images (and their masks) were created randomly over each epoch, being a total of 300 training and 24 validation images per epoch. Since the biometrics protocol in development should accept only images of a tooth positioned vertically, augmentation techniques, for example, rotation, are limited to small ranges in order to be beneficial for the HSB pattern learning. The parameters used for augmentations were rotation $\{-20, 20\}$ degrees, height, and width shift up to 20%, range in brightness up to 50%, zoom (in or out) up to 20%, and vertical and horizontal flip.

Since the final output image is a binary mask, the final activation is a sigmoid function. The optimizer of choice was Adam, with a learning rate $\alpha = 1.0 \times 10^{-5}$, and the chosen loss was binary cross-entropy defined as

$$\text{BCE}_{loss} = \frac{1}{N} \sum_{i=1}^N -[(y_i \ln p_i) + (1 - y_i) \ln (1 - p_i)], \quad (31)$$

where y_i is the true label and p_i is the predicted label for all N pixels in the image. The metric used for assessing performance was

**FIGURE 8**

Examples of manual and anisotropy-based segmentation automated segmentation and their mask overlaps for the teeth with indices 29, 35, 111, 140, 174, and 187. The three images for each tooth photograph (L1, L2, R1, R2), from left to right, are HSB image with manual mask, Hunter-Schreger Band (HSB) image with automated mask, and overlap of both masks (white is overlap, light gray is only manual mask, and dark gray is only automated mask).

TABLE 1 Training metrics of the best epoch of validation data set.

Batch size	Best epoch	Loss	Accuracy	Precision	Recall	AUC	IOUd
1	22	0.0675	0.9767	0.8885	0.9254	0.9955	0.7347
5	254	0.0544	0.9839	0.9403	0.9253	0.9918	0.8273
10	285	0.07	0.9828	0.9388	0.9170	0.9905	0.7247
15	285	0.0713	0.9836	0.9296	0.9342	0.9921	0.7153
20	298	0.0652	0.9835	0.9425	0.9147	0.9914	0.7190

AUC, Area Under the Curve; IOUd, Intersection Over Union from decimals.

Intersection Over Union (IOU). The previously described U-Net was trained over 300 epochs using different batch sizes (1, 5, 10, 15, and 20), and the weights of the epoch with best validation IOU scores were used as the final trained model.

3. Results

In order to assess the results obtained using the developed methods, images were manually segmented to generate a ground truth. The results were assessed by comparing the manual and the automated segmented regions from the same image. The manual selection was performed using the preprocessed grayscale images (Figure 1B) as input images as follows:

1. Selection of region visually greater than HSB area
2. Application of HSB filtering algorithm (“Filtering” in Figure 1) and visual location of improper regions
3. Selection of a smaller and better fitting region if there are improper areas
4. Repetition of steps 2 and 3 until no change is needed
5. Final region is selected.

Since this process gradually decreases the segmented region size, the manually selected ROI is considered to be the largest area with recoverable HSBs, or, more precisely, the largest area whose filtered output image from the HSB filtering algorithm has no visually important deformations for biometric usage.

3.1. ABS experimental results

The previously described ABS algorithm was tested using four sets of images, each from the same 31 extracted teeth. All photographs were taken with the teeth vertically positioned, with the incisal portion upward and cervical portion downward. Two sets were taken with left-side lighting (L1 and L2) and two other sets with right-side lighting (R1 and R2).

The average IOU score between the manual and automated segmented regions overall was 0.766 ± 0.106 SD (standard deviation). The residuals can be separated into an Exclusive Manual-Segmented Regions Over Union (EMSOU), that is, a potential region not selected by the algorithm, and an Exclusive Automate-Segmented Region Over Union (EASOU), which is a trespassed area outside the ROI. Once the EASOU is considered an area with no recoverable HSBs, its minimization is preferred

compared to the EMSOU. The average EMSOU was 0.191 ± 0.127 SD and the average EASOU was 0.042 ± 0.044 SD (Table 3 ABS all). The large SD compared to the average for EMSOU and EASOU indicates a non-parametric distribution for these results, with sparse high errors in only a few images, which can be seen in Figure 7. Some examples of ABS performance are shown in Figure 8. In addition to the IOU, the computed FPR (false-positive rate or misclassified background pixels rate) was 0.006, and the FNR (false-negative rate or misclassified foreground pixels rate) was 0.188.

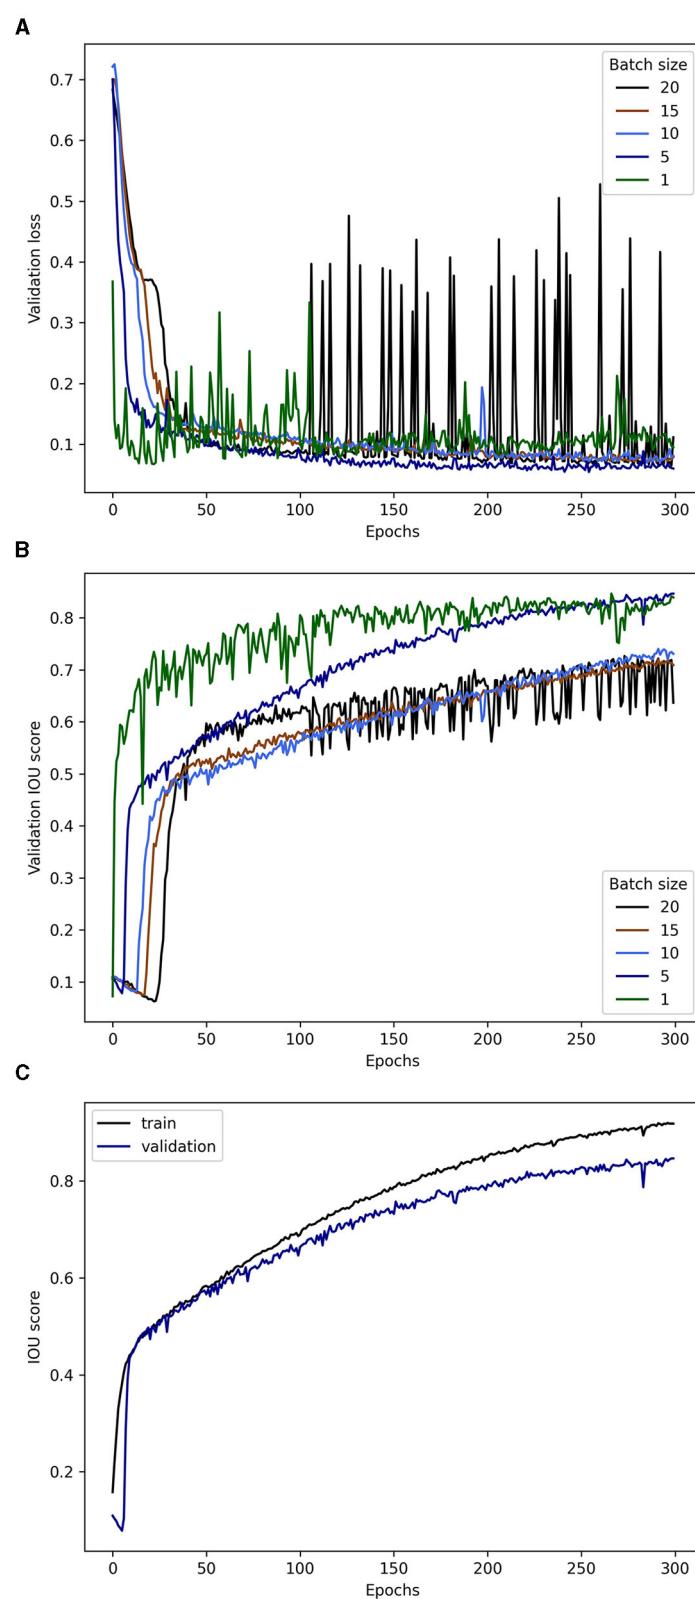
3.2. U-Net experimental results

According to the training results (Table 1), the hyper-parameter batch size of 5 produced the best result, with a loss of 0.0544 and an IOU score of 0.827 in the validation data set during the training. This IOU score (IOUd) is computed using the predicted decimal values for every pixel in the interval [0, 1] without any thresholding. The training progression loss and IOU score are shown in Figure 9. Other result metrics were very close among all batch sizes.

The learning curve for batch sizes 5, 10, and 15 was more consistent with increased overfitting (Figure 9), whereas batch sizes of 1 and 20 produced high fluctuation values through the training, with the lowest losses too early and too late, respectively. These cases of high-variability metrics, for example, IOU score, during the training are examples of a trade-off between high-frequency parameter tuning per epoch without generalization by using small batch sizes (the former) and low-frequency parameter tuning per epoch as an attempt for excessive generalizations when using batches that are too large (the latter). It has been shown that large batches tend to reach sharp minima whereas small batches move toward flat minima, reducing the generalization gap (Keskar et al., 2016), that is, the difference between the validation and test data sets results.

3.3. Comparison

The results of evaluation of both models on the test data set are shown in Table 2. The IOU score was computed using the threshold of 0.5 for every pixel with a predicted value in [0, 1]. The model with the best IOU score (0.8393) was the U-Net model trained with a batch size of 15, followed closely by batch sizes of 20, 10, and 5. The least loss (0.0747) was again the model with batch size of 5, with

**FIGURE 9**

Training progression through epochs. **(A)** Validation loss. **(B)** Validation Intersection Over Union (from decimals) score. **(C)** Training and validation data sets Intersection Over Union in the model with batch size of 5.

TABLE 2 Evaluation metrics for U-Net trained models and ABS model for all and only test images.

Batch size	Loss	Accuracy	Precision	Recall	AUC	IOUd	IOU score
ABS test	-	0.9699	0.9348	0.7958	0.8942	-	0.7539
ABS all	-	0.9697	0.9504	0.7982	0.8962	-	0.7663
1	0.0835	0.9714	0.9064	0.8394	0.9854	0.6573	0.7757
5	0.0747	0.9795	0.9409	0.8778	0.9823	0.7838	0.8295
10	0.0848	0.979	0.9476	0.8666	0.9762	0.6829	0.8324
15	0.0876	0.9799	0.9209	0.9039	0.9845	0.6815	0.8393
20	0.0789	0.9789	0.95	0.8633	0.9833	0.6791	0.8329

AUC, Area Under the Curve; IOUd, Intersection Over Union from decimals; IOU, Intersection Over Union.

TABLE 3 Mean and standard deviation of model scores.

Model	IOU (SD)	EMSOU (SD)	EASOU (SD)
ABS all	0.766 (0.106)	0.191 (0.127)	0.042 (0.044)
ABS test	0.752 (0.098)	0.192 (0.130)	0.055 (0.052)
U-Net	0.829 (0.067)	0.118 (0.086)	0.051 (0.05)
U-Net-CH	0.837 (0.065)	0.101 (0.084)	0.060 (0.057)

ABS, anisotropy-based segmentation; IOU, Intersection Over Union; EMSOU, Exclusive Manual-Segmented Region Over Union; EASOU, Exclusive Automate-Segmented Region Over Union.

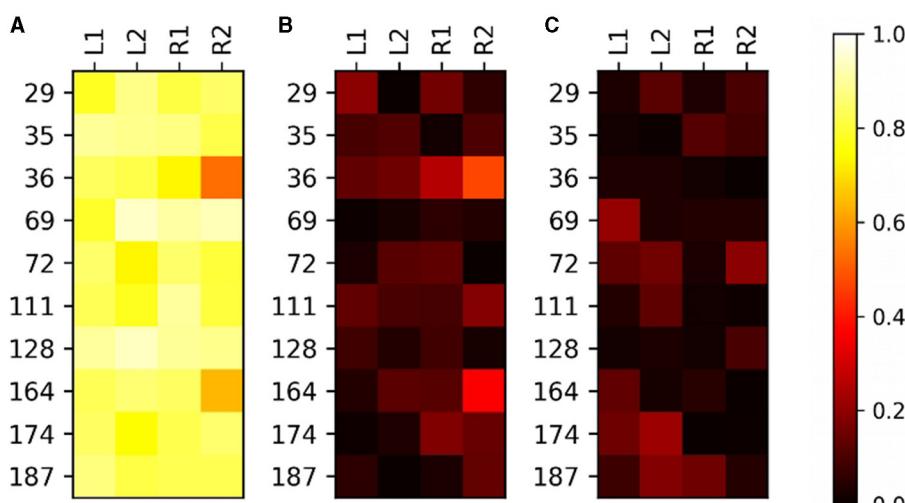


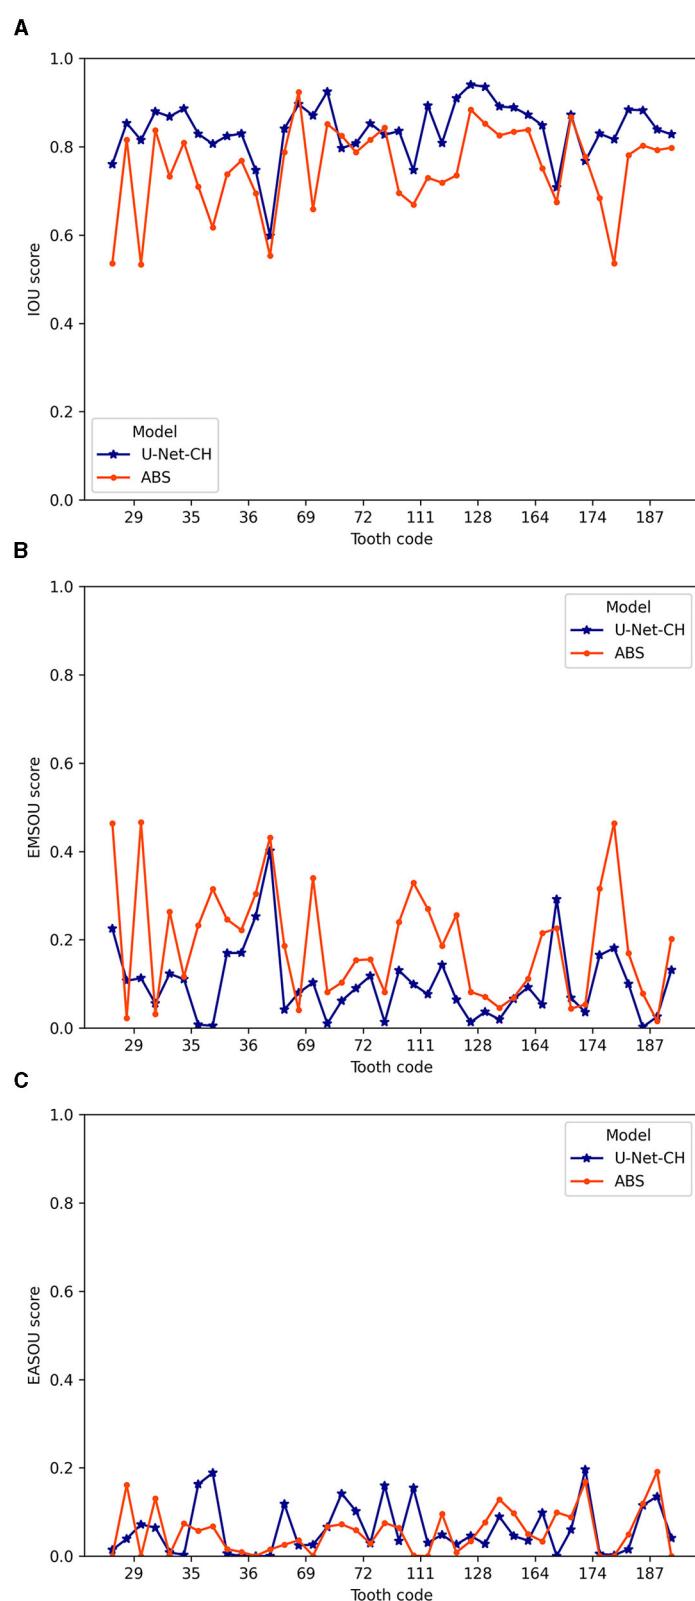
FIGURE 10

Results of the automated segmentation of U-Net-CH model on test data set. (A) Intersection Over Union (IOU). (B) Exclusive Manual-Segmented Region Over Union (EMSOU). (C) Exclusive Automate-Segmented Region Over Union (EASOU). Note that $\text{IOU}_{ij} + \text{EMSOU}_{ij} + \text{EASOU}_{ij} = 1$, for $(i,j) \in \mathbb{N}^2$.

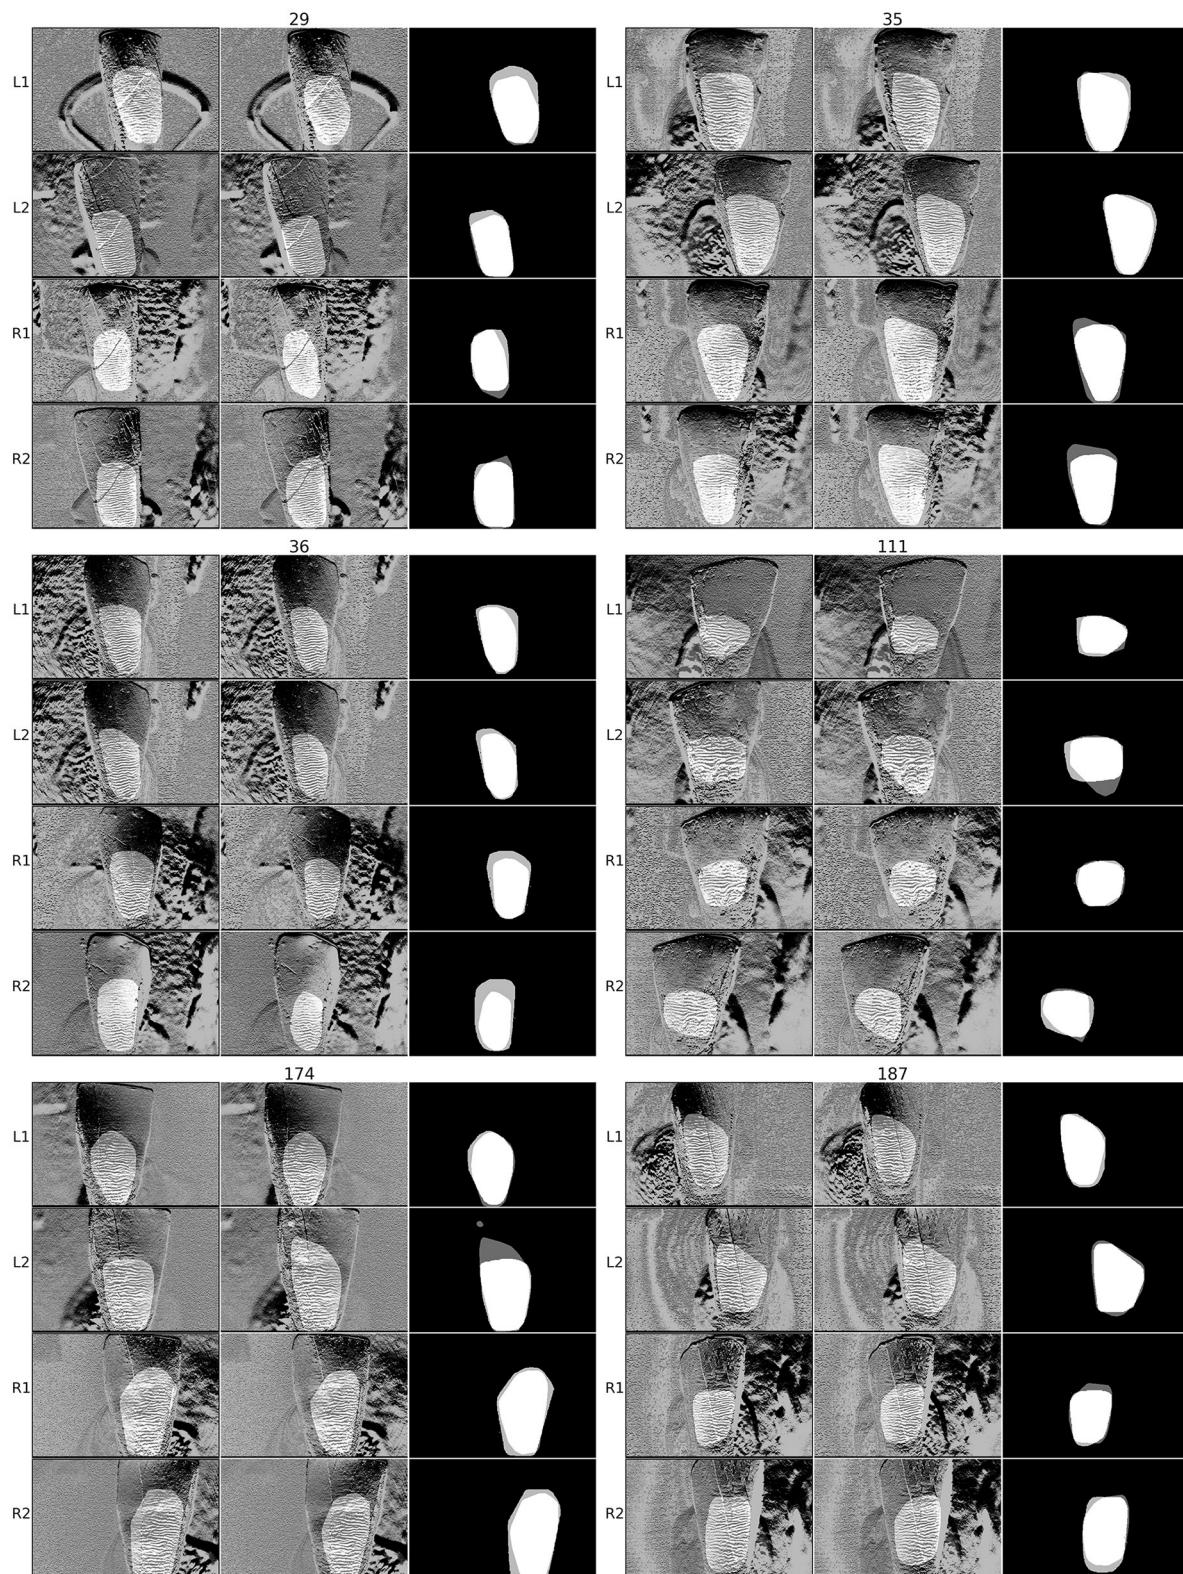
still large differences in the IOUd compared to the other batch sizes (≈ 0.10). Although a batch size of 15 resulted in better performance on the test data set, the gap between test data set IOUd and IOU scores reveals that all except the batch size of 5 had less confidence in classifying a pixel as foreground or background. This means that the mask output values of the U-Net tend to be closer to the cutoff value for a binary classification, which is usually 0.5 in the range [0,1]. This indicates a high degree of uncertainty and explains the strong variation between the IOUd and IOU scores in these batch size groups. The high uncertainty has been shown to handicap the

performance in predicting new data (Dolezal et al., 2022; Yang et al., 2022). The IOU score of the ABS model was the lowest.

For further analysis, we kept only the predicted masks by the U-Net model with a batch size of 5 because it has the lowest loss and the lowest gap between the IOUd and IOU scores. The 40 test-predicted masks underwent post-processing by the convex hull algorithm (U-Net-CH; Barber et al., 1996) to also select regions in concave areas left out by the foreground mask. Since the HSB pattern is a radial effect of the light on the enamel subsurface, it usually appears as a convex area. Hence, the

**FIGURE 11**

Detailed scores for the 10 teeth (40 images) in the test data set for anisotropy-based segmentation and U-Net-CH. **(A)** Intersection Over Union (IOU) score. **(B)** Exclusive Automate-Segmented Region Over Union (EASOU) score. **(C)** Exclusive Automate-Segmented Region Over Union (EASOU) score.

**FIGURE 12**

Examples of manual and U-Net-CH automated segmentation and their masks overlap for indexed teeth 29, 35, 36, 111, 174, and 187. The three images for each tooth photograph (L1, L2, R1, R2), from left to right, are Hunter-Schreger Band (HSB) image with manual mask, HSB image with automated mask, overlap of both masks (white is overlap, light gray is only manual mask, and dark gray is only automated mask).

concavities of U-Net segmentation might handicap the subsequent biometric performance. The average IOU score between manual and automated segmented regions was $0.837 \pm 0.06 SD$, that is almost 0.08 above the ABS's. The average EMSOU was $0.101 \pm 0.084 SD$ and the average EASOU was $0.06 \pm 0.057 SD$. Except for the EASOU score, these results are better than the ones from ABS (Table 3). The U-Net-CH not only improved the IOU and the EMSOU compared to U-Net but also increased average EASOU by 0.009. The U-Net-CH had an FPR of 0.007 and an FNR of 0.122. Compared to the ABS, the FPR of U-Net-CH is slightly higher (about 0.001), meaning its masks more frequently exceed the ROI boundaries, whereas the FNR is significantly lower (about 0.06), meaning it normally selects a larger area inside the ROI. Overall, the trained U-Net-CH was able to select a larger region inside ROI with a slightly greater overpass. The heatmaps for the IOU, EMSOU, and EASOU results are shown in Figure 10 for U-Net-CH and a detailed image-to-image comparison between the models ABS and U-Net-CH is shown in Figure 11 for only the test data set. Some examples of U-Net-CH performance on the test data set can be seen in Figure 12.

4. Discussion

Currently, both techniques for automated segmentation have acceptable performances regarding *ex vivo* teeth image sets. While U-Net-CH approach resulted in better segmentation quality, it also had more results overpassing the ground truth boundaries. The ABS is more conservative regarding the boundary limits, resulting not only in smaller segmented regions but also probably in more consistent biometric identification results since fewer false HSBs are selected. Due to the limited sample size for such a deep neural network, that is, the U-Net, increasing the sample size for training the model probably would improve its predictions and might also reduce the most critical error score, that is, the EASOU, of segmented areas. It is worth mentioning that U-Net is extensively used in medical imaging analysis, where biological structures have relatively more precise delimitation, for example, organs in MRI or computed tomography scans, whereas for the proposed application, apart from being convex, the mask is fuzzy and does not fit any particular shape. In addition, different backgrounds should be taken into consideration for training to make sure they will not interfere with the HSB area selection in real applications, where neighboring teeth will likely appear next to the targeted one. Apart from data set specificity, novel variations of U-Net architectures might offer possibilities for further improvement. Examples are the Residual U-Net, based on ResNet (He et al., 2016), which adds skip connections to convolution blocks to prevent the loss of feature identities in deep layers (Siddique et al., 2021; Wang et al., 2021), and the Inception U-Net, which adds an inception module between U-Net convolution block of layers, which consists of filters of different sizes that are concatenated before reaching the next convolution block. The more recent versions of inception architecture have the advantage of reducing the computational cost (Szegedy et al., 2014, 2016; Siddique et al., 2021).

On one hand, the use of ABS might be seamless with limited computational resources and readily available once it is implemented. Moreover, a semiautomated experience can be

implemented by offering the user ABS parameters to tweak in order to adapt the algorithm to the nuances the images might have without incurring errors caused by using, for example, a free selection tool. On the other hand, U-Net and its variations trained with a larger data set might achieve more robustness and better overall performance.

5. Conclusion

Automated segmentation is an important step in minimizing human mistakes in image analysis, primarily in the context of repetitive tasks, such as the presented biometric pipeline of HSBs, where multiple teeth should be registered to a database. The acquired performance of both employed methods will ease the development of subsequent processing steps. Apart from the biometric context, further applications of the proposed methods, mainly ABS, may be used to exploit other anisotropic patterns elsewhere.

Data availability statement

The raw data supporting the conclusions of this article will be made available by the authors, without undue reservation.

Ethics statement

The studies involving human participants were reviewed and approved by Research Ethics Committee of the Piracicaba Dental School CAAE 03596918.2.0000.5418. The patients/participants provided their written informed consent to participate in this study.

Author contributions

SL prepared the dental samples and designed the experiment. GF executed the image acquisition, developed the algorithms, and evaluation. SL and DB jointly supervised the project and revised the manuscript. All authors reviewed the manuscript and approved the final manuscript.

Funding

GF was supported by a fellowship from São Paulo Research Foundation (FAPESP, Grants 2018/23038-7 and 2020/07401-4). SL was supported by Grants from FAPESP (2022/10293-4) and Brazilian Council of Scientific and Technological Development (CNPq, 305783/2018-1). In addition, this study was supported by the German Ministry for Education and Research (BMBF) within the Forschungscampus MODAL (Project Grant 3FO18501).

Conflict of interest

The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Publisher's note

All claims expressed in this article are solely those of the authors and do not necessarily represent those of their affiliated

organizations, or those of the publisher, the editors and the reviewers. Any product that may be evaluated in this article, or claim that may be made by its manufacturer, is not guaranteed or endorsed by the publisher.

References

- Arrieta, Z. L., Fogalli, G. B., and Line, S. R. P. (2018). Digital enhancement of dental enamel microstructure images from intact teeth. *Microsc. Res. Tech.* 81, 1036–1041. doi: 10.1002/jemt.23070
- Arrieta, Z. L., and Line, S. R. P. (2017). Optimizing the analysis of dental enamel microstructure in intact teeth. *Microsc. Res. Tech.* 80, 693–696. doi: 10.1002/jemt.22852
- Barber, C. B., Dobkin, D. P., and Huhdanpaa, H. (1996). The quickhull algorithm for convex hulls. *ACM Trans. Math. Softw.* 22, 469–483.
- Cai, S., Tian, Y., Lui, H., Zeng, H., Wu, Y., and Chen, G. (2020). DenseUNet: a novel multiphoton *in vivo* cellular image segmentation model based on a convolutional neural network. *Quant. Imaging Med. Surg.* 10, 1275–1285. doi: 10.21037/qims-19-1090
- Dolezal, J. M., Srisuwananukorn, A., Karpeyev, D., Ramesh, S., Kochanny, S., Cody, B., et al. (2022). Uncertainty-informed deep learning models enable high-confidence predictions for digital histopathology. *Nat. Commun.* 13, 6572. doi: 10.1038/s41467-022-34025-x
- Dolz, J., Desrosiers, C., and Ben Ayed, I. (2019). “IVD-Net: intervertebral disc localization and segmentation in MRI with a multi-modal UNet,” in *Computational Methods and Clinical Applications for Spine Imaging*, eds G. Zheng, D. Belavy, Y. Cai, and S. Li (Cham: Springer International Publishing), 130–143.
- Fogalli, G. B., Line, S. R. P., and Baum, D. (2022). “Automatic segmentation of tooth images: optimization of multi-parameter image processing workflow,” in *EuroVis 2022 - Posters*, eds M. Krone, S. Lenti, and J. Schmidt (Eindhoven: The Eurographics Association), 11–13.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). “Deep residual learning for image recognition,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.
- Keskar, N. S., Mudigere, D., Nocedal, J., Smelyanskiy, M., and Tang, P. T. P. (2016). On large-batch training for deep learning: generalization gap and sharp minima. *arXiv preprint arXiv:1609.04836*.
- Koenigswald, W. v. (1994). U-shaped orientation of hunter-schreger bands in the enamel of moropus (mammalia: Chalicotheriidae) in comparison to some other perissodactyla. *Ann. Carn. Museum* 63, 49–65.
- Li, S., Chen, Y., Yang, S., and Luo, W. (2019). “Cascade dense-unet for prostate segmentation in MR images,” in *Intelligent Computing Theories and Application*, eds D.-S. Huang, V. Bevilacqua, and P. Premaratne (Cham: Springer International Publishing), 481–490.
- Line, S. R. P., and Bergqvist, L. P. (2005). Enamel structure of paleocene mammals of the São José de Itaborai Basin, Brazil. ‘Condylarthra’, Litopterna, Notoungulata, Xenungulata, and Astrapotheria. *J. Verteb. Paleontol.* 25, 924–928. doi: 10.1671/0272-4634(2005)0250924:ESOPMO2.0.CO;2
- Pandey, R., Lalchhanima, R., and Singh, K. R. (2020). “Nuclei cell semantic segmentation using deep learning UNet,” in *2020 Advanced Communication Technologies and Signal Processing (ACTS)* (IEEE), 1–6.
- Ramenzoni, L. L., and Line, S. R. (2006). Automated biometrics-based personal identification of the hunter-schreger bands of dental enamel. *Proc. R. Soc. B Biol. Sci.* 273, 1155–1158. doi: 10.1098/rspb.2005.3409
- Ronneberger, O., Fischer, P., and Brox, T. (2015). “U-Net: convolutional networks for biomedical image segmentation,” in *International Conference on Medical Image Computing and Computer-Assisted Intervention* (Cham: Springer International Publishing), 234–241.
- Shah, A., Zhou, L., Abrámovoff, M. D., and Wu, X. (2018). Multiple surface segmentation using convolution neural nets: application to retinal layer segmentation in OCT images. *Biomed. Opt. Express* 9, 4509. doi: 10.1364/BOE.9.004509
- Shen, W., and Tan, T. (1999). Automated biometrics-based personal identification. *Proc. Natl. Acad. Sci. U.S.A.* 96, 11065–11066.
- Siddique, N., Paheding, S., Elkin, C. P., and Devabhaktuni, V. (2021). U-net and its variants for medical image segmentation: a review of theory and applications. *IEEE Access* 9, 82031–82057. doi: 10.1109/ACCESS.2021.3086020
- Sweet, D., and Sweet, C. (1995). DNA analysis of dental pulp to link incinerated remains of homicide victim to crime scene. *J. Forens. Sci.* 40, 310–314.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). “Rethinking the inception architecture for computer vision,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (Los Alamitos, CA: IEEE Computer Society), 2818–2826.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., et al. (2014). Going deeper with convolutions. *arXiv preprint arXiv:1409.4842*. doi: 10.1109/CVPR.2015.7298594
- Tseng, Z. J. (2012). Connecting hunter-schreger band microstructure to enamel microwear features: new insights from durophagous carnivores. *Acta Palaeontol. Polonica* 57, 473–484. doi: 10.4202/app.2011.0027
- Valenzuela, A., de las Heras, S. M., Marques, T., Exposito, N., and Bohoyo, J. M. (2000). The application of dental methods of identification to human burn victims in a mass disaster. *Int. J. Legal Med.* 113, 236–239. doi: 10.1007/s004149900099
- von Koenigswald, W., Rensberger, J. M., and Pretzschner, H. U. (1987). Changes in the tooth enamel of early paleocene mammals allowing increased diet diversity. *Nature* 328, 150–152.
- Wang, Z., Zou, Y., and Liu, P. X. (2021). Hybrid dilation and attention residual U-Net for medical image segmentation. *Comput. Biol. Med.* 134, 104449. doi: 10.1016/j.combiomed.2021.104449
- Whittaker, D., and Rothwell, T. (1984). Phosphoglucomutase isoenzymes in human teeth. *Forens. Sci. Int.* 24, 219–223.
- Yang, Z., Lafata, K., Vaios, E., Hu, Z., Mullikin, T., Yin, F.-F., et al. (2022). Quantifying U-Net uncertainty in multi-parametric MRI-based glioma segmentation by spherical image projection. *arXiv preprint arXiv:2210.06512*.

4 RESULTADOS

Além dos resultados apresentados no artigo submetido na seção anterior, nesta seção apresentamos resultados obtidos nas demais etapas do fluxograma: filtro, extração de características e comparação biométrica. Como o trabalho foi desenvolvido sob a patente registrada no Instituto Nacional de Propriedade Industrial (INPI) com número de registro PI 0601672-3: USO DAS BANDAS DE HUNTER-SCHREGER DO ESMALTE DENTAL COMO PARÂMETRO BIOMÉTRICO PARA IDENTIFICAÇÃO HUMANA E ANIMAL, detalhes sobre estes algoritmos são mantidos em sigilo.

Filtro

O filtro das HSB remove os ruídos da imagem e transforma o padrão de cinza previamente selecionado na segmentação em uma imagem binária, ou seja, contendo apenas dois valores: zero e um (visivelmente: preto e branco). O desenvolvimento do algoritmo para filtro recorre à algumas técnicas usadas em impressão digital, como: estimativa de orientação e frequência das bandas (Hong et al. 1998). Diferentemente das impressões digitais, a orientação das HSB apresenta bruscas variações locais. Esse fator é ainda mais impactante porque o ruído presente na imagem com HSB evidenciadas é muito maior que o de imagens obtidas em sensores biométricos de impressão digital. Assim, desenvolvemos um método gradual de filtragem mostrado na Figura 2. A imagem com as HSB evidenciadas e com a região útil selecionada tem suas bordas removidas (1); ajuste de orientação global (2) e redimensionamento de acordo com a estimativa da frequência média das bandas (3), adaptados de Hong et al. 1998; filtragem vertical (4), binarização com equalização da razão branco/preto (5), suavização por redimensionamento (6), filtragem de pixels locais usando filtro de Gabor de modo iterativo (7). Este último processo (7) é realizado gradualmente com repetição de três vezes, estabelecida após comparações visuais do padrão das HSB entre imagem de entrada e imagem de saída, de modo a balancear ambas qualidade de filtragem e fidelidade. O aumento das repetições melhora a qualidade da filtragem em detrimento da fidelidade das HSB da imagem de entrada. Alguns exemplos de resultados obtidos com o fluxograma de filtro são apresentados na Figura 3.

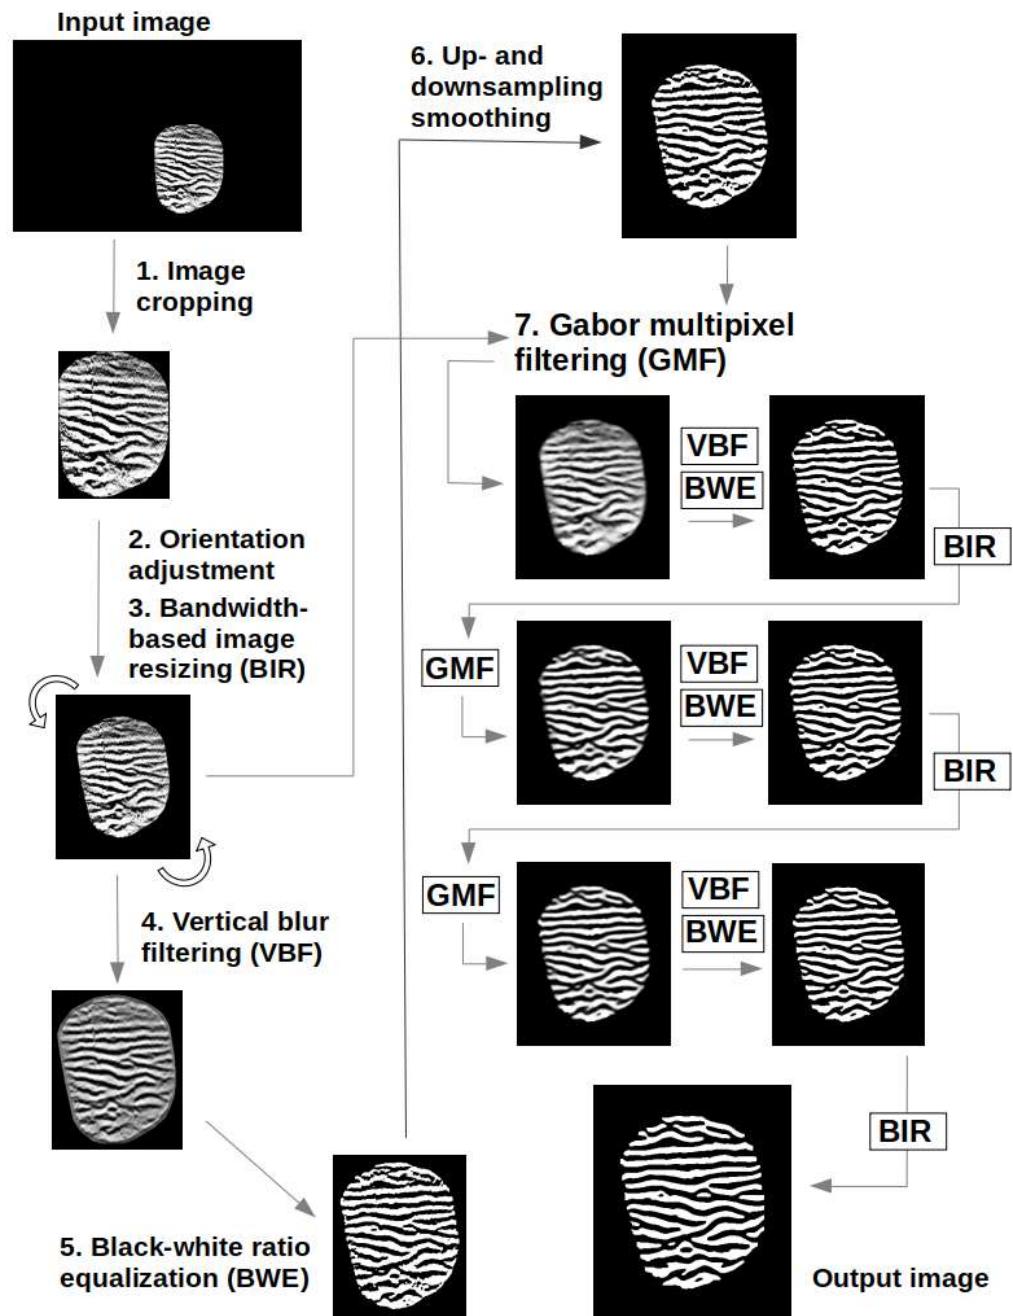


Figura 2. Fluxograma do filtro e binarização das HSB.

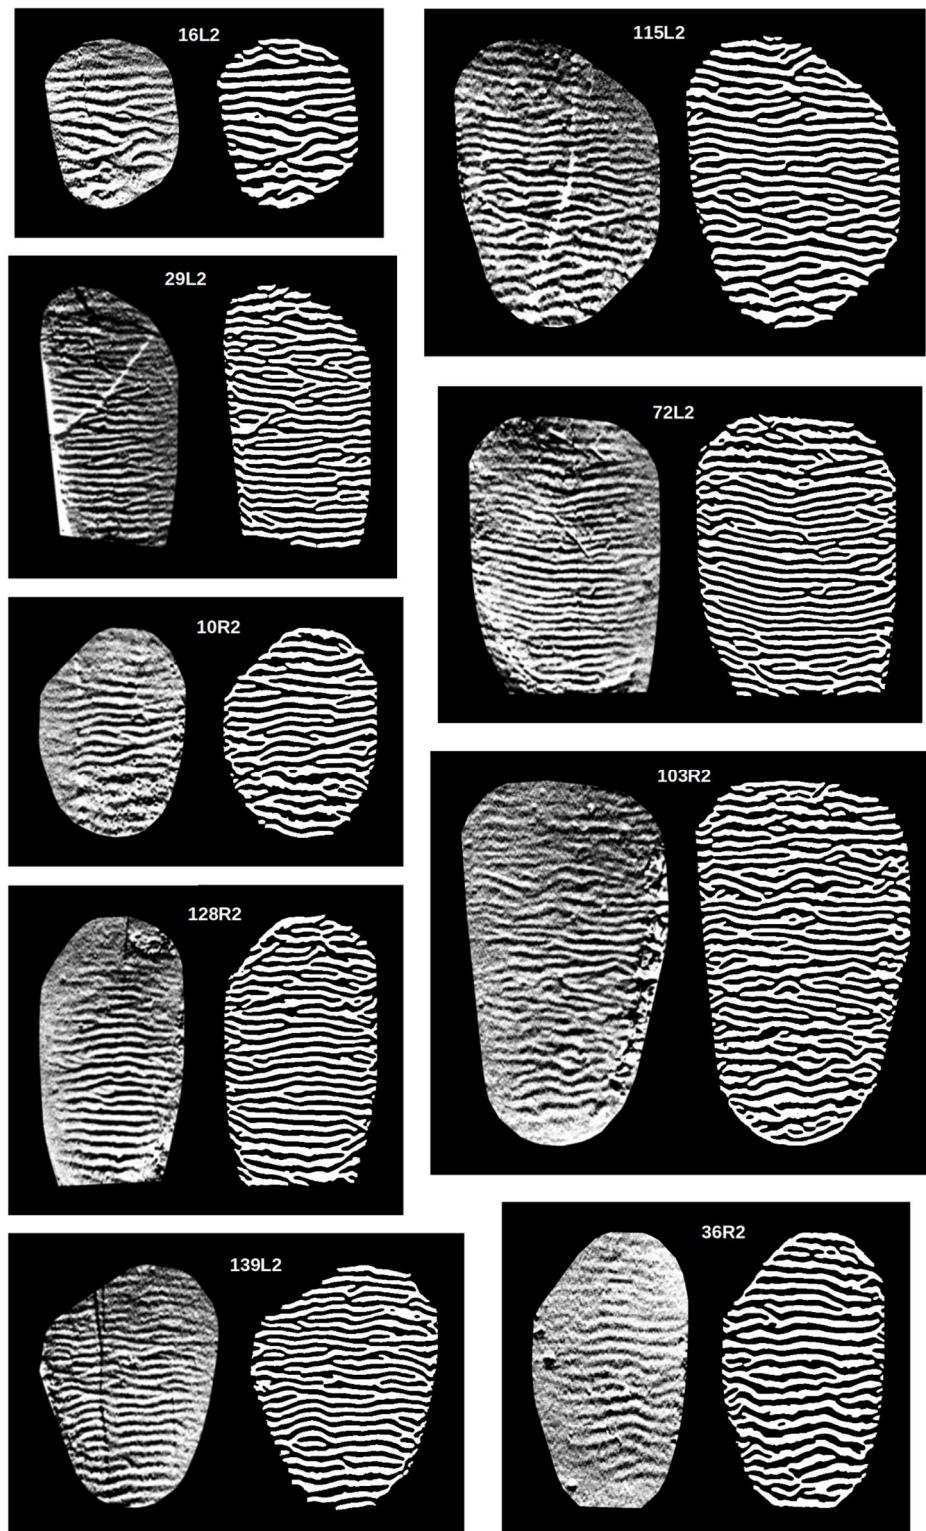


Figura 3. Exemplos de resultados obtidos com o algoritmo do filtro. Imagens de entrada e saída estão posicionadas lado a lado, esquerdo e direito, respectivamente.

Extração de características

A extração de características das HSB filtradas é bastante semelhante ao processo usado nas impressões digitais. As principais usadas são terminações e bifurcações. Essas minúcias são identificadas após esqueletização da imagem binária (Figura 4). Nesse processo, as bandas são reduzidas à espessura de um único pixel, enquanto mantêm sua extensão (Zhang e Suen 1984). Assim, é possível mapear regiões cujo número de pixels vizinhos seja igual a um para terminações e igual a três ou mais para bifurcações. Com isso, muitas falsas minúcias são encontradas. Um pós-processamento para remoção de falsas minúcias é aplicado usando diversas técnicas, entre elas, adaptações de Maltoni et al. 2009 e Gamassi et al. 2005. Devido às variações de iluminação da fotografia inicial, existe ambiguidade na determinação do tipo de minúcia encontrada: terminação ou bifurcação? Um exemplo está ilustrado na Figura 5. Para solucionar esse problema, usamos apenas terminações, porém para bandas claras e escuras. Desse modo, um número maior de minúcias pode ser comparado.

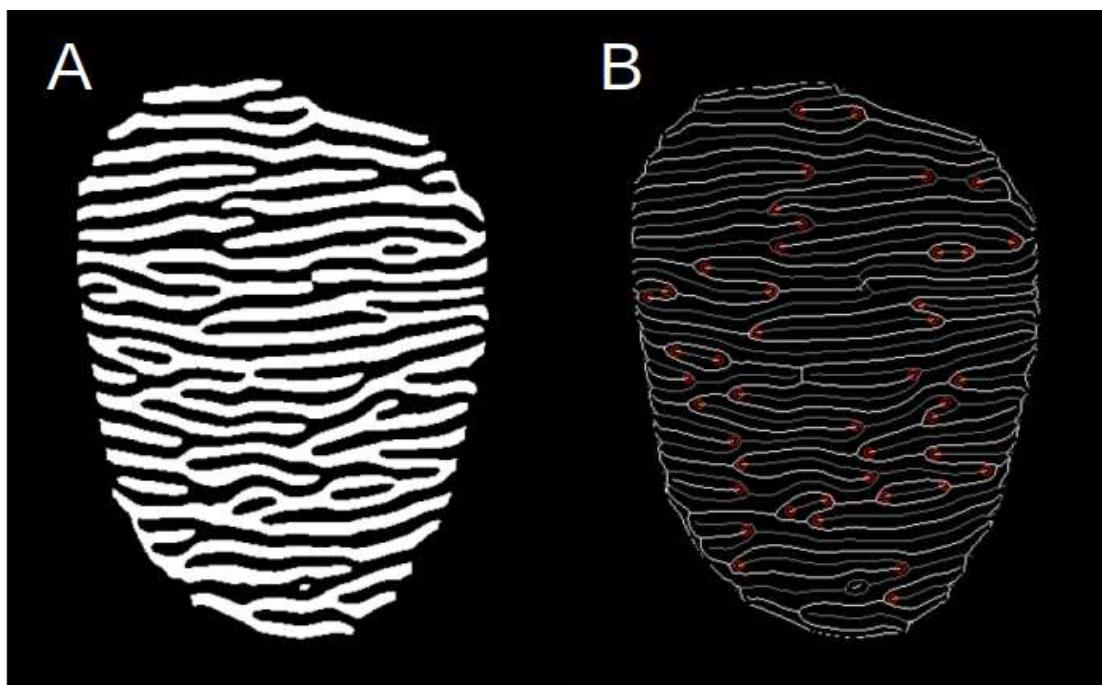


Figura 4. Exemplo do processo de esqueletização e identificação de minúcias. A) Imagem binária com as HSB filtradas. B) Esqueletização da imagem A com terminações identificadas. As linhas brancas representam as bandas brancas e as linhas cinzas representam as bandas pretas da imagem A. Apenas terminações são mostradas.

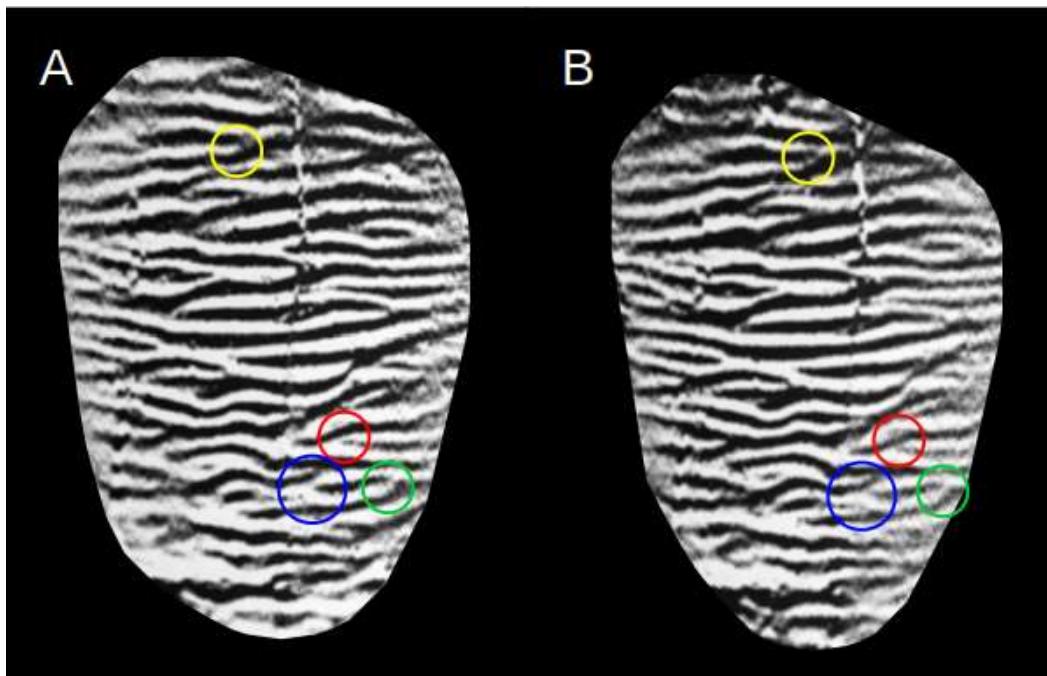


Figura 5. Exemplo de ambiguidade na identificação do tipo de minúcia. As imagens A e B são resultados de diferentes fotografias do mesmo dente. Os círculos coloridos destacam regiões análogas (mesma cor) onde a identificação do tipo de minúcia é subjetiva.

Comparação biométrica

A comparação biométrica utiliza as características previamente extraídas na identificação de um dente, que podem ser confrontadas com características de um ou múltiplos dentes de um banco de dados. Atualmente, com as atualizações dos sistemas automáticos de identificação de impressão digital (AFIS), não há mais compatibilidade para uso na identificação da *toothprint*, como relatado anteriormente (Ramenzoni e Line 2006) para o software Verifinger (Neurotechnology). Por isso, criamos um algoritmo específico para uso da *toothprint*, baseado em minúcias (Capelli et al. 2012) e textura (Jain et al. 2001) das *toothprints*. Após o cadastro de 115 dentes em dois momentos distintos, obtivemos quatro bancos de dados, sendo dois para iluminação do lado direito (R) e dois para iluminação do lado esquerdo (L). A comparação foi realizada apenas entre bancos de dados com iluminação do mesmo lado. O score final para cada comparação foi obtido usando o valor máximo do score obtido entre L e R ($\max(L,R)$) (Figuras 6 e 7). O atual tempo de execução em Python 3.9, usando um processador Intel® CoreTM i7-6500U CPU @ 2.50GHz × 4, 16GB RAM, é de aproximadamente 20 comparações por segundo.

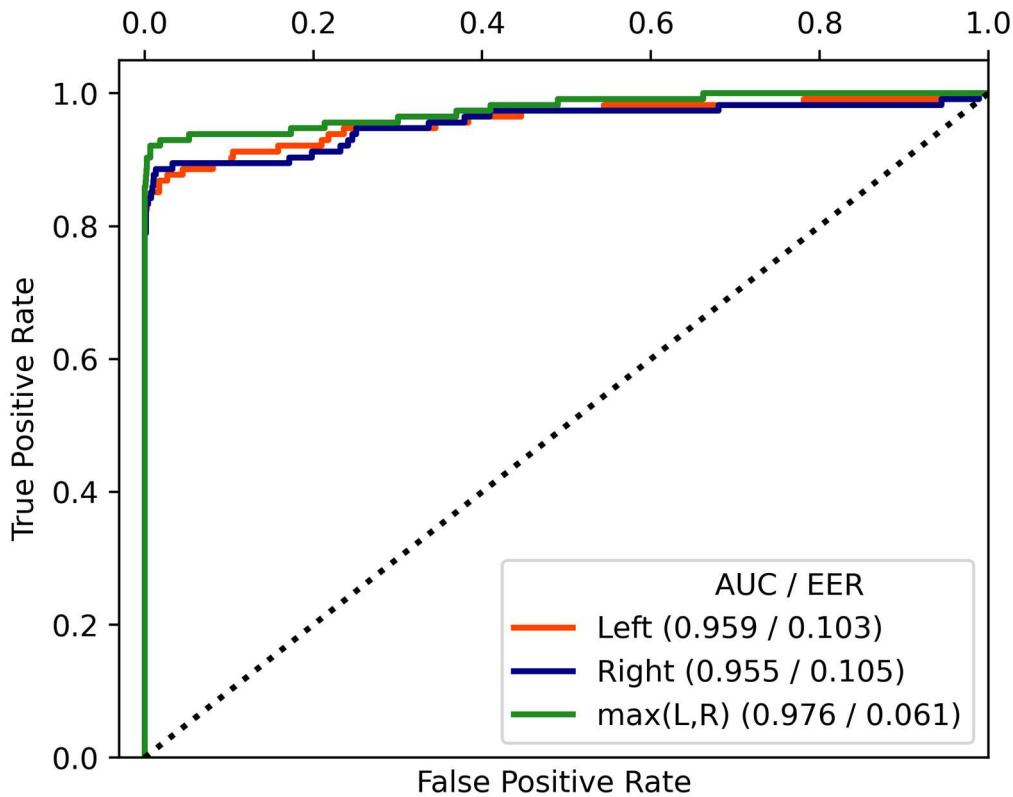


Figura 6. Curva ROC das comparações biométricas entre os 115 dentes com iluminação do lado esquerdo (Left), direito (Right) e usando o valor máximo entre direito e esquerdo (**max(L,R)**). AUC é a área sob a curva, e EER é a taxa de erro igual (Equal Error Rate) em [0,1].

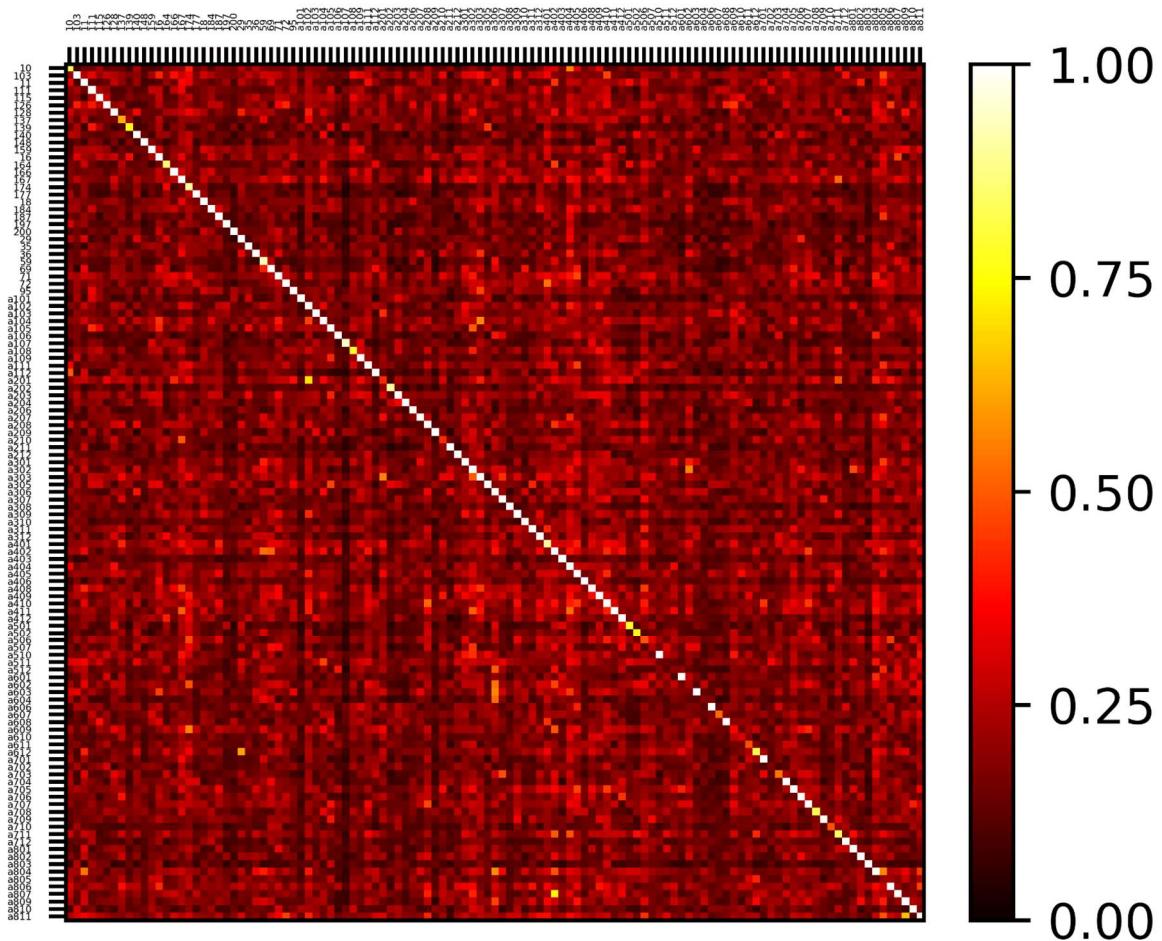


Figura 7. Matriz de similaridade das comparações biométricas entre 115 dentes calculada na forma $\max(L,R)$. A escala representa o grau de similaridade (score) entre as *toothprints* comparadas, sendo um o valor máximo e zero o valor mínimo.

O limiar da EER foi de aproximadamente 0,31. Para uma melhor visualização do desempenho atual desta metodologia biométrica, estabelecemos o limiar de 0,5 para cálculo da Taxa de Falso Positivo (FPR) e da Taxa de Verdadeiro Positivo (TPR). A identificação positiva em relação à distribuição da amostra revelou uma FPR de 0,002 (31 de 13225 comparações) e uma TPR de 0,877 (101 de 115 comparações). A Figura 8 mostra a condição dos dentes da amostra em relação à identificação biométrica com esse limiar de 0,5. Sem dúvida, os dentes hígidos apresentaram melhor desempenho quanto à identificação positiva. Proporcionalmente, dentes “cariados, restaurados ou fraturados” tiveram melhores resultados do que os dentes com “hipoplasia, manchas ou desgastes”. Uma hipótese plausível é de que as condições dentárias deste último grupo envolvam principalmente a face vestibular (anterior) dos dentes, enquanto

as condições do primeiro grupo localizam-se normalmente nas faces proximais (laterais) dos dentes, onde a região das HSB é menos atingida.

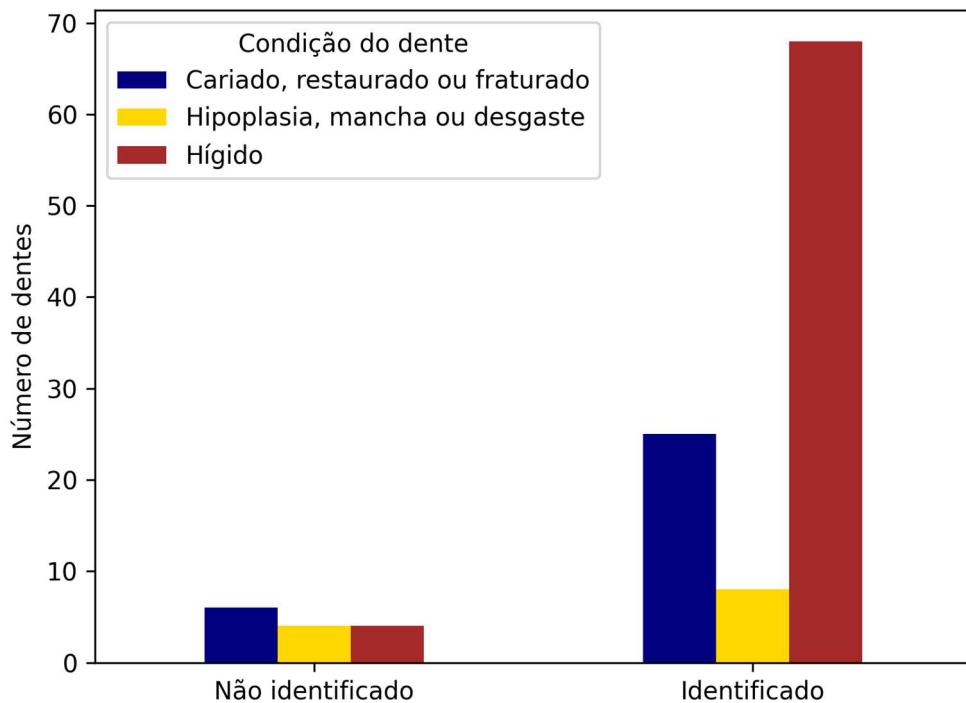


Figura 8. Distribuição da amostra de 115 dentes entre não identificados e identificados para um limiar de 0,5 de acordo com a condição do dente.

Adaptação do filtro para uso em impressões digitais a distância

Fotografias de dedos das mãos foram obtidas com diferentes iluminações (ambientes internos e externos) e o algoritmo de filtro das HSB foi adaptado para a impressão digital. A região da polpa do dedo em que aparecem os cumes e sulcos da impressão digital foi selecionada e recortada manualmente do restante da imagem (Figura 9A). Adaptamos o filtro criado para as HSB de modo a utilizá-lo em impressões digitais à distância. As impressões digitais possuem variação de orientação global em praticamente todas as direções, mas variações locais pequenas. Isso permitiu extrair bons resultados a partir da rotação da imagem ou direcionamento do filtro vertical usado nas HSB. Discretizamos a rotação em 8 ângulos fixos com intervalo aproximado de 22,5 graus: 0, 22, 45, 67, 90, 112, 135 e 157 graus. Um mapa de orientação é criado de modo a identificar o melhor ângulo discreto a ser utilizado para cada região da imagem (Figura 9B). O filtro é aplicado de maneira iterativa para cada região e a união das partes filtradas é realizada no fim do processo (Figura 9C). Para que a imagem filtrada

seja comparável às impressões digitais obtidas por sensores, deve-se virá-la horizontalmente e obter sua cópia negativa (Figura 9D).

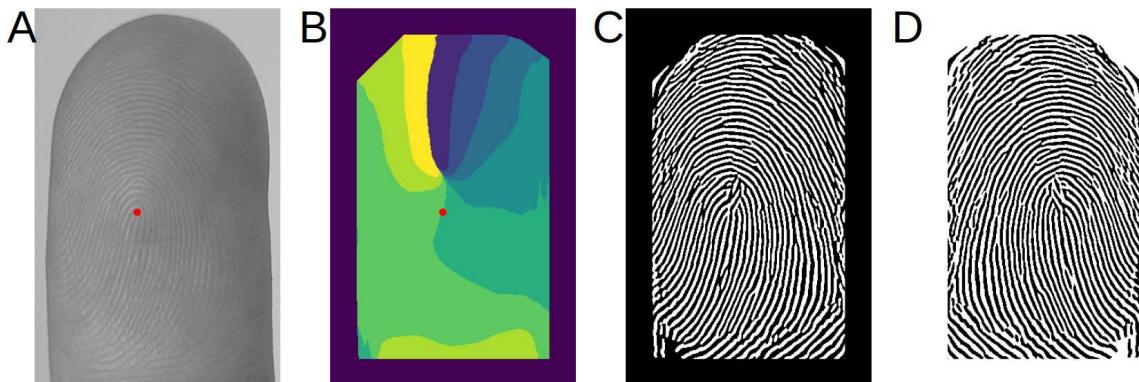


Figura 9. Ilustração de partes do processo de filtragem de impressões digitais obtidas a distância. A) Região de interesse da imagem inicial (polpa do dedo). B) Mapa de orientação das papilas do dedo, cada cor representa uma orientação. C) Imagem binária filtrada, resultado da imagem de entrada em A. D) Imagem virada horizontalmente e negativa simulando o registro papiloscópico do dedo. O ponto vermelho em A e B representa a posição central da impressão digital, conhecido como *core*.

Como as imagens são obtidas de fotografias, não existe um controle preciso da escala de tamanho. O ajuste de tamanho da imagem inicial é feito por meio da estimativa da frequência dos cumes e sulcos da polpa do dedo. Assim, para a comparação biométrica, pode ser necessária a transformação de escala. Outro ponto ainda a ser melhorado é a precisa identificação do centro da impressão digital, conhecido como *core* (Figura 9A e B, ponto vermelho). Essa imprecisão gera artefatos na imagem binária final, devido à orientação equivocada do filtro aplicado na região.

5 DISCUSSÃO

A identificação pessoal por meio da microestrutura do esmalte dentário possui suas peculiaridades, como a orientação das HSB predominantemente horizontal com alta variação local, dependência de iluminação específica, ambiguidade na caracterização das minúcias, e variabilidade na espessura das HSB. Mostramos que é possível realizar a identificação para a grande maioria dos dentes. Para isso, foi necessária a criação de métodos específicos combinados à adaptação de métodos existentes para o processamento das imagens. A validação do *pipeline* completo em dentes extraídos em condições variadas: íntegros, restaurados, fraturados, cariados, etc; revelou uma taxa de EER de 0.061, valor inferior ao obtido de impressões digitais por alguns sensores biométricos (Alshehri et al. 2018, Priesnitz et al. 2022). Considerando que a dentição anterior completa apresenta 12 dentes (incisivos e caninos), a chance de identificação pessoal aumenta muito.

Dentro do fluxograma apresentado, mostramos no artigo que a correta seleção da região do dente onde há HSB útil para uso biométrico é uma tarefa subjetiva. Os limites são mal definidos e a seleção de regiões muito extensas pode adicionar artefatos de imagem, enquanto a seleção de regiões pequenas pode excluir características importantes na identificação do dente. As duas técnicas usadas para segmentação: segmentação baseada em anisotropia (ABS) usando processamento de imagem clássico, e segmentação por rede neural convolucional U-Net resultaram em sobreposição média de 76,6% (ABS) e 83,7% (U-Net) em relação à segmentação de referência para as HSB. A dificuldade desse tipo de segmentação reside na ausência de contorno da região de interesse. Isso também explica os resultados relativamente não tão altos aos esperados de uma rede neural completamente convolucional. Variações das técnicas ainda abrem campo para novos testes e podem ser exploradas mesmo fora do contexto das *toothprints*.

Além dos erros na segmentação, erros em outras etapas do processo da obtenção da *toothprint* influenciam diretamente o resultado final e tendem a ter efeito cumulativo. Assim, se faz necessário um controle de qualidade. Começando pela fotografia, as variações de iluminação e posicionamento da câmera em relação ao dente podem interferir no contraste das HSB e causar distorção. A evidenciação das HSB ocorre de maneira direta sem problemas aparentes. A segmentação influencia no número de minúcias passíveis de identificação, mas também deve limitar-se à área de HSB com qualidade suficiente para ser binarizada com

fidelidade. O filtro, diferentemente dos filtros comumente usados em impressões digitais, é aplicado de maneira gradual e regiões com muito ruído podem prejudicar a filtragem. A extração de características biométricas é dependente das HSB filtradas, tanto em qualidade quanto em número de minúcias. E finalmente a comparação biométrica utiliza as minúcias e a textura das imagens filtradas para geração do *score* de similaridade. Assim, o estabelecimento de um controle de qualidade para essas etapas será fundamental para real aplicação da metodologia.

Além das vantagens do uso das HSB como meio biométrico mencionadas anteriormente, atualmente a metodologia proposta consegue armazenar os 12 dentes anteriores de um indivíduo usando menos de 100 kilobytes. Embora o uso de múltiplos dentes de um indivíduo tenha potencial para garantir resultados comparáveis aos métodos biométricos atuais em uso, acreditamos que seja possível aperfeiçoar diversas partes do fluxograma para maior eficiência em cada dente. Além disso, existem características inerentes aos dentes que ainda não foram exploradas, como por exemplo trincas de esmalte, que podem ajudar a reduzir as taxas de falso positivo.

Devido às semelhanças encontradas entre a impressão digital e as HSB surgiu a ideia de adaptação do algoritmo para impressão digital a distância (sem contato). Mostramos que é possível aplicar o algoritmo de filtro para as impressões digitais, embora ainda sem validação para comparações com imagens extraídas de forma convencional por sensores. Além disso, a identificação precisa do centro da impressão digital bem como possíveis defeitos na polpa do dedo, como exemplo as fissuras ou vinhos na pele, podem prejudicar o filtro. O uso prático desse tipo de ferramenta ainda requer a seleção automática da região das pontas dos dedos na fotografia e padronização para comparação biométrica. Recentemente o uso de técnicas para impressão digital sem contato vem sendo relatado na literatura para uso principalmente em *smartphones* (Kauba et al. 2021, Priesnitz et al. 2022). Embora a abordagem usando sensores demonstre maior segurança na identificação, parece já existir uma preferência do público em geral por métodos sem contato direto (Priesnitz et al. 2022).

6 CONCLUSÃO

Através do desenvolvimento em conjunto dos diversos algoritmos para identificação pessoal por meio da microestrutura do esmalte dentário, chamada de bandas de Hunter-Schreger, em dentes extraídos em diversas condições, foi possível quantizar a eficiência do método proposto, nomeado *Toothprint*. Mostramos que esse método é capaz de identificar dentes em momentos distintos através de um protocolo de captura de imagens fotográficas em condições específicas. O desempenho atual usando apenas um dente é inferior aos métodos biométricos mais utilizados, mas apresenta grande potencial para melhoramento. Além disso, a *Toothprint* possui vantagens quando aplicada em situações onde outros métodos de identificação forense são limitados. Também mostramos a aplicação com sucesso do filtro criado para impressões digitais sem contato. Ressaltamos que a validação biométrica ainda deve ser realizada para compatibilidade com os sistemas de impressão digital existentes.

REFERÊNCIAS

Alshehri H, Hussain M, Aboalsamh H, AlZuair, M. 2018. A Large-Scale Study of Fingerprint Matching Systems for Sensor Interoperability Problem. *Sensors* (Basel, Switzerland). 18. 10.3390/s18041008.

Arrieta ZL, Line SRP. 2017. Optimizing the analysis of dental enamel microstructure in intact teeth. *Microsc Res Tech* 80(7):693-696.

Arrieta ZL, Fogalli GB, Line SRP. 2018. Digital enhancement of dental enamel microstructure images from intact teeth. *Microsc Res Tech.*; 81: 1036– 1041. <https://doi.org/10.1002/jemt.23070>

Cappelli R, Ferrara M, Maltoni D. 2012. Minutiae-Based Fingerprint Matching. In: Cross Disciplinary Biometric Systems. Intelligent Systems Reference Library, vol 37. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-28457-1_7

Galbally J, Bostrom G, Beslay L. 2017. Full 3D Touchless Fingerprint Recognition:Sensor, Database and Baseline Performance. *Biometrics (IJCB)*, 2017 IEEE. doi 10.1109/BTAS.2017.8272702

Gamassi M, Piuri V., Sana D, Scotti F. 2005, May. Robust fingerprint detection for access control. In *Proc. of RoboCare Workshop* (pp. 1-3).

Hong L, Wan Y, Jain A. 1998. Fingerprint image enhancement: algorithm and performance evaluation," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 20, no. 8, pp. 777-789, Aug. doi: 10.1109/34.709565

Jain A, Ross A, Prabhakar S. 2001. Fingerprint Matching Using Minutiae And Texture Features. *Proc Int Conf Image*. 3. 282 - 285 vol.3. 10.1109/ICIP.2001.958106.

Kauba C, Söllinger D, Kirchgasser S, Weissenfeld A, Fernández Domínguez G, Strobl B, Uhl A. 2021. Towards Using Police Officers' Business Smartphones for Contactless Fingerprint Acquisition and Enabling Fingerprint Comparison against Contact-Based Datasets. *Sensors* (Basel). Mar 24;21(7):2248. doi: 10.3390/s21072248.

Koenigswald W, Pfretzchner H. 1987. Changes in the tooth enamel of early Paleocene mammal allowing increased diet diversity. *Nature* 106:150-152.

Koenigswald W. 1994. U-Shaped orientation of Hunter-Schreger bands in the enamel of moropus (mammalia, Chalecotheridae) in comparison to some other perissodactyla. *Ann. Carnegie Mus.* 63:49-64.

Koenigswald W, Rose K. 2005. The Enamel Microstructure of the Early Eocene Pantodont Coryphodon and the Nature of the Zigzag Enamel. *Journal of Mammalian Evolution*. 12. 419-432. 10.1007/s10914-005-6970-1.

Line SRP, Bergqvist LP. 2005. Enamel structure of Paleocene mammals of the São José de Itaboraí basin, Brazil. “Condylarthra”, Litopterna, Notoungulata, Xenungulata, and Astrapotheria. *J. Vert. Paleontol.* 25(4):924-928.

Maltoni D, Maio D, Jain AK, Prabhakar S. 2009. *Handbook of fingerprint recognition*. Springer London. <https://doi.org/10.1007/978-1-84882-254-2>

Noh D, Lee W, Son B, Kim J. 2018. Empirical study on touchless fingerprint recognition using a phone camera. *Journal of Electronic Imaging* 27(3), 033038. doi: 10.1117/1.JEI.27.3.033038.

Priesnitz J, Huesmann R, Rathgeb C, Buchmann N, Busch C. 2022. Mobile Contactless Fingerprint Recognition: Implementation, Performance and Usability Aspects. *Sensors*. 22(3):792. <https://doi.org/10.3390/s22030792>

Perry WL, Bass WM, Riggsby WS, Sirotnik K. 1988. The autodegradation of deoxyribonucleic acid (DNA) in human rib bone and its relationship to the time interval since death. *J. Forensic Sci.* 33:144-153.

Ramenzoni LL, Line SR. 2006 Automated biometrics-based personal identification of the Hunter-Schreger bands of dental enamel. *Proc Biol Sci.* 273(1590):1155-8.

Ravi J, Raja, KB, Venugopal RK, 2010. Fingerprint Recognition Using Minutia Score Matching. arXiv. <https://doi.org/10.48550/ARXIV.1001.4186>

Stefen C. 1999 Enamel microstructure of recent and fossil Canidae (Carnivora:Mammalia). *J. Vertebr. Paleontol.* 19, 576-587.

Stefen C. 2001 Enamel structure of arctoid carnivoran: Amphicyonidae, Ursidae, Procyonidae and Mustelidae. *J. Mammal.* 82:450-452.

Sweet DJ, Sweet CHW. 1995. DNA analyses of dental pulp to link incinerated remains of homicide victim to crime scene. *J Forensic Sci.* 40:310-314.

Valenzuela A, Martin-de las Heras S, Marques T, Exposito N, Bohoyo JM. 2000. The application of dental methods of identification to human burn victims in a mass disaster. *Int J Legal Med.* 113(4):236-9. doi: 10.1007/s004149900099.

Weicheng S, Tieniu T. 1999. Automated biometrics-based personal identification. *Proc. Natl. Acad. Sci. USA* 96:11065-11066.

Zhang TY, Suen CY. 1984. A fast parallel algorithm for thinning digital patterns. *Commun. ACM* 27, 3 (March 1984), 236–239. <https://doi.org/10.1145/357994.358023>

Anexo 1 – Relatório de similaridade

Desenvolvimento de algoritmos para processamento de imagens da microestrutura do esmalte dentário e impressões digitais obtidas a distância.

RELATÓRIO DE ORIGINALIDADE

18%	18%	6%	4%
ÍNDICE DE SEMELHANÇA	FONTES DA INTERNET	PUBLICAÇÕES	DOCUMENTOS DOS ALUNOS

FONTES PRIMÁRIAS

- | | | |
|---|---|----|
| 1 | repositorio.unicamp.br | 9% |
| 2 | bv.fapesp.br | 2% |
| 3 | Liza L. Ramenzoni. "Automated biometrics-based personal identification of the Hunter-Schreger bands of dental enamel", Proceedings of The Royal Society B Biological Sciences, 05/07/2006
Publicação | 1% |
| 4 | Zulieth López Arrieta, Sergio Roberto Peres Line. "Optimizing the analysis of dental enamel microstructure in intact teeth", Microscopy Research and Technique, 2017
Publicação | 1% |
| 5 | assets.researchsquare.com | 1% |
| | doczz.com.br | |

6	Fonte da Internet	1 %
7	iieta.org Fonte da Internet	1 %
8	www.plus.ac.at Fonte da Internet	1 %
9	link.springer.com Fonte da Internet	1 %
10	Submitted to American Public University System Documento do Aluno	1 %
11	mts.intechopen.com Fonte da Internet	1 %

[Excluir citações](#)

[Excluir bibliografia](#)

Desligado

Desligado

[Excluir](#)

correspondências

< 1%

Anexo 2 – Comprovante de submissão

frontiers About us All journals All articles Submit your research

Search My Frontiers

Frontiers in Imaging Sections Articles Research Topics Editorial Board About journal

ORIGINAL RESEARCH article

Front. Imaging, 10 August 2023
Sec. Imaging Applications
Volume 2 - 2023 | https://doi.org/10.3389/fimag.2023.1215764

Download Article

112 Total views 13 Downloads View article impact

View altmetric score

SHARE ON Twitter LinkedIn Facebook

Edited by Pankaj K. Sa National Institute of Technology Rourkela, India

Reviewed by Alessandro Bruno Università IULM, Italy Subrajeet Mohapatra Birla Institute of Technology, Mesra, India

TABLE OF CONTENTS

Abstract
1. Introduction
2. Methods
3. Results
4. Discussion
5. Conclusion
Data availability statement
Ethics statement

Segmentation of tooth enamel microstructure images using classical image processing and U-Net approaches

Giovani Bressan Fogalli^{1,2}, Sérgio Roberto Peres Line^{1*}, Daniel Baum²

¹ Department of Biosciences, Piracicaba Dental School, State University of Campinas, Piracicaba, Brazil
² Department of Visual and Data-Centric Computing, Zuse Institute Berlin, Berlin, Germany

Introduction: Tooth enamel is the hardest tissue in human organism, formed by prism layers in regularly alternating directions. These prisms form the Hunter–Schreger Band (HSB) pattern when under side illumination, which is composed of light and dark stripes resembling fingerprints. We have shown in previous works that HSB pattern is highly variable, seems to be unique for each tooth and can be used as a biometric method for human identification. Since this pattern cannot be acquired with sensors, the HSB region in the digital photograph must be identified and correctly segmented from the rest of the tooth and background. Although these areas can be manually removed, this process is not reliable as excluded areas can vary according to the individual's subjective impression. Therefore, the aim of this work was to develop an algorithm that automatically selects the region of interest (ROI), thus, making the entire biometric process straightforward.

Methods: We used two different approaches: a classical image processing method which we called anisotropy-based segmentation (ABS) and a machine learning method known as U-Net, a fully convolutional neural network. Both approaches were applied to a set of extracted tooth images.

Results: U-Net with some post processing outperformed ABS in the segmentation task with an Intersection Over Union (IOU) of 0.837 against 0.766.

Discussion: Even with a small dataset, U-Net proved to be a potential candidate for fully automated in-mouth application. However, the ABS technique has several parameters which allow a more flexible segmentation with interactive adjustments specific to image properties.

1. Introduction

Tooth enamel is the most highly mineralized tissue (95% of mineral) in an organism and is able to withstand high temperatures, abrasion, aggressive environments (i.e., humidity, pressure), and degradation over time ([Sweet and Sweet](#)).

frontiers | Frontiers in Imaging Sections Articles Research Topics Editorial Board About journal

CrossRef Full Text | Google Scholar

Tseng, Z. J. (2012). Connecting hunter–schreger band microstructure to enamel microwear features: new insights from durophagous carnivores. *Acta Palaeontol. Polonica* 57, 473–484. doi: 10.4202/app.2011.0027

CrossRef Full Text | Google Scholar

Valenzuela, A., de las Heras, S. M., Marques, T., Exposito, N., and Bohoyo, J. M. (2000). The application of dental methods of identification to human burn victims in a mass disaster. *Int. J. Legal Med.* 113, 236–239. doi: 10.1007/s004149900099

PubMed Abstract | CrossRef Full Text | Google Scholar

von Koenigswald, W., Rensberger, J. M., and Pretzschner, H. U. (1987). Changes in the tooth enamel of early paleocene mammals allowing increased diet diversity. *Nature* 328, 150–152.

PubMed Abstract | CrossRef Full Text | Google Scholar

Wang, Z., Zou, Y., and Liu, P. X. (2021). Hybrid dilation and attention residual U-Net for medical image segmentation. *Comput. Biol. Med.* 134, 104449 doi: 10.1016/j.combi.2021.104449

PubMed Abstract | CrossRef Full Text | Google Scholar

Whittaker, D., and Rothwell, T. (1984). Phosphoglucomutase isoenzymes in human teeth. *Forens. Sci. Int.* 24, 219–223.

Google Scholar

Yang, Z., Lafata, K., Vaios, E., Hu, Z., Mullikin, T., Yin, F.-F., et al. (2022). Quantifying U-Net uncertainty in multi-parametric MRI-based glioma segmentation by spherical image projection. *arXiv preprint arXiv:2210.06512*.

Google Scholar

Keywords: image processing, segmentation, fully convolutional neural network, tooth enamel, Hunter–Schreger bands, biometrics

Citation: Fogalli G.R., Line SRP and Baum D (2023) Segmentation of tooth enamel microstructure images using classical image processing and U-Net approaches. *Front. Imaging* 2:1215764. doi: 10.3389/fimag.2023.1215764

Received: 02 May 2023; **Accepted:** 19 July 2023;
Published: 10 August 2023

Edited by: Pankaj K. Sa, National Institute of Technology Rourkela, India

Reviewed by: Alessandro Bruno, Università IULM, Italy; Subrajeet Mohapatra, Birla Institute of Technology, Mesra, India

Copyright: © 2023 Fogalli, Line and Baum. This is an open-access article distributed under the terms of the Creative Commons Attribution License (CC BY). The use, distribution or reproduction in other forums is permitted, provided the original author(s) and the copyright owner(s) are credited and that the original publication in this journal is cited, in accordance with accepted academic practice. No use, distribution or reproduction is permitted which does not comply with these terms.

***Correspondence:** Sérgio Roberto Peres Line, sergline@unicamp.br

Disclaimer: All claims expressed in this article are solely those of the authors and do not necessarily represent those of their affiliated organizations, or those of the publisher, the editors and the reviewers. Any product that may be evaluated in this article or claim that may be made by its manufacturer is not guaranteed endorsed by the publisher.

Anexo 3 – Parecer do comitê de ética em pesquisa



UNICAMP - FACULDADE DE
ODONTOLOGIA DE
PIRACICABA DA
UNIVERSIDADE DE CAMPINAS
- FOP/UNICAMP



PARECER CONSUBSTANCIADO DO CEP

DADOS DA EMENDA

Título da Pesquisa: Desenvolvimento de softwares para optimização de imagens da microestrutura do esmalte dentário em dentes íntegros e impressões digitais obtidas a distância.

Pesquisador: GIOVANI BRESSAN FOGALLI

Área Temática:

Versão: 5

CAAE: 03596918.2.0000.5418

Instituição Proponente: Faculdade de Odontologia de Piracicaba - Unicamp

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 5.124.351

Apresentação do Projeto:

O parecer inicial é elaborado com base na transcrição editada do conteúdo do registro do protocolo na Plataforma Brasil e dos arquivos anexados à Plataforma Brasil. Os pareceres de retorno, emendas e notificações são elaborados a partir do último parecer e dos dados e arquivos da última versão apresentada. Trata-se de SOLICITAÇÃO DE EMENDA (E1) AO PROTOCOLO originalmente aprovado em 07/01/2019 para aumento no número de amostras a ser envolvido na pesquisa e para extensão de 9 meses no prazo de execução do projeto. O parecer foi atualizado de acordo com a documentação apresentada. A solicitação está detalhadamente descrita ao final do parecer.

A LISTA DE PESQUISADORES citada na capa do projeto de pesquisa inclui GIOVANI BRESSANFOGALLI (Cirurgião Dentista, Doutorando no PPG de Biologia Buco-Dental da FOP-UNICAMP, Pesquisador responsável, Orientando), SERGIO ROBERTO PERES LINE (Cirurgião Dentista, Docente Titular do Departamento de Morfologia da FOP-UNICAMP, Pesquisador participante, orientador), o que é confirmado na declaração dos pesquisadores e na PB.

DELINAMENTO DA PESQUISA: Trata-se de estudo clínico laboratorial, com etapas in silico,

Endereço: Av.Limeira 901 Caixa Postal 52

Bairro: Areião

CEP: 13.414-903

UF: SP

Município: PIRACICABA

Telefone: (19)2106-5349

Fax: (19)2106-5349

E-mail: cep@fop.unicamp.br



UNICAMP - FACULDADE DE
ODONTOLOGIA DE
PIRACICABA DA
UNIVERSIDADE DE CAMPINAS
- FOP/UNICAMP



Continuação do Parecer: 5.124.351

Outros	Respostaparecer.pdf	26/12/2018 20:04:23	GIOVANI BRESSAN FOGALLI	Aceito
Outros	3Comentarios.pdf	26/12/2018 20:03:39	GIOVANI BRESSAN FOGALLI	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	4TCLE.pdf	26/12/2018 19:59:53	GIOVANI BRESSAN FOGALLI	Aceito
Outros	CEPCompleto.pdf	28/11/2018 12:04:08	jacks jorge junior	Aceito
Outros	55Altarq.pdf	13/11/2018 12:33:16	GIOVANI BRESSAN FOGALLI	Aceito
Outros	54AltInfra.pdf	13/11/2018 12:32:39	GIOVANI BRESSAN FOGALLI	Aceito
Declaração de Instituição e Infraestrutura	52Declaralnstituicao.pdf	13/11/2018 12:29:01	GIOVANI BRESSAN FOGALLI	Aceito
Declaração de Pesquisadores	51DeclaraPesquisadores.pdf	13/11/2018 12:26:57	GIOVANI BRESSAN FOGALLI	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

PIRACICABA, 24 de Novembro de 2021

Assinado por:
jacks jorge junior
(Coordenador(a))

Endereço: Av.Limeira 901 Caixa Postal 52

Bairro: Areião

CEP: 13.414-903

UF: SP

Município: PIRACICABA

Telefone: (19)2106-5349

Fax: (19)2106-5349

E-mail: cep@fop.unicamp.br