



**ESCOLA BAHIANA DE MEDICINA E SAÚDE PÚBLICA**  
**CURSO BIOMEDICINA**

**CAROLINE SANT'ANA COSTA FERREIRA**

**USO DE INTELIGÊNCIA ARTIFICIAL EM *DEEP LEARNING* NA  
SEGMENTAÇÃO DA MAMA EM IMAGENS DE RESSONÂNCIA  
MAGNÉTICA COMO FERRAMENTA PARA O DIAGNÓSTICO  
DE CÂNCER DE MAMA: UMA REVISÃO SISTEMÁTICA**

**SALVADOR – BA**

**2023**

**CAROLINE SANT'ANA COSTA FERREIRA**

**USO DE INTELIGÊNCIA ARTIFICIAL EM *DEEP LEARNING* NA  
SEGMENTAÇÃO DA MAMA EM IMAGENS DE RESSONÂNCIA MAGNÉTICA  
COMO FERRAMENTA PARA O DIAGNÓSTICO DE CÂNCER DE MAMA: UMA  
REVISÃO SISTEMÁTICA**

Trabalho de Conclusão de Curso apresentado à  
Escola Bahiana de Medicina e Saúde Pública,  
como parte dos requisitos para obtenção do  
título de Bacharel em Biomedicina.

Orientador: Prof.<sup>a</sup> Dra. Mara Dias Pires

**SALVADOR – BA**

**2023**

**CAROLINE SANT'ANA COSTA FERREIRA**

**TÍTULO DO ARTIGO:**

**USO DE INTELIGÊNCIA ARTIFICIAL EM *DEEP LEARNING* NA SEGMENTAÇÃO DA MAMA EM IMAGENS DE RESSONÂNCIA MAGNÉTICA COMO FERRAMENTA PARA O DIAGNÓSTICO DE CÂNCER DE MAMA: UMA REVISÃO SISTEMÁTICA**

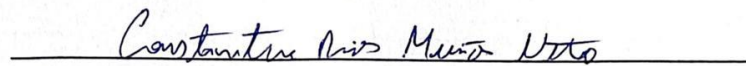
Este Trabalho de Conclusão de Curso foi julgado adequado à obtenção do grau de Bacharel em Biomedicina e aprovada em sua forma final pelo Curso de Biomedicina da Escola Bahiana de Medicina e Saúde Pública.

Salvador – BA, 11 de novembro de 2023



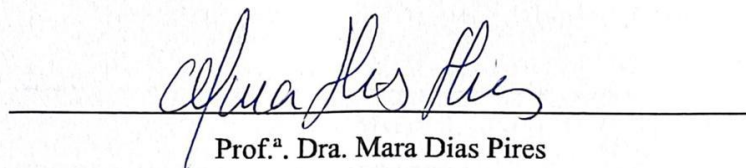
Prof. Thomas Pitangueira Barros

ESCOLA BAHIANA DE MEDICINA E SAÚDE PÚBLICA



Prof. Constantino Rios Muiños Neto

ESCOLA BAHIANA DE MEDICINA E SAÚDE PÚBLICA



Prof.ª. Dra. Mara Dias Pires

ESCOLA BAHIANA DE MEDICINA E SAÚDE PÚBLICA

## SUMÁRIO

<b>ARTIGO CIENTÍFICO:</b> .....	<b>5</b>
<b>1 INTRODUÇÃO</b> .....	<b>8</b>
<b>2 MATERIAIS E MÉTODOS</b> .....	<b>9</b>
2.1 ESTRATÉGIA DE BUSCA BIBLIOGRÁFICA .....	9
2.2 CRITÉRIOS DE ELEGIBILIDADE .....	10
2.3 ORGANIZAÇÃO E EXTRAÇÃO DOS DADOS .....	10
2.4 AVALIAÇÃO DA QUALIDADE.....	11
<b>3 RESULTADOS</b> .....	<b>11</b>
<b>4 DISCUSSÃO</b> .....	<b>14</b>
<b>5 CONCLUSÃO</b> .....	<b>15</b>
<b>6 AGRADECIMENTOS</b> .....	<b>15</b>
<b>7 REFERÊNCIAS</b> .....	<b>16</b>
<b>8 PROPOSTA DE SUBMISSÃO</b> .....	<b>19</b>
8.1 REVISTA .....	19
8.2 REGRAS DE SUBMISSÃO.....	19

ARTIGO CIENTÍFICO:

**USO DE INTELIGÊNCIA ARTIFICIAL EM *DEEP LEARNING* NA SEGMENTAÇÃO DA MAMA EM IMAGENS DE RESSONÂNCIA MAGNÉTICA COMO FERRAMENTA PARA O DIAGNÓSTICO DE CÂNCER DE MAMA: UMA REVISÃO SISTEMÁTICA**

*USE OF ARTIFICIAL INTELLIGENCE IN DEEP LEARNING IN BREAST SEGMENTATION IN MAGNETIC RESONANCE IMAGES AS A TOOL FOR BREAST CANCER DIAGNOSIS: A SYSTEMATIC REVIEW*

***DEEP LEARNING NA SEGMENTAÇÃO DA MAMA EM RM***

*DEEP LEARNING IN BREAST SEGMENTATION IN MRI*

CAROLINE SANT'ANA COSTA FERREIRA <sup>1,a</sup>

MARA DIAS PIRES <sup>2,b</sup>

1. Acadêmica em Biomedicina pela Escola Bahiana de Medicina e Saúde Pública (EBMSP), Salvador, BA, Brasil.

2. Farmacêutica e Bioquímica pela Universidade Paulista (UNIP), com doutorado em Ciências pelo Instituto de Ciências Biomédicas da Universidade de São Paulo (ICB-USP), com filiação institucional na Escola Bahiana de Medicina e Saúde Pública (EBMSP), Salvador, BA, Brasil.

Endereço para correspondência: Caroline Sant'Ana Costa Ferreira. Rua Dr. Gerino de Souza Filho, 420, cond. Casas do Bosque, n.º 342. Lauro de Freitas, BA, Brasil, 42711-830. E-mail: carolinescf1@gmail.com

a. <https://orcid.org/0009-0000-8578-848X>

b. <https://orcid.org/0000-0001-9620-3424>

## RESUMO

A segmentação de lesões em imagens é uma das tarefas que o *deep learning* pode ser aplicado, podendo detectar limites, tumores e massas, automaticamente. O objetivo deste estudo foi revisar o desempenho da Inteligência artificial em *deep learning* na segmentação de regiões mamárias e áreas tumorais da mama e descrever os algoritmos de redes neurais aplicados. Esta revisão sistemática foi elaborada seguindo o diagrama *Preferred Report Items for Systematics and Meta-Analyses*, sendo selecionados artigos das bases de dados Público/editora MEDLINE, *Scientific Electronic Library Online* e Literatura Latino-Americana e do Caribe em Ciências da Saúde. Para a seleção dos artigos foram adotados critérios de elegibilidade, obtendo um total de 8 artigos. Dentre os algoritmos encontrados nos estudos, *U-Net* obteve maior predominância nos artigos, apresentando um índice de coeficiente de similaridade de dados de 95%, na sua versão isolada e avançada e a sensibilidade de 94%, na versão avançada (*U-Net++*). Foi demonstrado que a segmentação automatizada apresenta resultados relevantes quando comparado com a segmentação manual realizada pelos radiologistas especialistas. Conclui-se que esta revisão mostrou que o *deep learning* na segmentação de imagens da mama em ressonância magnética tem um bom potencial e eficácia para auxiliar no diagnóstico de câncer de mama.

**Unitermos:** “Inteligência artificial”, “*deep learning*”, “processamento de imagem/segmentação”, “diagnóstico por imagem”, “câncer de mama” e “ressonância magnética”

## ABSTRACT

*The segmentation of lesions in images is one of the tasks that deep learning can be applied to, being able to detect boundaries, tumors and masses automatically. The objective of this study was to review the performance of Artificial Intelligence in deep learning in segmenting breast regions and breast tumor areas and describe the applied neural network algorithms. This systematic review was prepared following the Preferred Report Items for Systematics and Meta-Analyses diagram, with articles selected from the databases Público/editor MEDLINE, Scientific Electronic Library Online and Literatura Latino-Americana e do Caribe em Ciências da Saúde. of the articles, eligibility criteria were adopted, obtaining a total of 8 articles. Among the algorithms found in the studies, U-Net obtained the greatest predominance in the articles, presenting a data similarity coefficient index of 95%, in its isolated and advanced version, and sensitivity of 94%, in the advanced version (U-Net++). It has been demonstrated that automated segmentation presents relevant results when compared to manual segmentation performed by expert radiologists. It is concluded that this review showed that deep learning in the segmentation of breast images in MRI has good potential and effectiveness to assist in the diagnosis of breast cancer.*

**Keywords:** *“Artificial Intelligence”, “Deep learning”, “image processing/segmentation”, “diagnostic Imaging”, “Breast Cancer” e “Magnetic Resonance”.*

## 1 INTRODUÇÃO

Em 2020, a Organização Mundial de Saúde (OMS) notificou um total de 2,3 milhões de mulheres diagnosticadas com câncer de mama e 658 mil mortes em todo o mundo, obtendo uma maior predominância mundial. O câncer de mama, que atinge a maioria das mulheres, é definido pelo surgimento nas células de revestimento dos ductos, na maioria das vezes, ou lóbulos no tecido glandular da mama <sup>(1)</sup>. O câncer de mama mais frequente é o carcinoma ductal invasivo, que corresponde em torno de 70% a 80% dentre todos os carcinomas da mama <sup>(2)</sup>.

A taxa de cura clínica do câncer mamário precedente pode chegar a uma porcentagem acima de 90% em comparação ao estágio intermediário, que é de 50% a 70%, e ao estágio tardio, diminuindo as chances de sobrevivência <sup>(3)</sup>. Sendo assim, o diagnóstico precoce e preciso da doença é um fator relevante para auxiliar no tratamento e prognóstico, podendo aumentar as chances de cura do paciente e evitar uma suposta metástase <sup>(4)</sup>.

A ressonância magnética (RM) da mama é o método mais sensível para a detecção do carcinoma quando comparado a mamografia digital, tomossíntese digital e ultrassom, considerando sua capacidade em avaliar a forma, o tamanho, o escopo e a perfusão sanguínea das massas mamárias através de uma variedade de sequências de varredura <sup>(3)</sup>. Por meio da RM é possível obter imagens claras e detalhadas dos tecidos, facilitando a identificação de lesões que podem ser consideradas benignas em outras modalidades de imagem <sup>(5)</sup>.

Nas últimas décadas, devido ao avanço computacional, a inteligência artificial (IA) tem sido objeto de estudo com a descoberta de novos algoritmos e o acesso a dados disponíveis com maior facilidade <sup>(6)</sup>. Atualmente, um dos modelos amplamente utilizados pela IA, baseado em redes neurais, é o *deep learning* (DL) <sup>(3)</sup>. Esse método possui capacidade em aprender, automaticamente, através de representações de dados com vários níveis de concepções, sendo a tecnologia mais recente para especificação de imagens em ressonância magnética <sup>(7)</sup>.

A segmentação de lesões em imagens é uma das tarefas que o *deep learning* pode ser aplicado. Por meio dela é possível agrupar pixels ou conjunto de pixels da mesma propriedade, ou seja, partes de uma imagem que transmite a mesma categoria de um objeto <sup>(2)</sup>, podendo assim ser utilizada para detectar limites, tumores e massas de acordo com a descrição predefinida da região de interesse <sup>(8)</sup>. A segmentação correta das lesões mamárias garante uma classificação e diagnóstico precisos da doença



<sup>(3)</sup>, sendo considerada uma fase importante na imagem médica, porém, quando feita manualmente, é um processo demorado e exigente <sup>(8)</sup>.

Desse modo, o presente estudo tem como objetivo revisar o desempenho da IA em *deep learning* na segmentação de regiões mamárias e áreas tumorais da mama e descrever os algoritmos de redes neurais aplicados para segmentação da mama em RM, a fim de contribuir com o conhecimento sobre o desenvolvimento e as aplicabilidades da inteligência artificial para o diagnóstico de câncer de mama.

## 2 MATERIAIS E MÉTODOS

Trata-se de uma revisão sistemática elaborada seguindo o diagrama *Preferred Report Items for Systematics and Meta-Analyses* (PRISMA), efetuada no ano de 2023, através da busca de artigos científicos no período de 7 de agosto a 30 de setembro. A estratégia de busca para cada base de dados foi embasada na pergunta investigativa: “A inteligência artificial em *deep learning* é um método eficaz na segmentação de exames de imagem em ressonância magnética para auxiliar mulheres no diagnóstico de câncer de mama?”, que teve como suporte para sua formulação a estratégia PICOS (*Patient, Intervention, Comparison, Outcome and Study*).

### 2.1 Estratégia de busca bibliográfica

Foram selecionados artigos das seguintes bases de dados: Público/editora MEDLINE (PubMed), *Scientific Electronic Library Online* (SciELO) e Literatura Latino-Americana e do Caribe em Ciências da Saúde (LILACS). Os descritores e termos que foram verificados na plataforma Descritores em Ciências da Saúde (DeCS) e *Medical Subject Headings* (MESH) incluem, em português: “Inteligência artificial”, “aprendizado profundo”, “processamento de imagem/segmentação”, “diagnóstico por imagem”, “câncer de mama” e “ressonância magnética”; e em inglês: “*Artificial Intelligence*”, “*Deep learning*”, “*image processing/segmentation*”, “*diagnostic Imaging*”, “*Breast Cancer*” e “*Magnetic Resonance*”.

Para a associação das palavras-chave nos bancos de dados, foi aplicado o operador booleano AND, resgatando temas que incluíam os descritores e termos da pesquisa. Sendo assim, foi realizada a seguinte estratégia de busca: PubMed - (((((“*Artificial intelligence*”) AND (“*Deep Learning*”)) AND (“*Segmentation*”)) AND (“*Diagnosis*”)) AND (“*Breast cancer*”)) AND (“*Magnetic resonanc*”)); SciELO - (“Inteligência artificial”) AND (“Aprendizado profundo”) AND (“Segmentação”) AND

("Diagnóstico") AND ("Câncer de mama") AND ("Ressonância magnética"); LILACS - ("Aprendizado profundo" [Palavras] AND "Segmentação" [Palavras] AND "Câncer de mama" [Palavras]).

## 2.2 Critérios de elegibilidade

Para a seleção dos artigos foram adotados os seguintes critérios de inclusão: artigos científicos originais disponíveis na íntegra, publicados nos últimos 6 anos (2018-2023) no idioma português e inglês, tendo como objeto de pesquisa modelos humanos. Além disso, foram selecionados artigos que obtiveram considerável relevância para esse estudo, abordando sobre a segmentação de imagens da mama inteira ou da área tumoral em ressonância magnética utilizando o modelo *deep learning* para auxiliar no diagnóstico de câncer de mama. Como critérios de exclusão, foram rejeitados artigos em formato de revisão sistemática e de literatura, estudos de ponto de vista, artigos em duplicata e que não respondia a pergunta investigativa. O desenho de estudo não foi considerado fator de exclusão para a presente revisão.

## 2.3 Organização e extração dos dados

Na coleta de dados, foram selecionados os artigos científicos, previamente, por meio do título e, em seguida, através dos resumos, obtendo, por fim, a análise do artigo na íntegra. Os dados bibliográficos dos estudos foram organizados no programa Microsoft Excel, no qual foram avaliados o título e o resumo, quanto aos critérios de inclusão. Os estudos que atenderam aos critérios de inclusão foram armazenados e seus detalhes alimentados na planilha prévia do Microsoft Excel. Estudos completos que não seguiram os critérios, foram excluídos. Os resultados das buscas e avaliações foram reportados no fluxograma PRISMA, elaborado no programa Microsoft PowerPoint.

A extração dos dados foi feita identificando informações relevantes e padronizadas dos artigos, incluindo: primeiro autor; ano de publicação; população adotada (número e idade média); desenho utilizado; foco do estudo; equipamento de ressonância magnética manuseado; sequência operada no protocolo dos exames; algoritmo *deep learning* aplicado; métricas de avaliação de segmentação: coeficiente de similaridade de dados (CSD) e sensibilidade de segmentação (SS) ; principais descobertas do desempenho de segmentação; e resultados significativos. Os dados foram organizados em formato de tabela.

## 2.4 Avaliação da qualidade

Visando aprimorar o rigor científico e metodológico dos artigos encontrados, foi feita uma avaliação do risco de viés dos estudos. Para isso, foi utilizada a plataforma Joanna Briggs Institute (JBI), uma organização que tem como objetivo avaliar a confiabilidade, a relevância e os resultados dos artigos. Sendo assim, foi preenchida a lista de verificação de avaliação crítica do JBI <sup>(11)</sup> contendo questões referentes ao desenho de estudo dos artigos selecionados. Após a avaliação, foi categorizado os níveis do risco de viés em: alto, moderado e baixo, de acordo com a porcentagem de respostas positivas de cada artigo. Os estudos que apresentaram um resultado positivo acima de 70% foram classificados com baixo risco de viés, de 50% a 69% com moderado risco de viés e os que tiveram um resultado abaixo de 50% com alto risco de viés. A verificação JBI foi descrita através de um gráfico elaborado no programa Microsoft PowerPoint.

## 3 RESULTADOS

Após a busca bibliográfica, foram identificados, através de bases de dados e registros PubMed, SciELO e LILACS, 47 artigos. Desses estudos, 26 foram descartados decorrente à seleção feita a partir da triagem pelo título e resumo, incluindo estudos que não respondiam a pergunta investigativa e estudos de revisão de literatura. Foram selecionados para análise 21 artigos completos para avaliação e filtragem de elegibilidade, obedecendo critérios de artigos originais e disponíveis na íntegra, escritos em língua portuguesa e inglesa e dentro do período de 2018 a 2023. Após a leitura e aplicação dos critérios de seleção, restaram 8 artigos elegíveis (Figura 1).

A Tabela 1 evidencia as características gerais dos oito artigos incluídos na revisão. Os anos dos artigos selecionados variou de 2019 a 2022, considerando 2020 e 2022 os anos com maior número de publicações, com um total de 3 para cada ano. A maior parte dos estudos (n = 6) tiveram amostras acima de 100 pacientes, com idade média variando entre 35-51 anos. Todos os estudos utilizaram o desenho transversal retrospectivo (n = 8), porém, com focos diferentes de segmentação, sendo 3 com enfoque para a área tumoral, 4 para a região mamária e 1 para lesões de massa. Os artigos englobaram uma variedade de equipamentos de RM, empregando em 6 estudos sequências de imagens com contraste dinâmico (DCE) e em 4 estudos sequência de difusão (DWI). As imagens coletadas em todos os artigos foram analisadas e delineadas manualmente por radiologistas especialistas, servindo de parâmetro para determinar a verdade básica para qualificação.

A Rede Neural Convulacional (CNN) *U-Net* foi o algoritmo em *deep learning* que obteve maior predominância nos artigos ( $n = 6$ ), sendo testado isoladamente <sup>(13,17)</sup>, em combinação com outros métodos <sup>(11,12)</sup> e em uma versão melhorada <sup>(15)</sup>. Também foi utilizado o algoritmo *ResNet50* <sup>(10)</sup> e *Mask R-CNN* <sup>(16)</sup>. O índice de coeficiente de similaridade de dados foi a métrica de avaliação empregada, na maior parte dos artigos <sup>(11,12,13,14,15,16,17)</sup>, para medir a taxa de repetição da segmentação automática e manual. Dentre os estudos, o algoritmo *U-Net* isolado apresentou um índice CSD de 95% no treinamento de dois artigos <sup>(13,17)</sup>, na sua versão melhorada (*U-Net++*) também atingiu um índice de 95%, quando combinado com o algoritmo de aprendizado de máquina (SVM) apresentou desempenho de 93% <sup>(12)</sup> a 94% <sup>(11)</sup>, quando combinado com o aprendizado de transferência indicou um bom funcionamento com 97% no treinamento e 87% no teste <sup>(17)</sup>, quando comparado com o SegNet apontou um maior percentual, principalmente nas sequências de contraste dinâmico (92%; 87%). O algoritmo *Mask R-CNN* apresentou um CSD maior no treinamento (82%). Não foi aplicada a métrica de CSD no estudo com a Rede Neural *ResNet50* (Tabela 2).

Nos estudos com o algoritmo de combinação *U-Net* e SVM, Li YZ *et al.* <sup>(11)</sup> e Guo YY *et al.* <sup>(12)</sup> avaliaram a sensibilidade de segmentação (SS) da proporção de pontos tumorais corretamente segmentados em relação ao valor real, obtendo um valor de 94% e 92%, respectivamente, em comparação a outros estudos. No estudo com a arquitetura *U-Net++*, Jiao H *et al.* <sup>(15)</sup> também determinou a sensibilidade da segmentação para cada imagem de validação, alcançando um valor de 94%.

Dentre os estudos avaliados na lista de verificação da JBI, 7 foram categorizados com baixo risco de viés <sup>(10,11,12,13,15,16,17)</sup>, atendendo aos critérios e alcançando o percentual positivo acima de 70%, e 1 foi classificado com moderado risco de viés, apresentando respostas negativas e obtendo o percentual positivo entre 50% a 69% (Figura 2).

**TABELA 1.** Descrição das características gerais dos artigos selecionados

Autores e ano	Desenho do estudo	População	Foco do estudo (área segmentada)	Equipamento de RM	Sequência do exame
Zhou J <i>et al.</i> <sup>(10)</sup> , 2020	Transversal retrospectivo	N = 133; 91 malignos (IM: 51±10) e 62 benignas (IM: 45±11)	Tumores malignos e lesões benignas	3T (GE)	DCE (VIBRANT)
Li YZ <i>et al.</i> <sup>(11)</sup> , 2022	Transversal retrospectivo	N = 164; 98 com alta expressão KI-67 e 66 com baixa expressão	Câncer Ki-67	3T (PHILIPS, Ingenia)	DWI
Guo YY <i>et al.</i> <sup>(12)</sup> , 2022	Transversal retrospectivo	N = 272; 107 triplo-negativos e 165 cânceres com pressão molecular	Câncer triplo-negativo	3T (PHILIPS, Ingenia)	DCE (T2-FSE e STIR); DWI
Zhang Y <i>et al.</i> <sup>(13)</sup> , 2019	Transversal retrospectivo	N = 286 CDI unilateral para treinamento (IM: 49 anos); N = 28 saudáveis para validação (IM: 35 anos)	Região mamária	T: 3T (Siemens); V: 1.5T (GE e Siemens), 3T (GE e Siemens)	T: pré-contraste em T1; V: T1 sem contraste
Zhang L <i>et al.</i> <sup>(14)</sup> , 2020	Transversal retrospectivo	N = 98;	Região mamária	1,5T (Siemens e GE); 3T (Siemens)	4 conjuntos de dados: 2 DCE; 2 DWI
Jiao H <i>et al.</i> <sup>(15)</sup> , 2020	Transversal retrospectivo	N = 75 (IM: 47 anos)	Região mamária	3T (GE)	DWI; DCE (VIBRANT)
Zhang Y <i>et al.</i> <sup>(16)</sup> , 2022	Transversal retrospectivo	N = 241 para treinamento; N = 98 para teste (IM: 49 anos para ambos)	Lesões de massa (CDI em destaque)	T: 3T; TT: 1,5T (Siemens)	DCE (3D-FLASH)
Zhang Y <i>et al.</i> <sup>(17)</sup> , 2021	Transversal retrospectivo	3 dados: N = 286 sem gordura; N = 126 para treinamento (IM: 48,5 anos); N = 40 para teste (IM: 44 anos)	Região mamária em imagens de gordura	SG: 3T; T: 1,5T; TT: 3T (Siemens)	T1W pré-contraste; DCE (3D-FLASH)

IM, idade média; DCE, estudo dinâmico com contraste; VIBRANT, imagem de volume para avaliação da mama; DWI, sequência de difusão; T2-FSE, *Fast Spin Echo* ponderadas em T2; STIR, sequência da recuperação de inversão de curto período; CDI, carcinoma ductal invasivo; T, treinamento; V, validação; TT, teste; 3D-FLASH, sequência tridimensional rápida de baixo ângulo; SG, sem gordura; T1W, ponderado em T1

**TABELA 2.** Desempenho da segmentação avaliado pelo coeficiente de similaridade de dados (CSD)

Autores	Algoritmo DL	CSD (média)
Zhou J <i>et al.</i> <sup>(10)</sup>	<i>ResNet50</i>	NA
Li YZ <i>et al.</i> <sup>(11)</sup>	Combinação <i>U-Net</i> + SVM	94%
Guo YY <i>et al.</i> <sup>(12)</sup>	Combinação <i>U-Net</i> + SVM	93%
Zhang Y <i>et al.</i> <sup>(13)</sup>	<i>U-Net</i>	T: 95%; V: 86% (média de todas as RM)
Zhang L <i>et al.</i> <sup>(14)</sup>	<i>U-Net</i> e <i>SegNet</i>	<i>U-Net</i> : 92% (DCE 1); 87% (DCE 2); 85% (DWI 3); 72% (DWI 4)  <i>SegNet</i> : 84% (DCE 1); 80% (DCE 2); 77% (DWI 3); 65% (DWI 4)
Jiao H <i>et al.</i> <sup>(15)</sup>	<i>U-Net++</i>	95%
Zhang Y <i>et al.</i> <sup>(16)</sup>	<i>Mask R-CNN</i>	T: 82%; TT: 79%
Zhang Y <i>et al.</i> <sup>(17)</sup>	<i>U-Net</i>	T: 95% (sem AT); 97% (com AT)  TT: 83% (sem AT); 89% (com AT)

NA, não se aplica; SVM, algoritmo de aprendizado de máquina; RM, ressonância magnética; T, treinamento; V, validação; DCE, estudo dinâmico com contraste; DWI, sequência de difusão; CNN, rede neural convulacional; TT, teste; AT, aprendizado por transferência

#### 4 DISCUSSÃO

Nesse estudo de revisão, foi avaliado o desempenho da inteligência artificial em *deep learning* de segmentar regiões mamárias e áreas tumorais na mama, de forma automatizada, através de aplicações dos algoritmos de CNN em exames de ressonância magnética para auxiliar no diagnóstico de câncer de mama. Para isso, foram revisados um conjunto de dados de artigos transversais retrospectivos.

A partir das análises desses artigos, observa-se que o foco dos estudos para segmentação da mama inteira é predominante, porém, já se tem carcinomas importantes sendo estudados, como o câncer

Ki-67 <sup>(11)</sup>, câncer triplo-negativo <sup>(12)</sup> e o carcinoma ductal invasivo <sup>(13)</sup>. Além disso, foram testados uma variedade de equipamentos de RM com diferentes protocolos, o que promove viabilidade para uma possível integração dessas técnicas na prática clínica.

Dentre os algoritmos DL implementados, a CNN *U-Net* tem sido destaque nos estudos com bons desempenhos e resultados satisfatórios, com média de 95% de coeficiente de similaridade de dados (tabela 2) e média de 94% de sensibilidade quando calculado em sua versão melhorada (*U-Net++*) <sup>(15)</sup> e em combinação com SVM <sup>(11,12)</sup>. A partir das métricas de avaliação (CSD e a SS) verificadas nos artigos, foi mostrado que a segmentação automatizada através do algoritmo *deep learning* apresenta resultados relevantes quando comparado com a segmentação manual realizada pelos radiologistas especialistas (verdade básica).

Apesar de obter pontos importantes e relevantes para o tema, o estudo apresentou limitações por consequência da escassez de publicações, considerando ser um tópico recente e atual. Não foi encontrado nenhum estudo em língua portuguesa nas bases de dados (SciElo e LILACS), apenas estudos em inglês (PubMed). Sendo assim, é pertinente que pesquisem e explorem essa nova tecnologia de inteligência artificial em saúde, a fim de fornecer estratégias para profissionais radiologistas e imagenologistas e, conseqüentemente, assegurar o paciente para um melhor diagnóstico e prognóstico do câncer de mama.

## 5 CONCLUSÃO

Em suma, esta revisão mostrou que a IA em *deep learning* na segmentação de regiões mamárias e áreas tumorais da mama em ressonância magnética tem um bom potencial e eficácia para auxiliar no diagnóstico de câncer de mama, sendo capaz de atingir o seu objetivo e realizar o que foi proposto.

## 6 AGRADECIMENTOS

Agradeço, a princípio, a Deus por ter me abençoado nessa trajetória. Aos meus pais e família por todo incentivo, em especial a minha irmã Juliana Rinelle por me acompanhar e apoiar diariamente nesse processo. Agradeço aos meus amigos que foram essenciais nesse caminho, especialmente a Briena Rodrigues, Chloe Delayen, Isabela Reis e Júlia Góis por toda contribuição nesse momento tão importante. E, por fim, aos docentes prof.<sup>a</sup> Mara Dias, Prof. Thomas Pitangueiras, prof.<sup>a</sup> Léa Maria

dos Santos e prof.<sup>a</sup> Luciane Amorim pelos conhecimentos compartilhados e pela orientação nesse processo de formação.

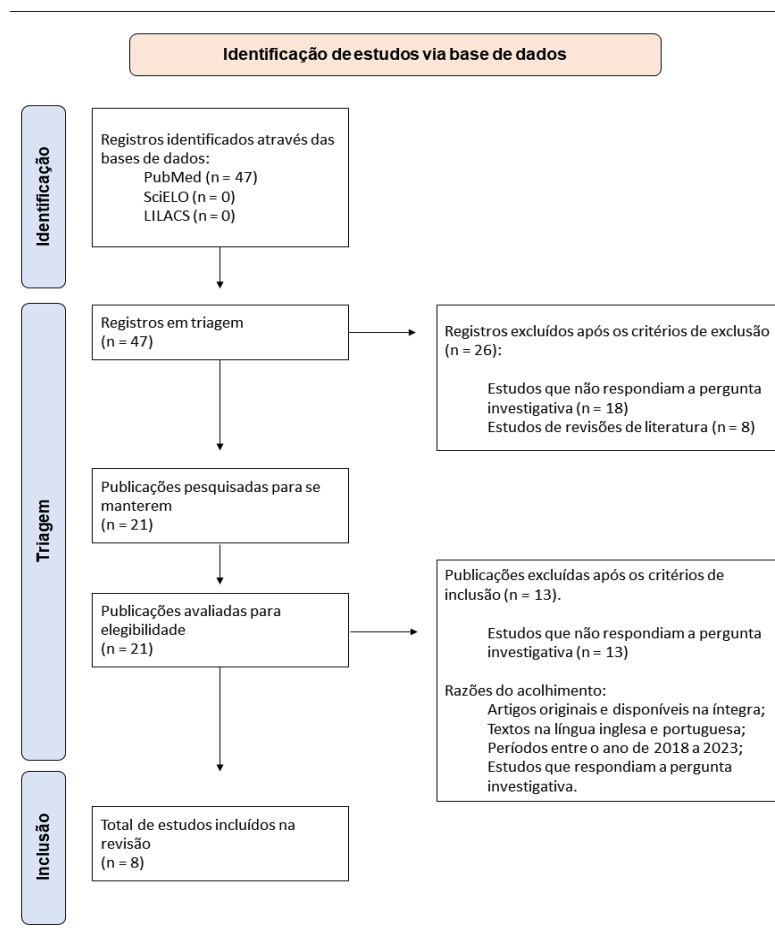
## 7 REFERÊNCIAS

1. Organização mundial de saúde (OMS). Breast câncer [internet] 26 mar. 2021. Acesso em: 14 abr. 2023. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/breast-cancer>.
2. Mahoro E, Akhloufi MA. Applying Deep Learning for Breast Cancer Detection in Radiology. *Curr Oncol*. 2022 Nov 16;29(11):8767-8793.
3. Lei YM, Yin M, Yu MH, et al. Artificial Intelligence in Medical Imaging of the Breast. *Front Oncol*. 2021 Jul 22;11:600557
4. Shamsi M, Pirayesh Islamian J. Breast cancer: early diagnosis and effective treatment by drug delivery tracing. *Nucl Med Rev Cent East Eur*. 2017;20(1):45-48.
5. Madani M, Behzadi MM, Nabavi S. The Role of Deep Learning in Advancing Breast Cancer Detection Using Different Imaging Modalities: A Systematic Review. *Cancers (Basel)*. 2022 Oct 29;14(21):5334.
6. Decuyper M, Maebe J, Van Holen R, et al. Artificial intelligence with deep learning in nuclear medicine and radiology. *EJNMMI Phys*. 2021 Dec 11;8(1):81.
7. Meyer-Bäse A, Morra L, Meyer-Bäse U, et al. Current Status and Future Perspectives of Artificial Intelligence in Magnetic Resonance Breast Imaging. *Contrast Media Mol Imaging*. 2020 Aug 28;2020:6805710.
8. Zambrano-Vizuet M, Botto-Tobar M, Huerta-Suárez C, et al. Segmentation of Medical Image Using Novel Dilated Ghost Deep Learning Model. *Comput Intell Neurosci*. 2022 Aug 12;2022:6872045.
9. Moola S, Munn Z, Tufanaru C, et al. Chapter 7: Systematic reviews of etiology and risk [Internet]. *JBIM Manual for Evidence Synthesis: Aromataris E, Munn Z (Editors)*. JBI, 2020. Disponível em: <https://synthesismanual.jbi.global>
10. Zhou J, Zhang Y, Chang KT, et al. Diagnosis of Benign and Malignant Breast Lesions on DCE-MRI by Using Radiomics and Deep Learning With Consideration of Peritumor Tissue. *J Magn Reson Imaging*. 2020 Mar;51(3):798-809.



11. Li YZ, Huang YH, Su XY, et al. Breast MRI Segmentation and Ki-67 High- and Low-Expression Prediction Algorithm Based on Deep Learning. *Comput Math Methods Med.* 2022 Oct 4;2022:1770531.
12. Guo YY, Huang YH, Wang Y, et al. Breast MRI Tumor Automatic Segmentation and Triple-Negative Breast Cancer Discrimination Algorithm Based on Deep Learning. *Comput Math Methods Med.* 2022 Aug 31;2022:2541358.
13. Zhang Y, Chen JH, Chang KT, et al. Automatic Breast and Fibroglandular Tissue Segmentation in Breast MRI Using Deep Learning by a Fully-Convolutional Residual Neural Network U-Net. *Acad Radiol.* 2019 Nov;26(11):1526-1535.
14. Zhang L, Mohamed AA, Chai R, et al. Automated deep learning method for whole-breast segmentation in diffusion-weighted breast MRI. *J Magn Reson Imaging.* 2020 Feb;51(2):635-643.
15. Jiao H, Jiang X, Pang Z, et al. Deep Convolutional Neural Networks-Based Automatic Breast Segmentation and Mass Detection in DCE-MRI. *Comput Math Methods Med.* 2020 May 5;2020:2413706.
16. Zhang Y, Chan S, Park VY, et al. Automatic Detection and Segmentation of Breast Cancer on MRI Using Mask R-CNN Trained on Non-Fat-Sat Images and Tested on Fat-Sat Images. *Acad Radiol.* 2022 Jan;29 Suppl 1(Suppl 1):S135-S144.
17. Zhang Y, Chan S, Chen JH, et al. Development of U-Net Breast Density Segmentation Method for Fat-Sat MR Images Using Transfer Learning Based on Non-Fat-Sat Model. *J Digit Imaging.* 2021 Aug;34(4):877-887. doi: 10.1007/s10278-021-00472-z.

**FIGURA 1.** Fluxograma de seleção dos artigos segundo o diagrama PRISMA



**FIGURA 2.** Gráfico da avaliação do risco de viés dos artigos conforme a lista de verificação da JBI

		QUESTÕES – ESTUDO TRANSVERSAL								
		Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	
ESTUDOS	Zhou J et al. (10), 2020	✓	✓	✓	✓	NA	NA	✓	✓	Baixo risco de viés
	Li YZ et al. (11), 2022	✓	–	✓	✓	NA	NA	✓	✓	Baixo risco de viés
	Guo YY et al. (12), 2022	✓	–	✓	✓	NA	NA	✓	✓	Baixo risco de viés
	Zhang Y et al. (13), 2019	✓	–	✓	✓	NA	NA	✓	✓	Baixo risco de viés
	Zhang L et al. (14), 2020	✗	✗	✓	✓	NA	NA	✓	✓	Moderado risco de viés
	Jiao H et al. (15), 2020	✓	–	✓	✓	NA	NA	✓	✓	Baixo risco de viés
	Zhang Y et al. (16), 2022	✓	–	✓	✓	NA	NA	✓	✓	Baixo risco de viés
	Zhang Y et al. (17), 2021	✓	–	✓	✓	NA	NA	✓	✓	Baixo risco de viés

Q1: Were the criteria for inclusion in the sample clearly defined?	✗ NÃO
Q2: Were the study subjects and the setting described in detail?	✓ SIM
Q3: Was the exposure measured in a valid and reliable way?	– POUCO CLARO
Q4: Were objective, standard criteria used for measurement of the condition?	NA NÃO APLICÁVEL
Q5: Were confounding factors identified?	
Q6: Were strategies to deal with confounding factors stated?	
Q7: Were the outcomes measured in a valid and reliable way?	
Q8: Was appropriate statistical analysis used?	

## 8 PROPOSTA DE SUBMISSÃO

### 8.1 Revista

A Radiologia Brasileira (RB) (ISSN 0100-3984) é o órgão científico do colégio brasileiro de radiologia e diagnóstico por imagem, que visa a publicação de artigos científicos para áreas de Radiologia, Medicina Nuclear, Ultrassonografia, Tomografia Computadorizada e Ressonância Magnética. A revista aceita publicação de trabalhos escritos em língua portuguesa ou inglesa.

### 8.2 Regras de submissão

Para artigos de revisão, é preciso ter até 4.000 palavras (incluindo-se tabelas e quadros e excluindo-se as referências), 16 figuras, 4 tabelas e 50 referências. Nas figuras compostas por duas ou mais imagens (A, B, C..), cada imagem é contada como uma figura. O número de autores deve se limitar a 6.

— Orientações gerais para o preparo de artigos científicos:

Os manuscritos devem ser digitados em espaço duplo (todas as páginas), com margens de pelo menos 3 cm e fonte Times New Roman 11 pontos contendo as seguintes partes: página de títulos; resumos e unitermos; texto e agradecimentos (se houver); referências; legenda de figuras e tabelas (se houver). Os Artigos Originais devem ser divididos em seções, com os itens: Introdução, Materiais e Métodos, Resultados, Discussão.

**PÁGINA DE TÍTULOS:** Esta página deve conter: título do artigo em português, título do artigo em inglês, nomes completos (por extenso e na forma abreviada) dos autores, a Instituição a que pertence cada autor, o número de registro no ORCID de cada autor, seus endereços completos e e-mails. O autor correspondente deverá ser claramente identificado e o seu endereço completo, número de telefone e e-mail devem ser fornecidos. Incluir um título resumido do artigo (máximo de 60 caracteres, inclusive espaços) para constar no topo das páginas do artigo.

**RESUMOS E UNITERMOS:** Resumos estruturados (em português e inglês) com no máximo 200 palavras devem ser incluídos em cada manuscrito de Artigo Original. Para Artigos de Revisão, resumos de 100 a 200 palavras devem sintetizar o conteúdo do artigo, que não deve

ser dividido em itens. Listar três a seis unitermos/keywords. Referências não devem ser citadas nos resumos dos trabalhos.

Os resumos devem conter os itens: **Objetivo:** Descreva a hipótese testada ou procedimentos avaliados. **Materiais e Métodos:** Descreva brevemente o que foi feito e os materiais utilizados, inclusive o número de pacientes, os métodos empregados para a avaliação dos dados e para evitar o viés. **Resultados:** Cite os achados do estudo, inclusive indicadores de significância estatística. Números reais e porcentagens devem ser incluídos. **Conclusão:** A(s) conclusão(ões) baseada(s) nos achados deve(m) ser resumida(s) em uma ou duas sentenças. **Unitermos:** Devem ser listados, abaixo dos resumos, três a seis Unitermos e respectivos keywords, preferentemente de acordo com os Descritores em Ciências da Saúde (DeCS) ou com o Medical Subject Headings (MeSH) da National Library of Medicine.

INTRODUÇÃO: Descreva brevemente o objetivo da investigação e explique a sua importância

MATERIAIS E MÉTODOS: Descreva o plano de pesquisa, os materiais (ou pacientes) e os métodos utilizados, nesta ordem. Explique em detalhes como a doença foi confirmada e como a subjetividade das observações foi controlada. Para garantir o anonimato no processo de revisão, o nome da Instituição onde o trabalho foi realizado e os nomes dos autores ou suas iniciais não devem ser mencionados.

RESULTADOS: Apresente os resultados em sequência lógica e clara. Se forem utilizadas tabelas, não duplique os dados tabulares no texto, mas descreva as tendências e pontos importantes.

DISCUSSÃO: Descreva as limitações do plano de pesquisa, materiais (ou pacientes) e métodos, considerando o objetivo e os resultados do estudo. Quando os resultados forem diferentes de resultados obtidos em estudos anteriores, justifique a discrepância.

CONCLUSÕES: Quando for o caso, descreva-as em sentenças resumidas. Agradecimentos: Devem-se mencionar colaborações de pessoas, instituições ou agradecimentos por apoio financeiro e auxílios técnicos que mereçam reconhecimento, mas não justificam a sua inclusão entre os autores.

REFERÊNCIAS: As referências devem ser numeradas, consecutivamente, na ordem que aparecem no texto e formatadas segundo as diretrizes do ICMJE, publicadas em

“Recommendations for the conduct, reporting, editing, and publication of scholarly work in medical journals”, atualizadas em 2018. As abreviaturas utilizadas para os periódicos citados nas referências devem seguir o padrão do PubMed. Exemplo de artigo de periódico: 1. Glazebrook KN, Magut MJ, Reynolds C. Angiosarcoma of the breast. AJR Am J Roentgenol. 2008;190:533-8. **Nota:** Quando mais de três autores forem listados, citar os três primeiros, seguidos da expressão et al.

TABELAS: Cada tabela deve ser digitada em espaço duplo, em fonte 11, sem linhas verticais ou horizontais. Cada tabela deve ter um breve título descritivo. As tabelas não deverão ter mais que uma página e deverão apresentar pelo menos quatro linhas e duas colunas de dados. As tabelas devem ser numeradas em algarismos arábicos, na ordem que são citadas no texto. As abreviaturas e explicações devem ser identificadas em notas embaixo de cada tabela e não no título, e identificadas pelas seguintes letras e sequência: (a), (b), (c), (d), (e). As tabelas devem ser autoexplicativas e não podem duplicar dados apresentados no texto ou nas figuras. A precisão de todos os cálculos aritméticos (porcentagens, totais, diferenças) deverá ser verificada e os dados tabulares deverão coincidir com os dados apresentados no texto.

FIGURAS E LEGENDAS: Cada figura será enviada no sistema em separado. Todas as figuras devem ter legendas. É essencial que a legenda descreva todas as características constantes de uma figura. As figuras devem ser limitadas às necessidades para mostrar as características essenciais descritas no manuscrito. É preferível que cada figura apresente apenas a(s) área(s) de interesse, com suficiente área ao redor para fins de orientação. É essencial indicar todas as características descritas na legenda, utilizando-se identificadores diferentes para cada característica. Nota: não devem ser utilizados triângulos equiláteros como setas ou pontas de setas. Os identificadores devem ser aplicados diretamente sobre a figura, encostados às lesões (ou estruturas) que se quer evidenciar. Nas figuras compostas por duas ou mais imagens (A, B, C,...), cada imagem é contada como uma figura. As imagens de fotografias devem vir em arquivos jpg, gif ou tiff, com resolução de 300 dpi para o tamanho aproximado de 9 × 12 cm. Ilustrações em cores somente serão assim publicadas se os editores concluírem que as cores são essenciais para transmitir a mensagem dessas ilustrações. As imagens de fotografias devem vir em arquivos jpg, gif ou tif, com resolução de 300 dpi para o tamanho aproximado de 9 x 12 cm.

UNIDADES E ABREVIATURAS: Medidas de radiação e valores laboratoriais devem se basear nas Unidades do Sistema Internacional (International System Units in Radiation Protection and Measurements, NCRP Report no. 28, August 1985). Abreviaturas e siglas devem ser evitadas e, preferentemente, não devem ser incluídas no título do artigo e no resumo. Quando citadas no texto, devem ser descritas por extenso na primeira menção e seguidas pela abreviatura ou sigla entre parênteses.