

IDENTIFICAÇÃO DE CÂNCER COLORRETAL POR MEIO DA ANÁLISE DE CARACTERÍSTICAS RADIÔMICAS: UMA ABORDAGEM PADRONIZADORA COM DEEP LEARNING

Colégio São Francisco de Sales – Diocesano
Orientando: Gonçalo Ponte Leite
Orientador: Victor Eduardo Alves da Silva Carvalho

INTRODUÇÃO

CADA VEZ MAIS, O PROCESSO DE IDENTIFICAR E DIAGNOSTICAR O CARÁTER BENIGNO OU CANCERÍGENO DE UM TUMOR VEM SENDO ENDEREÇADO POR TÉCNICAS DE DEEP LEARNING (“IA”), QUE GERAM MODELOS ANALISTAS QUE DEPENDEM DE GRANDES VOLUMES DE IMAGENS PARA RECONHECER OS PADRÕES TUMORAIS.

MAS, OS DADOS DISPONÍVEIS SÃO ESCASSOS, REDUNDANTES, SUBREPRESENTATIVOS, DESPROVIDOS DE CONTEXTO E PRODUZIDOS SEM UM PADRÃO.

TUDO ISSO, DIFICULTA OS ESFORÇOS PARA AUMENTAR A SOBREVIVÊNCIA DOS PACIENTES, ESPECIALMENTE A APADRONIZAÇÃO QUE É IMPROVÁVEL DE SER RESOLVIDA A NÍVEL DE PRODUÇÃO DE DADOS.

A PADRONIZAÇÃO DAS IMAGENS INTEGRADA À ANÁLISE IA É NECESSÁRIA PARA QUE OS MODELOS DE ANÁLISE TORNEM-SE GENERALISTAS O SUFICIENTE PARA SEREM UTILIZADOS PARA AMPLIAR O DIAGNÓSTICO PRECOCE EM PAÍSES POUCO DESENVOLVIDOS E/OU SEM AMPARO À PESQUISA SENDO INVIÁVEL DE ADOTAR PADRÕES DE DADOS OU TREINAR-SE IAS LOCAIS, O QUE É FUNDAMENTAL DADO A MAIOR LENTIDÃO DO TRATAMENTO.

AO EXPLORAR ESSE TEMA, ENFOCOU-SE NO CÂNCER COLORRETAL, POIS É O SEGUNDO E QUARTO CANCRO MAIS FATAL NO MUNDO E NO BRASIL, HAVENDO RELATIVAMENTE ESCASSOS ESTUDO SOBRE A PADRONIZAÇÃO DE SUAS IMAGENS

METODOLOGIA

PARA PADRONIZAR IMAGENS, OUTROS ESTUDOS UTILIZAM DE ALGORITMOS TRADICIONAIS DE PRÉ-PROCESSAMENTO OU = ENSINAM MODELOS DE IA COMO REALIZAR A PADRONIZAÇÃO A PARTIR DE EXEMPLOS EXPLÍCITOS DE QUAL SERIA A VERSÃO ESTANDARDIZADO DE UMA IMAGEM NÃO PADRONIZADA,

DIFERENTEMENTE, PROPÕE-SE UM MODELO GENERATIVO QUE ENTENDE A PADRONIZAÇÃO COMO O OBJETIVO ABSTRATO DE GERAR IMAGENS QUE SEJAM SIMILARES ENTRE SI - A PONTO DE NÃO PODER-SE DEFINIR QUAL É O PADRÃO VISUAL ORIGINAL DE CADA IMAGEM - MAS SEM DANIFICAR O CONTEÚDO CONTIDO NA IMAGEM

PARA FAZÊ-LO, USOU-SE GANs - MODELOS DE SÍNTESE DE IMAGENS BASEADO EM CARACTERÍSTICAS APRENDIDAS POR MODELOS DE CLASSIFICAÇÃO, PERMITINDO A PRODUÇÃO DE CARACTERÍSTICAS ABSTRATAS COMO HOMOGENEIDADE E PRESERVAÇÃO DE CONTEÚDO - E ARQUITETURA SIAMESA - A QUAL PERMITE A ANÁLISE DE IMAGENS AOS PARES, AMPLIANDO O VOLUME DE INPUT, PERMITINDO MELHOR APROVEITAMENTO DE DADOS, E PERMITINDO A APRENDIZAGEM DE CARACTERÍSTICAS GERAIS, EM DETRIMENTO DE CARACTERÍSTICAS ESPECÍFICAS APENAS DOS DADOS DE TREINAMENTO

DESENVOLVIMENTO

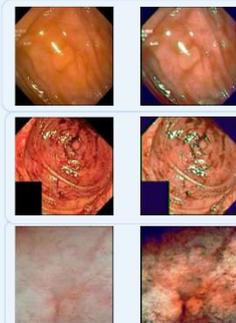
PARA O GERADOR DA PADRONIZAÇÃO ADOTOU-SE UMA U-NET - FACILITANDO A CONSERVAÇÃO DAS CARACTERÍSTICAS ORIGINAIS DA IMAGEM GRAÇAS ÀS “SKIP CONNECTIONS” - E PARA OS CLASSIFICADORES OU DISCRIMINADORES UTILIZOU-SE UMA RESNET PARA EXTRAIR AS CARACTERÍSTICAS DOS PARES DE IMAGEM. COMPUTOU-SE A DIFERENÇA ABSOLUTA ENTRE OS MAPAS DE CARACTERÍSTICAS DAS DUAS MENSAGENS A QUAL FOI FORNECIDA POR ENTRADA DE UMA REDE COMPLETAMENTE CONECTADA, INTERCALADAS POR RELUS E UMA SIGMOIDE AO FINAL PARA GARANTIR QUE A SAÍDA ESTÁ EM [0, 1].

COMO FUNÇÃO DE PERDA ADOTOU-SE A CONTRASTIVE LOSS. ADICIONAMENTO A PERDA DO DISCRIMINADOR RESPONSÁVEL PELA CONSERVAÇÃO DO CONTEÚDO FOI REGULARIZADO PELA PENALIZAÇÃO L1 PARA INCENTIVAR A CONSERVAÇÃO DE CARACTERÍSTICAS DE BAIXA FREQUÊNCIA OU REGIONAIS.

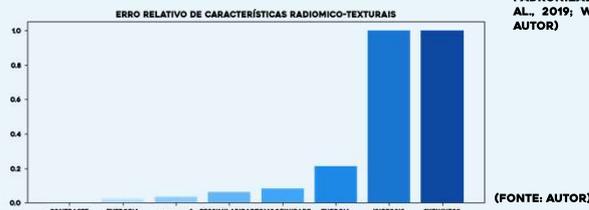
O TREINAMENTO FOI FEITO ALTERNANDO A APRENDIZAGEM DO GERADOR E DOS DISCRIMINADORES PARA QUE SEMPRE UM DOS LADOS OFEREÇA UM DESAFIO PARA O OUTRO E PERMITE A APRENDIZAGEM.

RESULTADOS & CONCLUSÕES

APESAR DO GERADOR TREINADO PRODUZIR IMAGENS SEMANTICAMENTE SIMILARES ÀS ORIGINAIS E MAIS PARECIDAS COM AS DEMAIS IMAGENS PADRONIZADAS - QUE APRESENTAM REDUÇÃO DO SANGUE, RECOLORIZAÇÃO DO MUCO, ILUMINAÇÃO MAIS CONSISTENTE E TEXTURA MAIS HOMOGÊNEA - OBSERVA-SE INTENSA MUDANÇA DE ALGUMAS CARACTERÍSTICAS RADIÔMICO-TEXTURAIS DA IMAGEM, ESPECIALMENTE NO DATASET CP-CHILD - COMO ILUSTRA O GRÁFICO.



COLUNA DA ESQUERDA: IMAGENS ORIGINAIS; COLUNA DA DIREITA: IMAGENS PADRONIZADAS - FONTE: JHA ET AL., 2019; WEI; JINGE TIAN, 2020; AUTOR)



(FONTE: AUTOR)

REFERÊNCIAS

- ISOLA, P. ET AL. IMAGE-TO-IMAGE TRANSLATION WITH CONDITIONAL ADVERSARIAL NETWORKS. [S.L.]: ARXIV. DISPONÍVEL EM: <HTTP://ARXIV.ORG/ABS/1611.07004>. ACESSO EM: 9 FEV. 2025. , 26 NOV. 2018
- LIANG, G. ET AL. GANAI: STANDARDIZING CT IMAGES USING GENERATIVE ADVERSARIAL NETWORK WITH ALTERNATIVE IMPROVEMENT. 2019.
- JHA, D. ET AL. KVASIR-SEG. [S.L.]: ARXIV. DISPONÍVEL EM: <HTTP://ARXIV.ORG/ABS/1911.07069>. ACESSO EM: 23 OUT. 2024.
- SILVA, H. E. C. D. ET AL. THE USE OF ARTIFICIAL INTELLIGENCE TOOLS IN CANCER DETECTION COMPARED TO THE TRADITIONAL DIAGNOSTIC IMAGING METHODS: AN OVERVIEW OF THE SYSTEMATIC REVIEWS. PLOS ONE, V. 18, N. 10, P. E0292063, 5 OUT. 2023.
- WEI, W.; JINGE TIAN. CP-CHILD.ZIP. [S.L.]: FIGSHARE. DISPONÍVEL EM: <HTTPS://FIGSHARE.COM/ARTICLES/CP-CHILD_ZIP/12554042/P>. ACESSO EM: 27 OUT. 2024.