

ECG-ResNeXt: Age Prediction in Pediatric Electrocardiograms and Its Correlations with Comorbidities

Pedro Robles Dutenhfner¹, Gabriel Lemos¹, Turi Rezende¹,
Jose Geraldo Fernandes¹, Diogo Tuler¹, Gisele Lobo Pappa¹,
Gabriela Miana Paixão², Antônio Luiz Pinho Ribeiro², Wagner Meira Jr.¹

¹ Departamento de Ciência da Computação, Universidade Federal de Minas Gerais
Belo Horizonte, MG, Brazil

² Faculdade de Medicina, Universidade Federal de Minas Gerais
Belo Horizonte, MG, Brazil

{pedroroblesduten, josegeraldof}@ufmg.br,

gabimiana@gmail.com, tom@hc.ufmg.br,

{gabriel.lemos, turirezende, diogochaves, glpappa, meira}@dcc.ufmg.br

Abstract. *Cardiovascular diseases are the leading cause of global mortality, with the electrocardiogram (ECG) being essential for cardiac health assessment. Beyond automatic diagnosis, the use of artificial intelligence models for age prediction from ECG data has shown great potential, enabling the identification of adverse clinical conditions by discrepancies in predicted age. In this pioneering study, we explore age prediction in pediatric data by proposing the ECG-ResNeXt model, which incorporates advancements such as inverted bottlenecks and Global Response Normalization, outperforming results obtained by previous models. Additionally, we analyze correlations between prediction errors and comorbidities, highlighting the clinical potential of this approach.*

Resumo. *Doenças cardiovasculares são a principal causa de mortalidade global, sendo o eletrocardiograma (ECG) essencial para avaliar a saúde cardíaca. Além do diagnóstico automático, o uso de modelos de inteligência artificial para a predição de idade a partir do ECG tem demonstrado grande potencial, de modo que quadros clínicos adversos sejam identificados por erros na idade predita. Neste trabalho pioneiro, exploramos a predição de idade em dados pediátricos, propondo o modelo ECG-ResNeXt, que incorpora avanços como inverted bottlenecks e Global Response Normalization e superou resultados obtidos por modelos anteriores. Além disso, analisamos correlações entre erros de predição e comorbidades, ressaltando o potencial clínico deste estudo.*

1. Introdução

As doenças cardiovasculares (DCVs) representam a principal causa de mortalidade global, sendo responsáveis por aproximadamente 17,9 milhões de óbitos anuais [World Health Organization 2024]. Nesse cenário, o eletrocardiograma (ECG) desempenha um papel crucial na avaliação da saúde cardiovascular e detecção de diversas condições cardíacas, oferecendo uma ferramenta diagnóstica acessível e não invasiva.

Embora a aplicação predominante de inteligência artificial (IA) em ECGs esteja voltada para a classificação de doenças com fins de diagnóstico [Liu et al. 2021, Ebrahimi et al. 2020], a predição de idade a partir do ECG tem se destacado como uma tarefa de importância crescente. Essa técnica permite estimar uma métrica associada idade biológica do paciente, fornecendo uma indicação do estado atual do sistema cardiovascular relacionada a fatores de risco e a condições subjacentes [Lima et al. 2021, Hirota et al. 2023]. Assim, a diferença entre a idade predita e a idade cronológica real pode estar correlacionada a quadros clínicos adversos, o que torna essa métrica potencialmente valiosa para a identificação precoce de indivíduos em risco.

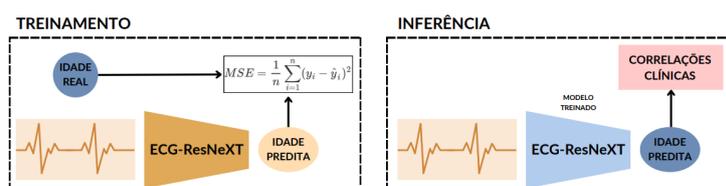


Figura 1. Pipeline de predição de idade como indicativo da idade cardiovascular, encapsulando outras correlações clínicas.

Os autores em [Lima et al. 2021] mostraram que a idade estimada por redes neurais profundas a partir de ECGs pode ser um poderoso preditor de mortalidade. Já os autores de [Hirota et al. 2023] demonstraram que a idade predita por IA utilizando ECGs tem uma forte associação com eventos cardiovasculares. O estudo revelou que, em pacientes com menos de 60 anos, a diferença entre a idade cronológica e a idade predita está linearmente associada ao risco de infartos e acidentes cardiovasculares.

Apesar de a maioria dos trabalhos em IA para medicina focarem exclusivamente em dados de adultos, recentemente houve um avanço em estudos de IA para cardiologia com foco em dados pediátricos [García-Vicente et al. 2023, Mayourian et al. 2024]. Esse é um campo promissor, uma vez que as crianças possuem características fisiológicas únicas que diferem significativamente das dos adultos [Chan et al. 2008]. Os dados pediátricos de ECG oferecem a possibilidade de entender melhor as variações na função cardíaca ao longo do crescimento e desenvolvimento, permitindo identificar potenciais riscos cardiovasculares desde cedo. No entanto, há limitações e dificuldades significativas, principalmente devido às rápidas mudanças fisiológicas que ocorrem durante o desenvolvimento infantil, especialmente durante a puberdade.

Até o momento, não encontramos registros de trabalhos que abordem a tarefa de predição de idade cardiológica em dados pediátricos. Com base em nosso conhecimento, este artigo se propõe a ser o primeiro a explorar a predição de idade em ECGs infantis. Para esse propósito, desenvolvemos um novo modelo de rede neural convolucional (CNN) para análise de eletrocardiogramas, denominado *ECG-ResNeXt*.

O *ECG-ResNeXt* integra o conceito de *inverted bottlenecks* [Sandler et al. 2018, Liu et al. 2022], uma abordagem inovadora a respeito da manipulações de dimensões no espaço latente da rede, juntamente com camadas de *Global Response Normalization* [Woo et al. 2023], que visam equilibrar o uso dos diferentes canais de representação, prevenindo problemas como o *feature collapse* e a redundância de informações. Essas inovações, especialmente o uso de *inverted bottlenecks*, consolidado no modelo ConvNeXt [Liu et al. 2022], têm mostrado resultados notáveis, superando até mesmo modelos

baseados em Transformers em tarefas de visão computacional. Assim, há novas possibilidades para sua aplicação em séries temporais, como ECGs, que tradicionalmente obtêm melhor desempenho com redes convolucionais, seja aplicadas exclusivamente ou utilizadas como extratoras de atributos para outros modelos [Zeng et al. 2023, Hu et al. 2022, Che et al. 2021]. Os detalhes técnicos do modelo *ECG-ResNeXt* serão discutidos nas seções seguintes deste trabalho.

O modelo proposto, *ECG-ResNeXt*, alcançou um erro absoluto médio de 2,12 anos, superando os resultados obtidos por arquiteturas consolidadas na literatura, ao serem treinados e avaliados em dados pediátricos. Ademais, para explorar as potencialidades clínicas da predição da idade em dados pediátricos, conduzimos análises detalhadas das idades preditas em conjunto com a presença de diversos quadros clínicos. Os erros entre a idade cardiovascular predita e a idade cronológica dos pacientes apresentaram fortes correlações com a presença de comorbidades, como obesidade e hipertensão arterial sistêmica. Ademais, situações em que a idade predita foi 5 ou mais anos superior à idade cronológica real estavam associadas a exames realizados por motivos cirúrgicos, palpitações e/ou dor torácica. Esses achados corroboram a hipótese de que a predição de idade em dados pediátricos, além das validações já realizadas em dados de adultos, pode ser uma ferramenta clínica valiosa.

2. Trabalhos Relacionados

Esta seção está dividida em duas partes: primeiro abordamos artigos que trabalharam no desenvolvimento de modelos de inteligência artificial para predição de idade a partir do ECG de adultos. Em seguida, discutimos trabalhos que adotaram dados pediátricos para o desenvolvimento de modelos preditivos para ECGs.

2.1. Predição de idade a partir do ECG

Trabalhos recentes abordaram a tarefa de predição de idade a partir do ECG. Utilizando um conjunto de dados de mais de 1,5 milhão de pacientes, os autores em [Lima et al. 2021] aplicaram um modelo de CNNs residuais para a predição de idade. O modelo atingiu erro absoluto médio (MAE) entre 8,38 e 10,04 anos. Foi demonstrado que uma idade predita acima de 8 anos da idade cronológica apresenta correlação com uma maior taxa de mortalidade. Já o artigo [Hirota et al. 2023] utilizou dados de pacientes com ritmo sinusal. O modelo, também baseado em CNNs, obteve um MAE de 6,14 anos entre a idade predita e a cronológica. O estudo revelou que os erros na idade predita estavam associadas de forma linear com a incidência de eventos cardiovasculares em pacientes com menos de 60 anos. Essas descobertas indicam que a idade predita pela IA pode ser útil na avaliação de risco cardiovascular, como indicador de mortalidade e de possibilidade eventos de risco.

Em [Chang et al. 2022] utilizando um conjunto de dados de ECG de Taiwan, os autores aplicaram um modelo de CNN para predição de idade e atingiram um MAE entre as idades cronológica e predita de 6,9 anos. As principais conclusões clínicas revelaram que erro na predição esteve associado a uma maior incidência de mortalidade por condições cardiovasculares, como insuficiência cardíaca e infarto agudo do miocárdio, sendo ainda mais evidente para erros maiores do que sete anos.

2.2. Inteligência artificial em dados pediátricos de ECG

Nos últimos anos, houve um aumento significativo no uso de técnicas de IA aplicadas a dados de ECGs pediátricos. Um exemplo é o trabalho de [Mayourian et al. 2024], que explorou a predição de defeitos do septo atrial secundário (ASD2) em uma população pediátrica com menos de 18 anos. O modelo de CNN foi avaliado em dois conjuntos de teste e alcançou uma AUROC superior a 0,8 para ambos.

Em [Chen et al. 2024] foi desenvolvido um modelo para detectar doenças cardíacas congênitas (CHD) em ECGs pediátricos. Já no trabalho de [Mori et al. 2021], foi desenvolvido um modelo de *deep learning* para diagnosticar defeitos do septo atrial (ASD) em pacientes pediátricos, utilizando dados de ECGs. O modelo combinou uma CNN com uma rede recorrente (LSTM), atingindo uma pontuação F1 de 0,81, apresentando métricas preditivas superiores a de médicos cardiologistas pediátricos, de modo a confirmar o potencial e possibilidades associadas ao desenvolvimento de modelos automáticos para a população infantil.

Por fim, [García-Vicente et al. 2023] investigou o uso de um modelo baseado em uma CNN para prever a gravidade de síndrome de apneia obstrutiva do sono (SAOS) em pacientes pediátricos. As métricas preditivas incluíram uma sensibilidade de 84,19% e especificidade de 46,15%. Este estudo destacou que o modelo pode identificar casos de SAOS pediátrica, sugerindo que essa abordagem simplificada pode facilitar o diagnóstico precoce e acessível da SAOS.

Ainda não foram encontrados trabalhos que abordem a tarefa de predição de idade em ECGs e suas possibilidades de aplicações clínicas em dados pediátricos. Assim, neste trabalho, buscamos ser pioneiros em explorar a predição de idade cardiovascular na população infantil. Além disso, trabalhamos para melhorar os modelos de CNNs apresentados na literatura, incorporando inovações técnicas propostas no campo de aprendizado profundo nos últimos anos.

3. ECG-ResNeXt

Esta seção apresenta a arquitetura do modelo proposto, a ECG-ResNeXt. Como mencionado, o modelo proposto em [Lima et al. 2021], que denominaremos de ResNet, apresentou excelentes resultados para previsão de idade de adultos a partir do ECG. Dessa forma, utilizamos a estrutura da rede apresentada como ponto de partida para o desenvolvimento do nosso próprio modelo, que inclui duas principais características novas: (i) *inverted bottlenecks* e (ii) uma camada de *Global Response Normalization* (GRN).

Inicialmente descreveremos a ResNet base, e então detalharemos nossas contribuições. A ResNet é uma rede neural convolucional residual que segue uma estrutura bem definida. O bloco de entrada é composto por uma camada de convolução 1D, seguida de *batch normalization* e uma ativação ReLU. Após o bloco de entrada, a rede é composta por uma série de blocos residuais, cada um subdividido em três sub-blocos:

1. **First Branch:** Processa o dado de entrada por meio de uma camada de convolução 1D, seguida de *batch normalization*, ReLU, *dropout*, e outra camada de convolução 1D.
2. **Residual Branch:** Uma cópia do dado de entrada é processada por uma ramificação residual, cuja função é aplicar uma camada de max pooling seguida de uma camada de convolução 1D.

3. **Second Branch:** Os resultados da *First Branch* e da *Residual Branch* são somados. Em seguida, o dado resultante é duplicado: uma cópia é passada por uma sequência de *batch normalization*, ReLU, e *dropout*, e posteriormente enviada para uma nova repetição da *First Branch*; a outra cópia é enviada diretamente para uma nova repetição da *Residual Branch*.

Este processo é repetido por quatro vezes, e o resultado final é transformado por uma camada linear, sendo utilizado para a predição da idade.

Com base nessa estrutura, adicionamos o conceito de *inverted bottlenecks* (IB) à rede. A ideia central do IB reside na manipulação das dimensões dos canais ao longo do bloco. Este processo segue um padrão de expansão-compressão. Inicialmente, utiliza-se uma convolução com *kernels* de tamanho grande, que reduz a dimensionalidade espacial dos dados, mas mantém o número de canais inalterado. Em seguida, após uma normalização por camada de (*Layer Normalization*), aplica-se uma convolução 1x1 seguida de uma função de ativação GeLU, processo que expande o número de canais. Por fim, uma nova convolução 1x1 é aplicada para comprimir o número de canais de volta à dimensão original, completando o processo de expansão-compressão.

As principais vantagens dos *inverted bottlenecks* estão associadas a modelos computacionalmente eficientes, ao mesmo tempo em que melhora a expressividade da rede. O processo de expansão das dimensões dos canais capacita a rede a capturar e processar informações complexas, aumentando sua expressividade. Na Figura 2 podemos observar uma comparação intuitiva e clara de um bloco clássico de ResNet e um bloco que segue a arquitetura de inverted bottlenecks, consolidado pela rede ConvNeXt.

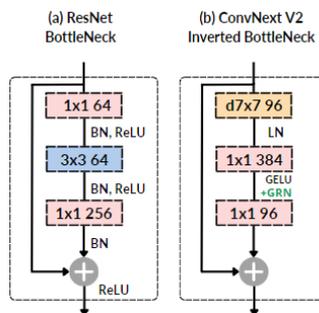


Figura 2. Estrutura de um bloco clássico de ResNet e um bloco de Inverted Bottleneck. Os valores de canais são arbitrários no exemplo.

Nesse sentido, todos os blocos da ResNet original foram substituídos por blocos de *inverted bottlenecks*. Realizamos essa modificação tanto no bloco de entrada da rede quanto na *first branch* e na *second branch*. A única parte da rede que permaneceu inalterada foi a *residual branch*, onde a operação de *MaxPool* e convolução 1D foram mantidas.

Os blocos da rede ECG-ResNeXt seguem a estrutura de expansão-compressão apresentada anteriormente. A primeira convolução do bloco utiliza um *kernel size* de 10, *stride* de 4 e *padding* de 4, reduzindo assim as dimensões espaciais dos dados em um fator de 4, sem alterar o número de canais. Em seguida, diferente da ResNet original, aplicamos uma camada de *Layer Normalization*. No processo de expansão, utilizamos uma convolução 1x1 seguida pela ativação GeLU para aumentar em quatro vezes o número

de canais. Finalmente, uma outra convolução 1x1 é aplicada para reduzir o número de canais. O resultado desse processo é então somado ao resultado da *residual branch*.

Além disso, como apresentado na versão ConvNeXt-v2 [Woo et al. 2023], utilizamos, após a não linearidade GeLU, uma camada de *Global Response Normalization* (GRN). A camada de GRN foi introduzida com o objetivo de evitar um problema conhecido como *feature collapse*, no qual as ativações dos canais de uma rede neural se tornam redundantes, levando a uma menor diversidade de características. A *Global Response Normalization* funciona em três etapas principais:

1. **Agregação Global:** Para cada entrada $X \in \mathbb{R}^{H \times W \times C}$, agregamos as características em um vetor $g_x \in \mathbb{R}^C$ utilizando a norma L2 de cada canal:

$$g_x = (\|X_1\|_2, \|X_2\|_2, \dots, \|X_C\|_2)$$
2. **Normalização:** Aplicamos uma normalização divisiva $N(\cdot)$ ao vetor g_x para calcular a importância relativa de cada canal: $N(\|X_i\|_2) = \frac{\|X_i\|_2}{\sum_{j=1}^C \|X_j\|_2}$
3. **Calibração:** As características originais X são então calibradas com os valores normalizados, utilizando os parâmetros aprendíveis γ e β :

$$X'_i = \gamma \times (X_i \times N(\|X_i\|_2)) + \beta + X_i$$

As principais vantagens da *Global Response Normalization* incluem o aumento da diversidade de características, a prevenção do colapso de informações e a maior eficiência da rede na captura de dados relevantes. A arquitetura completa do modelo ECG-ResNeXt pode ser vista na Figura 3.

Na *second branch*, mantemos a estrutura de IB, mas sem a aplicação da primeira convolução, o que significa que as dimensões espaciais dos dados não são alteradas. Diferentemente da ResNet original, antes de enviar o dado para uma repetição da *residual branch*, o circuito é fechado com a adição de uma identidade residual. Uma cópia deste resultado é enviada para uma nova repetição da *first branch*, enquanto outra cópia é enviada para uma nova repetição da *residual branch*, repetindo esse processo três vezes.

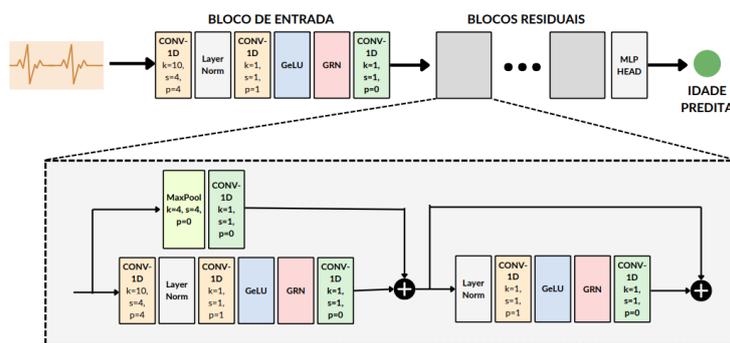


Figura 3. Arquitetura completa do modelo ECG-ResNeXt

4. Base de Dados

O conjunto de dados utilizado neste estudo compreende uma coorte de exames eletrocardiográficos pediátricos, coletados e analisados pela equipe da Rede de Teleassistência de Minas Gerais, do Hospital das Clínicas da Universidade Federal de Minas Gerais. A base

de dados contém 163.242 exames de 148.738 pacientes únicos, abrangendo indivíduos de 0 a 18 anos de idade. Uma descrição quantitativa detalhada encontra-se na Tabela 1.

Tabela 1. Resumo dos conjuntos de dados utilizados no estudo, incluindo o número de exames, pacientes únicos e distribuição por sexo.

Conjunto de Dados	Número de Exames	Número de Pacientes Únicos	Homens / Mulheres
Conjunto Completo	163242	148738	91085 / 72157
Treino	130592	118990	72866 / 57726
Validação	16291	14873	9060 / 7231
Teste	16359	14875	9159 / 7200

Para cada indivíduo, o conjunto de dados apresenta a idade cronológica real em anos. No entanto, considerando que em dados pediátricos há uma rápida variação fisiológica em um curto espaço de tempo, também abordamos a idade com granularidade em meses. Para isso, utilizamos a data de nascimento e a data de realização do exame para o cálculo em meses. Contudo, 43% pacientes apresentavam valores faltantes no atributo de data do exame. Nesses casos, consideramos a idade em anos multiplicada por 12, o que explica os picos observados no histograma à direita da Figura 4.

Ademais, a base contém informações sobre o quadro clínico de cada paciente, abordando a presença de comorbidades como obesidade, doenças de chagas, hipertensão, entre outros, além do motivo de realização do exame. Tais atributos permitem a realização de investigações de correlações entre a idade cardiovascular predita e situações médicas específicas.

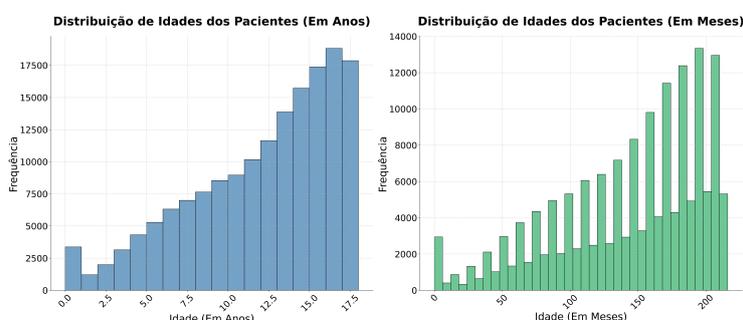


Figura 4. Histograma das idades do conjunto de dados utilizados. À esquerda a idade estão em anos e, à direita, em meses

Para o treinamento do modelo com dados pediátricos, os sinais de ECG foram processados seguindo a mesma abordagem que em [Lima et al. 2021], porém, enquanto o trabalho original aplica um processo de *padding* para garantir que o dado de entrada tenha 4096 amostras, optamos por cortar os sinais de ECG. Isso resultou em um sinal de ECG de 2560 amostras com 12 derivações (*leads*), que foi utilizado como entrada para a rede, de forma *end-to-end*. O conjunto de dados foi dividido em treino, validação e teste, com proporções de 80%, 10% e 10%, respectivamente. A separação dos dados foi realizada de maneira aleatória a partir de id de identificação de cada paciente, garantindo que não haja exames do mesmo paciente em diferentes subconjuntos. Detalhes dos subconjuntos podem ser vistos na Tabela 1.

Tabela 2. Métricas de predição de idade (MAE e MSE) separadas por unidade de tempo (meses e anos) para os modelos ResNet e ECG-ResNeXt.

Métrica	Unidade	ResNet	ECG-ResNeXt
MAE	Meses	28.43	26.70
MSE	Meses	1520.69	1350.53
MAE	Anos	2.65	2.12
MSE	Anos	13.56	8.84

5. Experimentos e Resultados

O treinamento da rede foi conduzido com o otimizador AdamW [Loshchilov and Hutter 2017], em um processo de escalonamento cossenoidal da taxa de aprendizado [Loshchilov and Hutter 2016]. A taxa de aprendizado inicial foi definida como 0.0001 e reduzida cossenoidalmente até 0.00001 ao longo do treinamento, com o objetivo de minimizar a perda de *Mean Squared Error* (MSE) entre a idade predita e a real. Utilizamos *early stopping*, encerrando o treinamento quando o erro no conjunto de validação não apresentava melhora após sete épocas consecutivas. A implementação do modelo foi realizada utilizando a biblioteca PyTorch e o treinamento realizado de forma paralela utilizando 4 GPUs NVIDIA V100. Além disso, para avaliação de resultados, também treinamos o modelo ResNet seguindo o mesmo protocolo de treino.

Métricas preditivas: Após o treinamento, ambos os modelos foram aplicados ao conjunto de teste para coletar as métricas de desempenho. Duas métricas principais foram utilizadas para avaliar a tarefa de regressão na predição de idade: Mean Absolute Error (MAE) e Mean Squared Error (MSE).

Os resultados apresentados na Tabela 1 indicam que o modelo ECG-ResNeXt obteve valores menores tanto para MAE quanto para MSE, em comparação com o modelo ResNet. O MAE, que mede a média dos erros absolutos, trata os erros de forma linear, sem diferenciar penalizações entre erros grandes e pequenos. Já o MSE, que considera o quadrado dos erros, penaliza mais severamente os erros maiores, tornando-o mais sensível a discrepâncias significativas. Os resultados sugerem que o modelo ECG-ResNeXt não apenas apresenta um erro médio absoluto menor, mas também demonstra uma menor incidência de erros grandes.

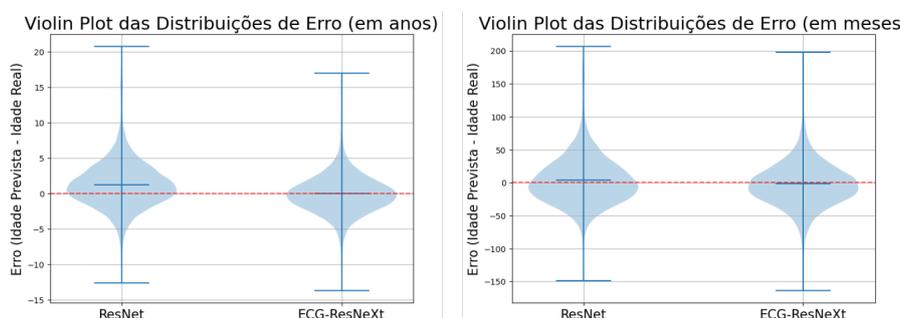


Figura 5. Distribuições dos erros na predição para os modelos ResNet e ECG-ResNeXt, para o treinamentos com alvo em anos (à esquerda) e em meses (à direita)

A Figura 5 ilustra as distribuições de erro dos modelos ResNet e ECG-ResNeXt treinados para a predição de idade em meses e anos. A análise dessas distribuições revela

que o ECG-ResNeXt apresenta erros menores em ambas as métricas, com uma diferença mais acentuada na predição de idade em anos. Utilizamos os testes Smirnov-Kolmogorov e Mann-Whitney para avaliar a diferença estatística entre as distribuições. Com p-valor menor que 0.05 para ambos os testes, rejeitamos a hipótese nula que as distribuições são iguais.

Análises clínicas: Com o resultado preditivo validado, buscamos as possibilidades clínicas que podem emergir da predição de idade em crianças, oferecendo novas perspectivas para a medicina cardiovascular na população pediátrica. Os resultados foram analisados utilizando o subconjunto de teste e, para evitar problemas em relação a dados faltantes, usamos a predição em anos.

Com base nas informações de comorbidades da base de dados, criamos uma variável que identifica se um paciente possui pelo menos uma comorbidade entre as especificadas. Utilizamos a técnica de *Bootstrap* para comparar as medianas dos erros entre os grupos de pacientes com e sem comorbidades. O resultado obtido indica que a diferença na mediana dos erros entre pacientes com e sem comorbidades é de 0,21, com um intervalo de confiança de 95% entre 0,145 e 0,282. Como este intervalo de confiança não inclui o valor zero, podemos concluir que há uma diferença estatisticamente significativa nas distribuições de erros entre os dois grupos, sugerindo que a presença de comorbidades está associada a uma variação na acurácia da predição da idade.

Em seguida, analisamos a presença de comorbidades em diferentes faixas de erro de predição: 2, 5 e 7 anos e geral (a situação onde nenhum filtro foi aplicado). Na Figura 6, para cada comorbidade, são mostradas as taxas de ocorrência para diferentes escalas de erro de predição, juntamente com seus respectivos intervalos de confiança. Essa representação permite uma visualização clara da associação entre o grau de erro na predição da idade cardiovascular e a presença de comorbidades nos indivíduos avaliados.

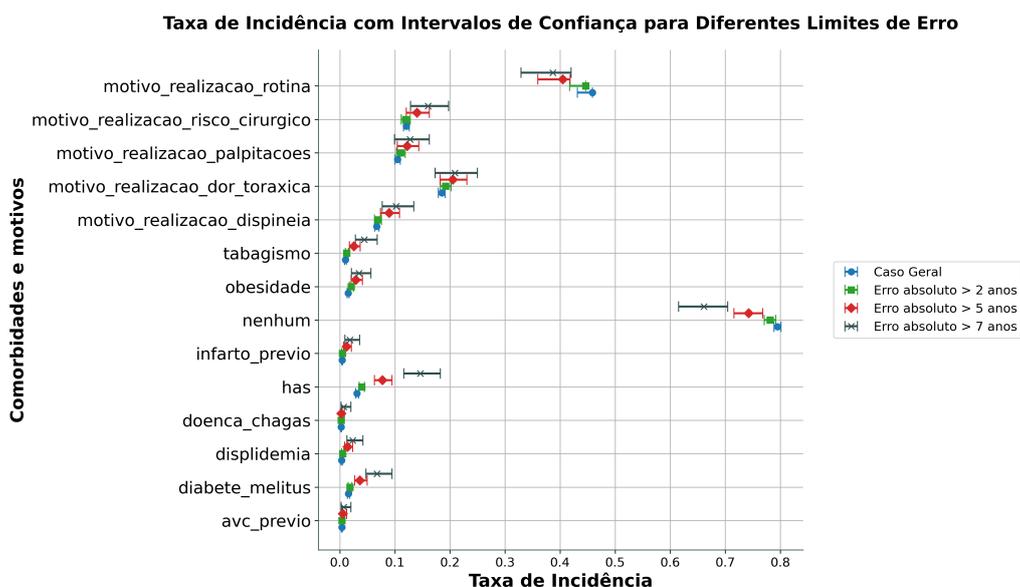


Figura 6. Taxas de comorbidades e motivos e seus intervalos de confiança para diferentes faixas de erro na predição da idade.

Destaca-se que, no atributo associado a nenhuma comorbidade (“nenhum”), uma

maior escala de erro, tanto de 2 quanto de 5 e 7 anos, está associada a exames com uma menor taxa de comorbidade. Ou seja, maiores erros de predição estão correlacionados com a presença de mais comorbidades. Seguindo essa mesma lógica, observa-se nos primeiros valores do gráfico, referentes aos motivos do exame, que, quando o exame se trata de um exame de rotina, maiores erros estão associados a uma menor taxa de comorbidade. Isso pode indicar que exames com maiores erros de predição não eram exames de rotina, mas sim exames voltados para uma análise clínica específica. Essa observação é corroborada pelas linhas associadas aos motivos de risco cirúrgico e realização de exames devido a palpitações e dor torácica, onde maiores erros estão associados a uma maior proporção desses motivos.

Para uma análise mais criteriosa e detalhada de algumas comorbidades, apresentamos a distribuição do erro na idade predita, para os exames com presença e para exames sem a presença de determinada condição clínica.

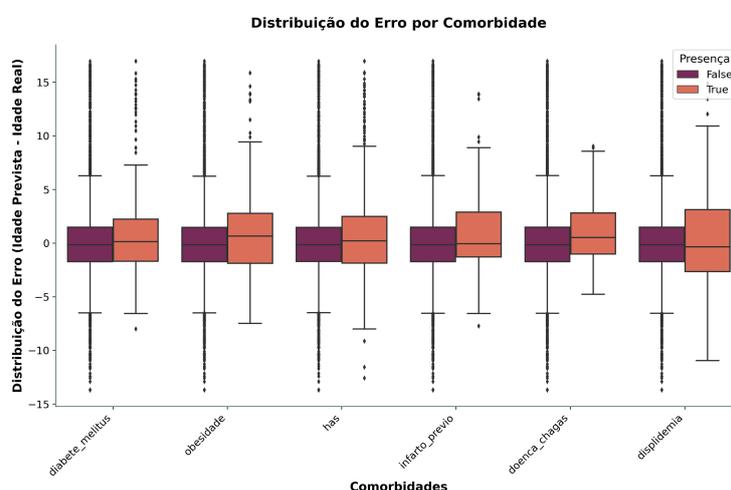


Figura 7. BoxPlot da distribuição do erro, em meses, da idade predita, comparando a presença ou ausência de diversas comorbidades.

A análise dos *boxplots* revela que os diversos quadros clínicos estão associados a um maior erro na predição da idade quando essas condições estão presentes, principalmente relacionados a uma idade predita maior que a idade cronológica verdadeira. Este resultado pode ser explicado pelos impactos que essas condições exercem na saúde cardiovascular e, conseqüentemente, nos sinais eletrofisiológicos capturados pelos ECGs. Para confirmação de significância estatística, novamente foi realizado o teste de Kolmogorov-Smirnov para comparar as distribuições do erro de predição da idade entre grupos com e sem a presença das diferentes comorbidades. Os resultados indicaram que, para os casos de diabetes mellitus, obesidade e hipertensão arterial sistêmica, as distribuições do erro são significativamente diferentes, com p-valores de 0,010708, 0,000036 e 0,000004, respectivamente. Esses achados sugerem que o erro de predição da idade está associado à presença dessas condições clínicas.

Doenças como diabetes mellitus, obesidade e hipertensão arterial sistêmica (HAS) afetam diretamente a saúde cardiovascular e a precisão da interpretação de ECGs automatizados, levando a maiores erros preditivos. Por exemplo, a HAS pode causar hipertrofia ventricular esquerda, caracterizada pelo aumento da espessura das paredes ventriculares,

que altera os padrões de condução elétrica e dificulta a interpretação precisa do ECG.

Esses resultados sugerem que a presença de comorbidades complexas, que têm um impacto direto no sistema cardiovascular, pode interferir na precisão dos modelos de predição de idade a partir de ECG. De modo a reforçar o potencial clínico da tarefa de predição de idade em dados pediátricos, podendo servir como um indicador de comorbidades e quadros cardiovasculares de risco.

6. Conclusões

Neste estudo, apresentamos o primeiro trabalho de desenvolvimento e aplicação de modelo de inteligência artificial para a predição de idade em dados pediátricos. Para isso, propomos um novo modelo de redes neurais convolucionais que incorpora importantes inovações técnicas propostas nos últimos anos da área de *deep learning*, principalmente o uso do conceito de *inverted bottlenecks* e camadas de *Global Response Normalization*. O modelo proposto apresentou resultados promissores na predição de idade a partir de ECGs pediátricos, superando arquitetura anterior consolidada da predição de idade em adultos. Além disso, foram exploradas as potencialidades clínicas da tarefa de predição de idade em dados infantis. Nesse sentido, demonstramos que o erro na idade preditiva pode estar correlacionado com a presença de comorbidades implícitas.

Porém, há algumas limitações que merecem atenção. A base de dados utilizada é composta por exames de uma única região geográfica, o que pode limitar a generalização dos resultados para outras populações. Além disso, dado que a população pediátrica abrange uma ampla faixa etária com significativas variações fisiológicas, uma direção promissora é o desenvolvimento de modelos específicos para diferentes faixas etárias, permitindo capturar de forma mais precisa as particularidades de cada estágio do desenvolvimento infantil.

7. Agradecimentos

Esse trabalho foi parcialmente financiado pelo CNPq, CAPES e FAPEMIG, além do CIIA-Saúde. Agradecemos também o Centro de Telesaúde de Minas Gerais, pelo acesso aos dados e colaborações no âmbito deste trabalho.

Referências

- Chan, T. C., Sharieff, G. Q., and Brady, W. J. (2008). Electrocardiographic manifestations: pediatric ecg. *The Journal of emergency medicine*, 35(4):421–430.
- Chang, C.-H., Lin, C.-S., Luo, Y.-S., Lee, Y.-T., and Lin, C. (2022). Electrocardiogram-based heart age estimation by a deep learning model provides more information on the incidence of cardiovascular disorders. *Frontiers in Cardiovascular Medicine*, 9:754909.
- Che, C., Zhang, P., Zhu, M., Qu, Y., and Jin, B. (2021). Constrained transformer network for ecg signal processing and arrhythmia classification. *BMC Medical Informatics and Decision Making*, 21(1):184.
- Chen, J., Huang, S., Zhang, Y., Chang, Q., Zhang, Y., Li, D., Qiu, J., Hu, L., Peng, X., Du, Y., et al. (2024). Congenital heart disease detection by pediatric electrocardiogram based deep learning integrated with human concepts. *Nature Communications*, 15(1):976.

- Ebrahimi, Z., Loni, M., Daneshtalab, M., and Gharehbaghi, A. (2020). A review on deep learning methods for ecg arrhythmia classification. *Expert Systems with Applications: X*, 7:100033.
- García-Vicente, C., Gutiérrez-Tobal, G. C., Jiménez-García, J., Martín-Montero, A., Gosal, D., and Hornero, R. (2023). Ecg-based convolutional neural network in pediatric obstructive sleep apnea diagnosis. *Computers in Biology and Medicine*, 167:107628.
- Hirota, N., Suzuki, S., Motogi, J., Nakai, H., Matsuzawa, W., Takayanagi, T., Umemoto, T., Hyodo, A., Satoh, K., Arita, T., et al. (2023). Cardiovascular events and artificial intelligence-predicted age using 12-lead electrocardiograms. *IJC Heart & Vasculature*, 44:101172.
- Hu, R., Chen, J., and Zhou, L. (2022). A transformer-based deep neural network for arrhythmia detection using continuous ecg signals. *Computers in Biology and Medicine*, 144:105325.
- Lima, E. M., Ribeiro, A. H., Paixão, G. M., Ribeiro, M. H., Pinto-Filho, M. M., Gomes, P. R., Oliveira, D. M., Sabino, E. C., Duncan, B. B., Giatti, L., et al. (2021). Deep neural network-estimated electrocardiographic age as a mortality predictor. *Nature communications*, 12(1):5117.
- Liu, X., Wang, H., Li, Z., and Qin, L. (2021). Deep learning in ecg diagnosis: A review. *Knowledge-Based Systems*, 227:107187.
- Liu, Z., Mao, H., Wu, C.-Y., Feichtenhofer, C., Darrell, T., and Xie, S. (2022). A convnet for the 2020s. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 11976–11986.
- Loshchilov, I. and Hutter, F. (2016). Sgdr: Stochastic gradient descent with warm restarts. *arXiv preprint arXiv:1608.03983*.
- Loshchilov, I. and Hutter, F. (2017). Decoupled weight decay regularization. *arXiv preprint arXiv:1711.05101*.
- Mayourian, J., Geggel, R., La Cava, W. G., Ghelani, S. J., and Triedman, J. K. (2024). Pediatric electrocardiogram-based deep learning to predict secundum atrial septal defects. *Pediatric Cardiology*, pages 1–6.
- Mori, H., Inai, K., Sugiyama, H., and Muragaki, Y. (2021). Diagnosing atrial septal defect from electrocardiogram with deep learning. *Pediatric cardiology*, 42(6):1379–1387.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L.-C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4510–4520.
- Woo, S., Debnath, S., Hu, R., Chen, X., Liu, Z., Kweon, I. S., and Xie, S. (2023). Convnext v2: Co-designing and scaling convnets with masked autoencoders. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 16133–16142.
- World Health Organization (2024). Cardiovascular diseases. Accessed: 2024-08-16.
- Zeng, Z., Kaur, R., Siddagangappa, S., Rahimi, S., Balch, T., and Veloso, M. (2023). Financial time series forecasting using cnn and transformer. *arXiv preprint arXiv:2304.04912*.