

Abordagem Computacional Baseada em *Deep Learning* para o Diagnóstico de Endometriose Profunda através de Imagens de Ressonância Magnética

Wesley K. R. Figueredo¹, Italo F. S. da Silva¹, João O. B. Diniz²,
Aristófanés C. Silva¹, Anselmo C. de Paiva¹,
Alice C. C. Brandão Salomão³, Marco A. P. de Oliveira⁴

¹Núcleo de Computação Aplicada — Universidade Federal do Maranhão (UFMA)
Caixa Postal 65.085-580 — São Luís — MA — Brasil

²Instituto Federal de Educação, Ciência e Tecnologia do Maranhão (IFMA)
Caixa Postal 65.940-000 — Grajaú — MA — Brasil

³Clínica Fonte de Imagem - Rio de Janeiro, RJ - Brazil

⁴Universidade do Estado do Rio de Janeiro (UERJ) - Rio de Janeiro, RJ - Brazil

{wesley.kelson, francyles, ari, paiva}@nca.ufma.br,
{endometriose, brandaosalomao}@gmail.com
joao.bandeira@ifma.edu.br

Abstract. *Endometriosis is a disease that affects several organs, especially those in the pelvic structure, and considerably reduces the quality of life of the person affected. The disease mainly affects women of childbearing age. And, it can be identified via imaging exams. A method for automatically identifying the endometriosis lesion in magnetic resonance images using image processing techniques and a modified VGG-16 is proposed in this work. It has the purpose of serving as an aid in the diagnosis and to help to reduce the need to use invasive methods to perform these, the time of diagnosis, and false negative results. It achieved an accuracy of 83.89%, a sensitivity of 84.15%, and a specificity of 83.86%.*

Resumo. *Endometriose é uma doença que atinge vários órgãos, principalmente aqueles na estrutura pélvica, e reduz consideravelmente a qualidade de vida da pessoa afetadas. A doença afeta, principalmente, mulheres em idade fértil. Pode ser identificada via exames de imagem. Neste trabalho, Propõe-se um método para identificação automática da lesão de endometriose em imagens de ressonância magnética usando técnicas de processamento de imagem e uma VGG-16 modificada, a fim de servir como auxílio no diagnóstico, na redução da necessidade da utilização de métodos invasivos para realização destes, o tempo de diagnóstico e os resultados falsos negativos. Acurácia de 83,89%, sensibilidade de 84,15%, e especificidade de 83,86% foram alcançadas.*

1. Introdução

A endometriose é uma doença inflamatória que ocorre quando células do endométrio, o revestimento uterino, são encontradas fora da cavidade uterina. A teoria mais aceita para explicar a origem da doença é a da menstruação retrógrada, em que o tecido endometrial

é expelido durante a menstruação, mas em vez de ser eliminado pelo corpo, migra para os ovários ou a cavidade abdominal. Lesões endometriais maiores que 5 milímetros são consideradas profundas, enquanto as menores são superficiais.

A lesão de endometriose pode ser encontrada em regiões como o trato intestinal, septo retovaginal e ligamentos uterossacros [Coutinho Junior et al. 2008, Caraça et al. 2011], e os sintomas variam conforme o órgão afetado, podendo causar dor pélvica, disquezia, disúria e infertilidade. O intestino está envolvido em cerca de 37% dos casos na região pélvica, sendo o reto e o sigmoide as partes mais atingidas, equivalendo a 74% dos casos no intestino [Bailey et al. 1994].

A endometriose tem alta incidência em mulheres de diferentes faixas etárias, sendo que a prevalência é estimada em cerca de 10% da população mundial. No Brasil, estima-se que existam mais de 7 milhões de casos da doença [SOUZA et al. 2020]. O diagnóstico da endometriose pode ser complicado e demorado, cerca de 12 anos, uma vez que seus sintomas são semelhantes aos de outras condições, tornando difícil a identificação da presença da doença, o que pode levar a uma significativa diminuição na qualidade de vida [Pontes and Claudino 2021].

Diversos métodos são usados para diagnosticar a endometriose, como a laparoscopia e a ressonância magnética (RM). A laparoscopia é considerada o método mais confiável, pois permite a visualização da região de interesse de perto através de uma cirurgia minimamente invasiva. Embora a RM seja menos efetiva que a laparoscopia, ela é amplamente utilizada por ser uma técnica não invasiva e permitir a visualização dos tecidos através de imagens coronais, sagitais e axiais, sem a necessidade de contraste iodado ou radiação ionizante. A RM atinge uma acurácia, sensibilidade e especificidade em torno de 90% para endometriose profunda [Balleyguier et al. 2002, Coutinho Junior et al. 2008, Moura et al. 2019].

Métodos baseado em visão computacional vêm sendo desenvolvidos e trazendo resultados expressivos em várias modalidades de imagens e patologias [Diniz et al. 2021, Silva et al. 2021, Júnior et al. 2021]. Isso mostra que esse tipo de abordagem pode ser crucial para patologias como a endometriose. E, há uma escassez de trabalhos relacionados à visão computacional e endometriose, especialmente em imagens de RM. Por isso, este trabalho busca contribuir com o estado da arte, propondo o desenvolvimento de um novo método, baseado em técnicas de processamento de imagem e *Deep Learning*, capaz de classificar a presença de lesões de endometriose no reto e sigmoide em imagens de RM. E então, ajudar a diminuir a necessidade de procedimentos invasivos para diagnóstico, o tempo de identificação da doença e resultados falsos negativos, servindo como uma segunda opinião para o especialista responsável.

O método proposto é composto por uma etapa que recebe as imagens do exame de RM, e identifica uma região menor envolvendo os órgãos de interesse da análise. Essa região é passada para uma segunda etapa que executa um processo baseado em *Deep Learning* para a extração de características e classificação, indicando, portanto, se o paciente possui ou não endometriose.

Acredita-se que o trabalho proposto tem as seguintes contribuições: (1) a construção de uma base de imagens de RM para a classificação de pacientes com ou sem endometriose; (2) a proposta de uma abordagem automática para extração de uma região

de interesse, visando redução do escopo de estudo e processamento e de um método automático para classificação de pacientes que possuem endometriose; (3) a proposta de uma modificação na arquitetura da rede VGG-16 para a tarefa de classificação dos pacientes.

Este trabalho está organizado da seguinte forma: os trabalhos relacionados são apresentados na Seção 2; o método proposto é explicado na Seção 3; na Seção 4, são descritos os detalhes dos experimentos e mostrados os resultados obtidos; e, por fim, na Seção 5, apresenta-se a conclusão e trabalhos futuros.

2. Trabalhos relacionados

Há trabalhos que analisam o resultado manual de um especialista em imagens de ressonância magnética e em outras formas de diagnóstico, como via laparoscopia. No estudo conduzido por Bazot et al. (2004), determinou-se a capacidade de identificar lesões de endometriose em várias regiões da pelve antes da cirurgia em uma amostra de 195 pacientes. Os resultados mostraram que, para a região do reto e sigmoide, foi possível obter uma sensibilidade de 88%, especificidade de 97,8% e acurácia de 94,9%. Já na pesquisa de Scardapane et al. (2013), os resultados indicaram uma acurácia entre 84% e 100%, sensibilidade entre 67% e 100% e especificidade de 85% para os diferentes locais avaliados. A vagina foi o local onde se obteve 100% de sensibilidade, porém havia um único caso. Moura et al. (2019) realizaram um estudo comparativo do diagnóstico de endometriose no retossigmoide em imagens de RM e em ultrassonografia transvaginal. O resultado mostrou que a sensibilidade obtida para ambas as formas de diagnóstico foi de 90%, com especificidade de 96%.

O trabalho de Visalaxi and Muthu (2021) usou aprendizado por transferência com um modelo da arquitetura ResNet50 para classificar imagens de laparoscopia que apresentam ou não endometriose, e obteve uma acurácia de 90%. Usando Faster R-CNN e Mask R-CNN, Leibetseder et al. (2022) conseguiram uma precisão média de 32,4% para segmentação da endometriose em imagens de laparoscopia. O trabalho também realizou testes com variações de operações de *augmentation*, e obteve os melhores resultados com as operações de corte e rotação. Visalaxi and Sudalaimuthu (2022) usaram a U-Net para segmentar lesões em vários locais da pelve. Os melhores resultados obtidos foram de 0,72 o IOU e dice de 0,74. Entretanto, o autor não parece indicar se os valores discutidos nos resultados foram obtidos na base de teste. Estes trabalhos usaram a base de imagens *gynecologic laparoscopy endometriosis dataset* (GLENDATA) [Leibetseder et al. 2020].

O trabalho de Yang et al. (2021) faz a classificação de pacientes com endometriose profunda de ultrassom transvaginal e RM 3D. Além disso, fez um estudo do diagnóstico por especialistas através dessas imagens. A base utilizada é privada e consiste de 118 pacientes com endometriose e 206 com outras doenças ginecológicas. Para imagens de RM 3D, utilizou-se o modelo IC3D e alcançou acurácia de 99,2% no diagnóstico.

Trabalhos que utilizam métodos automáticos para diagnóstico endometriose são escassos, especialmente em RM. Por isso, busca-se abranger este leque de trabalhos com um método novo que auxilie na descoberta de pacientes com endometriose, e indique em quais fatias a lesão é visível para que o especialista consiga localizá-la mais facilmente.

3. Método proposto

Nesta seção é apresentado o método proposto que tem como objetivo a descoberta de pacientes que possuem endometriose através de um processo dividido em duas etapas, conforme pode ser visto na Figura 1.

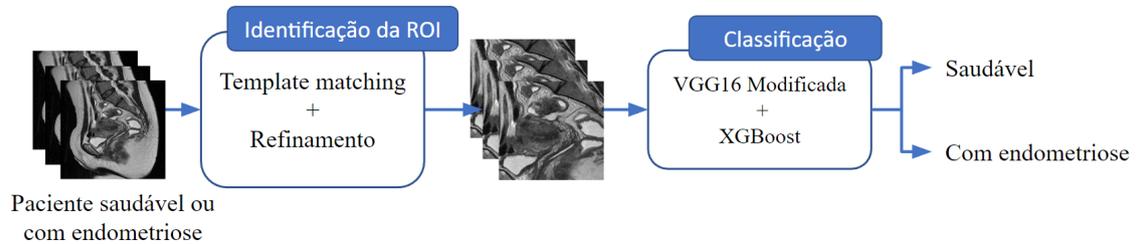


Figura 1. Fluxo do método proposto.

O método proposto possui duas etapas: a identificação da região de interesse (ROI) e a classificação. A primeira consiste em selecionar uma área específica do exame que contém apenas os órgãos relevantes para a análise. As ROIs selecionadas são então passadas para a segunda etapa, que determina se há presença de lesões nas imagens do exame de um paciente. Se nenhuma lesão for encontrada, o paciente é considerado saudável. As etapas do método são detalhadas nas seções seguintes.

3.1. Identificação da Região de Interesse (ROI)

A imagem de RM contém informações fora do escopo, além disso, processá-la em seu tamanho original é computacionalmente mais custoso. Para solucionar essas questões, foi desenvolvida a identificação da ROI, que reduz o tamanho da imagem, eliminando informações irrelevantes. O fluxo para extração dessa ROI é indicado na Figura 2.

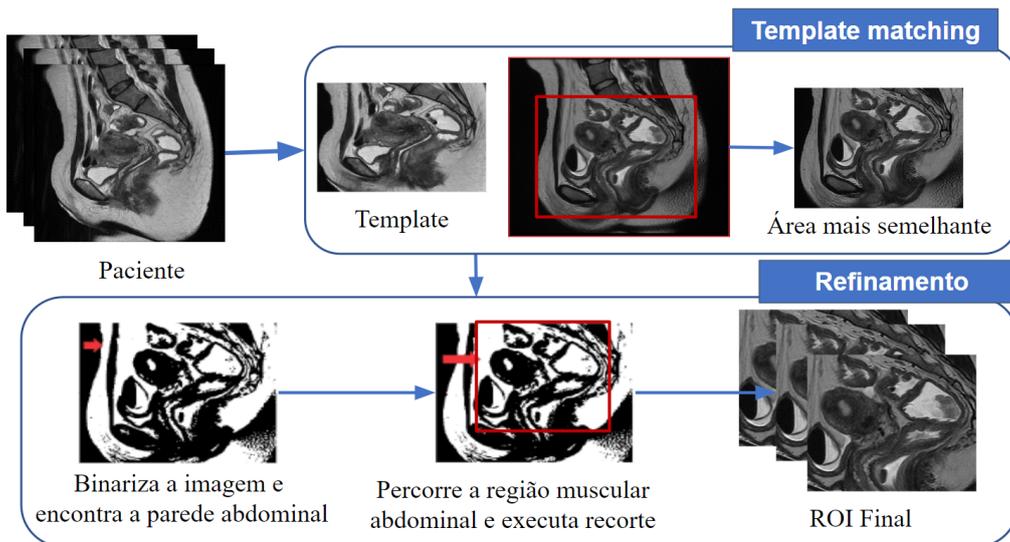


Figura 2. Fluxo da etapa de identificação da ROI

Para extrair a ROI, usou-se a técnica *template matching* [Brunelli 2009]. A partir da análise das imagens, uma imagem com a parte mais visível dos órgãos da região pélvica

foi selecionada e recortada para conter uma área mínima com os órgãos. Entretanto, diferenças no tamanho e disposição dos órgãos entre os pacientes, bem como diferenças no nível de cinza, podem levar a falhas no resultado do *template matching*. Para corrigir isso, a informação de borda da parede abdominal é adicionada à imagem de *template* com o objetivo de fornecer informações de posicionamento. O *template* utilizado está disponível na Figura 3.

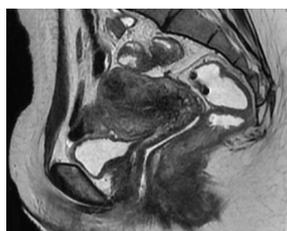


Figura 3. *Template* utilizado

O método usa o *template matching* para percorrer todas as imagens de um exame e encontrar a região mais semelhante. Durante a execução, devido a pequenas diferenças no tamanho do reto e sigmoide entre os pacientes, o *template* é usado em diferentes tamanhos: o original, 0,98 e 1,02 do valor de dimensão original. Esses valores foram selecionados empiricamente para melhorar os resultados na busca pela combinação entre o *template* e a imagem.

Apesar de se adicionar a região da parede abdominal para melhorar a localização, essa informação é desnecessária e aumenta o tamanho da imagem, exigindo mais recursos computacionais. Portanto, após a aplicação do *template matching*, a estrutura é removida usando técnicas de processamento de imagem.

Para obter a ROI da imagem, primeiramente, faz-se a binarização da imagem para diferenciar entre áreas escuras e claras. Em seguida, busca-se pela parede abdominal por meio de uma análise pixel a pixel, a partir do pixel mais superior à esquerda que não for branco. Com esse pixel, tem-se a parte exterior do abdômen. A partir desse ponto, percorre-se os pixels brancos no eixo x até encontrar novamente um pixel preto, que representa a região do músculo abdominal. Continua-se a percorrer o eixo x até encontrar um pixel branco, que é a região onde se encontram os órgãos. A partir desse pixel, faz-se um corte na imagem considerando a altura da imagem de entrada encontrada pelo *template matching* e o valor de x desse pixel.

Por fim, a ROI final é definida sobre a imagem resultante dos passos anteriores por meio de recorte de 256x256 a partir do pixel mais superior à esquerda, englobando o reto e o sigmoide.

3.2. Classificação dos pacientes com endometriose

Nesta etapa, uma rede VGG-16 [Simonyan and Zisserman 2014], rede neural profunda com arquitetura simples e eficiente, com modificações é usada para determinar a presença de lesões nos pacientes e em quais imagens elas podem ser encontradas, como ilustrado na Figura 4.

Propõe-se uma mudança na VGG-16 com a substituição de algumas das camadas densas por camadas recorrentes (RCL) [Liang and Hu 2015]. Essa arquitetura permite o

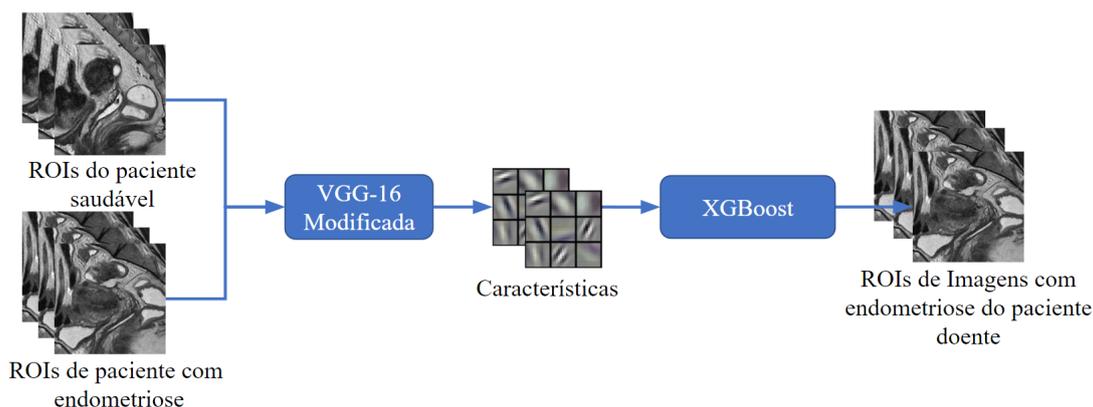


Figura 4. Etapa de Classificação

fluxo de informação entre as camadas, reduzindo o número de parâmetros do modelo e permitindo a construção de uma rede mais profunda. A presença de caminhos mais longos na RCL possibilita que o modelo aprenda características da vizinhança e altamente complexas [Liang and Hu 2015, Alom et al. 2018]. Assim, permite-se que a rede se adapte a características importantes na identificação das lesões. Além disso, utiliza-se a função sigmoide como camada de saída para o treinamento. A Figura 5 mostra esta arquitetura.

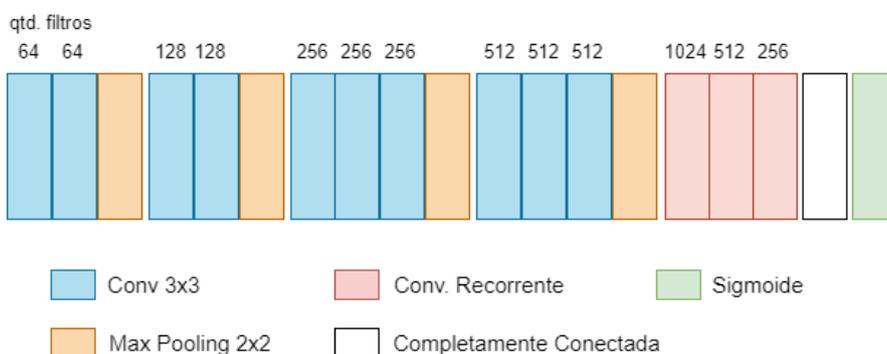


Figura 5. Arquitetura da VGG-16 modificada.

A rede foi treinada para, ao receber como entrada as ROIs dos pacientes extraídas na etapa anterior, indicar a presença ou ausência de lesão. Nesse processo, a rede aprende a extrair características, chamadas de *Deep Features*, as quais podem ser utilizadas em outros experimentos por outros classificadores a fim de se verificar a possibilidade de se encontrar melhores resultados. Nesse sentido, o método passa as características extraídas na última RCL ao classificador XGBoost [Chen and Guestrin 2016].

O XGBoost é um algoritmo de aprendizado de máquina supervisionado que utiliza a técnica Gradient tree boosting para combinar árvores de decisão fracas em um modelo robusto. Ele é adequado para tarefas de regressão e classificação e possui regularização para melhorar a generalização e evitar *overfitting*. Comparado a outros métodos, o XGBoost se destaca pela escalabilidade, extensibilidade, paralelismo e eficiência no consumo de recursos de hardware [Chen et al. 2015].

4. Experimentos e Resultados

Nesta seção, apresentam-se informações sobre a base de imagens usada nos experimentos, bem como demais detalhes relativos ao hardware e software utilizados, definição de hiperparâmetros, além dos resultados obtidos pelo método proposto.

Neste trabalho, foi utilizada a linguagem de programação Python no sistema operacional Windows, com a seguinte configuração de hardware: CPU Intel Core i7-6700HQ com velocidade de 2GHz, 16 GB de RAM e placa de vídeo Nvidia GeForce GTX 1070.

4.1. Base de Imagens

Neste trabalho, usou-se uma base privada criada em colaboração com dois especialistas e a Clínica Fonte Imagem, no Rio de Janeiro. A base de dados, atualmente, possui 106 exames de RM T2, com dimensões de 512×512 pixels, sendo 86 com endometriose e 20 saudáveis. O total de imagens é de 3.365, das quais 2.939 não apresentam lesão de endometriose e 426 possuem. As marcações das lesões foram feitas apenas em pacientes com lesões com tamanho superior a 2 cm e localizadas exclusivamente na região do reto e sigmoide. Para a marcação da lesão, foi estabelecido um protocolo em que se marca primeiro a imagem que apresenta a maior parte da lesão, seguida de duas imagens posteriores e duas anteriores, ou mais se necessário, conforme a análise do especialista em relação ao esforço e tempo necessários para uma marcação precisa.

4.1.1. Preparação da base

A base de imagens foi dividida em três conjuntos: treinamento, validação e teste. Cada imagem do exame de um paciente foi atribuída a apenas um dos conjuntos, para garantir precisão dos resultados. 62 pacientes foram aleatoriamente selecionados para o conjunto de treinamento, enquanto 22 foram destinados a validação e outros 22 ao conjunto de teste. O grupo de teste incluiu 4 pacientes saudáveis na validação, 4 no teste e 12 no conjunto de treinamento. Há 82 imagens com endometriose e 632 imagens sem a doença.

Foram aplicadas três operações de *data augmentation* para testes: brilho, rotação e zoom. Após diversos testes com as imagens, concluiu-se que as operações devem ser moderadas para evitar alterações drásticas. A rotação foi definida com variação de 5 graus no sentido horário e anti-horário, enquanto o brilho e zoom tiveram variação de 0,9 a 1,1 em relação aos valores originais. Essas operações foram aplicadas apenas às imagens do treinamento com endometriose, resultando em um total de 2.593, igualando ao número de imagens saudáveis. No conjunto de teste, foram utilizadas as imagens sem as operações.

4.2. Configurações experimentais

A avaliação dos resultados foi feita de duas formas: por paciente e por imagem. Se uma imagem do exame de um paciente for classificada como tendo endometriose, então esse paciente é considerado não saudável.

Foram utilizados os seguintes hiperparâmetros na classificação: O otimizador Adam [Kingma and Ba 2014] com taxa de aprendizado de 0,001, um *batch size* de 16, e *early stopping* com 30 épocas. A otimização dos hiperparâmetros do XGBoost foi realizada utilizando a técnica de *grid search*, resultando em um *subsample* de 0,75, *max_depth* de 2, *min_child_weight* de 1, *learning_rate* de 0,5 e *n_estimators* de 150.

Tabela 1. Resultados da classificação por imagem.

REDE	ACC	SEN	ESP	PREC	F1
VGG-16	0,8697	0,6463	0,8987	0,453	0,5327
VGG-19	0,8782	0,5122	0,9256	0,4719	0,4912
Resnet50	0,8739	0,5244	0,9193	0,4574	0,4886
InceptionV3	0,8922	0,4756	0,9462	0,5342	0,5032

As seguintes métricas foram utilizadas para a avaliação dos resultados: acurácia (ACC), sensibilidade (SEN), precisão (PREC), especificidade (SPE) e F1-score (F1) [DINIZ et al. 2021].

4.3. Resultados da Etapa de Identificação da ROI

O principal objetivo dessa etapa é reduzir o escopo de busca da lesão de endometriose na imagem. A fim de avaliar o desempenho desta etapa, constatou-se que todas as lesões foram mantidas dentro da região de interesse, tendo uma sensibilidade de 100%. A Figura 6 apresenta um exemplo de resultado dessa etapa.

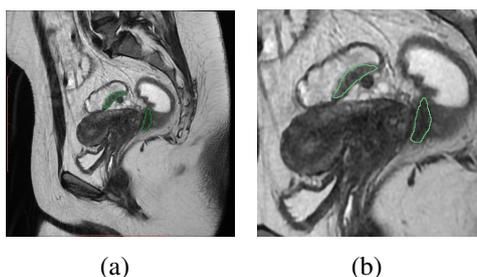


Figura 6. Exemplo de resultado da identificação da ROI. (a) A imagem original, e (b) a ROI.

4.4. Resultados da Etapa de Classificação

Para classificar quais pacientes possuem endometriose e em quais imagens do exame a lesão se encontra, realizou-se diversos testes com várias arquiteturas para obter os melhores resultados. Foram avaliadas arquiteturas pré-treinadas com o classificador XGBoost: VGG-16, VGG-19, ResNet50 e InceptionV3 [Szegedy et al. 2016].

A Tabela 1 apresenta a comparação desses resultados por imagem, e os resultados por paciente são apresentados na Tabela 2. Observa-se que a VGG-16 conseguiu identificar todos os pacientes que possuíam endometriose, no entanto, classificou corretamente apenas 1 dos 4 pacientes saudáveis do teste. Também foi observada uma menor diferença entre a sensibilidade e a especificidade na análise por imagem com esta arquitetura.

Após análise do resultado anterior, foram conduzidos experimentos com uma versão modificada da VGG-16, conforme descrito na Seção 3.2. As Tabelas 3 e 4 mostram os resultados com esta modificação da VGG-16. Elas apresentam os resultados da aplicação da VGG-16 com os pesos inicializados da ImageNet e balanceamento de pesos por classe. Também são apresentados resultados de testes com a arquitetura modificada usando o XGBoost, com a parte da VGG-16 pré-treinada (“pt” na tabela), com

Tabela 2. Resultados da classificação por paciente.

REDE	ACC	SEN	ESP	PREC	F1
VGG-16	0,8636	1.0	0,2500	0,8571	0,9231
VGG-19	0,7273	0,8333	0,2500	0,8333	0,8333
Resnet50	0,7727	0,9444	0,0000	0,8095	0,8718
InceptionV3	0,8182	0,8889	0,5000	0,8889	0,8889

Tabela 3. Resultados da classificação por imagem usando a VGG16.

VGG-16	Bal.	ACC	SEN	ESP	PREC	F1
Padrão	P	0,7577	0,9756	0,7294	0,3187	0,4805
Modificada + XGBoost (pt)	P	0,8599	0,6829	0,8829	0,4308	0,5283
Modificada + XGBoost	Aug	0,8025	0,7073	0,8149	0,3314	0,4514
Modificada + XGBoost	P	0,8389	0,8415	0,8386	0,4035	0,5455
Modificada	P	0,8396	0,6707	0,8643	0,4198	0,5164

inicialização de pesos e aumento de dados, e com inicialização de pesos e pesos por classe. Por fim, é apresentada a versão da rede sem o XGBoost. A coluna “Bal.” indica o tipo de balanceamento utilizado: peso por classe (P) ou aumento de dados (Aug).

A VGG-16 padrão teve o maior valor de sensibilidade, porém perdeu bastante em especificidade em comparação aos outros experimentos. Ao utilizar a versão modificada com a parte pré-treinada da VGG-16 e o XGBoost, obteve-se um valor semelhante à execução realizada pela VGG-16 (Tabela 1), com ganho de sensibilidade e com erro na classificação de pacientes com endometriose.

A VGG-16 modificada com XGBoost e balanceamento de pesos obteve o melhor resultado na avaliação por paciente. Embora não tenha atingido os melhores valores de sensibilidade e especificidade na classificação por imagem, os valores obtidos foram altos em comparação com os demais experimentos, incluindo o uso de aumento de dados. Além disso, teve o melhor valor de f1-score (Tabela 3) e identificou corretamente todos os pacientes com endometriose e um paciente saudável (Tabela 4).

Para avaliar a robustez da classificação com a VGG-16 modificada com XGBoost, utilizou-se *cross-validation leave-one-out* [Wong 2015] dividido em 5 conjuntos. A média e o desvio padrão dos resultados por imagem e por paciente desse processo podem ser vistos na Tabela 5. É possível observar que os resultados não têm grande alteração, apesar de que, em um dos conjuntos, um paciente com endometriose foi classificado como

Tabela 4. Resultados da classificação por paciente usando a VGG16.

VGG-16	Bal.	ACC	SEN	ESP	PREC	F1
Padrão	P	0,8182	1,0000	0,0000	0,8182	0,9000
Modificada + XGBoost (pt)	P	0,8182	0,9444	0,2500	0,8500	0,8947
Modificada + XGBoost	Aug	0,8182	1,0000	0,0000	0,8182	0,9000
Modificada + XGBoost	P	0,8636	1.0000	0,2500	0,8571	0,9231
Modificada	P	0,8182	0,9444	0,2500	0,8500	0,8947

Tabela 5. Resultados do *cross-validation* para a classificação por imagem e por paciente.

Tipo de avaliação	Bal.	ACC	SEN	ESP	PREC	F1
Média por imagem	P	0,7881	0,6970	0,8014	0,3439	0,4577
Desvio padrão por imagem	P	0,0490	0,1001	0,05749	0,0508	0,0562
Média por paciente	P	0,8298	0,9882	0,15	0,8336	0,9040
Desvio padrão por paciente	P	0,0270	0,0263	0,1369	0,0226	0,01571

saudável, reduzindo minimamente a sensibilidade na classificação por paciente.

Algumas imagens de pacientes com endometriose que não apresentavam lesão foram erroneamente classificadas como positivas para a doença. Essas fatias estavam próximas às que realmente possuíam lesão. Além disso, a escassez de imagens de pacientes saudáveis com o reto e sigmoide visíveis pode prejudicar o método, já que muitas imagens saudáveis foram extraídas dos exames de pacientes com endometriose.

Com a classificação atingindo, em seu melhor treinamento, um valor de 84,15% de sensibilidade na classificação por imagem, esse resultado se aproxima aos de sensibilidade dos diagnósticos feitos por especialistas, como no trabalho de Moura et al. (2019), que conseguiu sensibilidade de 90%, mostrando, portanto, a aplicabilidade do método proposto. O método proposto, na análise por paciente, conseguiu uma acurácia de 86,36% e sensibilidade 100%.

5. Conclusão e Trabalhos Futuros

Identificar a endometriose precocemente é crucial para melhorar a qualidade de vida do paciente, uma vez que a doença pode causar sintomas persistentes e graves. Para ajudar no diagnóstico precoce, propõe-se um método que aplica técnicas de processamento de imagem e *Deep Learning* para identificar pacientes com endometriose.

A classificação de imagens obteve sensibilidade e especificidade superiores a 80%, por imagem, sem identificar pacientes com endometriose como saudáveis. No entanto, a escassez de imagens saudáveis que exibam claramente a região do reto e sigmoide é uma das principais dificuldades. A maioria das imagens disponíveis na base de dados é de pacientes com endometriose, ou seja, grande parte das imagens que apresentam a região do reto e sigmoide estão sendo usadas no conjunto de pacientes com a doença. Esse desequilíbrio pode ter afetado o desempenho na classificação de pacientes saudáveis.

Para melhorar os resultados alcançados, é essencial aumentar a base de pacientes saudáveis, que está em construção. Além disso, serão feitas as etapas de detecção e de segmentação da lesão, visando auxiliar o especialista no diagnóstico e mapeamento da lesão para procedimento cirúrgico.

6. Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, Fundação de Amparo a Pesquisa do Maranhão (FAPEMA), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), e Empresa Brasileira de Serviços Hospitalares (Ebserh) Brazil (Proc. 409593/2021-4).

Referências

- Alom, M. Z., Hasan, M., Yakopcic, C., Taha, T. M., and Asari, V. K. (2018). Recurrent residual convolutional neural network based on u-net (r2u-net) for medical image segmentation. *arXiv preprint arXiv:1802.06955*.
- Bailey, H. R., Ott, M. T., and Hartendorp, P. (1994). Aggressive surgical management for advanced colorectal endometriosis. *Diseases of the colon & rectum*, 37:747–753.
- Balleyguier, C., Chapron, C., Dubuisson, J., Kinkel, K., Fauconnier, A., Vieira, M., Hélénon, O., and Menu, Y. (2002). Comparison of magnetic resonance imaging and transvaginal ultrasonography in diagnosing bladder endometriosis. *The Journal of the American Association of Gynecologic Laparoscopists*, 9(1):15–23.
- Bazot, M., Darai, E., Hourani, R., Thomassin, I., Cortez, A., Uzan, S., and Buy, J.-N. (2004). Deep pelvic endometriosis: Mr imaging for diagnosis and prediction of extension of disease. *Radiology*, 232(2):379–389.
- Brunelli, R. (2009). *Template matching techniques in computer vision: theory and practice*. John Wiley & Sons.
- Caraça, D., Podgaec, S., Baracat, E., and Abrão, M. (2011). Mecanismos fisiopatológicos da dor pélvica na endometriose profunda. *Diagn Tratamento*, 16(2):57–61.
- Chen, T. and Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pages 785–794.
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Chen, K., et al. (2015). Xgboost: extreme gradient boosting. *R package version 0.4-2*, 1(4):1–4.
- Coutinho Junior, A. C., Lima, C. M. A. d. O., Coutinho, E. P. D., Ribeiro, É. B., Aidar, M. N., and Gasparetto, E. L. (2008). Ressonância magnética na endometriose pélvica profunda: ensaio iconográfico. *Radiologia Brasileira*, 41:129–134.
- Diniz, J., Ferreira, J., Silva, G., Quintanilha, D., Silva, A., and Paiva, A. (2021). Segmentação de coração em tomografias computadorizadas utilizando atlas probabilístico e redes neurais convolucionais. In *Anais do XXI Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 83–94, Porto Alegre, RS, Brasil. SBC.
- DINIZ, J. O. B. et al. (2021). Métodos para segmentação de medula espinhal e esôfago em tomografia computadorizada de planejamento à radioterapia.
- Júnior, D. D., Cruz, L., Diniz, J., Júnior, G. B., and Silva, A. (2021). Classificação automática de glóbulos brancos usando descritores de forma e textura e extreme gradient boosting. In *Anais do XXI Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 95–106, Porto Alegre, RS, Brasil. SBC.
- Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Leibetseder, A., Kletz, S., Schoeffmann, K., Keckstein, S., and Keckstein, J. (2020). GLENDa: gynecologic laparoscopy endometriosis dataset. In *MultiMedia Modeling - 26th International Conference, MMM 2020, Daejeon, South Korea, January 5-8, 2020, Proceedings, Part II*, volume 11962 of *Lecture Notes in Computer Science*, pages 439–450. Springer.

- Leibetseder, A., Schoeffmann, K., Keckstein, J., and Keckstein, S. (2022). Endometriosis detection and localization in laparoscopic gynecology. *Multimedia Tools and Applications*, pages 1–25.
- Liang, M. and Hu, X. (2015). Recurrent convolutional neural network for object recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3367–3375. IEEE Computer Society.
- Moura, A. P. C., Ribeiro, H. S. A. A., Bernardo, W. M., Simões, R., Torres, U. S., D’Ippolito, G., Bazot, M., and Ribeiro, P. A. A. G. (2019). Accuracy of transvaginal sonography versus magnetic resonance imaging in the diagnosis of rectosigmoid endometriosis: Systematic review and meta-analysis. *PLoS One*, 14(4):e0214842.
- Pontes, I. F. and Claudino, E. L. (2021). Dor pélvica e achados indiretos da endometriose na ecografia pélvica: Uma correlação estatística. *Research, Society and Development*, 10(8):e49210817709–e49210817709.
- Scardapane, A., Lorusso, F., Bettocchi, S., Moschetta, M., Fiume, M., Vimercati, A., Pepe, M., Angelelli, G., and Stabile Ianora, A. (2013). Deep pelvic endometriosis: accuracy of pelvic mri completed by mr colonography. *La Radiologia Medica*, pages 1–16.
- Silva, G., Oliveira, F., Diniz, J., Diniz, P., Quintanilha, D., Silva, A., Paiva, A., and Cavalcanti, E. (2021). An automatic method for prostate segmentation on 3d mri scans using local phylogenetic indexes and xgboost. In *Anais do XXI Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 165–176, Porto Alegre, RS, Brasil. SBC.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- SOUZA, L. G., BARROS, A. M. D. A., and Monteiro, M. R. S. (2020). A importância do ca-125 para o diagnóstico precoce da endometriose. *Revista de Patologia do Tocantins*, 7(1):66–70.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2818–2826.
- Visalaxi, S. and Muthu, T. S. (2021). Automated prediction of endometriosis using deep learning. *International Journal of Nonlinear Analysis and Applications*, 12(2):2403–2416.
- Visalaxi, S. and Sudalaimuthu, T. (2022). Automated segmentation of endometriosis using transfer learning technique. *F1000Research*, 11(360):360.
- Wong, T.-T. (2015). Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. *Pattern Recognition*, 48(9):2839–2846.
- Yang, M., Liu, M., Chen, Y., He, S., and Lin, Y. (2021). Diagnostic efficacy of ultrasound combined with magnetic resonance imaging in diagnosis of deep pelvic endometriosis under deep learning. *The Journal of Supercomputing*, 77(7):7598–7619.