

## INTELIGÊNCIA ARTIFICIAL COMO ARTIFÍCIO NO DIAGNOSTICO PRECOCE DE DOENÇAS ORAIS: UMA REVISÃO DE LITERATURA

**Adrielle Marques de Brito**

Discente – Centro Universitário Fametro – Unifametro

[adrielle.brito@aluno.unifametro.edu.br](mailto:adrielle.brito@aluno.unifametro.edu.br)

**Dayane Vitória Tamboril de Andrade**

Discente – Centro Universitário Fametro – Unifametro

[dayane.andrade01@aluno.unifametro.edu.br](mailto:dayane.andrade01@aluno.unifametro.edu.br)

**Victória Melo da Silva**

Discente – Centro Universitário Fametro – Unifametro

[victoria.silva03@aluno.unifametro.edu.br](mailto:victoria.silva03@aluno.unifametro.edu.br)

**Karla Geovanna Ribeiro Brígido**

Docente – Centro Universitário Fametro – Unifametro

[karla.brigido@unifametro.professor.edu.br](mailto:karla.brigido@unifametro.professor.edu.br)

**Jandenilson Alves Brígido**

Docente – Centro Universitário Fametro – Unifametro

[jandenilson.brigido@professor.unifametro.edu.br](mailto:jandenilson.brigido@professor.unifametro.edu.br)

**Área Temática:** Clínica Odontológica, Odontologia Restauradora e Reabilitadora

**Área de Conhecimento:** Ciências da Saúde

**Encontro Científico:** XII Encontro de Iniciação à Pesquisa

### RESUMO

**Introdução:** Dada a alta prevalência de doenças orais, incluindo as incapacitantes e agressivas o diagnóstico precoce torna-se um fator determinante do sucesso do tratamento. Neste cenário a Inteligência Artificial pode ser usada como auxiliar deste diagnóstico. **Objetivo:** Analisar o uso da Inteligência Artificial bem como suas ferramentas como artifício auxiliar no diagnóstico precoce das diversas doenças orais, através de uma revisão de literatura. **Métodos:** Trata-se de uma revisão de literatura, e para seu desenvolvimento foram coletados trabalhos nas bases de dados PubMed, Biblioteca Virtual de Saúde (BVS) e EBSCOhost, com os descritores “Artificial Intelligence”, “Early Diagnosis” e “Mouth Diseases”, publicados de 2014 a 2024, resultando treze artigos ao final. **Resultados:** As diversas formas de Inteligência Artificial se mostraram capazes de prever e precisar o diagnóstico de algumas patologias orais, como o câncer oral e periodontite, a partir de diferentes insumos de treinamento, principalmente usando Redes Neurais Artificiais (RNA). **Considerações finais:** Conclui-se que a ampla variedade de aplicações de sistemas de aprendizado de máquina permite o diagnóstico precoce, mas faz-se necessário mais estudos a fim de confirmar esses resultados, e para que a aplicação das IAs abarque cada vez mais alterações orais, auxiliando assim no diagnóstico odontológico mais rápido, não substituindo o cirurgião-dentista, mas o amparando e auxiliando na tomada de decisões.

**Palavras-chave:** Inteligência artificial; Diagnóstico Precoce; Doenças da Boca.

## INTRODUÇÃO

As doenças orais são de forma simplificada definidas como condições que afetam os tecidos da cavidade oral, havendo uma vastidão destas patologias. Qualificadas como um problema de saúde pública devido à grande prevalência e incidência em todas as regiões do mundo, elas impactam em dor e sofrimento que prejudicam o funcionamento do corpo humano e afetam a qualidade de vida (Petersen et al., 2005; Petersen, 2008).

Dada a prevalência e variedade destas condições, inclusive das capazes de causar sequelas permanentes e morte quando não diagnosticadas e tratadas a tempo, após sofrer transformações malignas, originadas de tecidos morfológicamente alterados (Silva et al., 2011), a prevenção e o diagnóstico precoce são as medidas mais eficazes para melhorar o prognóstico, e aumentar as taxas de sobrevivência. (Leôncio et al., 2015) Como por exemplo no câncer oral onde a detecção precoce levará a uma redução de 70% na taxa de mortalidade (Erickson et al., 2018).

Então, é neste cenário que a Inteligência Artificial (IA) pode ser usada como artifício auxiliar no diagnóstico precoce de patologias orais incapacitantes presentes na Odontologia. Ao longo dos anos, a IA mudou a forma como ela é praticada, com diagnósticos baseados em computadores e aplicações radiológicas, ganhando um impulso enorme, a IA conecta-se à odontologia em uma perspectiva abrangente, devido à necessidade de procedimentos e tratamentos precisos e troca instantânea de informações (Mazzochi, 2020).

Abrangido pela IA, um dos setores mais aprofundados é o aprendizado de máquina (machine learning), método que possibilita a identificação de padrões por técnicas de classificação com base em casos e experimentos anteriores, prevendo os valores de saída (Bini, 2018) assim como acontece com a inteligência humana (Erickson, 2017). Ainda dentro do machine learning são compreendidos algoritmos como redes neurais artificiais (RNA), que são inspiradas no cérebro humano tendo capacidade de aprender e de se adaptar, capazes de reconhecer semelhanças quando apresentada para um novo padrão de entrada resultando num padrão de saída previsto (Haykin, 2001). As RNA têm demonstrado funcionar bem para fins de diagnóstico, em vários estudos o diagnóstico dado por um cirurgião-dentista e comparado com o obtido pela RNA, resultou em alta especificidade e sensibilidade da RNA.

Também é importante que sejam definidos termos como: Aprendizado Profundo (Deep Learning) que é o campo do aprendizado de máquina que tenta modelar uma extensa quantidade de dados utilizando várias camadas de processamento, que recentemente permitiram a avaliação automatizada de imagens médicas para gerar diagnóstico e prognóstico (Haider,

2020). O aprendizado profundo fornece classificação precisa e excede o nível humano de classificação para um conjunto de dados de imagem muito grande (Dey et al. 2017).

Ao decorrer das últimas décadas, inúmeras aplicações na área da saúde tiveram grandes avanços científicos através de técnicas e tecnologias cada vez mais recentes e sofisticadas. Contribuindo em grande escala para a solução de problemas e geração de melhores condições de trabalho para os profissionais da área, logo, maior qualidade de vida para os pacientes (Neto, 2020). O uso de métodos de IA para análise de imagens pode potencialmente fornecer uma abordagem prática, de baixo custo e universal para detecção precoce de doenças orais (Ilhan et al., 2020; Kar et al., 2020; Thankappan et al., 2020; Van der Waal, 2018)

Diante do exposto, esse trabalho teve como objetivo analisar o uso da Inteligência Artificial, bem como suas ferramentas, como artifício auxiliar no diagnóstico precoce das diversas doenças orais, por meio de uma revisão de literatura.

## **METODOLOGIA**

O presente estudo se refere a uma revisão de literatura, e para sua execução foi realizada busca nas bases de dados: PubMed, Biblioteca Virtual de Saúde (BVS) e EBSCOhost, utilizando os descritores “Artificial Intelligence”, “Early Diagnosis” e “Mouth Diseases”, assim como seus termos alternativos, em um recorte temporal dos últimos 10 anos (2014-2024).

Resultando em 149 trabalhos encontrados, após leitura de títulos e resumos e aplicados os critérios de inclusão, que foram: estudos publicados entre 2014 e 2024; estudos nos idiomas português e inglês; estudos clínicos, analíticos, descritivos, estudos de coorte e estudos investigativos, selecionaram-se 58. Então, aplicaram-se os critérios de exclusão: artigos incompletos, de acesso não disponível, artigos duplicados, estudos que não se apresentaram pertinentes ao tema, estudos de revisão narrativa, além de teses, dissertações e monografias, restando 24 estudos. Ao final, houve leitura integral e manteve-se 13 trabalhos para o desenvolvimento da presente revisão.

## **RESULTADOS E DISCUSSÃO**

A presente revisão constou com levantamento bibliográfico feito em um recorte temporal de 10 anos, restando 13 artigos a fim de embasá-la, abaixo a Tabela 1 mostra os resultados obtidos, de acordo com os autores, ano de publicação, objetivo, conjunto de dados, objeto de treinamento, quando aplicável, tipo de Inteligência Artificial usada, e principais achados dos trabalhos eleitos.

**Tabela 1. Resultados dos estudos selecionados.**

<b>AUTOR/ ANO /</b>	<b>OBJETIVOS</b>	<b>DOENÇA BUCAL / TIPO DE IA</b>	<b>PRINCIPAIS ACHADOS</b>
Sharma; Om (2015)	Projetar um modelo de mineração de dados usando rede neural probabilística e rede neural de regressão geral (PNN/GRNN) para detecção precoce e prevenção de malignidade oral.	Câncer Oral / Aprendizado de Máquina – ML (RNAs)	Classificação entre maligno e benigno: precisão de 99,02%. Classificação do tipo de malignidade: maior que 92% nos dois conjuntos de dados. O desempenho do modelo para predição do estágio: total de 86,83% para os dois conjuntos. A precisão geral do modelo para prever a sobrevivência usando 14 atributos é de 69,95%.
Jeyaraj e Nadar (2018)	Desenvolver um algoritmo de aprendizado profundo para um sistema automatizado de detecção de câncer oral auxiliado por computador, investigando imagens hiperespectrais do paciente.	Câncer Oral / Aprendizado de Máquina - ML (Rede Neural Convolutiva – CNN)	Classificação de tumores malignos ou benignos: precisão de 91,4%. Enquanto, SVM 82,4% e para o DBN 84,5%. Classificação de tumor maligno e tumor pré-canceroso: 91,56% de precisão. Enquanto 85,5% para SVM e 87,2% para DBZ. Aumento na precisão em 4,5% usando muitos conjuntos de dados de indivíduos com câncer para a fase de treinamento para 500 conjuntos de dados de imagem obtidos.
Sunny et al (2019)	Explorar a utilidade/eficácia clínica de um sistema de telecitologia em combinação com um modelo de estratificação de risco baseado em Rede Neural Artificial (RNA).	Lesões malignas/potencialmente malignas orais (OPML) / Aprendizado de Máquina – ML (RNA)	Precisão geral de 84–86% na detecção de lesões orais. OPML detectado com baixa sensibilidade (18%). Agregando processamento de imagem e o modelo forneceu precisão 93% nas lesões malignas e 73% nas OPML de alto grau. Precisão geral em 30%.
Chan et al (2019)	Desenvolver uma rede neural convolutiva profunda inovadora (DCNN) combinada com mapa de textura para detectar regiões cancerosas e marcar o ROI em um único modelo automaticamente	Câncer Oral / Aprendizado de Máquina – ML (RNA, CNN)	No resultado experimental, a sensibilidade e especificidade médias de detecção são de até 0,9687 e 0,7129, respectivamente, com base na transformada wavelet. E a sensibilidade e especificidade médias de detecção são de até 0,9314 e 0,9475, respectivamente, com base no filtro Gabor
McRae et al (2019)	Desenvolver uma Point-of-Care Oral Cytology Tool (POCOCT) - ferramenta de citologia oral no ponto de atendimento	Lesões Orais Potencialmente Malignas (OPML) / Aprendizado de Máquina - ML	Os fenótipos foram determinados com precisão de (99,3%) por meio do ensaio citológico automatizado e da abordagem ML. Os algoritmos clínicos resultaram em características de desempenho aceitáveis (área sob a curva de 0,81 para displasia benigna vs. leve e 0,95 para benigna vs. maligna).
Jubair et al (2020)	Desenvolver uma CNN leve e profunda capaz de diferenciar lesões orais entre benignas malignas e potencialmente malignas a partir de um conjunto de imagens clínicas.	Câncer Oral / Aprendizado de Máquina - ML (Rede Neural Convolutiva – CNN)	EfficientNet-B0, apresentou precisão média de 85%, a especificidade média de 84,5% e a sensibilidade média de 86,7%. A CNN desenvolvida poderá ser usada como aplicativo, prático e de baixo custo para detecção precoce de câncer oral.
Farhadia; Shokouhi; Torkzaban (2020)	Projetar um sistema de suporte à tomada de decisão baseado em máquina de vetor de suporte (SVM) para diagnosticar várias doenças periodontais.	Periodontite / Aprendizado de Máquina - ML (SVM - Máquina de Vetores de Suporte)	O modelo de classificação SVM baseado na função kernel radial teve melhor desempenho, com precisão geral de classificação correta de 88,7%. A classificação correta da categoria para gengivite foi de 96,0%, para periodontite localizada foi de 64,0% e para periodontite generalizada foi de 92,2%.
Alalharith et al (2020)	Desenvolver e avaliar as técnicas de detecção e reconhecimento de objetos de última geração e algoritmos de aprendizagem profunda para detecção automática de doença intraorais.	Gengivite / Aprendizado Profundo - DL	Modelo de detecção de dentes baseado no Faster R-CNN 100% de acurácia, na detecção de dentes em imagens IO, 100% de precisão, 51,85% de recall e 100% de mAP. Detecção de inflamação: acurácia: 77,12%, precisão: 88,02%, recall: 41,75% e mAP: 68,19%.
Alabi et al (2021)	Fornecer uma revisão sistemática da aplicação diagnóstica e prognóstica do aprendizado de máquina no carcinoma espinocelular oral	Carcinoma espinocelular oral / Aprendizado de Máquina - ML	41 estudos publicados. A maioria usou os algoritmos SVM e RNA como técnicas de aprendizado de máquina. Sua especificidade variou de 0,57 a 1,00, sensibilidade de 0,70 a 1,00 e precisão de 63,4% a 100,0% nesses estudos. Modelos apresentando

	(CEO).		desempenhos promissores para análises diagnósticas e prognósticas em CEO.
Zhang et al (2022)	Rastrear potenciais biomarcadores relacionados ao estresse do retículo endoplasmático (ERS) de periodontite usando métodos de aprendizado de máquina e explorar sua relação com células imunes.	Periodontite / Aprendizado de Máquina – ML (LASSO e SVM-RFE)	36 genes diferencialmente expressos (DEGs) de periodontite relacionados a ERS do conjunto de treinamento. 11 DEGs principais foram rastreados. SERPINA1, ERLEC1 e VWF apresentaram altos valores diagnósticos. Esses 03 genes: SERPINA1, ERLEC1 e VWF, apresentaram-se com potencial de biomarcador para periodontite.
Warin et al (2022)	Avaliar o desempenho de algoritmos de CNN para a classificação e detecção de distúrbios potencialmente malignos orais (OPMDs) e carcinoma espinocelular oral (OSCC).	Distúrbios potencialmente malignos orais (OPMDs) e carcinoma espinocelular oral (OSCC) / Aprendizado de Máquina – ML (Algoritmos de CNN)	As melhores AUC (área sob a curva) da classificação: DenseNet-196, foi de 1,00 e 0,98 em OSCC e OPMDs. A AUC dos melhores modelos de detecção de objetos baseados em CNN multiclasse: Faster R-CNN, foi de 0,88 e 0,64 em OSCC e OPMDs. Em comparação, o DenseNet-196 produziu o melhor desempenho de classificação de imagem multiclasse com AUC de 1,00 e 0,98 em OSCC e OPMD. Equiparáveis a especialistas e superiores aos de clínicos gerais
Gu et al (2023)	Construir um modelo de ML para predição do desenvolvimento de SCCOT dentro de um período de 5 anos com base nos níveis de proteínas plasmáticas.	Carcinoma espinocelular da língua oral (SCCOT) / Aprendizado de Máquina – ML	22 proteínas foram identificadas como importantes. A previsão do SVM forneceu o melhor equilíbrio de precisão (sensibilidade: 0,867, especificidade: 0,859, precisão balanceada: 0,863). 03 principais contribuintes para a previsão foram a interleucina 10, o fator 2 associado ao receptor de TNF e a peptídeo relacionada à calicreína 12.
Soni et al (2024)	Utilizar avanços recentes em aprendizado profundo para classificação de imagens médicas para automatizar o diagnóstico precoce de imagens de histopatologia oral, facilitando assim a detecção rápida e precisa do câncer oral.	Carcinoma espinocelular oral / Aprendizado Profundo - DL	Entre 17 modelos de CNN o modelo EfficientNetB0 aprimorado, demonstrou precisão de 91,1%, sensibilidade de 92,2%, especificidade de 91,0%, precisão de 91,3%, taxa de falsos positivos (FPR) de 1,12%. Superando o desempenho de abordagens de última geração no campo.

Fonte: Autores

O diagnóstico adequado é primordial no sucesso do tratamento de qualquer doença, sobretudo nas mais complexas, como o câncer oral, no modelo desenvolvido por Sharma e Om (2015), baseado em mineração de dados e no uso de uma RNA, a IA conseguiu classificar os casos entre malignos e benignos com uma precisão de 99,02%, predizendo qual o tipo de malignidade com precisão de 92% tanto no conjunto de treinamento quanto no conjunto de validação.

Jeyaraj e Nadar (2018), também visando desenvolver um algoritmo para detecção automática do câncer, projetaram uma Rede Neural Convolutiva Profunda Particionada para o sistema automatizado auxiliado por computador. O seu desempenho foi verificado pela precisão da classificação. Obteve-se precisão por esse algoritmo particionado de 94,5%, com especificidade de 98% e sensibilidade de 94%.

A precisão destes sistemas de detecção também foi vista na pesquisa de Sunny e colaboradores (2019), onde seu sistema de telecitologia combinado com um modelo de

estratificação de risco baseado em RNA, mostrou precisão variada de 84% a 86% na detecção de lesões orais. No entanto, lesões potencialmente malignas foram detectadas com baixa sensibilidade, e a previsão geral do modelo girou em torno de 30%, desta maneira a plataforma avaliada no estudo mostrou-se eficaz para o diagnóstico remoto, uma vez que poderia reter com sucesso características de valor diagnóstico.

Chan et al (2019) relatou que quase metade de todos os cânceres orais não são diagnosticados até o estágio III ou IV. Para solucionar esse problema, o estudo apresentou uma rede neural convolucional profunda combinada com mapa de textura para rastreamento e detecção de câncer bucal. Os resultados confirmaram que o modelo fornece uma boa capacidade de marcar automaticamente as regiões de alto risco e, portanto, fornece uma ferramenta útil para a triagem do câncer de boca, pois identifica com precisão imagens clínicas.

Além das CNN, outro método de Aprendizado de Máquina empregado é a Máquina de Vetores de Suporte (SVM), usado em um sistema para diagnosticar problemas periodontais, essa IA quando baseada na função kernel radial, conseguiu precisar a classificação destas patologias em 88,7%, classificando corretamente os casos de gengivite em 96% dos casos, periodontite localizada em 64% e periodontite generalizada em 92,2%, mostrando desempenho aceitável na predição de doença periodontal, facilitando o processo diagnóstico, útil para dentistas de pouca experiência (Farhadian; Shokouhi; Torkzaban, 2020).

Dada a prevalência do carcinoma espinocelular oral (CEO), Gu et al (2023) e Soni et al (2024), aplicaram Inteligência Artificial para diagnóstico precoce, em modelos que respectivamente empregaram reconhecimento de proteínas plasmáticas e classificação de imagens de histopatologia oral, para detecção por meio de máquina. No sistema desenvolvido por Gu e colaboradores, 22 proteínas foram identificadas como importantes, com destaque para 03 principais contribuintes para a previsão do desenvolvimento de carcinoma espinocelular de língua, dando precisão geral de 86,3% para predição do câncer.

Por fim, em revisão sistemática realizada por Alabi et al. (2021), demonstrou-se que a maioria dos estudos utiliza SVM e RNA como técnicas de machine learning, com precisão que varia de 63,4% a 100%.

## CONSIDERAÇÕES FINAIS

Frente ao exposto, é claro o crescente uso da Inteligência Artificial, em suas mais diversas abordagens na Odontologia diagnóstica. Após análise dos estudos vê-se que a ampla variedade de aplicações de sistemas de aprendizado de máquina permite o diagnóstico precoce

uma vez que, as análises podem ser feitas a partir de diferentes insumos, sejam fotografias orais, seja rastreamento de biomarcadores, nas mais diversas patologias orais.

Há uma grande gama de estudos que envolvem o uso de RNAs na detecção precoce do câncer oral, demonstrando precisão de identificação acima dos 90%, no entanto, é necessário que a aplicação desses métodos seja empregada também na predição de outras doenças bucais.

## REFERÊNCIAS

ALABI, Rasheed Omobolaji et al. Machine learning in oral squamous cell carcinoma: Current status, clinical concerns and prospects for future—A systematic review. **Artificial intelligence in medicine**, v. 115, p. 102060, 2021.

ALALHARITH, Dima M. et al. A deep learning-based approach for the detection of early signs of gingivitis in orthodontic patients using faster region-based convolutional neural networks. **International Journal of Environmental Research and Public Health**, v. 17, n. 22, p. 8447, 2020.

BINI, Stefano A. Artificial intelligence, machine learning, deep learning, and cognitive computing: what do these terms mean and how will they impact health care?. **The Journal of arthroplasty**, v. 33, n. 8, p. 2358-2361, 2018.

CHAN, Chih-Hung et al. Texture-map-based branch-collaborative network for oral cancer detection. **IEEE transactions on biomedical circuits and systems**, v. 13, n. 4, p. 766-780, 2019.

DEY, D. et al. A deep learning framework using convolution neural network for classification of impulse fault patterns in transformers with increased accuracy. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 24, n. 6, p. 3894-3897, 2017.

DO NASCIMENTO NETO, Conrado Dias et al. Inteligência artificial e novas tecnologias em saúde: desafios e perspectivas. **Brazilian Journal of Development**, v. 6, n. 2, p. 9431-9445, 2020.

ERICKSON, Bradley J. et al. Deep learning in radiology: does one size fit all?. **Journal of the American College of Radiology**, v. 15, n. 3, p. 521-526, 2018.

ERICKSON, Bradley J. et al. Machine learning for medical imaging. **radiographics**, v. 37, n. 2, p. 505-515, 2017.

FARHADIAN, Maryam; SHOKOUHI, Parisa; TORKZABAN, Parviz. A decision support system based on support vector machine for diagnosis of periodontal disease. **BMC Research Notes**, v. 13, p. 1-6, 2020.

GU, Xiaolian et al. Early detection of squamous cell carcinoma of the oral tongue using multidimensional plasma protein analysis and interpretable machine learning. **Journal of Oral Pathology & Medicine**, v. 52, n. 7, p. 637-643, 2023.

HAIDER, Stefan P. et al. Applications of radiomics in precision diagnosis, prognostication and treatment planning of head and neck squamous cell carcinomas. **Cancers of the head & neck**, v. 5, p. 1-19, 2020.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Bookman Editora, 2001.

ILHAN, B. et al. Improving oral cancer outcomes with imaging and artificial intelligence. **Journal of dental research**, v. 99, n. 3, p. 241-248, 2020.

JEYARAJ, Pandia Rajan; SAMUEL NADAR, Edward Rajan. Computer-assisted medical image classification for early diagnosis of oral cancer employing deep learning algorithm. **Journal of cancer research and clinical oncology**, v. 145, p. 829-837, 2019.

JUBAIR, Fahed et al. A novel lightweight deep convolutional neural network for early detection of oral cancer. **Oral Diseases**, v. 28, n. 4, p. 1123-1130, 2022.

KAR, Ankita et al. Improvement of oral cancer screening quality and reach: The promise of artificial intelligence. **Journal of Oral Pathology & Medicine**, v. 49, n. 8, p. 727-730, 2020.

MAZZOCHI, Ana Caroline Debastiani. Inteligência artificial: um conceito futurista no diagnóstico odontológico. 2020.

MCRAE, Michael P. et al. Point-of-care oral cytology tool for the screening and assessment of potentially malignant oral lesions. **Cancer cytopathology**, v. 128, n. 3, p. 207-220, 2020.

PETERSEN, P. E. et al. The global burden of oral diseases and risks to oral health Bulletin of the World Health Organization, **Geneve**, v. 83, n. 9, p. 661-669, sep. 2005.

PETERSEN, PE. World Health Organization global policy for improvement of oralhealth-World Health Assembly 2007. **International Dental Journal**, London, v. 58, p. 115-121, 2008.

SHARMA, Neha; OM, Hari. Usage of probabilistic and general regression neural network for early detection and prevention of oral cancer. **The Scientific World Journal**, v. 2015, n. 1, p. 234191, 2015.

SILVA, Uoston Holder da; ARAÚJO, Djaíra Leitão de; SANTANA, Elisabeth Barros de. Ocorrência de estomatite protética e queilite actínica diagnosticadas no centro de especialidades odontológicas da faculdade ASCES, Caruaru-PE. **Odontologia Clínica-Científica (Online)**, v. 10, n. 1, p. 79-83, 2011.

SONI, Aradhana et al. Enhancing oral squamous cell carcinoma detection: a novel approach using improved EfficientNet architecture. **BMC Oral Health**, v. 24, n. 1, p. 601, 2024.

SUNNY, Sumsum et al. A smart tele-cytology point-of-care platform for oral cancer screening. **PloS one**, v. 14, n. 11, p. e0224885, 2019.

THANKAPPAN, Krishnakumar et al. Oral cancer screening using mobile phone-based (mHealth) approach versus conventional oral examination approach, protocol of a cluster randomized study with cost-effectiveness analysis. **International Journal of Surgery Protocols**, v. 23, p. 1-5, 2020.

VAN DER WAAL, I. Skin cancer diagnosed using artificial intelligence on clinical images. **Oral diseases**, v. 24, n. 6, 2018.

WARIN, Kritsasith et al. AI-based analysis of oral lesions using novel deep convolutional neural networks for early detection of oral cancer. **Plos one**, v. 17, n. 8, p. e0273508, 2022.

ZHANG, Qingyu et al. Identification of Endoplasmic Reticulum Stress-Related Biomarkers of Periodontitis Based on Machine Learning: A Bioinformatics Analysis. **Disease Markers**, v. 2022, n. 1, p. 8611755, 2022.