

Otimização da parametrização em exames de FMD
utilizando aprendizado profundo

LUCAS HENRIQUE CASTELO NOVO

Trabalho de Conclusão de Curso
MBA em Inteligência Artificial e Big Data

UNIVERSIDADE DE SÃO PAULO
Instituto de Ciências Matemáticas e de Computação

Otimização da parametrização em
exames de FMD utilizando aprendizado
profundo

LUCAS HENRIQUE CASTELO NOVO

USP - São Carlos

2024

LUCAS HENRIQUE CASTELO NOVO

Otimização da parametrização em exames de FMD utilizando aprendizado profundo

Trabalho de conclusão de curso apresentado ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientadora: Profa. Dra. Roseli Aparecida Francelin Romero.

USP - São Carlos

2024

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

C349o CASTELO NOVO, LUCAS HENRIQUE
Otimização da parametrização em exames de FMD
utilizando aprendizado profundo / LUCAS HENRIQUE
CASTELO NOVO; orientadora Roseli Aparecida
Francelin Romero. -- São Carlos, 2024.
45 p.

Trabalho de conclusão de curso (MBA em
Inteligência Artificial e Big Data) -- Instituto de
Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2024.

1. FMD. 2. DEXINED. 3. HED. 4. FMDVIEW. 5.
DETECÇÃO DE BORDAS. I. Romero, Roseli Aparecida
Francelin, orient. II. Título.

Bibliotecários responsáveis pela estrutura de catalogação da publicação de acordo com a AACR2:
Gláucia Maria Saia Cristianini - CRB - 8/4938
Juliana de Souza Moraes - CRB - 8/6176

DEDICATÓRIA

“Este trabalho de pesquisa é dedicado a todos os pacientes, médicos e funcionários da Bview Sistemas que contribuíram com exames, experiência e conhecimentos. As incontáveis horas de troca de ideias fizeram a diferença. Fica meus sinceros agradecimentos a todos.”

AGRADECIMENTOS

Aos Dr. Andrei Carvalho Sposito, Dr. Íkaro Breder, Dr. Thiago Quinaglia, que contribuíram com todo conhecimento para auxiliar no desenvolvimento do software de FMD.

A Dra. Sheila Tatsumi Kimura Medorima, pelo incentivo e incansável apoio durante toda a jornada de desenvolvimento

As Dra. Isabella Bonilha e Dra Vaneza Lira W. Wolf pelas inúmeras coletas de dados e horas de empenho analisando vídeos e identificando problemas.

A Dra. Marta Duran Fernandez pela ajuda com a parte técnica e incentivo ao meu aprimoramento pessoal, trazendo sempre novidades e desafios.

Ao Danilo Henrique de Sousa Brittner, profissional dedicado que me ajudou em grande parte da programação e desenvolvimento das ferramentas que hoje estão presentes no FMDview.

EPÍGRAFE

“Ciência e tecnologia revolucionam nossas vidas, mas a memória, a tradição e o mito moldam nossas respostas”.

Arthur Schlesinger - Historiador

RESUMO

CASTELO NOVO, L. H. **Otimização da parametrização em exames de FMD utilizando aprendizado profundo.** 2024. 52 f. Trabalho de conclusão de curso (MBA em Inteligência Artificial e Big Data) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2024.

Exame de FMD envolve a avaliação da função endotelial realizada pela Dilatação Mediada pelo Fluxo (FMD do inglês: Flow-Mediated Dilatation). Este é um método não invasivo, confiável e de fácil execução que utiliza a ultrassonografia de alta resolução para avaliar a resposta vascular ao estresse de cisalhamento (hiperemia reativa). Mesmo na ausência de obstrução coronariana importante, a disfunção endotelial pode provocar isquemia miocárdica. Portanto, esta avaliação pode ser utilizada em pesquisas clínicas para avaliar a progressão da doença aterosclerótica possibilitando intervenções precoces em casos de disfunção endotelial. Entretanto, esta técnica apresenta algumas limitações e requer técnicas precisas de medição, pois a interpretação dos dados pode ser influenciada pela habilidade do operador e/ou pela condição do paciente e requer também a presença de um especialista com muita experiência na área.

Neste trabalho, é realizada uma investigação sobre como aprimorar o exame de FMD visando torná-lo mais preciso com o uso de técnicas de Inteligência Artificial (IA) para detecção de bordas, visando minimizar as interferências causadas por artefatos presentes nas imagens de ultrassom da artéria.

Dentre os desafios desta técnica encontra-se a dificuldade de detecção de bordas arteriais, por exemplos como detecção de artefatos na imagem, inclinação arterial e tônus vascular dentre outros. Resultados obtidos mostram que modelos de redes neurais profundas combinadas com técnicas de processamento de imagens podem contribuir para a melhoria do exame de FMD.

Palavras-chave: FMD; DEXINED; HED; FMDVIEW.

ABSTRACT

CASTELO NOVO, L. H. **Optimization of parameterization in FMD exams using deep learning.** 2024. 52 f. Trabalho de conclusão de curso (MBA em Inteligência Artificial e Big Data) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2024.

The FMD exam involves the evaluation of endothelial function performed by Flow-Mediated Dilation (FMD). This is a non-invasive, reliable, and easy-to-perform method that uses high-resolution ultrasound to assess vascular response to shear stress (reactive hyperemia). Even in the absence of significant coronary obstruction, endothelial dysfunction can cause myocardial ischemia. Therefore, this evaluation can be used in clinical research to assess the progression of atherosclerotic disease, allowing for early interventions in cases of endothelial dysfunction. However, this technique has some limitations and requires precise measurement techniques, as data interpretation can be influenced by the operator's skill and/or the patient's condition, and it also requires the presence of a highly experienced specialist.

This work investigates how to improve the FMD exam to make it more accurate by using Artificial Intelligence (AI) techniques for edge detection, aiming to minimize the interferences caused by artifacts present in the ultrasound images of the artery.

Among the challenges of this technique is the difficulty of detecting arterial borders due to factors such as image artifacts, arterial inclination, and vascular tone, among others. The results obtained show that deep neural network models combined with image processing techniques can contribute to improving the FMD exam.

Keywords: FMD; DEXINED; HED; FMDVIEW.

LISTA DE ILUSTRAÇÕES

Figura 1 - Extração de características de borda.....	22
Figura 2- Arquitetura do software atual	23
Figura 3 - Seleção de regiões de interesse (ROI) de fluxo e diâmetro	25
Figura 4 - Parâmetro de Teste e Calibração de escalas	25
Figura 5 - Parâmetros do filtro de análise de Bordas	25
Figura 6 - Código fonte da rotina de análise	26
Figura 7 - Filtro de Nona Ordem.....	26
Figura 8 - Multiplicador de Valor de Pixels	26
Figura 9 - Filtro de uma faixa de cor	27
Figura 10 - Ferramenta de busca de borda	27
Figura 11- Como funciona a busca de parede	27
Figura 12 - Conversão de Pixels x cm.....	28
Figura 13 - Marcação de Bordas.....	28
Figura 14 - o BSDS300 (MARTIN et al., 2001), as imagens foram segmentadas por 3 pessoas vide ilustração.....	32
Figura 15 - BSDS500, imagens e suas segmentações por humanos (ARBELÁELZ et al., 2011).....	33
Figura 16 - Fluxograma da arquitetura proposta (DexiNed)	34
Figura 17 - Comparativo de filtragem	35
Figura 18 - Detecção de Bordas Comparativo Amostra 1	36
Figura 19 - Estrutura Geral do Vaso Sanguíneo.....	37

LISTA DE TABELAS

Tabela 1 - Tabela comparativa de diâmetros obtidos por Amostra.....	39
---	----

LISTA DE ABREVIATURAS E SIGLAS

Elemento opcional. É composto de uma relação alfabética das abreviaturas e siglas utilizadas no texto seguido do seu significado.

FMD	–	Flow-Mediated Dilation
DL	–	Redes Neurais de Profundas

SUMÁRIO

1. INTRODUÇÃO	19
2. REVISÃO BIBLIOGRÁFICA	21
2.1 Métodos de visão aplicada ao FMD	21
3. O SISTEMA ATUAL	23
3.1. Arquitetura Geral	23
3.2. OBS Studio:	24
3.3. FMDVIEW User:	24
3.4. FMDVIEW Analyzer:	24
4. DESENVOLVIMENTO	29
4.1. Metodologia	29
4.2. HED	29
4.3. DexiNed (Kornia)	31
5. RESULTADOS.....	35
5.1. Comparativo.....	35
6. CONCLUSÃO	41

1. INTRODUÇÃO

A avaliação da função endotelial realizada pela dilatação mediada pelo fluxo (FMD) é um método não invasivo e de fácil execução que utiliza a ultrassonografia de alta resolução para avaliar a resposta vascular ao estresse de cisalhamento (hiperemia reativa). Mesmo na ausência de obstrução coronariana importante, a disfunção endotelial pode provocar isquemia miocárdica. Portanto, esta avaliação pode ser utilizada em pesquisas clínicas para avaliar a progressão da doença aterosclerótica possibilitando intervenções precoces em casos de disfunção endotelial. Entretanto, esta técnica apresenta algumas limitações e requer técnicas precisas de medição, pois a interpretação dos dados pode ser influenciada pela habilidade do operador e/ou pela condição do paciente. A avaliação da função endotelial, geralmente, é realizada na artéria braquial esquerda, aproximadamente dois centímetros acima da fossa antecubital. O monitoramento do diâmetro arterial obtido em eixo longitudinal é contínuo, em sua fase basal, seguido de fase isquêmica por compressão temporária com uso do manguito acoplado a manômetro de mercúrio no antebraço esquerdo, 50 mmHg acima da pressão arterial sistólica. Após cinco minutos, a pressão do manguito é liberada e a variação do fluxo é registrada nos primeiros 30 segundos da hiperemia reativa. Posteriormente, há a comparação entre as fases do teste a fim de avaliar a capacidade de resposta do endotélio vascular.

Dentre os desafios desta técnica, encontra-se a dificuldade de detecção de bordas arteriais, devido a inúmeras condições do paciente e do executor do exame, por exemplo, detecção de artefatos na imagem, inclinação arterial e tônus vascular dentre outros.

O sistema existente pode ser aprimorado com o uso de IA para detectar as melhores combinações de parâmetros de ajuste nas imagens, oferecer benefícios significativos, melhorar a eficiência e a precisão na identificação tornando os processos mais confiáveis e o resultado mais seguro.

Para isto serão empregadas técnicas de Redes Neurais Profundas (DL), que são um tipo de redes neurais com múltiplas camadas interligadas conhecidas por sua capacidade de aprender e modelar relações complexas entre entradas e saídas de dados, podendo obter resultados difíceis de alcançar com programação tradicional.

São ideais quando há um grande volume dados disponíveis e apresentando uma convergência grande para alcançar excelentes resultados de classificação. Cada neurônio na camada de entrada recebe informação da imagem e pesos aleatórios (entre zero e um), tendo como

referência que pesos baixos indicam menos probabilidade de associação com o objeto de estudo, e pesos altos indicam o contrário.

As DL podem auxiliar na melhor parametrização de filtros visando evitar a detecção de anomalias, com o propósito de minimizar os fatores de erros encontrados e auxiliar na retomada da credibilidade dos dados do FMD.

Neste trabalho, serão investigados alguns modelos DL para determinar qual é o mais adequado para a calibração nas imagens.

2. REVISÃO BIBLIOGRÁFICA

Neste capítulo, será abordada a importância da literatura existente sobre o exame de FMD, destacando a escassez de publicações específicas e a relevância da padronização dos procedimentos para reduzir erros durante a execução do exame. Serão discutidos os principais fatores que contribuem para a variabilidade nos resultados, como o manuseio pelos operadores e a detecção de bordas arteriais. Além disso, será analisado o uso de ferramentas tecnológicas, incluindo inteligência artificial, para otimizar o processo e aumentar a confiabilidade dos diagnósticos.

2.1 Métodos de visão aplicada ao FMD

Após uma extensa pesquisa sobre o tema, restou comprovado que não há muita literatura acadêmica voltada exatamente para o exame.

Perante a literatura encontrada em sua maioria refere-se a informações relacionadas aos procedimentos do exame que é essencial para padronizar a atuação do médico afim de reduzir a variabilidade da amostragem.

Revela-se como um dos grandes fatores de erros do FMD o manuseio e a avaliação do especialista que conduz o exame, como relatado por Thijssen et al. (2019): "Fatores metodológicos (experiência laboratorial) - Possivelmente, a fonte metodológica mais importante de variabilidade na FMD é a formação adequada dos operadores. A orientação e o treinamento por colegas especialistas parecem cruciais, uma vez que a menor variabilidade está presente em laboratórios mais experientes..." (tradução nossa)¹.

Mesmo com certo treinamento por parte dos operadores, ainda existem fatores críticos de erro, como a análise de bordas para realizar a detecção das paredes da artéria. Neste ponto, é possível encontrar artigos direcionados utilizando ferramentas clássicas de visão, mas pouco se discute no contexto de inteligência artificial e aprendizagem de máquina.

Entre as referências encontradas em artigos sobre o exame, é importante ressaltar o trabalho de Woodman et al. (2001): "Desenvolvemos um programa de software computadorizado de detecção de bordas e rastreamento de parede para permitir a medição

¹ Methodological factors (lab experience)

Possibly the most important methodological source of variability in the FMD is proper operator training. Guidance and training by expert colleagues seem crucial, since lower variability is present in more experienced laboratories..." - Thijssen DHJ, Bruno RM, van Mil A, Holder SM, Fata F, Greyling A

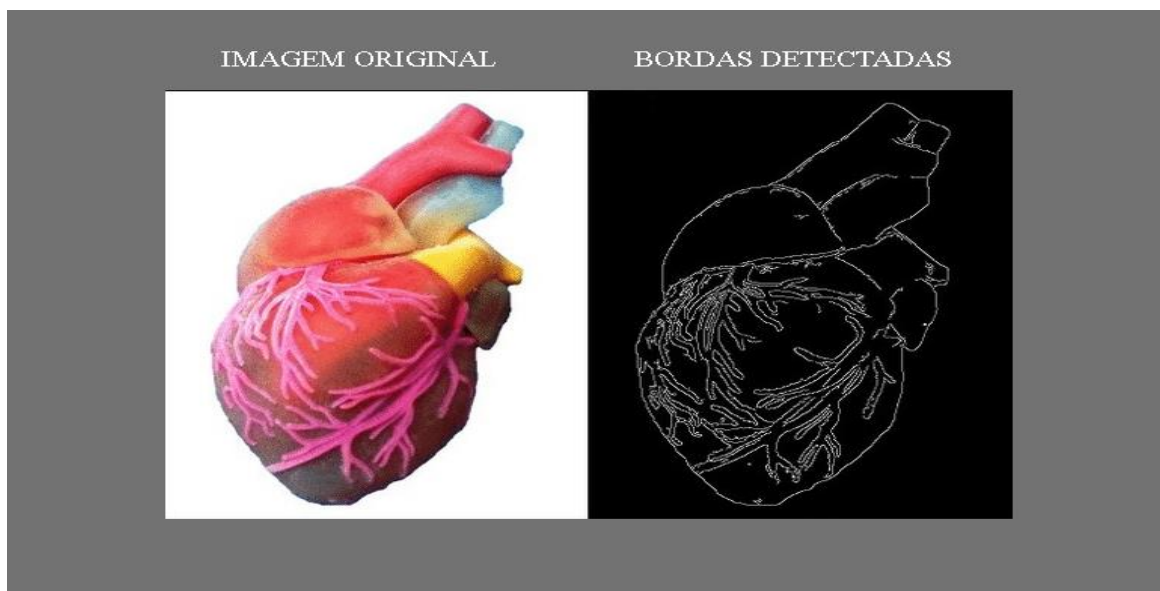
precisa e reprodutível do diâmetro arterial para estudos clínicos da função endotelial na circulação periférica" (tradução nossa)², sendo este trabalho a base para o desenvolvimento do FMDviewer, software de análise arterial.

Torna-se ainda mais desafiador este teste, quando é constatado que ainda não existe nenhum modelo padrão ouro, devido a própria falha de ferramentas de visão clássica concatenar em toda a gama de variabilidade genética até a complexa gama de parâmetros que dependem do operador.

Para a otimização e eficácia do Software atual devem ser reduzidos os fatores de erro, essencialmente na detecção de bordas, usufruindo de ferramentas de detecção de bordas eletrônicas a fim de auxiliar o operador a obter a melhor análise do vídeo em sua totalidade, minimizando os impactos da variabilidade humana no teste, elevando a confiabilidade dos resultados obtidos.

A detecção de bordas eletronicamente é uma forma de identificar e extrair características de uma imagem através de uma variedade de métodos matemáticos, identificando assim mudanças bruscas de comportamento do brilho da imagem, estes pontos de variação são nomeados de Bordas (ou limites) da imagem.

Figura 1 - Extração de características de borda



² Methodological factors (lab experience)

Possibly the most important methodological source of variability in the FMD is proper operator training. Guidance and training by expert colleagues seem crucial, since lower variability is present in more experienced laboratories..." - Thijssen DHJ, Bruno RM, van Mil A, Holder SM, Fata F, Greyling A

3. O SISTEMA ATUAL

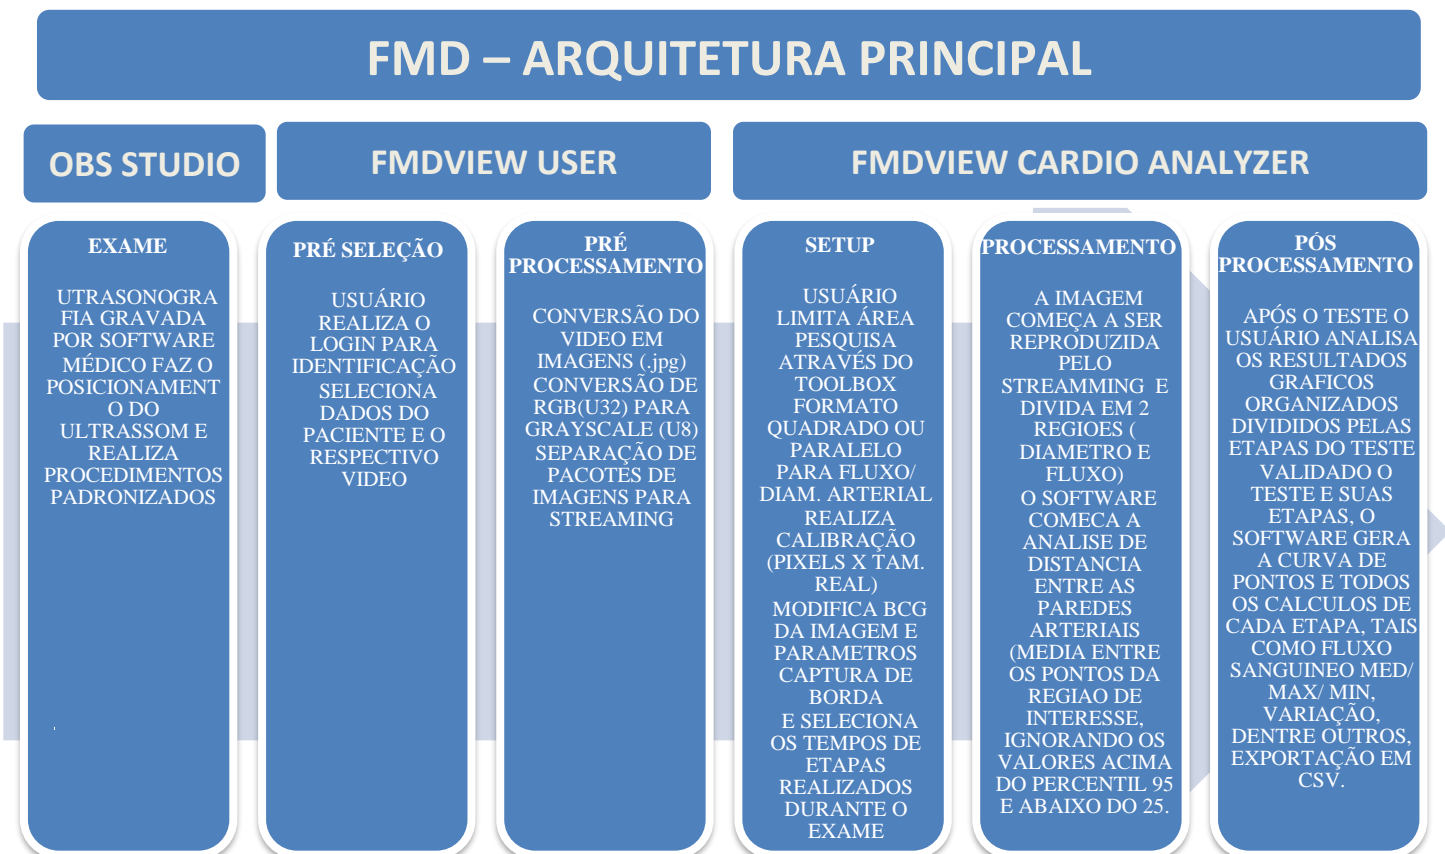
Neste capítulo, será detalhada a arquitetura atual do sistema, que consiste em um conjunto de softwares usados para captura, processamento e análise de imagens de ultrassom no exame de FMD. Serão apresentados os três principais componentes: o **OBS Studio**, que realiza a gravação em tempo real das imagens; o **FMDView User**, responsável pela coleta de informações do paciente e pela organização dos dados; e o **FMDView Cardio Analyzer**, que realiza a análise e a parametrização das imagens. Além disso, serão descritas as ferramentas e algoritmos utilizados na detecção de bordas e na calibração das imagens, fundamentais para a precisão do exame.

3.1. Arquitetura Geral

A arquitetura atual do sistema consiste em conjunto de softwares, sendo estes: OBS Studio realiza a captura e gravação de imagens do ultrassom; o pós-processamento é dividido em duas aplicações - FMDView User utilizado para a seleção de informações e entrada de dados do paciente e FMDView Cardio Analyzer utilizado para parametrização da análise e posterior processamento.

Para melhor entendimento da arquitetura do sistema, faz-se necessário o detalhamento das funcionalidades dos softwares.

Figura 2- Arquitetura do software atual



3.2. OBS Studio:

Por meio de um dispositivo de conexão, é possível realizar uma captura em tempo real da imagem em alta definição, permitindo que o OBS grave todo o processo em qualidade FULLHD. Depois de concluído o procedimento, o vídeo do exame é arquivado para ser posteriormente avaliado.

3.3. FMDVIEW User:

Após inserir o vídeo na lista de avaliação, o profissional acessa o sistema para iniciar a identificação do paciente. Nesse momento, informações como nome, idade, doenças e outros detalhes são registradas no sistema e o vídeo é associado ao número do paciente.


Após a coleta de dados, o FMDVIEW User alterna dinamicamente para o aplicativo FMDVIEW Analyzer.

3.4. FMDVIEW Analyzer:

A partir do FMDVIEW User, o FMDVIEW Analyzer inicia-se o processo de conversão do vídeo transformando seus frames em imagens .jpg (Joint Photographics Experts Group). As dimensões são mantidas, no entanto, as propriedades de cor RGB (RED, Green, Blue) são modificadas para escala de cinza. O resultado são pacotes de cerca de três minutos, contendo 180 frames com FPS (Frames per second) fixado em 60 frames. Esses pacotes são projetados para um streaming durante a análise e reprodução do vídeo pelo software.

Após a conclusão da fase de conversão e organização dos dados, a aplicação espera pela configuração do utilizador para restringir a área de interesse por meio de uma caixa de ferramentas em formato quadrado ou paralelo. Além disso, é possível selecionar a segmentação das áreas de fluxo e diâmetro na imagem do ultrassom.

Figura 3 - Seleção de regiões de interesse (ROI) de fluxo e diâmetro



Definida a região de interesse, o próximo passo é realizar a calibração (proporção entre pixels e centímetros) e ajustar as configurações do filtro BCG para identificar com maior precisão o contorno arterial.

Figura 4 - Parâmetro de Teste e Calibração de escalas

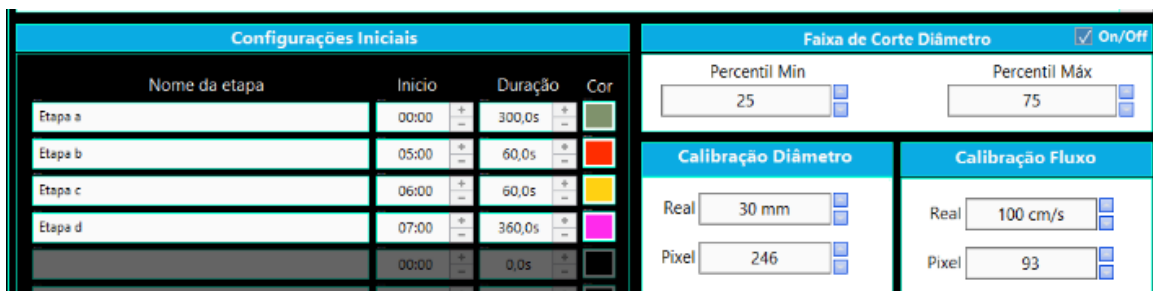



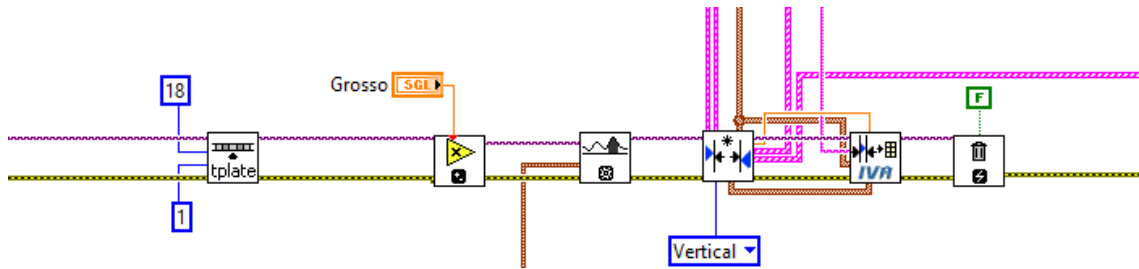
Figura 5 - Parâmetros do filtro de análise de Bordas



A parametrização inicial pode não ser a melhor definição para toda a extensão do teste, devido a variabilidade de escolhas a eficácia do software fica muito dependente da interpretação do avaliador.


A detecção atual da parede arterial do FMDView foi desenvolvida através de uma varredura de pixels utilizando-se de ferramentas de detecção de borda e rastreamento de parede, tendo como referência o trabalho de Woodman et al. (2001).

Figura 6 - Código fonte da rotina de análise



Para um melhor entendimento de como funciona o sistema atual, as ferramentas da análise atual serão descritas abaixo:


Figura 7 - Filtro de Nona Ordem



IMAQ 9ª ORDER FILTER: Ordena ou classifica os valores de pixel ao redor do pixel que está sendo processado. Os dados são colocados em uma matriz e o pixel que está sendo processado é definido como o enésimo valor do pixel, sendo o enésimo pixel o número ordenado.


Uma operação mediana (pixel central) é vantajosa porque padroniza os valores do nível de cinza sem modificar significativamente a forma dos objetos ou o brilho geral da imagem. Você pode usar este VI para aplicar um filtro de mediana selecionando a ordem correta, $(f^2 - 1) / 2$, onde f é o tamanho da matriz de convolução.

Figura 8 - Multiplicador de Valor de Pixels




IMAQ MULTIPLY: Duplicação a imagem base realizando uma multiplicação por valor definido pelo usuário correlacionado ao parâmetro de cor.

Figura 9 - Filtro de uma faixa de cor




IMAQ TRESHROLD: Seleccionando uma faixa mínima e máxima de escala de cinza esta ferramenta realiza uma filtragem. Em nossa aplicação estamos utilizando somente o valor mínimo do filtro afim de eliminar possíveis fragmentos de pixel no meio da artéria.

Figura 10 - Ferramenta de busca de borda




IVA Gauge Algorithm Minimum: mede a distância horizontal ou vertical, entre o centro e os limites da área de busca de uma imagem.

Figura 11- Como funciona a busca de parede



Retorna a posição dos pontos (pixels) encontrados e através do ponto máx. e min do encontrado determina a reta da parede de pixels.

Figura 12 - Conversão de Pixels x cm



IVA STORE GAUGE RESULTS: realiza a calibração da distância (conversão para mm) dos pontos selecionados e a medição entre as duas extremidades arteriais encontradas.

Os pontos resultantes de toda essa análise são marcados na imagem e exibidos ao usuário conforme a imagem abaixo:

Figura 13 - Marcação de Bordas



4. DESENVOLVIMENTO

Neste capítulo, serão apresentados dois métodos de detecção de bordas aplicados no exame de FMD: o HED (Detecção de Bordas Aninhadas Holisticamente) e o DexiNed (Rede de Inserção Extrema Densa para Detecção de Bordas). Para tanto foram utilizadas amostras de oito pacientes com dados adquiridos de diferentes aparelhos de ultrassom, garantindo variabilidade e precisão. O primeiro método, HED, baseia-se na arquitetura de redes neurais convolucionais VGG. O segundo método, DexiNed, utiliza padrões avançados de segmentação de bordas, como o BSDS300 e o BSDS500, mostrando-se superior em termos de nitidez e precisão das bordas. Ambos os métodos serão discutidos em termos de suas arquiteturas, desempenho e vantagens em relação a métodos tradicionais de detecção de bordas.

4.1. Metodologia

Para realizarmos as comparações entre os métodos utilizamos um conjunto de dados de oito pacientes, selecionados de forma aleatória dentro do banco de dados e para aumentar ainda mais a variabilidade utilizamos aquisições de aparelhos de ultrassom diferentes. Sendo metade das amostras de um ultrassom da marca Philips e outra da (GE) General Electric.

Utilizando as amostras, foi desenvolvido um código para randomização do conjunto em amostras para treinamento e amostras para validação das IA garantindo assim que as ferramentas utilizadas terão os mesmos conjuntos.

4.2. HED

O primeiro método proposto é a utilização da Detecção de bordas aninhadas holisticamente (HED) auxiliando o operador a obter a melhor análise do vídeo em sua totalidade, minimizando os impactos da variabilidade humana no teste, elevando a confiabilidade dos resultados obtidos. Utilizando o algoritmo de aprendizagem profunda com base no artigo: Detecção de bordas aninhadas holisticamente (HED), método esse que apresenta uma arquitetura de blocos VGG (Grupo de Geometria Visual) e detecta bordas com muita eficiência e agilidade frente a outros métodos de detecção tradicionais.

A VGG Network, também conhecida como Rede do Grupo de Geometria Visual, é uma arquitetura de rede neural convolucional bastante reconhecida no campo da visão computacional. Criada pela Universidade de Oxford, é admirada por sua clareza e eficiência na coleta de características visuais, sendo desenvolvida por Karen Simonyan e Andrew Zisserman.

Utilizando redes neurais convolucionais, a VGG Network aceita uma imagem de entrada, normalmente pré-processada para garantir a formatação adequada, e a analisa por meio de camadas convolucionais e de pooling para capturar as características visuais. Sua arquitetura é composta por conjuntos de camadas convolucionais seguidas de pooling, apresentando camadas totalmente conectadas.

Um dos benefícios dessa arquitetura é a capacidade de implementar transfer learning, permitindo a reaplicação dos pesos já treinados em novos conjuntos de dados, o que pode agilizar o processo de treinamento e aprimorar a performance em tarefas particulares. No entanto, apesar de sua eficiência, a VGG Network pode encontrar dificuldades, como um treinamento prolongado e a ocorrência de overfitting em datasets menores.

Bastante empregada em tarefas como identificação de objetos, categorização de imagens e reconhecimento de padrões, foi uma das precursoras das redes neurais profundas no campo da visão computacional. Apesar do aparecimento de novas arquiteturas, como ResNet e Inception, que oferecem desempenho superior, a VGG Network permanece em evidência devido à sua simplicidade e à facilidade na implementação.

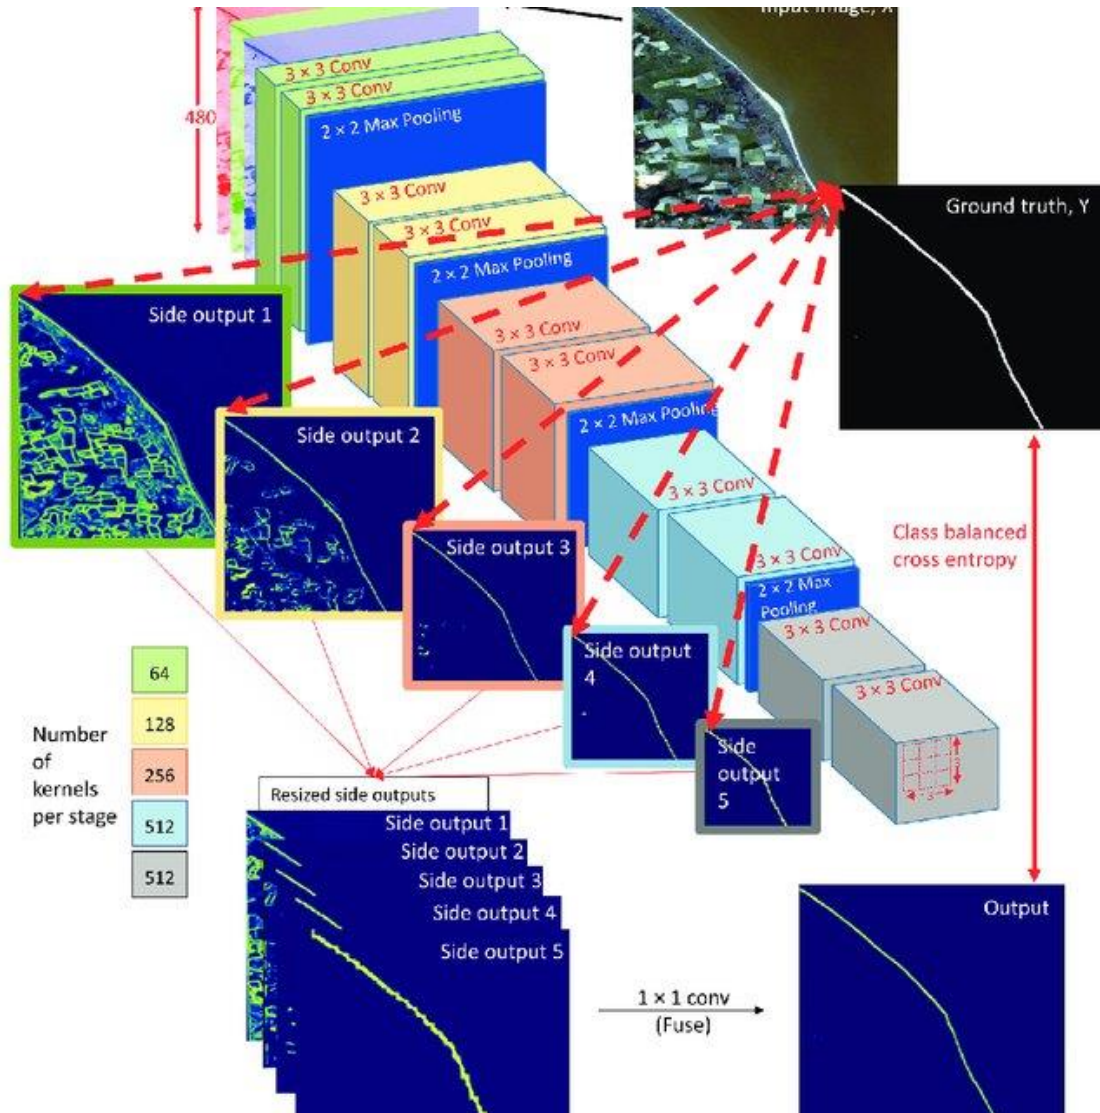
A arquitetura final da rede HED, adota uma VGGnet modificada compreendendo 5 estágios com diferentes avanços e tamanhos de campo receptivos conectando camadas de saída laterais a camadas convolucionais específicas e cortando o último estágio para reduzir a intensidade computacional.

Realiza uma previsão imagem a imagem por meio de um modelo de aprendizado profundo que aproveita redes neurais convulsionais. Aprendendo automaticamente representações hierárquicas ricas (guiadas por supervisão profunda nas respostas laterais) que são importantes para resolver a ambiguidade desafiadora na detecção de bordas e limites de objetos.

Em conclusão, a arquitetura HED proposta com supervisão profunda permite previsões de mapas de bordas progressivamente grosseiras a finas, de local a global. Ele supera arquiteturas alternativas em termos de precisão média e pontuação nos conjuntos de dados validados. A supervisão profunda desempenha um papel vital na garantia da conectividade do caminho da rede e na atualização dos parâmetros da camada de saída por meio da propagação

de erros. Esta abordagem enfatiza a importância da supervisão profunda para obter resultados de detecção de bordas de alta qualidade em múltiplas escalas.

Figura 14 - Arquitetura base da HED



Fonte: Online and HED Paper

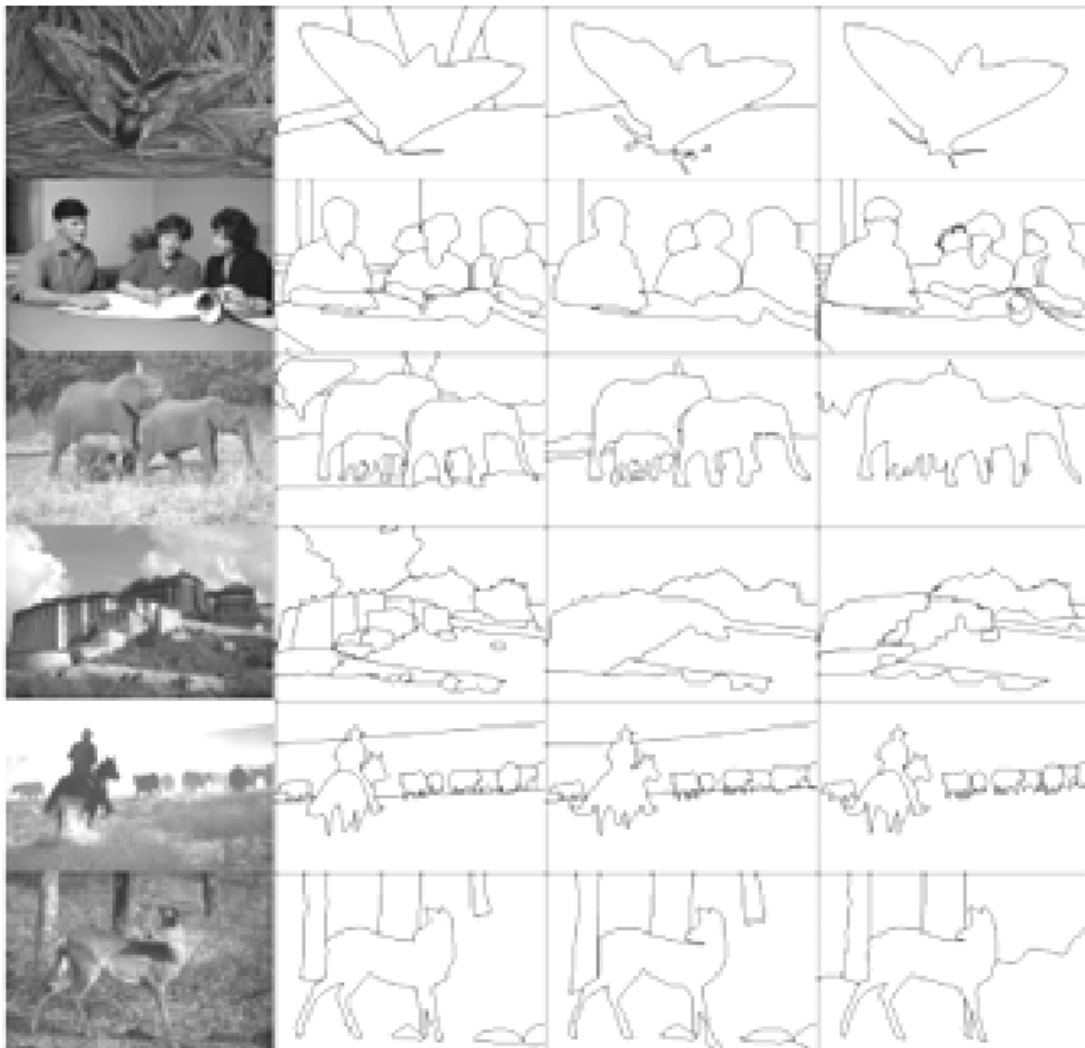
4.3. DexiNed (Kornia)

Para o segundo método optamos por utilizar uma nova arquitetura chamada Rede de Inserção Extrema Densa para Detecção de Borda (DexiNed), que utiliza conjuntos treinados conforme os padrões BSDS300 e valida no BSDS500 e foi proposta por Xavier et al.

“O BSDS300 calcula uma nota para técnicas de detecção de bordas que caracterizem as fronteiras (boundaries) ou contornos (contours) dos objetos nas imagens, com dois objetivos: 1- servir de base de comparação para diferentes algoritmos; e, 2- avaliar ao longo do tempo o

progresso das técnicas em relação ao nível de desempenho humano.” - Segmentação de Imagens Naturais Baseada em Modelos de Cor de Diferença Cromática, Máscaras de Detecção de Contornos e Supressão Morfológica de Texturas - DIOGO CAVALCANTI COSTA ,2015, Recife.


Figura 15 - o BSDS300 (MARTIN et al., 2001), as imagens foram segmentadas por 3 pessoas vide ilustração.



O conjunto BSDS500 por sua vez é uma expansão do seu antecessor, o BSDS300, que é composto por mais 200 imagens para testes. O conjunto segue as diretrizes de verdade fundamental (ground truths), que foram gerados por cinco pessoas diferentes e posteriormente unificados.

Além disso o conjunto que já contava com a análise de detecção de contornos dos objetos avaliada pelas curvas precisão/revocação, passa a contemplar três novos critérios de avaliação de técnicas de segmentação de imagens baseadas em regiões, hierárquicas ou não: Variação da Informação (Variation of Information), Índice de Rand (Rand Index) e Cobertura da Segmentação (Segmentation Covering)

Figura 16 - BSDS500, imagens e suas segmentações por humanos (ARBELÁELZ et al., 2011)



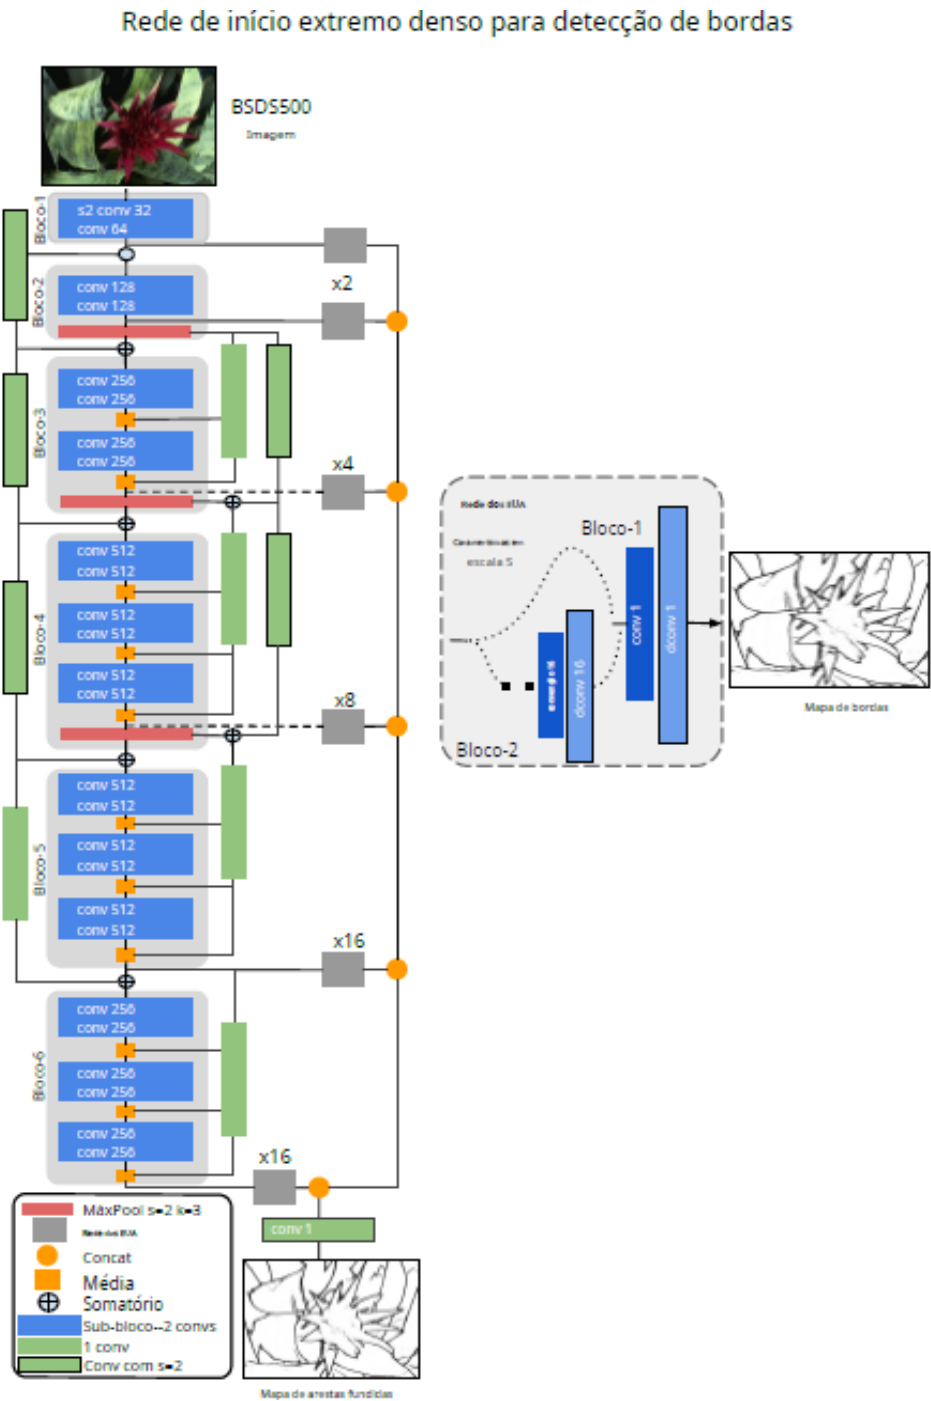
A DexiNed, proposta em 2020, supera outros algoritmos similares e generaliza bem para diversos conjuntos de dados sem ajustes finos. Tendo uma qualidade superior evidente em relação às bordas mais nítidas e mais finas que ele produz, contando com uma arquitetura de dois blocos: Um bloco de Dense Extreme Inception Network (Inception) e upsampling Net (USNet).

A arquitetura Dexi contém seis blocos agindo de forma similar a um codificador. Cada bloco contém em sua construção sub-blocos menores com um grupo de camadas convolucionais, que apresenta em sua funcionalidade realizar a análise de bordas da imagem de entrada em diferentes resoluções.

Através de conexões que acoplam os blocos, bem como seus sub-blocos (representados em formas retangulares cinza-claro e azul na Fig.9) fornecem para uma USNet separada estes dados para gerar um mapa de borda multi escalar.

O modelo possui 35 milhões de parâmetros, uma quantidade semelhante à de classificação e reconhecimento de imagens, e 66 camadas convolucionais. A rede DexiNed produz dois tipos de saída: uma fusão e a média das imagens.

Figura 17 - Fluxograma da arquitetura DexiNed




5. RESULTADOS

Neste capítulo, serão apresentados os resultados da comparação entre diferentes métodos de detecção de bordas em exames de FMD, com quatro amostras de complexidade variável. O modelo DexiNed mostrou-se superior na preservação da camada íntima arterial, superando métodos tradicionais e ao HED, que sofreu com interferências de artefatos e deformação em sua filtragem. Serão discutidos os desafios para implementar esses métodos de inteligência artificial, incluindo a necessidade de treinamento especializado e ajustes no fluxo clínico.

5.1. Comparativo

Dentre todos os dados dos pacientes foram selecionadas quatro imagens para comparação dos métodos, com diferentes níveis de complexidade. Submetidas aos diferentes métodos de detecção, obtivemos os seguintes resultados:


Figura 18 - Comparativo de filtragem



Dentre as amostras selecionadas estão os maiores problemas da captura deste teste, variabilidade de ângulo, contraste e artefatos (interferências no centro da artéria ou nas proximidades da borda).

Realizada a conversão as imagens foram submetidas a uma medição manual para comparação com o sistema atual, para uma comparação de desempenho.


Figura 19 - Detecção de Bordas Comparativo Amostra 1



Após a primeira amostragem dentre os modelos, ficou constatado que todos os métodos responderam bem ao propósito de detecção de bordas, porém quando analisamos o modelo atual (Figura 18 – Quadro inferior esquerdo) podemos observar a presença de artefatos e ao confrontar com os demais modelos perceber que o HED sofre interferência deste artefato, o que viria a ser confirmado após as medições.

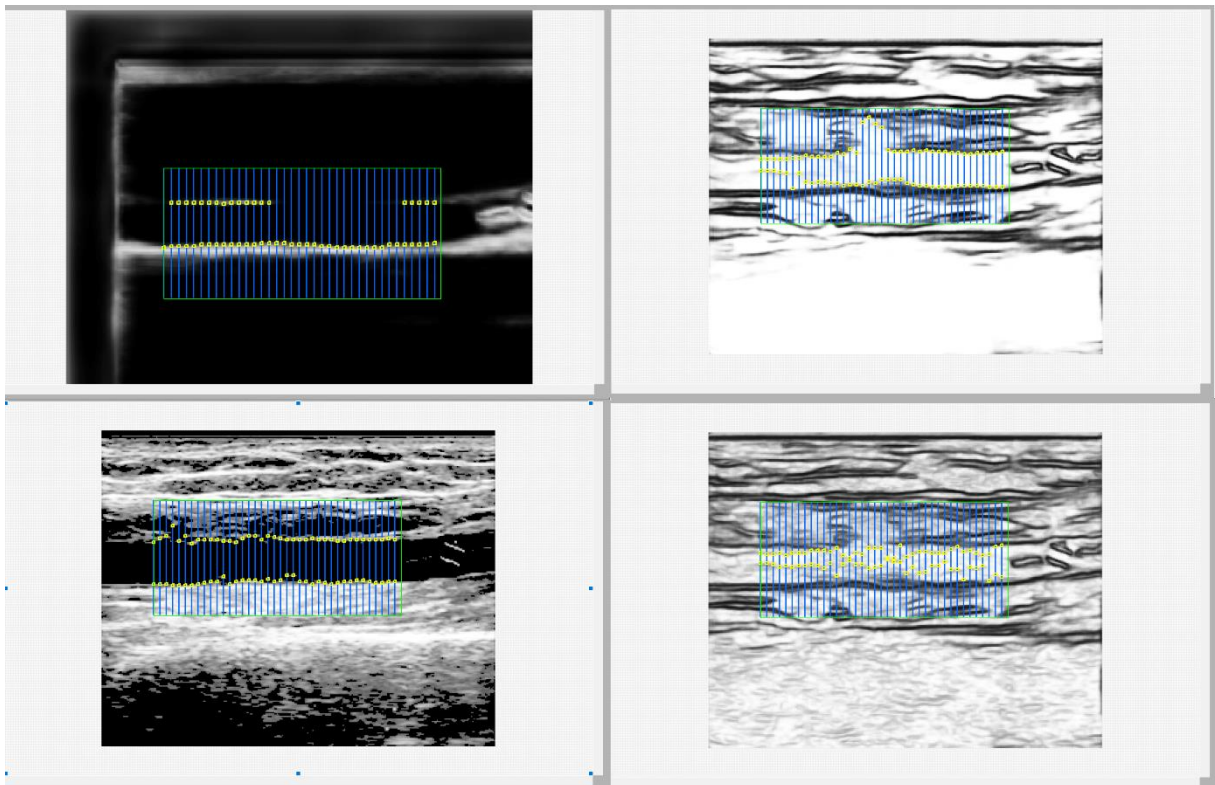
Os modelos da Dexined, apresentaram um comportamento superior ao modelo atual, vale destacar que apesar de ambos aparentarem ter a mesma resposta, a saída das médias apresentando menos filtragem se sobressaía do ponto de vista clínico devido a preservação da intima arterial (camada do endotélio antes da adventícia).

Figura 20 - Estrutura Geral do Vaso Sanguíneo

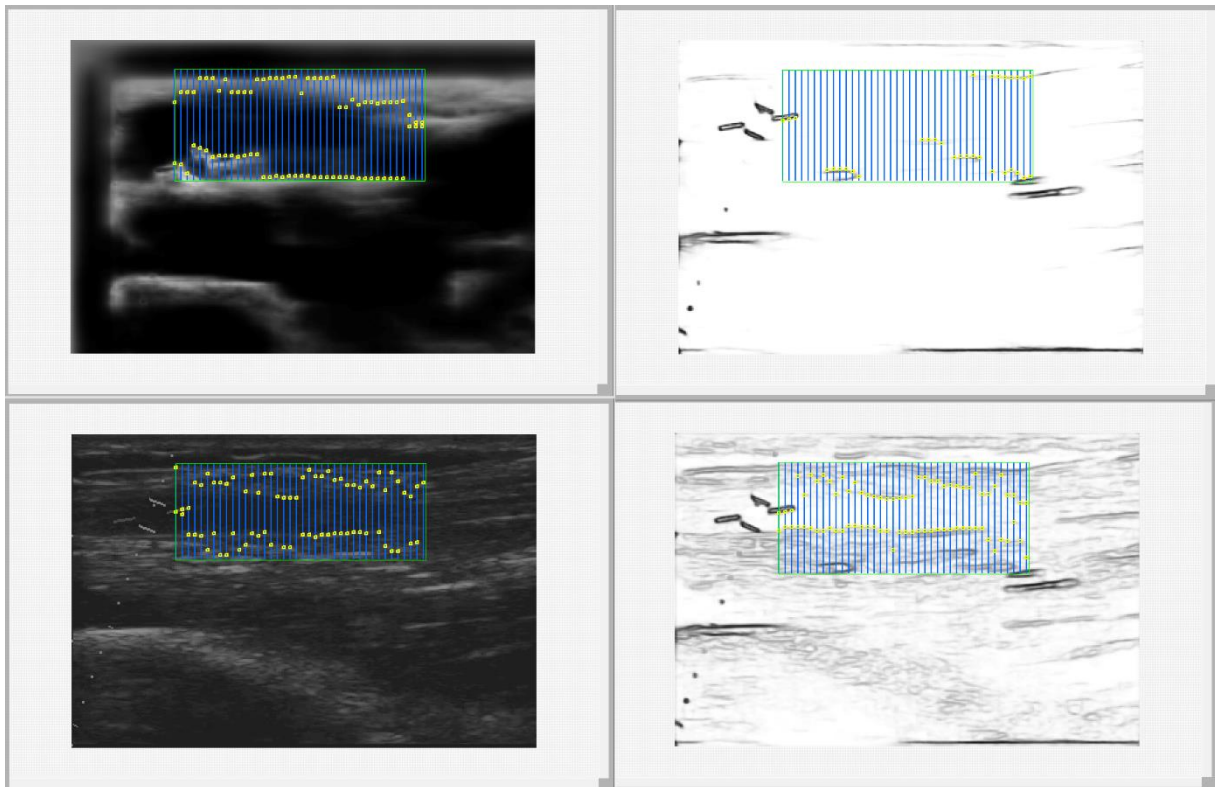


Fonte: Unifal-MG, 2024

Figura 21 - Detecção de Bordas Comparativo Amostra 2

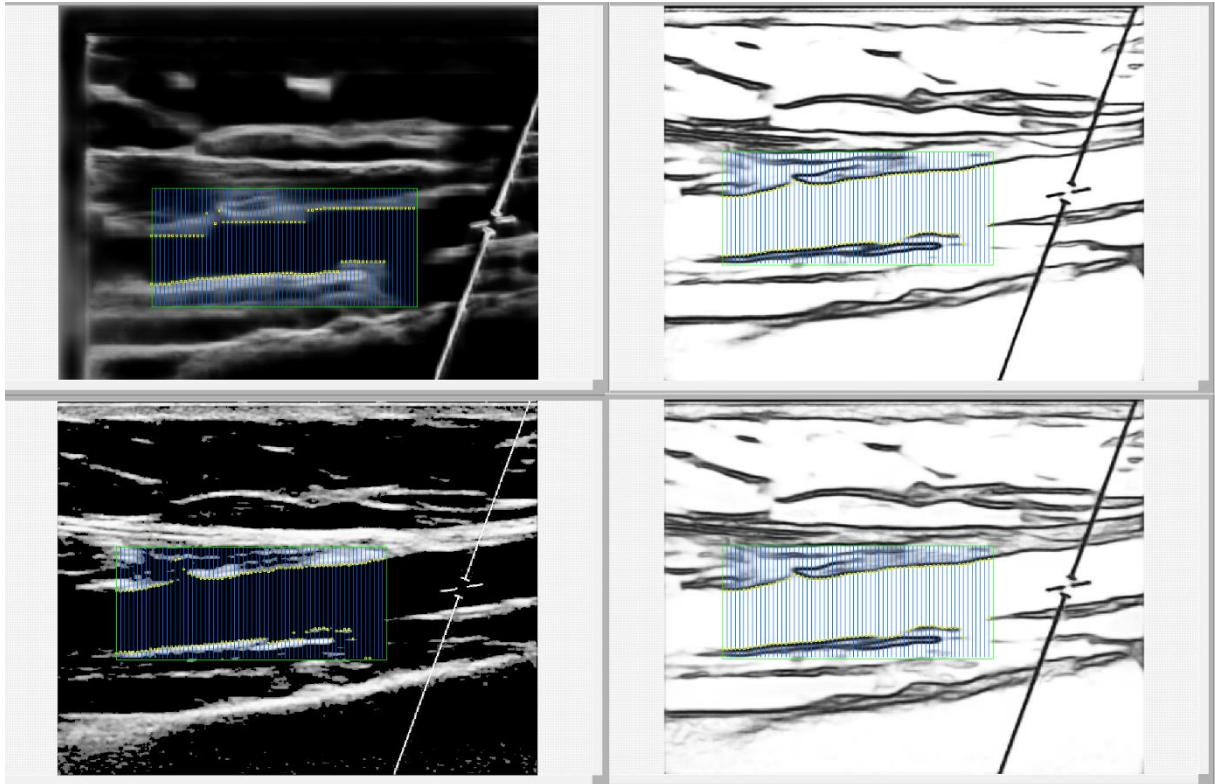


Esta imagem foi propositalmente adicionada ao conjunto de validação devido a sua baixa resolução, por ser de procedência de um antigo ultrassom. Conforme esperado os modelos apresentaram dificuldade, seja por detecções excessivas de artefatos na parte interna da artéria ou por falta de brilho para identificar parcialmente a borda.

Figura 22 - Detecção de Bordas Comparativo Amostra 3

Dentre os casos clínicos mais complexos de detecção estão os pacientes com artérias e/ou vasodilatação pequena, como observado na imagem acima. Nestes casos em sua maioria o sistema falha na detecção, fazendo com que o médico seja obrigado a alterar o processo de ganho no ultrassom afim de gerar contrastes mais vividos.

Figura 23 - Detecção de Bordas Comparativo Amostra 4



Muito semelhante ao primeiro modelo, porém apresentado uma variação de angular, os modelos responderam de bem a esta condição de teste.

Após as medições temos os seguintes dados comparativos:

Tabela 1 - Tabela comparativa de diâmetros obtidos por Amostra

AMOSTRAS X MEDIÇÕES	FMDVIEW	HED	DEXINED MÉDIA	DEXINED FUSÃO
<i>Amostra 1</i>	0,202131 cm	0,248065 cm	0,191185 cm	0,192273 cm
<i>Amostra 2</i>	0,165196 cm	0,266097 cm	0,095056 cm	0,134313 cm
<i>Amostra 3</i>	0,135176 cm	0,140188 cm	0,265542 cm	0,359151 cm
<i>Amostra 4</i>	0,393490 cm	0,305570 cm	0,365501 cm	0,365048 cm

Os resultados mostram que a Dexined, em particular, apresenta um resultado igual ou superior ao das ferramentas clássicas de visão, como abordado anteriormente devido à sua capacidade de gerar bordas mais nítidas e uma preservação mais detalhada das estruturas arteriais, como a camada íntima gerando uma nova perspectiva de resultados. Essas melhorias são especialmente importantes para garantir a confiabilidade dos exames de FMD, que desempenham um papel crucial na detecção precoce de disfunções endoteliais e na prevenção de doenças cardiovasculares.

No entanto, o sucesso na implementação de métodos baseados em inteligência artificial, como o explorado neste trabalho, também impõe desafios adicionais, como a necessidade de um corpo técnico especializado para a calibração e treinamento contínuo dos modelos. Realizando o treinamento do modelo da Dexined, através do auxílio médico para geração de novas imagens de ultrassom com marcações manuais, seguindo o modelo de segmentação por três pessoas.

Além disso, a integração dessas soluções no ambiente clínico exigirá uma adaptação dos fluxos de trabalho existentes e, possivelmente, um aumento no treinamento de operadores para lidar com as novas ferramentas.

Para uma maior definição dos impactos sobre os resultados, dependem de futuras adaptações no software existente para a reprodução de ambos os métodos e avaliação do conjunto de etapas junto a um corpo técnico para avaliar o ciclo basal x fase hiperemia (Linha basal x diâmetro máximo).

Portanto, a otimização da parametrização em exames de FMD por meio de aprendizado de máquina não apenas representa um avanço tecnológico significativo, mas também pode proporcionar maior precisão nos diagnósticos e intervenções clínicas. Ainda assim, futuros estudos e testes em larga escala serão necessários para validar a aplicabilidade dessas técnicas em diferentes cenários clínicos e consolidar o seu uso como padrão ouro na prática médica.

Este estudo serve como um ponto de partida para o desenvolvimento contínuo de soluções tecnológicas na área da saúde, visando aprimorar tanto a eficiência quanto a eficácia dos exames de FMD.

O estudo conclui que a otimização dos exames de FMD com aprendizado de máquina pode aumentar a precisão diagnóstica, mas ainda requer estudos adicionais para validação.

6. Conclusão

O presente trabalho abordou a otimização da parametrização em exames de Dilatação Mediada pelo Fluxo (FMD) utilizando técnicas de aprendizado profundo, sendo a análise da função endotelial crucial para a detecção precoce de disfunções que podem levar a complicações cardiovasculares. Através da aplicação de Inteligência Artificial, especialmente redes neurais profundas, buscamos aprimorar a precisão na detecção de bordas arteriais, minimizando os erros frequentemente associados à interpretação humana.

Considerações sobre o Ajuste de Parâmetros: Durante o desenvolvimento deste projeto, foi observado que a correta identificação da linha endotelial é fundamental para a avaliação precisa da dilatação arterial. Como mencionado nas discussões, a supressão excessiva do endotélio pode resultar em uma percepção reduzida da dilatação, o que compromete os resultados do exame. O ajuste adequado dos parâmetros é essencial para garantir que a linha endotelial seja visualizada de forma clara e precisa, evitando que se aproxime demais da adventícia ou se afaste excessivamente.

Importância da Identificação da Linha Endotelial: A identificação precisa da linha endotelial não apenas melhora a qualidade dos dados obtidos, mas também permite uma análise mais confiável das variações na função vascular. Como discutido, manter um padrão consistente durante os ajustes pode resultar em uma maior capacidade de detectar variações significativas no FMD, contribuindo para diagnósticos mais eficazes e intervenções precoces.

Resultados Obtidos e Sugestões Futuras: Os resultados deste estudo indicam que a implementação de técnicas de aprendizado profundo pode efetivamente melhorar a detecção de bordas arteriais e, conseqüentemente, a precisão do exame FMD. Após interpretação médica, os resultados da melhora significativa da preservação mais detalhada das estruturas arteriais, como a camada íntima podem gerar uma nova perspectiva de resultados.

No entanto, é recomendável que futuras pesquisas explorem mais profundamente as interações entre diferentes parâmetros de ajuste e suas influências nos resultados, a comparação entre múltiplos ajustes também pode fornecer insights valiosos sobre como otimizar ainda mais os processos.

Concisamente este trabalho não apenas contribui para o entendimento das complexidades envolvidas na avaliação da função endotelial, mas também abre caminhos para futuras inovações tecnológicas que podem transformar a prática clínica na área cardiovascular.

A continuidade das investigações nesse campo é essencial para o avanço das metodologias diagnósticas e para a melhoria dos cuidados com os pacientes.

REFERÊNCIAS

Al-Qaisi M, Kharbanda RK, Mittal TK, Donald AE. Measurement of endothelial function and its clinical utility for cardiovascular risk. *Vasc Health Risk Manag*. 2008;4(3):647-52

ARBELÁEZ, P.; MAIRE, M.; FOWLKES, C.; MALIK, J. Contour detection and hierarchical image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v.33, n.5, p.898- 916, 2011.

CASTELO NOVO, LUCAS. Traditional-and-DeepLearning-based-EdgeDetection. GitHub, 2024. Commit: VK-Ant/Traditional-and-DeepLearning-based-EdgeDetection:master. Disponível em: <<https://github.com/Lucky210591/Traditional-and-DeepLearning-based-EdgeDetection>>. Acesso em: 5 out. 2024

CAVALCANTI COSTA, DIOGO. Segmentação de Imagens Naturais Baseada em Modelos de Cor de Diferença Cromática, Máscaras de Detecção de Contornos e Supressão Morfológica de Texturas, Recife,2015.
https://repositorio.ufpe.br/bitstream/123456789/18620/1/TESE_DIOGO_CAVALCANTI_COSTA.pdf. Acesso em: 05 jan. 2024

Corretti MC, Anderson TJ, Benjamin EJ, Celermajer D, Charbonneau F, Creager MA, et al. Guidelines for the ultrasound assessment of endothelial-dependent flow-mediated vasodilation of the brachial artery: A report of the International Brachial Artery Reactivity Task Force. *Journal of the American College of Cardiology*. 2002;39(2):257-65.

Flammer AJ, Anderson T, Celermajer DS, Creager MA, Deanfield J, Ganz P, et al. The assessment of endothelial function: from research into clinical practice. *Circulation*. 2012;126(6):753-67.

Green DJ, Jones H, Thijssen D, Cable NT, Atkinson G. Flow-mediated dilation and cardiovascular event prediction: does nitric oxide matter? *Hypertension*. 2011;57(3):363-9.

Grompone von Gioi, Rafael; Randall, Gregory. A Brief Analysis of the Dense Extreme Inception Network for Edge Detection

<https://www.ipol.im/pub/art/2022/423/article.pdf>. Acesso em: 07 out. 2024

MARTIN, D.; FOW LKES, C.; T AL, D.; MALIK, J. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. Proceedings of the Eighth International Conference On Computer Vision (ICCV), v.2, p.416-423, Canadá, 2001.

M C, S M, TF L, JJ K, JE D. Assessment of atherosclerosis: the role of flowmediated dilatation. European Heart Journal. 2010;31(23):2854-61.

Quinaglia T, Matos-Souza JR, Feinstein SB, Sposito AC. Flow-mediated dilation: An evolving method. Atherosclerosis. 2015;241(1):143-4.

Thijssen DHJ, Bruno RM, van Mil A, Holder SM, Fata F, Greyling A, et al. Expert consensus, and evidence-based recommendations for the assessment of flow mediated dilation in humans. Eur Heart J. 2019;40(30):2534-47

VENKATKUMAR, V. K. Edge Detection: Gradient (Sobel, Prewitt, Canny) vs Deep Learning Holistically-Nested Approach. Medium, 2023. Disponível em: https://medium.com/@VK_Venkatkumar/edge-detection-gradient-sobel-prewitt-canny-vs-deep-learning-holistically-nested-approach-49bff706ae57. Acesso em: 13 março. 2024.

VENKATKUMAR, V. K. Edge Detection Using Kornia: Sobel, Canny & Deep Learning Based DexiNed (Part II). Medium, 2023. Disponível em: https://medium.com/@VK_Venkatkumar/edge-detection-using-kornia-sobel-canny-deep-learning-based-dexined-part-ii-e2c31672058f. Acesso em: 07 set. 2024.

Xavier Soria, Angel Sappa, Patricio Humanante and Arash Akbarinia. Dense Extreme Inception Network for Edge Detection, arXiv:2112.02250v2 [cs.CV], 26 de fevereiro de 2023.

Woodman RJ, Playford DA, Watts GF, Cheetham C, Reed C, Taylor RR, Puddey IB, Beilin LJ, Burke V, Mori TA, Green D. Improved analysis of brachial artery ultrasound using a novel edge-detection software system. *J Appl Physiol* 2001; 91:929–937.