

PREDIÇÃO DA SOBREVIVÊNCIA DE RESTAURAÇÕES DENTÁRIAS UTILIZANDO MACHINE LEARNING A PARTIR DE UM ESTUDO CLÍNICO RANDOMIZADO

**KAILA ANDRESSA DOS SANTOS OLIVEIRA¹; LAYLLA GALDINO DOS SANTOS²; LUANA
CARLA SALVI³; TATIANA PEREIRA CENCI⁴; LUIZA GIODA NORONHA⁵ LUIZ ALEXANDRE
CHISINI⁶**

¹Universidade Federal de Pelotas – kaila.andressa20@gmail.com

²Universidade Federal de Pelotas – laylla.galdino1996@gmail.com

³Universidade Federal de Pelotas – luanacarlasalvi@gmail.com

⁴Universidade Federal de Pelotas – tatiana.dds@gmail.com

⁵Universidade Federal de Pelotas – luizagnoronha@gmail.com

⁶Universidade Federal de Pelotas - alexandrechisini@gmail.com

1. INTRODUÇÃO

A inteligência artificial (IA) é um termo geral que se refere a capacidade de executar uma tarefa com a ajuda de uma máquina e/ou tecnologia de forma automatizada (AHMED et al., 2021). Dentro da IA existe a subárea de aprendizado de máquina (*Machine Learning*) que utiliza algoritmos para aprender padrões estatísticos complexos dos dados com diversos objetivos e aplicações. O aprendizado de máquina vem sendo amplamente utilizado em diversos campos, incluindo a odontologia, com o objetivo principal de identificar lesões em imagens e fazer predições por meio da análise de um determinado conjunto de dados (BARBOSA; PORTES, 2019).

Como uma tecnologia emergente, a IA tem sido amplamente aplicada na saúde. Na odontologia ela tem sido utilizada para identificar lesões de cárie em radiografias, assim como no desenvolvimento de predições que avaliam o risco de diferentes desfechos de saúde bucal. A IA pode distinguir entre características normais e patológicas, identificar infecções e prever desfechos de tratamentos. Embora seu uso na odontologia esteja se expandindo rapidamente, nenhum estudo utilizou dados de ensaios clínicos randomizados para modelar a sobrevivência de restaurações, e nosso objetivo é preencher essa lacuna (AHMED et al., 2021).

No âmbito da Odontologia Restauradora, a reabilitação de dentes posteriores amplamente destruídos por meio do uso de coroas unitárias metalocerâmicas e restaurações de resina composta retidas por pino de fibra de vidro desempenha um papel fundamental no tratamento de dentes tratados endodonticamente (POLLETO-NETO et al., 2024). A aplicação de aprendizado de máquina (*ML*) surge como uma ferramenta promissora nesse cenário, permitindo prever a sobrevivência dessas restaurações com base em dados clínicos e características dos materiais utilizados. Apesar da relevância dessas abordagens, ainda não existem estudos que utilizem ensaios clínicos randomizados para modelar de forma precisa os desfechos odontológicos. Nesse contexto, este trabalho tem como objetivo desenvolver um modelo preditivo que possibilite aos cirurgiões-dentistas tomar decisões mais assertivas e personalizadas, otimizando os resultados clínicos a longo prazo.

2. METODOLOGIA

Para a criação do modelo preditivo, utilizamos dados de um ensaio clínico randomizado (ECR) prospectivo com grupos paralelos, aprovado pelo Comitê de Ética em Pesquisa (CEP 122/2009) da UFPEL. Nesse estudo, foram realizadas 75 restaurações, das quais 34 eram coroas metalocerâmicas e 41 eram restaurações de resina composta retidas por pinos de fibra de vidro, todas aplicadas em um total de 82 pacientes alocados de forma aleatória. Após um acompanhamento médio de 8,1 anos, a sobrevivência das restaurações foi avaliada. As

restaurações que necessitaram de substituição completa, apresentaram descolamento irreparável ou exigiram a extração do dente foram classificadas como falhas não reparáveis. Enquanto as restaurações que puderam ser reparadas ou recimentadas foram consideradas falhas reparáveis. Foram avaliados dois cenários: a) sucesso, em que as restaurações não precisaram de qualquer intervenção; e b) sobrevivência, em que as restaurações, mesmo reparadas, permaneciam funcionais.

Para modelagem estatística do presente estudo os dados foram inicialmente manipulados no Software Stata 16.0 para categorização das variáveis e limpeza do banco. Logo após o banco de dados foi importado para o Jupyter Notebook, que utiliza linguagem Python, onde foi realizado o pré-processamento dos dados categóricos (One hot encode) e contínuos (Z-Score). Após os dados processados, foram divididos em dois conjuntos: 80% para o treino do modelo e 20% para teste, garantindo que a maior parte dos dados fosse utilizada para o treinamento, enquanto uma menor parcela foi reservada para avaliação do desempenho. Para lidar com o desequilíbrio de classes, foi aplicado a técnica Synthetic Minority Oversampling Technique (SMOTE) no conjunto de treino, o que assegurou um balanceamento adequado e evitou vieses em favor da classe majoritária.

O modelo selecionado para o aprendizado de máquina foi o Extreme Gradient Boosting (XGBoost), devido à sua capacidade de lidar com dados complexos e desbalanceados. O ajuste dos hiperparâmetros foi realizado com o auxílio da biblioteca Hyperopt, permitindo a otimização do desempenho do modelo. A interpretação das previsões foi realizada através do uso de SHapley Additive exPlanations (SHAP), que forneceu insights sobre as variáveis que mais influenciaram nas decisões do modelo. A avaliação de desempenho foi conduzida por meio de métricas como a área sob a curva (AUC), precisão, sensibilidade, especificidade e F1-Score, permitindo uma compreensão ampla da eficácia preditiva do modelo de problema de classificação. Todo o processo foi implementado em linguagem de programação Python, utilizando bibliotecas especializadas para análise e modelagem.

3. RESULTADOS E DISCUSSÃO

Os resultados obtidos pelas métricas de desempenho do modelo desenvolvido na metodologia indicaram um desempenho satisfatório, com a área sob a curva (AUC) de 0,83, demonstrando a capacidade do modelo em diferenciar eficazmente entre restaurações que sobreviveram e aquelas que falharam. A acurácia do modelo nos dados de teste foi de 0,73, indicando que, em média, 73% das previsões realizadas estavam corretas. A sensibilidade (Recall) foi de 0,66, refletindo que o modelo identificou corretamente 66% das restaurações que falharam, enquanto a especificidade foi de 0,40, mostrando que 40% das restaurações previstas como falhas foram corretamente classificadas. A precisão também foi de 0,40, sugerindo que 40% das restaurações previstas como falhas realmente falharam. O F1 score, que avalia o equilíbrio entre precisão e sensibilidade, foi de 0,50, sugerindo um desempenho moderado, mas com espaço para melhorias adicionais.

A análise das variáveis foi realizada por meio da técnica SHAP, que permitiu identificar os fatores mais impactantes nas decisões do modelo preditivo. A variável mais significativa foi o tipo de restauração (coroa metalocerâmica e resina composta), com o material utilizado desempenhando um papel fundamental para a sobrevivência nesse conjunto de dados; seguido pelo tipo de cimento (autoadesivo dual e adesivo convencional) utilizado na cimentação das restaurações também foi um fator importante. A terceira variável mais importante foi a localização do dente na arcada (anterior ou posterior), influenciando na sobrevivência das restaurações. Além disso, observou-se um papel fundamental do número de paredes remanescentes dentárias. O tipo de dente (incisivos, caninos, molares) também foi outra variável importante para o modelo, evidenciando a complexidade das variáveis envolvidas.

A longevidade das restaurações dentárias depende principalmente do material utilizado, embora fatores como características da cavidade, hábitos do paciente e a habilidade do dentista também desempenharem um papel importante (DEMARCO et al., 2023). Na odontologia, o uso de *Machine Learning*, especialmente algoritmos como o XGBoost, tem mostrado grande potencial em áreas como diagnóstico, planejamento de tratamento e predição de desfechos clínicos, demonstrando alta eficácia na análise de grandes conjuntos de dados e na previsão de resultados com precisão (AHMED et al., 2021).

O estudo de Toledo Reyes (2023), que buscou desenvolver e validar modelos de prognóstico para cáries em dentes decíduos e permanentes, observou que após 2 e 10 anos de acompanhamento os modelos apresentaram elevada performance. Os dados analisados derivaram de uma coorte prospectiva de 10 anos no Sul do Brasil. Foram considerados fatores demográficos, socioeconômicos, psicossociais, comportamentais e clínicos, e os algoritmos utilizados incluíram árvore de decisão, random forest, XGBoost e regressão logística. Em todos os modelos, a área sob a curva (AUC) foi superior a 0,70 no conjunto de treinamento e teste para prever lesões de cárie em dentes decíduos após 2 anos de acompanhamento, sendo a severidade das lesões de cárie na linha de base o preditor mais forte.

Estudos recentes, avaliaram as causas de falha em restaurações realizadas por estudantes de odontologia, concluindo que fatores relacionados tanto ao paciente quanto ao tratamento influenciam o insucesso das restaurações. O estudo registrou uma precisão significativa, com AUC de 0,935 e acurácia de 0,75 (ALIAGA et al., 2018). Esses resultados corroboram a importância de monitorar fatores clínicos e individuais na longevidade das restaurações, assim como os dados do presente estudo, que destacam a relevância de variáveis como o material utilizado e a localização do dente para prever o sucesso das restaurações utilizando aprendizado de máquina.

4. CONCLUSÕES

O modelo desenvolvido demonstrou desempenho promissor na previsão da sobrevivência das restaurações. Contudo, para que seus resultados possam ser usados como suporte na tomada de decisões clínicas, é essencial expandir a amostra de pacientes e realizar validações externas.

5. REFERÊNCIAS BIBLIOGRÁFICAS

AHMED, N et. al. Artificial Intelligence Techniques: Analysis, Application, and Outcome in Dentistry-A Systematic Review. **Journal of Dental Research**, 2020.

POLETTI-NETO, V et. al. Single crown vs. composite for glass fiber post-retained restorations: An 8-year randomized clinical trial. **Journal of Dentistry**, v.142, p 2024.

BARBOSA, LM; PORTES, LAF. A inteligência artificial. **Revista Tecnologia Educacional**, Rio de Janeiro, n° 236, p16-27, 2019.

DEMARCO, FF; et al. Longevity of composite restorations is definitely not only about materials. **Dental Materials**, v39, p1-12, 2023.

ALIAGA, ij. et al. Prediction and failure analysis of composite resin restorations in the posterior sector applied in teaching dental students. **Journal of Ambient Intelligence and Humanized Computing**, v11, p4537-4544, 2020.

REYES, LT. et al; Early Childhood Predictors for Dental Caries: A Machine Learning Approach. **Journal of Dental Research**, v102, 2023.