

# Classificando Modelos de Implantes Dentários Usando Redes Neurais Convolucionais com Dados Sintetizados

Henrique Almeida Louzada  
Information Systems  
PUC Minas - Contagem  
Minas Gerais  
henriquelouz@gmail.com

Maria Inês Lage de Paula  
Information Systems  
PUC Minas - Contagem  
Minas Gerais  
milpaula@pucminas.br

**Resumo**—Classificar implantes dentários em imagens de radiografia usando Redes Neurais Convolucionais implica em treiná-las utilizando imagens dificilmente disponíveis publicamente. Este trabalho busca construir uma base de dados sintética de implantes dentários e testar a sua eficácia ao utilizá-la para treinar uma dessas redes. Três diferentes modelos de implantes foram metodicamente fotografados, sendo utilizadas técnicas de *Data Augmentation* básicas e de Transferência de Estilo para criar uma base de dados de treinamento. Foi coletada também uma pequena quantidade de imagens reais de radiografias para compor um conjunto de teste e arquitetada uma Rede Neural Convolucional simples. Treinar essa rede com o conjunto sintético e testar com o conjunto real resultou em um modelo preditivo de 71% de acurácia geral, o que evidencia a possibilidade do uso de uma base de dados sintética para essa finalidade. Implicações sobre os resultados e trabalhos futuros foram discutidos.

**Abstract**—Classifying dental implants in radiography images using Convolutional Neural Networks implies training them using images that are hardly publicly available. This work seeks to build a synthetic database of dental implants and test its effectiveness when using it to train one of these networks. Three different implant models were methodically photographed and basic *Data Augmentation* and Style Transfer techniques were used to create a training database. Some real X-ray images were collected to compose a test dataset and a simple Convolutional Neural Network was architected. Training this network with the synthetic set and testing it with the real set resulted in a predictive model with 71% overall accuracy, which highlights the possibility of using a synthetic database for this purpose. Implications for results and future work were discussed.

## I. INTRODUÇÃO

Os implantes dentários têm um papel fundamental na área de odontologia por oferecerem soluções para questões de saúde e estética bucal. Pessoas que perderam dentes permanentes podem recuperar as funções dos mesmos recorrendo aos implantes.

Um implante dentário, na maioria das vezes, é composto por duas peças: uma broca oca, que é implantada na gengiva do paciente; e outra peça removível, que imita um dente natural e possui um encaixe na ponta para se fixar na parte oca da primeira peça [1]. Essa segunda peça é removível para que, caso aconteça alguma adversidade que venha a danificá-la, possa ser reposta sem a necessidade de procedimentos cirúrgicos

adicionais. Entretanto, quando essas adversidades ocorrem, o paciente pode não saber a marca ou modelo do implante que foi avariado para poder dar continuidade ao procedimento de reposição com outro profissional [2]. Além disso, os diversos modelos disponíveis no mercado diferem entre si em termos de especificação, podendo não ser compatíveis uns com os outros [1]. Tendo isso em vista, o profissional encarregado pela manutenção do implante precisa analisar as características da peça implantada para que ele possa adquirir peças removíveis compatíveis [3].

Dentistas experientes são capazes de identificar os modelos dos implantes mais facilmente, porém esta não é uma tarefa trivial [4]. Saghiri *et al.* apontam que o recurso de apoio a essa tarefa mais usado atualmente é o *site whatimplantisthat.com*, que consiste em um catálogo de radiografias de implantes para que o usuário possa comparar com as imagens que deseja identificar, e ressaltam a falta de processos sistematizados e eficientes de classificação dos implantes [3].

Constata-se que, para lidar com situações dessa natureza, bem como para resolver outros problemas na área de saúde, a tecnologia de visão computacional vem sendo cada vez mais utilizada. Detecção de tumores em imagens de ressonância magnética [5] e identificação de modelos de artroplastia de joelho [6] são alguns exemplos de sua aplicação. Para apoiar a identificação de modelos de implantes dentários, já se aplicam técnicas de visão computacional em imagens de radiografia [2], [7], [8]. Nesse sentido, a identificação desses objetos utilizando inteligência artificial requer um processo de arquitetura e treinamento de uma Rede Neural Convolucional com uma base robusta de dados etiquetados [9]. Surge então o problema: dados clínicos etiquetados não se encontram facilmente disponíveis, até porque são essencialmente privados [2]. Radiografias dentárias são consideradas documentos sensíveis, visto que podem inclusive auxiliar na identificação de indivíduos, já que as características dentárias são, assim como as impressões digitais, únicas para cada indivíduo [10]. Portanto, a alternativa proposta por este trabalho é a de que, no sentido de se facilitar a obtenção de dados para treinamento suficientes para o adequado treinamento de uma rede neural,

pode-se sintetizar uma base que contenha imagens que não necessariamente foram retiradas de radiografias de pacientes. Dessa forma, este trabalho tem como objetivo fabricar uma base de imagens de implantes dentários sintetizada a partir de especificações encontradas na literatura especializada e verificar sua eficácia no processo de treinamento de um modelo preditivo de visão computacional. Tal base de dados será constituída por um banco de imagens de próteses não implantadas, registradas com o intuito único de retratar as suas características, somadas a imagens resultantes de procedimentos de *Data Augmentation* [8], [10]. Em seguida, será arquitetada uma Rede Neural Convolutiva simples, que será treinada com essa base. Os modelos preditivos resultantes desse treinamento serão testados com imagens reais, para que o desempenho do *dataset* possa ser verificado.

## II. REFERENCIAL TEÓRICO

Diferentes contribuições já foram feitas para auxiliar o processo de detecção de modelos de próteses dentárias. Michelinakis *et al.* desenvolveram uma aplicação que utiliza regressão logística para reduzir o problema da detecção de um modelo a partir de 9 perguntas sobre suas especificações [11]. Nuzzolese *et al.*, por sua vez, produziram um catálogo técnico que é disponibilizado para auxiliar dentistas forenses com suas investigações, criado a partir de radiografias retiradas de forma padronizada. Esses pesquisadores fabricaram um dispositivo que posiciona os implantes variando a rotação em 0°, 30° e 60° e a inclinação em -10°, 0°, 10°, buscando, assim, que todas as características do modelo sejam registradas nas 9 radiografias resultantes [10].

Estudos recentes passam a explorar técnicas de visão computacional com a intenção de melhorar a eficiência da detecção de modelos, descartando a dependência de uma experiência profissional significativa para realizar essa atividade: Takahashi *et al.* utilizaram uma arquitetura de Rede Neural Convolutiva para detecção de implantes em uma base de dados com 1282 radiografias panorâmicas, obtendo 71% de precisão média geral [7]; Sukegawa *et al.* compararam 5 configurações de redes neurais diferentes que utilizam técnicas como ajustes finos e aprendizagem por transferência para a detecção de implantes dentários em radiografias, e chegaram a obter 93% de acurácia, a partir de uma base com 8859 imagens [2]; Saïd *et al.* utilizaram uma configuração de rede neural com aprendizagem por transferência a partir de uma rede pré-treinada, obtendo 93,8% de acurácia geral, em uma base de dados com 1206 imagens [8].

Dentre as técnicas envolvidas no contexto de visão computacional, as Redes Neurais Convolutivas são utilizadas por combinarem camadas de convolução, que extraem da imagem somente o necessário à análise, com algoritmos de aprendizado de máquina que operam com as imagens resultantes das saídas dessas camadas [9]. Na área da saúde, os avanços desse recurso computacional tornam cada vez mais comum o seu uso em tarefas que envolvem imagens médicas [12]. Complementar a essa técnica existe também o *Data Augmentation*, que consiste em criar novas versões de uma imagem a partir

de uma imagem de referência, variando diversas de suas características, tais como sua posição ou coloração, bem como inserindo ruídos ou apagando aleatoriamente algumas de suas partes, para aumentar conjuntos de treinamento [13]. Esse tipo de técnica já foi utilizado no treinamento de Redes Neurais Convolutivas para identificação de modelos de implantes dentários, como por exemplo no estudo feito por Saïd *et al.* em que foi usado o programa de edição de imagens Photoshop para empregar o *Data Augmentation*, variando aspectos como rotação horizontal, angulação, tom, brilho, contraste, ofuscação, nitidez ou correção de uma gama de imagens originais [8]. O *Data Augmentation* se estende inclusive a técnicas mais avançadas como a Transferência de Estilo, que consiste em uma técnica de tradução de imagem para imagem. Dada uma imagem de entrada e uma imagem de estilo, o objetivo é transformar a entrada aplicando aspectos da imagem de estilo [13]. Esse recurso é útil para aumentar conjuntos de dados clínicos devido a suas diversas aplicações, como colorização e envelhecimento de imagens [14]. A utilização desse tipo de técnica procura incrementar as bases de treinamento para ajudar a reduzir o *overfitting*, que acontece quando uma Rede Neural Convolutiva aprende uma função específica demais para a modelagem de um conjunto de dados, comprometendo sua capacidade de predição [2], [13].

## III. MÉTODO DE FABRICAÇÃO DA BASE DE DADOS E CONFIGURAÇÃO DA REDE NEURAL

Neste trabalho são utilizados dois conjuntos de dados: um de treinamento, que entra na rede neural e contribui com o ajuste de pesos; e outro de teste, que não é apresentado à rede e serve para a validação do modelo final. Sendo assim, além de fabricar as imagens usadas para o treinamento, utilizamos radiografias reais para a testagem. Os subtópicos desta seção detalham cada recurso utilizado, bem como as especificações da rede neural arquitetada.

### A. Obtenção de Radiografias Para Teste do Modelo

O estudo parte de uma pesquisa por casos clínicos de fabricantes de implantes em busca de imagens de radiografias já etiquetadas para a testagem do modelo. Buscas com termos como "*implant clinical cases*" no site Google trazem livros digitais com exemplos reais de utilização dos implantes comercializados por seus fabricantes, como o catálogo da NeoDent, do qual foram obtidas algumas imagens utilizadas nos testes [15].

### B. Materiais e Fotografias Originais

Para popular o subconjunto de dados de treinamento, são adquiridas uma unidade de cada modelo de implante entre os três cujas imagens foram encontradas com maior frequência ao longo do procedimento descrito na subseção anterior.

De posse dos implantes, são tiradas fotografias seguindo as especificações de catalogação técnica citadas no item II: 9 fotografias variando a rotação em 0°, 30° e 60° e a inclinação em -10°, 0°, 10° de cada modelo [10], resultando em 27 imagens no total. Essas fotografias são tiradas utilizando uma câmera Canon Eos Rebel T7i.

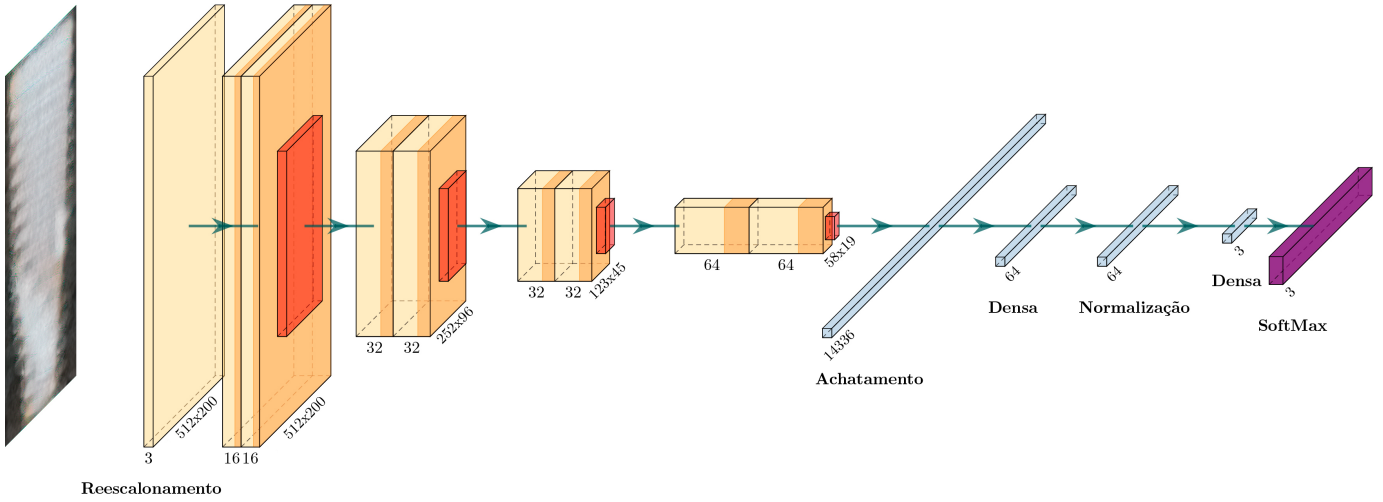


Figura 1. Arquitetura da Rede Neural Convolutional utilizada para a identificação de modelos de implantes dentários a partir de dados sintetizados.

### C. Data Augmentation

As imagens registradas, em formato jpg, são recortadas para o tamanho de 512 x 200 pixels e então é aplicada a Transferência de Estilo [16], a fim de transformar as fotografias dos implantes em uma imagem que remeta a uma radiografia. Para isso, foi utilizada uma implementação feita em Python v3.7.11, que usa a biblioteca Torch v1.9.0 com CUDA v10.2, executada em um Jupyter Notebook através da ferramenta Google Colab [17]. São aplicadas 1500 iterações usando a imagem de conteúdo como entrada, e os pesos de 5 para o conteúdo (imagem original), 2 para o estilo (imagem com o estilo desejado), e 15 para a variação total. Tais valores foram calibrados a partir de exaustivas comparações de cada imagem resultante com exemplos de radiografias reais.

Feito isso, para aplicar o *Data Augmentation* básico, é utilizado então o módulo Keras da biblioteca TensorFlow v2.5 do Python v3.8.5 [14]. Para cada imagem original são geradas outras 20, variando os aspectos de rotação em 7°, brilho entre 0.5 e 1.5, e *zoom* entre 1 e 1.5, além de inversão horizontal e vertical. O resultado deste procedimento é uma base de treinamento artificial com 540 imagens, ou 180 para cada uma das 3 classes.

### D. Rede Neural Convolutional

Utilizamos neste estudo uma rede neural com camadas convolucionais que extraem o formato geral da imagem, as bordas e os ângulos. Em seguida, as camadas densas ao final da rede realizam a classificação do modelo [8]. Ao todo, são 4 conjuntos de camadas convolucionais que combinam duas *Conv2D* com função de ativação *relu* e número crescente de filtros, uma camada *MaxPooling2D* e uma camada *Dropout* com taxa de 25% para ajudar a amenizar o *overfitting* [13]. A entrada da rede é uma camada de reescalamento das imagens para valores entre 0 e 1, e as camadas finais tratam do achatamento para vetor, da normalização dos lotes e da classificação das imagens com camadas densas. A camada de

saída é uma camada de ativação *softmax*, já que se tratam de classes codificadas com *one hot* [18]. A rede neural é treinada ao longo de 80 épocas com taxa de aprendizado de 2%. A arquitetura dessa rede pode ser vista na Figura 1.

A rede é implementada utilizando o módulo Keras da biblioteca TensorFlow v2.5 e a biblioteca OpenCV v4.1.2 do Python v3.8.5, em um computador com sistema operacional Windows 10 com 16 GB de memória, um processador de 4 núcleos e 8 *threads* e uma placa de vídeo de microarquitetura Turing (capacidade de computação 7.5) com 6 GB de memória.

### E. Procedimento de Análise dos Resultados

Para análise dos resultados obtidos, são utilizadas as métricas de performance propostas por Sokolova *et al.*, sendo consideradas as métricas de Acurácia, Precisão Macro, *Recall* Macro e Escore F1 Macro [19]. Tais métricas relacionam as quantidades de Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP) e Falsos Negativos (FN) da seguinte maneira:

$$1) \quad Acurácia = \frac{VP + VN}{VP + FP + FN + VN}$$

$$2) \quad Precisão_{Macro} = \frac{\sum_{i=1}^l \frac{VP_i}{VP_i + FP_i}}{l}$$

$$3) \quad Recall_{Macro} = \frac{\sum_{i=1}^l \frac{VP_i}{VP_i + FN_i}}{l}$$

$$4) \quad Escore F_{Macro} = \frac{(\beta^2 + 1) Precisão_{Macro} Recall_{Macro}}{\beta^2 Precisão_{Macro} + Recall_{Macro}}$$

Os resultados do estudo se norteiam por superar a marca de 33.3% de Acurácia Geral, que é alcançada ao se escolher aleatoriamente uma entre as três classes possíveis. Para comparar os resultados do modelo preditivo com uma decisão aleatória, utilizamos um recurso chamado Curva ROC, que

relaciona a Taxa de Verdadeiros Positivos  $\frac{VP}{PT}$  com a Taxa de Falsos Positivos  $\frac{FP}{PT}$  (onde PT são os Positivos Totais) de cada classe, e então mede a área abaixo da curva ROC, que indica o quanto um classificador está próximo do ideal (1.0), ou do aleatório (0.5).

Utilizamos ainda o Mapeamento de Ativação de Classe Ponderada por Gradiente para identificar em um exemplar VP de cada classe do conjunto de teste quais os aspectos de maior peso para ativação dos neurônios da rede [20].

#### IV. RESULTADOS

Esta seção apresenta a saída do processo de fabricação do conjunto de dados e a análise do desempenho do modelo preditivo gerado pela rede neural.

##### A. Confeção dos Conjuntos de Dados

Iniciando pelo processo de pesquisa, livros digitais de casos clínicos da fabricante NeoDent proporcionaram radiografias dos modelos Alvim, Drive e Helix. Após recortar implantes únicos das 70 imagens encontradas, foi obtido um conjunto de 105 imagens, sendo 23 do modelo Alvim, 37 do modelo Drive e 45 do modelo Helix. O conjunto de imagens do modelo Helix possuía as menores resoluções e dimensões entre os demais.

Com a base de testes já garantida, foram adquiridos exemplares de cada um dos implantes através da loja virtual da fabricante para o registro em fotografia: um implante NeoDent Alvim CM 3.5mm x 13mm; um Drive CM 4.3mm x 11.5mm; e um Helix GM 4.0mm x 11.5mm. As fotografias foram tiradas com iluminação semelhante, e os implantes foram posicionados verticalmente.

Partindo das fotografias originais, começamos o procedimento de *Data Augmentation*. As imagens tiveram o seu fundo recortado e substituído por um fundo monocromático, destacando somente os atributos do implante em si. Foi então escolhida uma imagem entre as do conjunto de imagens de teste para que seu estilo fosse transferido às fotos originais. Ao final das 1500 iterações de transferência de estilo, cada uma das fotografias originais passava a possuir a sua réplica agora com o estilo de radiografia transferido. A Figura 2 mostra um exemplo de resultado desse processo.

O processo de *Data Augmentation* é então finalizado com a geração de 20 imagens a partir de cada uma das imagens com estilo transferido através de manipulações simples usando o módulo Keras. A base de treinamento estava pronta com 540 imagens.

##### B. Modelo Preditivo Final

A base de dados sintética foi utilizada como entrada na Rede Neural Convolucional. Ao final da 80ª época de treinamento, obtivemos, no teste com a base de imagens reais, um modelo preditivo de 71% de acurácia geral. Para a classe Alvim, a precisão foi de 64%, o *recall* de 70% e o *score* F1 de 67%. Para a classe Drive, a precisão foi de 90%, o *recall* de 70% e o *score* F1 de 69%. Para a classe Helix, a precisão foi de 65%, o *recall* de 73% e o *score* F1 de 69%. As médias Macro indicam a média aritmética simples de cada uma das métricas




Figura 2. Saída da 1500ª iteração da transferência de estilo para a fotografia do modelo NeoDent Helix a 0° de rotação e 0° de inclinação. Em sequência, estão o conteúdo, o estilo e o resultado. As métricas assinaladas indicam a perda de aspectos detectáveis por redes neurais para cada uma das entradas no resultado.

analisadas, 73%, 71% e 71% para precisão, *recall* e *score* F1, respectivamente. O suporte indica a quantidade de imagens testadas para cada classe. Essas métricas são detalhadas na Tabela I.

Tabela I  
RELATÓRIO DE CLASSIFICAÇÃO PARA O MODELO PREDITIVO GERADO PELA REDE NEURAL CONVOLUCIONAL ARQUITETADA

Classe	Precisão	Recall	Score F1	Suporte
Alvim	0.64	0.70	0.67	23
Drive	0.90	0.70	0.79	37
Helix	0.65	0.73	0.69	45
<b>Média (macro)</b>	0.73	0.71	0.71	105
<b>Acurácia Geral</b>	0.71			105

A classe Alvim, apesar de apresentar o menor suporte, conseguiu pontuações próximas à classe Helix, que possuía 22 unidades a mais de suporte. Por outro lado, a classe Drive, a mais visualmente distinta, mesmo com 37 unidades de suporte chegou a 90% de precisão.

A Figura 3 apresenta a visualização da Curva ROC do modelo preditivo final. Nota-se que a curva da classe Drive teve a maior AUC (*Area Under the Curve*), 0,96, e a curva da classe Helix, a menor AUC, 0,75. A curva da classe Alvim se manteve próxima a da média macro, apresentando AUC de 0,89 e 0,87, respectivamente.

A Figura 4 mostra o Mapeamento de Ativação de Classe Ponderada por Gradiente para um exemplar VP de cada classe. Dois pontos a serem destacados são a influência de aspectos exteriores aos implantes na classificação e um ponto de baixa ativação na parte central de cada exemplar, onde se encontram aspectos interiores do implante, que são registrados por imagens de raio X, mas não por fotografias externas.

#### V. IMPLICAÇÕES E TRABALHOS FUTUROS

Este estudo evidencia a possibilidade de se treinar redes neurais convolucionais com dados sintéticos para auxiliar a

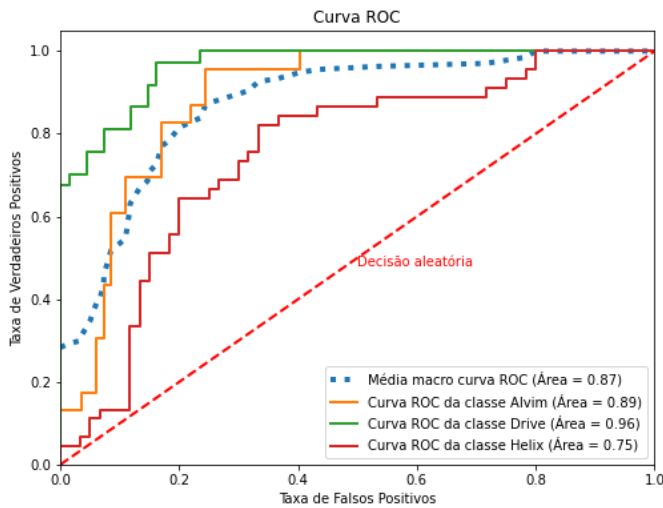


Figura 3. Curvas ROC obtidas para as classes Alvim, Drive, Helix e para a Média macro. Esse recurso relaciona a Taxa de Verdadeiros Positivos com a Taxa de Falsos Positivos, traçando a função de Decisão Aleatória para comparação.




Figura 4. Mapeamento de Ativação de Classe Ponderada por Gradiente em imagens de teste para cada uma das classes analisadas. O gradiente vai de azul a vermelho, e indica o grau de ativação dos neurônios da rede para cada parte da imagem.

tarefa de identificação de modelos de implantes dentários em determinadas imagens de radiografias. A diferença entre a acurácia geral do modelo preditivo e a acurácia de uma escolha aleatória mostra que esforços nesse sentido auxiliam a resolução do problema. Dada a grande diversidade de implantes disponíveis no mercado, e também a exclusividade regional de alguns deles, um modelo preditivo independente de dados reais pode auxiliar um nicho sem recursos para realizar a tarefa de identificação para a reposição de peças.

É necessário, contudo, que a base de dados para treinamento seja incrementada para melhor generalizar novas entradas. Portanto, como trabalhos futuros, entendemos que repetir o procedimento com exemplares distintos (em termos de tamanho ou encaixe) de um mesmo modelo, coletar mais imagens de teste, ou mesmo utilizar outras técnicas de *Data Augmentation*,

como as Redes Adversárias Generativas, pode vir a melhorar o modelo no que se refere à generalização e capacidade de identificação de bases de dados mais expressivas. Essas redes são capazes de gerar imagens artificiais fiéis às reais o suficiente para agregarem às bases de treinamento, e já são utilizadas na medicina para tarefas semelhantes. Outra consideração refere-se à possibilidade de substituição das fotografias por radiografias, que captariam os aspectos internos do implante, que também podem ser usados para distinção dos modelos.

## VI. CONCLUSÃO

Nosso trabalho apresenta uma abordagem para identificação de modelos de implantes dentários em imagens de radiografia utilizando uma Rede Neural Convolutacional treinada com uma base de imagens sintéticas. Visto que as técnicas de visão computacional estão no estado-da-arte dos recursos para resolução desse tipo de problema, buscamos auxiliar para a solução de uma questão recorrente do emprego dessa técnica: a disponibilidade de dados reais para treinamento. Este problema é ainda mais acentuado no contexto dos implantes dentários, uma vez que radiografias odontológicas são documentos privados. Por isso, fabricamos uma base de dados a partir de fotografias tiradas de exemplares de implantes não inseridos e técnicas de *Data Augmentation*. Testando a eficácia dessa base de dados em um modelo preditivo resultante do treinamento de uma rede neural, utilizando como entrada imagens reais de radiografias de implantes, obtivemos uma acurácia geral de 71%, superior a uma escolha aleatória de 33,3% de acurácia.

Apesar de evidenciar a possibilidade de criar um modelo preditivo a partir de dados sintéticos, é importante destacar que a acurácia apresentada neste trabalho é dependente de duas variáveis de entrada: os conjuntos de treinamento e de teste. Isso quer dizer tanto que o conjunto de treinamento ainda pode ser melhorado, incluindo mais imagens de mais classes para conseguir generalizar com maior eficácia, quanto que o conjunto de teste influencia nos resultados. Quanto mais imagens reais para teste, mais certeza se poderá ter sobre a capacidade de generalização do modelo quando testado com outras bases desconhecidas pela rede neural.

## REFERÊNCIAS

- [1] B. Guillaume, "Dental implants: A review," *Morphologie*, vol. 100, no. 331, pp. 189–198, 2016.
- [2] S. Sukegawa, K. Yoshii, T. Hara, K. Yamashita, K. Nakano, N. Yamamoto, H. Nagatsuka, and Y. Furuki, "Deep neural networks for dental implant system classification," *Biomolecules*, vol. 10, no. 7, 2020.
- [3] M. A. Saghir, P. Freag, A. Fakhzadeh, A. M. Saghir, and J. Eid, "Current technology for identifying dental implants: a narrative review," *Bulletin of the National Research Centre*, vol. 45, no. 1, p. 7, Jan 2021.
- [4] R. Gunaseelan and M. Rajan, "Overview of the SwissPlus Implant System," *Journal of Oral Implantology*, vol. 31, no. 3, pp. 121–128, 06 2005.
- [5] H. Mohsen, E.-S. A. El-Dahshan, E.-S. M. El-Horbaty, and A.-B. M. Salem, "Classification using deep learning neural networks for brain tumors," *Future Computing and Informatics Journal*, vol. 3, no. 1, pp. 68–71, 2018.
- [6] P. H. Yi, J. Wei, T. K. Kim, H. I. Sair, F. K. Hui, G. D. Hager, J. Fritz, and J. K. Oni, "Automated detection & classification of knee arthroplasty using deep learning," *The Knee*, vol. 27, no. 2, pp. 535–542, 2020.

- [7] T. Takahashi, K. Nozaki, T. Gonda, T. Mameno, M. Wada, and K. Ikebe, "Identification of dental implants using deep learning-pilot study," *Int J Implant Dent*, vol. 6, no. 1, p. 53, Sep 2020.
- [8] M. Hadj Saïd, M. K. Le Roux, J. H. Catherine, and R. Lan, "Development of an Artificial Intelligence Model to Identify a Dental Implant from a Radiograph," *Int J Oral Maxillofac Implants*, vol. 36, no. 6, pp. 1077–1082, 2020.
- [9] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," in *2017 International Conference on Engineering and Technology (ICET)*, 2017, pp. 1–6.
- [10] E. Nuzzolese, S. Lusito, B. Solarino, and G. Di Vella, "Radiographic dental implants recognition for geographic evaluation in human identification," *J Forensic Odontostomatol*, vol. 26, no. 1, pp. 8–11, Jun 2008.
- [11] G. Michelinakis, A. Sharrock, and C. W. Barclay, "Identification of dental implants through the use of Implant Recognition Software (IRS)," *Int Dent J*, vol. 56, no. 4, pp. 203–208, Aug 2006.
- [12] S. M. Anwar, M. Majid, A. Qayyum, M. Awais, M. Alnowami, and M. K. Khan, "Medical image analysis using convolutional neural networks: A review," *Journal of Medical Systems*, vol. 42, no. 11, p. 226, Oct 2018.
- [13] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *Journal of Big Data*, vol. 6, no. 1, p. 60, Jul 2019.
- [14] Y. Xu, Y. Li, and B.-S. Shin, "Medical image processing with contextual style transfer," *Human-centric Computing and Information Sciences*, vol. 10, no. 1, p. 46, Nov 2020.
- [15] NeoDent, "Clinical case books," <https://www.straumann.com/neodent/en/professionals/clinical-evidence/professional-support/clinical-cases.html>, [Acessado em 01/09/2021].
- [16] L. A. Gatys, A. S. Ecker, and M. Bethge, "Image style transfer using convolutional neural networks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2016.
- [17] J. Cochoy, "style-transfer," [https://github.com/jeremycochoy/style-transfer/blob/master/Pytorch\\_Style\\_Transfer.ipynb](https://github.com/jeremycochoy/style-transfer/blob/master/Pytorch_Style_Transfer.ipynb), 2019.
- [18] K. Potdar, T. Pardawala, and C. Pai, "A comparative study of categorical variable encoding techniques for neural network classifiers," *International Journal of Computer Applications*, vol. 175, pp. 7–9, 10 2017.
- [19] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing & Management*, vol. 45, no. 4, pp. 427–437, 2009.
- [20] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-cam: Visual explanations from deep networks via gradient-based localization," *International Journal of Computer Vision*, vol. 128, no. 2, p. 336–359, Oct 2019.