

Avaliação do Uso Redes Neurais Convolucionais para Identificação de Lesões Cariosas Dentárias

Mateus F. de C. Ferreira¹, Paula D. Portella², Juliana F. de Souza², Bruna C. Dias²,
Luciana R. da S. Assunção², Lucas F. de Oliveira¹

¹Departamento de Informática, ²Departamento de Estomatologia – Universidade Federal do Paraná (UFPR) – Curitiba – Paraná – Brazil

{mateus.fecassio, julianafeltrin1, brunacristined}@gmail.com,
pauladresch@hotmail.com, lurassuncao@yahoo.com.br,
lferrari@inf.ufpr.br

Abstract. *This study evaluates the use of convolutional neural networks to identify different levels of dental caries, a common disease that affects different age groups. Seven neural networks were evaluated and, the ResNet50 was the model that obtained the best results, with an accuracy of 92.10%, sensitivity 0.972 and specificity 0.874 in the classification of the proposed problem.*

Resumo. *Este trabalho avalia a utilização de redes neurais convolucionais para identificar diferentes níveis de lesões cariosas dentária, uma doença comum que afeta diferentes faixas etárias. Foram avaliadas sete redes neurais e a ResNet50 foi o modelo que obteve melhores resultados, com acurácia de 92,10%, sensibilidade 0,972 e especificidade 0,874 na classificação do problema proposto.*

1. Introdução

A cárie dentária é a doença bucal mais frequente, acometendo as diferentes faixas etárias, sendo proveniente do consumo frequente de alimentos contendo açúcares associado à uma higiene bucal inadequada e ao consequente acúmulo de placa bacteriana nas superfícies dentárias. Por possuir etiologia multifatorial e dinâmica, fatores genéticos e até mesmo psicossociais podem aumentar o risco dos indivíduos em desenvolver as sequelas da doença, chamadas de lesões cariosas (PITTS *et al.*, 2017). A partir do processo de metabolização, após a ingestão frequente de açúcares, há uma queda no *pH*, provocando a perda do equilíbrio preexistente entre as bactérias presentes na cavidade bucal. Como consequência, o ambiente se torna propício para a proliferação de bactérias cariogênicas, com propriedades acidúricas e acidogênicas, causando a perda dos minerais das estruturas dentárias (PITTS *et al.*, 2017).

No Brasil, segundo dados da Pesquisa Nacional de Saúde Bucal, foi verificado que a porcentagem de pessoas que possuem ou já possuíram lesões cariosas é crescente em relação ao avanço da idade. Aos 5 anos, por exemplo, cerca de 54% das crianças possuem algum dente permanente com histórico de cárie dentária. Quando avança a idade analisada, percebe-se que a taxa aumenta para aproximadamente 76% na fase adulta e se aproxima dos 100% entre idosos (MINISTÉRIO DA SAÚDE, 2012). Dentre os principais métodos utilizados para a detecção da cárie, o exame visual é considerado o padrão-ouro e pode ser realizado com auxílio de sondas de ponta romba, assim como de exames complementares, sendo o exame radiográfico o mais utilizado.

Clinicamente, a cárie dentária pode apresentar lesões de diferentes aspectos, de acordo com seu estágio de desenvolvimento, e, portanto, demandar diferentes tipos de intervenções (OMS, 2013). As manchas brancas iniciais, consideradas lesões reversíveis, são passíveis de inativação através de procedimentos não-invasivos de prevenção (PITTS *et al.*, 2019). As cavidades, por outro lado, como há perda de estrutura dentária, requerem procedimentos operatórios de média à alta complexidade, dependendo da profundidade da lesão.

A importância do diagnóstico de lesões cáries em seus diferentes estágios justifica a necessidade de criar soluções alternativas de diagnósticos, não só de baixo custo, mas também alternativas que superem as subjetividades inerentes a diferentes examinadores, melhorando a acurácia do exame clínico e, conseqüentemente, decisões de tratamento mais adequadas, com conseqüente benefício à saúde e bem-estar do paciente. Abordagens de diagnósticos baseados em reconhecimento de padrões em imagens, utilizando conceitos de inteligência artificial e aprendizagem de máquina, têm sido alvos de estudos recentes e podem ser ferramentas auxiliares ao diagnóstico da doença, especialmente em regiões em que há escassez de recursos.

2. Fundamentação Teórica

A aprendizagem de máquina é uma ramificação dentro do escopo da inteligência artificial que aplica algoritmos para sintetizar relações entre dados e informações, permitindo que um programa de computador extraia conhecimento a partir de experiências acumuladas na resolução de problemas anteriores (MONARD; BARANAUSKAS, 2003). Assim que obtido o conhecimento necessário, o objetivo dos programas de aprendizagem de máquina é o de prever eventos ou cenários que até então são desconhecidos (AWAD; KHANNA, 2015).

Pelo fato da capacidade desses modelos de aprendizagem de máquina de conseguir caracterizar grandes matrizes de dados e aprender a partir de exemplos, já existem diversas aplicações em problemas reais. Este trabalho estende uma das vertentes de aplicabilidade desses algoritmos de aprendizagem de máquina que, desde o final dos anos 90, têm ganhado cada vez mais notoriedade: a análise de imagens na área da saúde para auxiliar o diagnóstico (LITJENS *et al.*, 2017).

2.1. Redes Neurais Convolucionais

O surgimento das Redes Neurais Convolucionais (RNC) está intrinsecamente relacionado ao surgimento das Redes Neurais Artificiais – partindo da premissa de simular o cérebro humano a partir da construção de um neurônio artificial – e é um tipo específico de rede que é muito mais fácil de ser treinada e obtém uma generalização melhor (LECUN; BENGIO; HINTON, 2015).

As RNCs utilizam o conceito de autoaprendizagem, sendo capazes de aprenderem as representações a partir dos dados brutos, dispensando assim a utilização de extratores de características manuais. Além disso, são projetadas para lidar com dados que vêm na forma de várias matrizes, como por exemplo imagens coloridas compostas por três matrizes de 2D (duas dimensões) de intensidade de *pixels* nos três canais de cores RGB manuais (LECUN; BENGIO; HINTON, 2015). A Figura 1 apresenta um esquema dos estágios e camadas de uma rede neural convolucional, demonstrando que cada tipo de camada possui uma função específica na transmissão do sinal de entrada. As principais

camadas presentes em uma RNC são as camadas convolucionais, agregação e camadas totalmente conectadas.

A etapa de extração de características aprende a identificar traços genéricos e que sejam úteis para uma determinada tarefa alvo. Além disso, as camadas que compõe essa etapa conseguem extrair características que não mudam mesmo com a rotação de objetos bidimensionais, graças a sua estrutura que utiliza camadas convolucionais com filtros, ativações e agregações (DARTORA, 2018). Por outro lado, na etapa de classificação, as camadas totalmente conectadas empregam as características locais extraídas e armazenadas em vetores de características, para realizar a classificação da entrada na rede usando um algoritmo de aprendizado de máquina (DARTORA, 2018), com o objetivo de descobrir conjuntos de matrizes que sejam capazes de extrair características distintivas e úteis para classificar imagens, suprimindo variações irrelevantes nesse processo (LECUN; BENGIO; HINTON, 2015).




Figura 1. Estágios e Camadas de uma Rede Neural Convolucional. FONTE: Adaptado de Kategaru (2020).

3. Trabalhos Correlatos

Silva (2021) buscou detectar e classificar lesões de cáries dentárias utilizando dois algoritmos de detecção de objetos em tempo real: YOLOv3 e YOLOv4. A utilização desses modelos permite delimitar uma região de interesse nas imagens, realçando uma possível cárie para que seja analisada com maior atenção. Os melhores valores obtidos, para a YOLOv4, incluem precisão 0,75; sensibilidade 0,8 e *F1-score* 0,78.

4. Metodologia

Este estudo utilizou imagens a partir de superfícies oclusais de dentes extraídos provenientes do Banco de Dentes Humanos (BDH), vinculados ao Curso de Odontologia da Universidade Federal do Paraná (UFPR) e ao Curso de Odontologia da Universidade Estadual de Ponta Grossa (UEPG). O exame clínico foi realizado por três examinadores calibrados ($Kappa \geq 0,8133$), sendo a classificação final do índice averiguada por um quarto examinador (examinador de referência). Os dados foram tabulados no *software* SPSS (versão 20.0 IBM, Brasil). As imagens foram obtidas por meio da câmera Canon EOS Rebel T61®, com *flash* Canon Macro Ring Lite MR-14ex® e lente macro Ultrasonic®.

A primeira etapa de processamento das imagens recebidas consistiu em realizar o procedimento de corte da região do dente no banco de imagens. Por outro lado, uma vez que todas as imagens tiveram a região do dente delimitada, parte das imagens foram separadas para testes e, no restante, foi executado o procedimento de *data augmentation*, um método que aumenta artificialmente o tamanho do conjunto de treinamento original,

aplicando transformações que preservam as classes (MONSHI *et al.*, 2021). As técnicas utilizadas desse procedimento incluem: rotação, redimensionamento, espelhamento (horizontal e vertical), aplicação de *zoom*, ajuste de nitidez e ajuste de saturação. A Figura 2 apresenta algumas imagens de dentes extraídos que serão utilizadas neste estudo.




Figura 2. Imagens de dentes extraídos. Em a) superfície oclusal hígida e em b) superfícies oclusais dentárias com diferentes estágios de lesões cariosas.

A Tabela 1 apresenta a disposição das imagens utilizadas neste estudo separadas em duas classes: “hg” (ou hígido), classe de superfícies oclusais de dentes saudáveis, sem nenhum indício de lesão de cárie dentária; e “cárie”, contendo imagens de diferentes níveis de lesões cariosas oclusais dentárias. Destaca-se que os valores contidos na Tabela são posteriores ao procedimento de *data augmentation* na base de treinamento e validação. A fim de comparação, o banco original de imagens continha 701 dentes da classe “hg” e 4.859 dentes da classe “cárie”.

Tabela 1. Configuração da Base de Dados

Classe	Base de Treinamento			Base de Testes	Total Geral
	Treinamento	Validação	Total		
hg	3.728	825	4.553	198	4.751
cárie	17.551	3.987	21.538	283	21.521
Total Geral	21.279	4.812	26.091	481	26.572

As RNCs testadas para a classificação do problema proposto incluem: a) ResNet18; b) ResNet34; c) ResNet50; d) AlexNet; e) VGG16; f) VGG19; e g) DenseNet121. Durante o treinamento das RNCs propostas neste estudo, diversas configurações de parâmetros de treinamento foram testadas. Os atributos da melhor configuração de treinamento encontrada incluem: a) Utilização da etapa de transferência de aprendizagem, carregando os pesos ajustados das redes do domínio original do problema para resolver um outro domínio; b) Embaralhamento dos dados de treinamento, impedindo que as redes tendessem a classificar melhor a última classe apresentada; c) Taxa de aprendizagem de 0,001, que decai a uma taxa de 0,1 a cada 5 iterações; d) Função de perda: entropia cruzada; e e) Otimizador SGD (*Stochastic Gradient Descent*), com taxa de *momentum* fixa em 0,9.

5. Resultados Preliminares

A Tabela 2 apresenta os principais resultados das métricas avaliadas para a melhor configuração das redes proposta referente à aplicação dos modelos de RNCs propostos no banco de teste, que contém imagens que não foram vistas pelas redes durante o treino e validação. A coluna “Época” corresponde ao momento, durante o treinamento, em que

a RNC obteve menor valor de *loss* (quanto menor o valor, melhor é o modelo). Ao examinar os resultados da Tabela 2, em termos de acurácia, a RNC que apresentou melhores valores foi a ResNet50, com acurácia de 92,10%; precisão 0,915; sensibilidade 0,954; especificidade 0,874 e *F1-score* 0,934.

Tabela 2. Resultados das métricas avaliadas para cada classificador

RNC	Época	Acurácia (%)	Precisão	Sensibilidade	Especificidade	F1-score
Resnet18	24	90,02	0,880	0,961	0,813	0,919
Resnet34	3	90,44	0,881	0,968	0,813	0,923
Resnet50	4	92,10	0,915	0,954	0,874	0,934
AlexNet	6	91,68	0,904	0,961	0,854	0,932
VGG16	4	90,44	0,879	0,972	0,808	0,923
VGG19	1	90,64	0,884	0,968	0,818	0,924
DenseNet121	1	91,48	0,901	0,961	0,848	0,930

Por apresentar, majoritariamente, os melhores resultados, e por questão de brevidade, a Figura 3 apresenta algumas medidas para avaliar a eficiência das redes. Em a) é apresentado os valores de acurácia e *loss* para a ResNet50 durante o treinamento do modelo e em b) é apresentada a matriz de confusão para essa mesma rede.

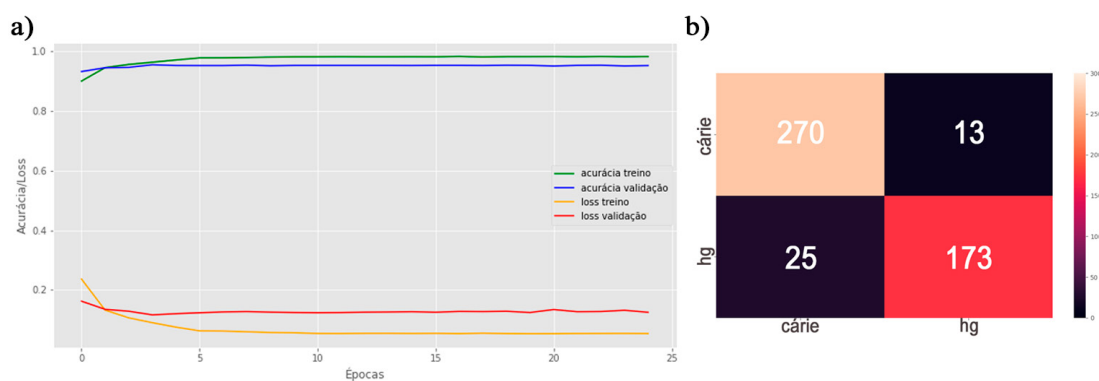


Figura 3. Avaliação da rede ResNet50. a) Acurácia e Loss durante o treinamento e b) Matriz de Confusão

Analisando os dados presentes na Tabela 2, bem como a Figura 3 a), é possível perceber que a ResNet50 – assim como os outros modelos – se ajustou fortemente aos dados de treinamento, aprendendo a representá-los de maneira precisa, o que é um indício de *overfitting*. Esse fato é corroborado pela relativa estabilidade nos valores de acurácia e *loss* à medida em que a rede é submetida a mais iterações durante o treinamento, indicando que a partir de um determinado ponto, o modelo parou de aprender a distinguir as diferenças subjetivas entre as duas classes do problema proposto.

Por outro lado, a Figura 3 b) mostra que a Resnet50 classificou 270 imagens corretamente como cárie (Verdadeiro Positivo - VP), 173 imagens hígdos corretamente (Verdadeiro Negativo – VN), 13 imagens de dentes com cárie como hígdos (Falso Negativo – FN) e 25 imagens de dentes hígdos como cariadados (Falso Positivo – FP). Ao analisar os FNs e FPs notou-se que as confusões ocorreram por conta de manchas nos dentes e/ou baixo grau de lesão cariada dentária, o que dificulta a diferenciação entre dentes hígdos e cariadados.

6. Considerações Finais

Este trabalho apresentou uma análise comparativa de diferentes redes neurais convolucionais para a identificação de lesões cariosas em superfícies oclusais dentárias. As redes selecionadas para essa atividade, apesar de entrarem em *overfitting* ao longo do treinamento, apresentaram resultados satisfatórios no que se refere à discriminação do dente com superfície hígida daquele com superfície cariada independente do estágio da lesão cariada.

Referências

- AWAD, M; KHANNA, R. Machine Learning. In: Efficient Learning Machines: Theories, Concepts and Applications for Engineers and System Designers. 1ª ed. Apress Open, 2015. p-1-18.
- DARTORA, A. Reconhecimento Automático De Padrões Radiológicos Utilizando Aprendizado Profundo. 2018. 73 p. Universidade Federal do Paraná, Curitiba, 2018. Disponível em: <https://acervodigital.ufpr.br/handle/1884/57977>.
- KATEGARU, Swapna. Convolutional Neural Network | Deep Learning. Developers Breach. 2020. Disponível em: <https://developersbreach.com/convolution-neural-network-deep-learning/>.
- LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep Learning. Nature. v. 521, p.436–444, mai. 2015. Disponível em: <https://www.nature.com/articles/nature14539>.
- LITJENS, Geert et al. A survey on deep learning in medical image analysis. Medical Image Analysis. v. 42. p.60-88, jul. 2017. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1361841517301135>.
- MINISTÉRIO DA SAÚDE. Pesquisa Nacional de Saúde Bucal: Resultados Principais. Brasília, DF: Ministério da Saúde, 2012.
- MONARD, M.C; BARANAUSKAS; J.A. Conceitos sobre Aprendizado de Máquina. In: Sistemas inteligentes: Fundamentos e Aplicações. Editora Manole, 2003. p-39-56.
- MONSHI, M et al. CovidXrayNet: Optimizing data augmentation and CNN hyperparameters for improved COVID-19 detection from CXR. Science Direct. v.133, jun 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0010482521001694>.
- NIGEL, B.P. et al. Dental Caries. Nature Reviews Disease Primers. v.3, no. 17030, Mai. 2017. Disponível em: <https://www.nature.com/articles/nrdp201730>.
- ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS). Oral health surveys: basics methods. 5th ed. Geneva: World Health Organization, 2013.
- PITTS, N. B. et al. Early Childhood Caries: IAPD Bangkok Declaration. Journal of dentistry for children, Chicago, v.86, n.2, p. 72, 2019.
- PITTS, N.B et al. Dental Caries. Nature Reviews Disease Primers. v.3, no. 17030, Mai. 2017. Disponível em: <https://www.nature.com/articles/nrdp201730>.
- SILVA, C.L.F. (2021) Análise Comparativa de Modelos de Redes Neurais Convolucionais YOLO na Detecção e Classificação de Lesões Cariadas Dentárias. (Monografia de Graduação). Universidade Federal do Paraná. Curitiba.