



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
SISTEMAS DE INFORMAÇÃO

IVAN FERREIRA DA SILVA LIMA

**CLASSIFICAÇÃO DE CÂNCER DE MAMA UTILIZANDO APRENDIZAGEM DE
MÁQUINA: UMA REVISÃO SISTEMÁTICA DA LITERATURA BRASILEIRA**

Recife

2022

IVAN FERREIRA DA SILVA LIMA

**CLASSIFICAÇÃO DE CÂNCER DE MAMA UTILIZANDO APRENDIZAGEM DE
MÁQUINA: UMA REVISÃO SISTEMÁTICA DA LITERATURA BRASILEIRA**

Trabalho apresentado ao Programa de Graduação em Sistemas de informação do Centro de Informática da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Bacharel em Sistemas de Informação.

Orientador: Prof. Dr. Fernando Maciano de Paula Neto

Recife

2022

IVAN FERREIRA DA SILVA LIMA

CLASSIFICAÇÃO DE CÂNCER DE MAMA UTILIZANDO APRENDIZAGEM DE MÁQUINA: UMA REVISÃO SISTEMÁTICA DA LITERATURA BRASILEIRA

Trabalho apresentado ao Programa de Graduação em Sistemas de informação do Centro de Informática da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Bacharel em Sistemas de Informação.

Recife, xx de março de 2022

BANCA EXAMINADORA

Prof. Dr. Fernando Maciano de Paula Neto (Orientador)
UNIVERSIDADE FEDERAL DE PERNAMBUCO

Prof. Dr. Teresa Bernarda Ludermir (2º membro da banca)
UNIVERSIDADE FEDERAL DE PERNAMBUCO

AGRADECIMENTOS

A todos os professores do curso de Sistema de Informação do Centro de Informática da Universidade Federal de Pernambuco (UFPE), em especial o Prof. Fernando Neto.

Aos meus pais, por todo o apoio.

“Um objetivo é um sonho com cronograma.” (Napoleon Hill).

RESUMO

De acordo com o Instituto Nacional do Câncer (INCA), o câncer de mama é a principal causa de morte, por câncer, entre as mulheres no Brasil. Uma das maneiras de proporcionar maior probabilidade de cura é começar o tratamento da doença em fase inicial. Por isso, estudos vêm sendo desenvolvidos para realizar o diagnóstico precoce, utilizando principalmente inteligência artificial. Este trabalho propõe uma Revisão Sistemática da Literatura de artigos acadêmicos publicados por pesquisadores brasileiros sobre a classificação da doença, que fazem uso de técnicas de aprendizado de máquina entre os anos de 2015 e 2021.

Palavras-chave: computação de diagnóstico médico; algoritmos de aprendizado de máquina; câncer de mama.

ABSTRACT

According to the National Cancer Institute (INCA), breast cancer is the leading cause of cancer-related death among women in Brazil. One of the ways to provide a treatment that is more likely to cure is to start treating the disease at an early stage. Therefore, studies have been developed to carry out early diagnosis, mainly using artificial intelligence. This work proposes a systematic literature review of academic articles published by Brazilians on disease prediction using machine learning techniques between 2015 and 2021.

Keywords: medical diagnostic computing; machine learning algorithms; breast cancer.

LISTA DE FIGURAS

Figura 1 – Detalhamento das etapas do método proposto por Kitchenham	15
Figura 2 – Quantidade de estudos filtrados por base	20
Figura 3 – Estudos aceitos após aplicação dos critérios de inclusão e de exclusão	21
Figura 4 – Quantidade de estudos iniciais e estudos aceitos após seleção por título e resumo	21
Figura 5 – Total de publicações por ano que foram analisadas.....	26
Figura 6 – Principais técnicas utilizadas nos estudos analisados	28
Figura 7 – Métricas de avaliação mais utilizadas nos estudos analisados.....	31
Figura 8 – Exames mais utilizados nos estudos analisados.....	41

LISTA DE TABELAS

Tabela 1	– Palavras-chave dos termos de busca e seus sinônimos	16
Tabela 2	– <i>String</i> de busca	17
Tabela 3	– Critérios de inclusão	17
Tabela 4	– Critérios de exclusão	17
Tabela 5	– Nível de qualidade gerado a partir do somatório dos critérios de qualidade	18
Tabela 6	– Estudos primários remanescentes.....	22
Tabela 7	– Avaliação dos critérios de qualidade, Q1, Q2, Q3, Q4 e Q5, definidos na seção 3.2.6.....	25
Tabela 8	– Técnicas mais utilizadas nos estudos analisados.....	27
Tabela 9	– Métricas de avaliação mais utilizadas nos estudos analisados	30
Tabela 10	– Técnicas que mostraram melhor desempenho nos estudos analisados	32
Tabela 11	– Base de dados em que foram extraídas as informações dos estudos analisados .	36
Tabela 12	– Ambientes de modelagem e validação utilizados nos estudos analisados	39

LISTA DE ABREVIATURAS E SIGLAS

CE	Critérios de exclusão
CI	Critérios de inclusão
csv	<i>comma-separated values</i>
IA	Inteligência artificial
INCA	Instituto Nacional do Câncer
ML	<i>Machine learning</i>
PS	Primários selecionados
QCP	Questão central de pesquisa
QSP	Questões secundárias de pesquisa
RSL	Revisão sistemática de literatura

SUMÁRIO

1	INTRODUÇÃO	12
1.1	OBJETIVOS	13
1.1.1	Objetivo geral	13
1.1.2	Objetivos específicos	13
1.2	QUESTÕES DE PESQUISA	13
2	REFERENCIAL TEÓRICO	14
2.1	CÂNCER DE MAMA	14
2.1.1	Diagnóstico precoce	14
2.2	INTELIGÊNCIA ARTIFICIAL	14
2.2.1	Aprendizado de máquina	14
3	PROTOCOLO DO ESTUDO SISTEMÁTICO DA LITERATURA	15
3.1	PERGUNTAS DA PESQUISA	15
3.2	ESTRATÉGIA DE BUSCA	16
3.2.1	Fonte de busca	16
3.2.2	Termos de busca	16
3.2.3	<i>String</i> de busca	16
3.2.4	Critérios de seleção dos estudos	17
3.2.4.1	Critérios de inclusão	17
3.2.4.2	Critérios de exclusão	17
3.2.5	Processo de seleção dos estudos	18
3.2.6	Avaliação de qualidade	18
3.2.7	Extração dos dados	19
4	RESULTADO E SUMARIZAÇÃO DO ESTUDO	20
4.1	BUSCA.....	20
4.1.1	Critérios de seleção dos estudos	20
4.1.2	Seleção por título e resumo	21
4.1.3	Seleção por critérios de qualidade	22
4.2	VISÃO GERAL DOS ESTUDOS	26
4.2.1	Publicações por ano	26
4.2.2	Mapeamento das evidências	26
4.2.2.1	QSP1: Quais são as técnicas de aprendizado de máquina usadas atualmente para diagnosticar o câncer de mama?	26

4.2.2.2 QSP2: Quais são as métricas de avaliação?.....	30
4.2.2.3 QSP3: Quais são as técnicas que mostraram melhor desempenho em contextos específicos?.....	31
4.2.2.4 QSP4: Como e quais dados foram coletados?.....	36
4.2.2.5 QSP5: Quais são os conjuntos de modelagem e validação que foram utilizados? (ambiente experimental).....	39
4.2.2.6 QSP6: De quais exames as informações foram retiradas?	41
4.2.3 Limitações da pesquisa e ameaça à validade.....	41
5 CONCLUSÃO E TRABALHOS FUTUROS.....	42
5.1 CONCLUSÕES	42
5.2 TRABALHOS FUTUROS	43
REFERÊNCIAS.....	44

1 INTRODUÇÃO

De acordo com o relatório estatístico apresentado pela GLOBOCAN em 2020, o câncer de mama é o tipo mais frequente entre as mulheres, além de ter a maior mortalidade, atrás apenas do câncer de pulmão (SUNG *et al.*, 2021). Para mudar essa situação, a melhor maneira de se proporcionar maior chance de cura é começar o tratamento da doença em fase inicial (INSTITUTO NACIONAL DO CÂNCER [INCA], 2021).

A informática em saúde pode ser considerada uma área de muita relevância, visto que se trata de um ramo cujo objetivo é favorecer a qualidade de vida da população por meio de avanços tecnológicos, como: *software*, *hardware* e sistemas de informação. Essa área estuda o desenvolvimento de soluções computacionais que auxiliem os profissionais de saúde ou hospitais a prestarem melhor assistência aos pacientes ou melhor gestão hospitalar. O uso da nanotecnologia para tratamento de câncer, telemedicina, prontuário eletrônico e cirurgias robóticas assistidas é um exemplo da contribuição dos estudos dessa área de pesquisa. A informação é hoje encarada como recurso essencial para organizações (AMARAL, 1994). A necessidade por informação já é realidade em hospitais, clínicas médicas e consultórios que buscam, com o uso da tecnologia, fazer tratamento mais eficiente, realizar diagnósticos com mais eficácia, melhorar a prevenção de doenças etc.

Há diversas pesquisas realizadas no ramo da inteligência artificial (IA), para que, por intermédio de dados médicos coletados em hospitais ou universidades, consiga ser feito o diagnóstico precoce de alguma patologia, e assim realizar tratamento em fases iniciais da doença.

Nos últimos anos, há uma grande quantidade de estudos que usam métodos de aprendizado de máquinas, como árvore de decisão, floresta aleatória, máquina de vetores de suporte e aprendizado profundo, e tentam prever o câncer de mama, utilizando dados médicos, como mamografia ou imagens de ultrassonografia. Esse tipo de pesquisa vem sendo realizado ao redor do mundo, mas também existem trabalhos executados por brasileiros e até mesmo estudos que utilizam bases de dados brasileiras. Para esse trabalho, foram analisados apenas estudos realizados por brasileiros, no intuito de conhecer o estado da arte sobre diagnóstico precoce de câncer de mama e analisar quais as linhas de atuação dos pesquisadores no Brasil.

1.1 OBJETIVOS

1.1.1 Objetivo geral

O objetivo deste trabalho é realizar uma revisão sistemática da literatura, analisando somente trabalhos realizados por brasileiros, de maneira a identificar os tipos de técnicas de inteligência artificial para o diagnóstico de câncer de mama no Brasil e a mapear os desafios dessa área.

1.1.2 Objetivos específicos

- Usar as bibliotecas digitais para encontrar estudos realizados por brasileiros sobre sistemas que, por meio da inteligência artificial, conseguem diagnosticar precocemente câncer de mama;
- Fazer seleção nos estudos encontrados;
- Responder às questões propostas nesta pesquisa.

1.2 QUESTÕES DE PESQUISA

Esta pesquisa compreende uma revisão sistemática de literatura (RSL), realizada com base nas diretrizes propostas por Kitchenham e Charters (2007). Dito isto, foram propostas uma questão central de pesquisa (QCP), “Como funciona e quais são as características das técnicas inteligentes usadas na classificação do câncer?”, e seis questões secundárias de pesquisa (QSP), declaradas da seguinte forma:

- QPS1: Quais são as técnicas de aprendizado de máquina usadas atualmente para diagnosticar o câncer de mama?
- QPS2: Quais são as métricas de avaliação?
- QPS3: Quais são as técnicas que mostraram melhor desempenho em contextos específicos?
- QPS4: Como e quais dados foram coletados?
- QPS5: Quais são os conjuntos de modelagem e validação que foram utilizados? (ambiente experimental)
- QPS6: De quais exames as informações foram retiradas?

2 REFERENCIAL TEÓRICO

2.1 CÂNCER DE MAMA

O câncer de mama é uma doença causada pela multiplicação desordenada de células anormais da mama, que forma um tumor com potencial de invadir outros órgãos. Sendo a principal causa de morte por câncer entre as mulheres no Brasil, vale salientar que essa patologia também afeta homens (INCA, 2021).

No Brasil, estimativas de 2021 mostram que 66.280 novos casos foram diagnosticados com tumor maligno na mama. Além disso, no ano de 2019, 18.295 pessoas morreram da doença, sendo 18.068 mulheres e 227 homens (INCA, 2021).

2.1.1 Diagnóstico precoce

Uma das maneiras de proporcionar maior chance de cura é começar o tratamento na fase inicial, o que permite um tratamento menos agressivo. Por isso, o Ministério da Saúde recomenda que mulheres realizem, a cada dois anos, o exame da mamografia (INCA, 2021).

2.2 INTELIGÊNCIA ARTIFICIAL

De acordo com Gomes (2010), a IA é um ramo da Ciência da Computação, cujo interesse é fazer com que os computadores pensem ou se comportem de forma inteligente. A IA também sistematiza e automatiza tarefas intelectuais, e, portanto, é potencialmente relevante para qualquer esfera da atividade intelectual humana (SILVA, 2005).

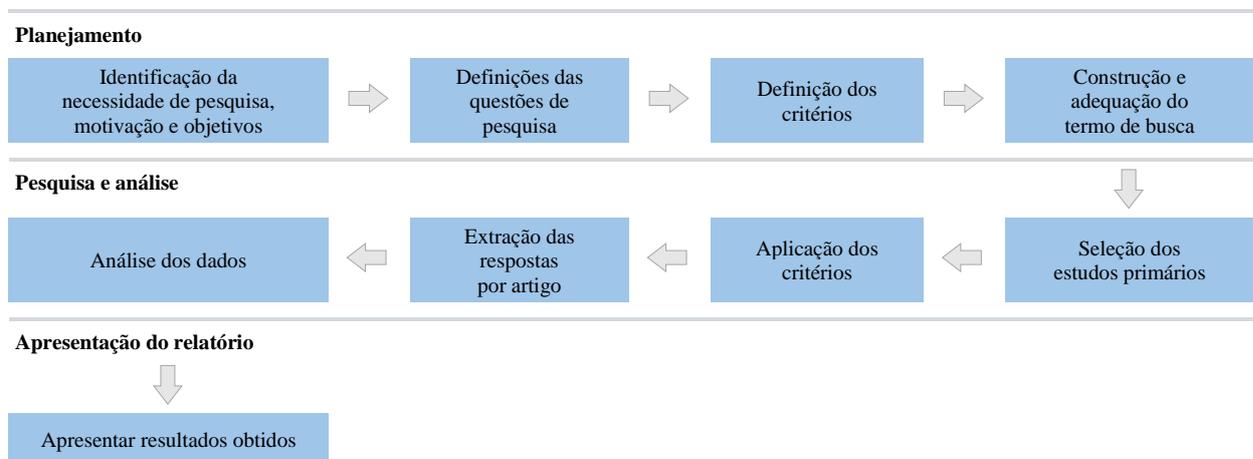
2.2.1 Aprendizado de máquina

Aprendizado de máquina é um ramo da inteligência artificial baseado na ideia de que sistemas podem aprender com dados (SAS INSTITUTE, 2021). Já a IBM (2019) entende que aprendizado de máquina é uma tecnologia na qual os computadores têm a capacidade de aprender conforme as respostas esperadas por meio de associações de diferentes dados, os quais podem ser imagens, números e tudo que essa tecnologia possa identificar.

3 PROTOCOLO DO ESTUDO SISTEMÁTICO DA LITERATURA

O método utilizado nesta pesquisa foi a RSL aplicada somente a estudos escritos por brasileiro. Essa técnica permite a obtenção de uma visão ampla em uma área de pesquisa para determinar se existe evidência de pesquisa em um tópico e para fornecer uma indicação da quantidade da evidência (KITCHENHAM; CHARTERS, 2007). A Figura 1 resume essas etapas e atividades relacionadas.

Figura 1 – Detalhamento das etapas do método proposto por Kitchenham



Fonte: adaptada de Kitchenham e Charters (2007).

3.1 PERGUNTAS DA PESQUISA

A questão central norteadora deste estudo é: “Como funciona e quais as características das técnicas inteligentes usadas na classificação do câncer?”. A partir dessa pergunta, seis questões específicas foram definidas, possibilitando melhor busca por respostas concretas, a saber:

- QPS1: Quais são as técnicas de aprendizado de máquina usadas atualmente para diagnosticar o câncer de mama?
- QPS2: Quais são as métricas de avaliação?
- QPS3: Quais são as técnicas que mostraram melhor desempenho em contextos específicos?
- QPS4: Como e quais dados foram coletados?
- QPS5: Quais são os conjuntos de modelagem e validação que foram utilizados? (ambiente experimental)
- QPS6: De quais exames as informações foram retiradas?

3.2 ESTRATÉGIA DE BUSCA

Buscando responder a todas as perguntas da pesquisa, utilizando-se de estudos com maior relevância, foi realizada estratégia de busca automática em bibliotecas digitais e definida estruturação da *string* de busca que seria utilizada nas fontes automáticas. Para essa finalidade, foi estruturada a *string* de busca utilizada nas fontes automáticas.

3.2.1 Fonte de busca

Brereton *et al.* (2007) definem as bases Scopus, ScienceDirect, ACM e IEEE Xplore como bibliotecas digitais importantes na área da computação. Essas fontes de dados são renomadas e conhecidas na área da Tecnologia da Informação, em razão da quantidade e qualidade dos artigos publicados. Além disso, permitem rápido e fácil acesso aos estudos, por meio de interface simples e ferramentas de filtros para pesquisa. Dessa maneira, as mesmas foram utilizadas neste trabalho.

3.2.2 Termos de busca

A Tabela 1 expõe as palavras-chave e seus sinônimos.

Tabela 1 – Palavras-chave dos termos de busca e seus sinônimos

Palavras-chave	Sinônimos
Machine learning	Artificial intelligence
Predicting	Identify, predict, diagnosis
Breast cancer	

Fonte: O autor (2022).

3.2.3 *String* de busca

A composição da *string* de busca se deu a partir dos termos relacionados às perguntas de pesquisa e do levantamento em fontes relacionadas, além de abreviações de alguns termos. Sendo assim, a *string* ficou conforme mostra a Tabela 2, a seguir:

Tabela 2 – *String* de busca

<i>String</i> de busca
‘machine learning’ OR ML OR ‘artificial intelligence’ OR AI AND identify OR Predicting OR predict OR Diagnosis AND ‘breast cancer’

Fonte: O autor (2022).

3.2.4 Critérios de seleção dos estudos

Após a realização da busca nas bibliotecas digitais, cada estudo teve seu título, palavras-chave e resumo avaliados, sendo eliminados aqueles que claramente fugiam do escopo do mapeamento. Os critérios de inclusão (CI) e de exclusão (CE) são apresentados nas tabelas 3 e 4, a seguir.

3.2.4.1 Critérios de inclusão

Tabela 3 – Critérios de inclusão

Critério	Descrição
CI1	Publicações que estejam disponíveis nas bases pesquisadas
CI2	Publicações do período de 2015 até 2021
CI3	Publicações em inglês
CI4	Estudos primários
CI5	Estudos realizados por brasileiros

Fonte: O autor (2022).

3.2.4.2 Critérios de exclusão

Tabela 4 – Critérios de exclusão

Critério	Descrição
CE1	Publicações pagas, indisponíveis para <i>download</i> ou visualização
CE2	Publicações anteriores a 2015
CE3	Estudos secundários
CE4	Estudos duplicados
CE5	Publicações que não foram realizadas por brasileiros
CE6	Publicações com menos de quatro páginas

Fonte: O autor (2022).

3.2.5 Processo de seleção dos estudos

Na primeira etapa da fase de seleção de estudos, os resultados encontrados mediante o uso da *string* de busca nas bibliotecas digitais citadas anteriormente foram guardados em uma planilha eletrônica compartilhada, na qual os dados foram extraídos e classificados. O conteúdo extraído foram os metadados: título, autores, tipo de artigo publicado, ano de publicação, número de páginas e fonte.

Na segunda etapa, foi realizada análise do título e resumo do artigo, na qual foram aplicados os critérios de inclusão e exclusão já mencionados. Em alguns casos, fez-se necessário também a leitura da introdução e conclusão de estudos para realizar confirmações sobre a validade do trabalho.

A terceira etapa teve como objetivos aplicar os critérios de avaliação e realizar o processo de extração de dados. Nessa etapa, foi realizada a leitura de todos os artigos restantes, bem como a análise de suas qualidades e o registro das respostas para as perguntas secundárias.

3.2.6 Avaliação de qualidade

Essa avaliação é feita com a finalidade de ajudar na interpretação dos resultados e de determinar a força das inferências. Assim, foram definidos os critérios de qualidade:

- Q1: Contexto claro;
- Q2: Metodologia bem definida;
- Q3: Aplicação prática;
- Q4: Discussão relevante e consistente;
- Q5: Limitações e ameaças da pesquisa comentadas.

Para esses critérios foi utilizada uma escala simples de três valores: 0 (não atende); 0,5 (atende parcialmente); e 1 (atende totalmente). Os trabalhos foram classificados de acordo com o somatório das notas dos critérios de qualidade avaliados (Tabela 5).

Tabela 5 – Nível de qualidade gerado a partir do somatório dos critérios de qualidade

Classificação	Intervalo
Baixa	$0 \leq N \leq 2$
Média	$2 \leq N \leq 3$
Alta	$3 \leq N \leq 5$

Fonte: O autor (2022).

Os trabalhos que não possuem resposta para nenhuma das perguntas da pesquisa estabelecidas na seção 3.1 também foram classificados como sendo de baixa qualidade.

3.2.7 Extração dos dados

A extração dos dados objetiva desenvolver formas de coletar os dados obtidos por meio dos estudos para responder às questões da pesquisa. A extração se deu a partir da criação de uma planilha eletrônica. O conteúdo extraído foram os metadados e os fragmentos importantes do texto dos artigos, os quais indicavam a resposta para cada uma das perguntas de pesquisa. Além disso, foi definido um identificador único para cada estudo.

4 RESULTADO E SUMARIZAÇÃO DO ESTUDO

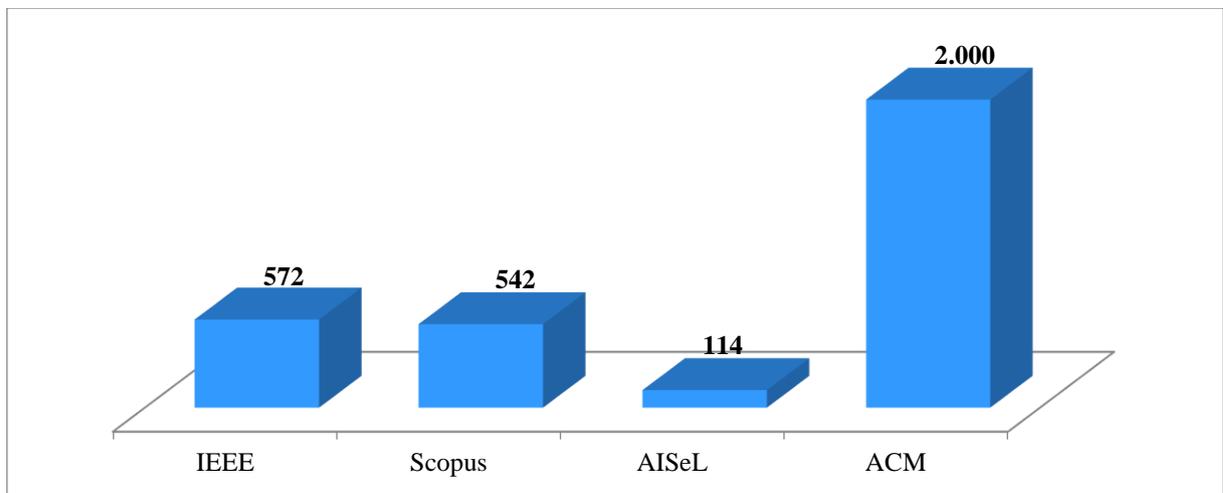
4.1 BUSCA

A *string* de busca foi aplicada no campo de texto da pesquisa avançada de cada biblioteca digital definida. Além disso, foram extraídos de todas as bases: título, nome dos autores, ano de publicação, quantidade de páginas e *link*. As informações fornecidas pela Scopus e pela IEEE Xplore foram exportadas no formato *comma-separated values* (.csv).

Já as demais bibliotecas digitais, ACM e AISEL, foram extraídas no formato *text file* (.txt), e foram manipuladas para serem salvas em uma planilha eletrônica. Todos os dados de todas as bibliotecas foram armazenados em uma planilha do Google Sheets.

No total foram extraídos dados de 3.258 estudos. Na base da ACM foram encontrados 4.820 estudos, porém apenas 2 mil foram disponibilizados. Um resumo dos números de estudos obtidos durante esta etapa pode ser visto na Figura 2.

Figura 2 – Quantidade de estudos filtrados por base



Fonte: O autor (2022).

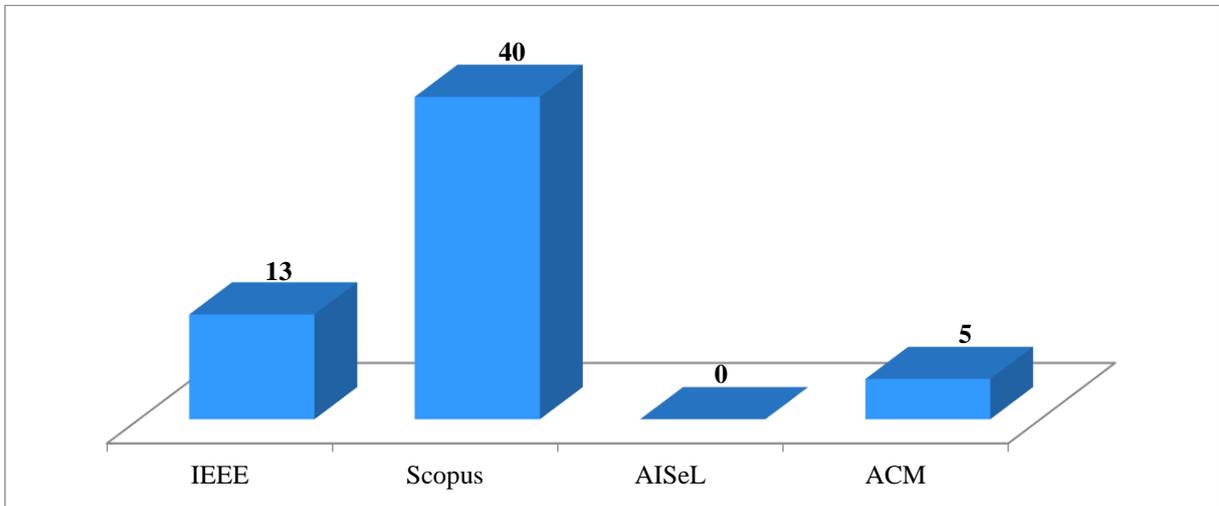
Observa-se, portanto, que a ACM teve a maior quantidade de estudos encontrados na primeira busca.

4.1.1 Critérios de seleção dos estudos

Foram aplicados os critérios de inclusão e exclusão já mencionados em seções anteriores. Ao final dessa fase, foram constatados 58 estudos aprovados, sendo 13 na

IEEE Xplore, 29 na Scopus e 5 na ACM (Figura 3). Nenhum estudo da base AISeL foi selecionado.

Figura 3 – Estudos aceitos após aplicação dos critérios de inclusão e de exclusão

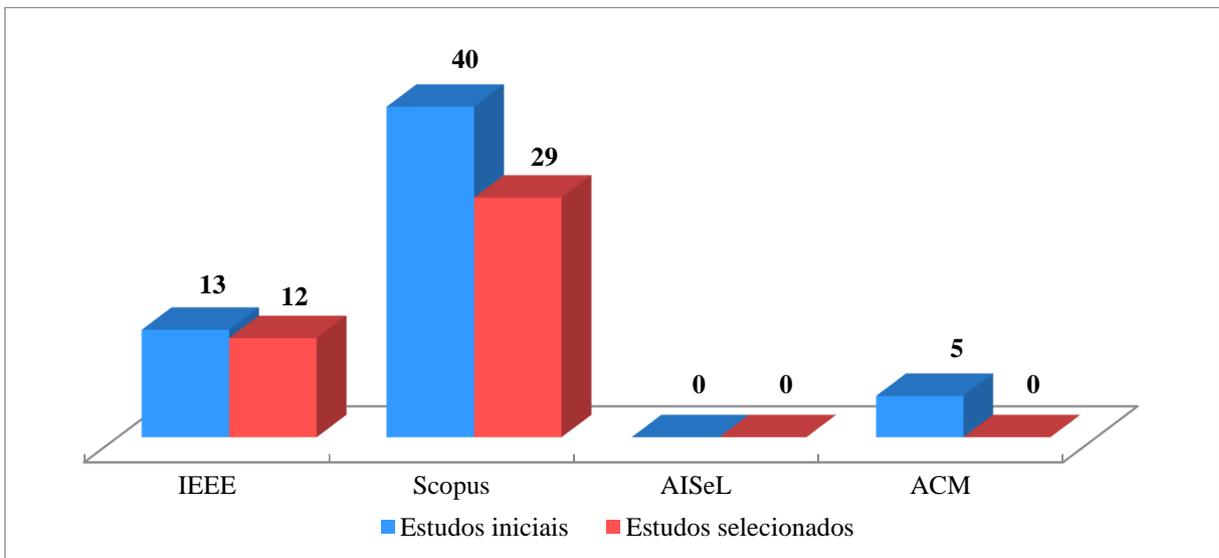


Fonte: O autor (2022).

4.1.2 Seleção por título e resumo

Como citado na seção 3.3.5, os títulos e resumos dos trabalhos encontrados foram analisados. Após essa análise, o número de artigos a serem analisados passou a ser 41, conforme mostra a Figura 4.

Figura 4 – Quantidade de estudos iniciais e estudos aceitos após seleção por título e resumo



Fonte: O autor (2022).

4.1.3 Seleção por critérios de qualidade

Para iniciar esta etapa, foi criado um ID para identificar unicamente o trabalho na pesquisa. A Tabela 6 apresenta os estudos restantes após os filtros nas secções 4.1.1, 4.1.2 e 4.1.3.

Tabela 6 – Estudos primários remanescentes

(continua)

ID	Título	Autor	Ano	Fonte
PS1	Fuzzy morphological extreme learning machines to detect and classify masses in mammograms	Azevedo, W. W.; Lima, S. M. L.; Fernandes, I. M. M.; Rocha, A. D. D.; Cordeiro, F. R.; Silva-Filho, A. G.; Santos, W. P.	2015	IEEE
PS2	Morphological extreme learning machines applied to detect and classify masses in mammograms	Azevedo, W. W.; Lima, S. M. L.; Fernandes, I. M. M.; Rocha, A. D. D.; Cordeiro, F. R.; Silva-Filho, A. G.; Santos, W. P.	2015	IEEE
PS3	Classification of breast regions as mass and non-mass based on digital mammograms using taxonomic indexes and SVM	Oliveira, F. S. S.; Carvalho Filho, A. O.; Silva, A. C.; Paiva, A. C.; Gattass, M.	2015	Scopus
PS4	Breast cancer detection with logistic regression improved by features constructed by Kaizen programming in a hybrid approach	Melo, V. V.	2016	IEEE
PS5	Interpretable models to predict breast cancer	Ferreira, P.; Dutra, I.; Salvini, R.; Burnside, E.	2016	IEEE
PS6	A hybrid model to support the early diagnosis of breast cancer	Carvalho, D.; Pinheiro, P. R.; Pinheiro, M. C. D.	2016	Scopus
PS7	Breast tumor classification in ultrasound images using support vector machines and neural networks	Nascimento, C. D. L.; Silva, S. D. S.; Silva, T. A.; Pereira, W. C. A.; Costa, M. G. F.; Costa Filho, C. F. F.	2016	Scopus
PS8	Application of artificial neural network models in segmentation and classification of nodules in breast ultrasound digital images	Marcomini, K. D.; Carneiro, A. A. O.; Schiabel, H.	2016	Scopus
PS9	Breast cancer histopathological image classification using convolutional neural networks	Spanhol, F. A.; Oliveira, L. S.; Petitjean, C.; Heutte, L.	2016	IEEE
PS10	Detection and classification of masses in mammographic images in a multi-kernel approach	Lima, S. M. L.; Silva-Filho, A. G.; Santos, W. P.	2016	Scopus
PS11	Computer aided diagnosis for breast diseases based on infrared images	Araújo, A. S.; Conci, A.; Montenegro, A. A.; Resmini, R.; Araújo, C.; Lebon, F.	2017	IEEE
PS12	Deep features for breast cancer histopathological image classification	Spanhol, F. A.; Cavalin, P. R.; Oliveira, L. S.; Petitjean, C.; Heutte, L.	2017	IEEE

Tabela 6 – Estudos primários remanescentes

(continuação)

ID	Título	Autor	Ano	Fonte
PS13	Proposal of new hybrid fuzzy clustering algorithms: application to breast cancer dataset	Coutinho, P. H. S.; Chagas, T. P.	2017	IEEE
PS14	Mammogram classification using back-propagation neural networks and texture feature descriptors	Pérez, M.; Benalcazar, M. E.; Tusa, E.; Rivas, W.; Conci, A.	2017	IEEE
PS15	Automatic mass detection in mammography images using particle swarm optimization and functional diversity indexes	Silva Neto, O. P.; Silva, A. C.; Paiva, A. C.; Gattass, M.	2017	Scopus
PS16	Convolutional neural networks for static and dynamic breast infrared imaging classification	Baffa, M. F. O.; Lattari, L. G.	2018	IEEE
PS17	Breast cancer diagnosis based on mammary thermography and extreme learning machines	Santana, M. A.; Pereira, J. M. S.; Silva, F. L.; Lima, N. M.; Sousa, F. N.; Arruda, G. M. S.; Lima, R. C. F.; Silva, W. W. A.; Santos, W. P.	2018	Scopus
PS18	An analysis of machine learning classifiers in breast cancer diagnosis	Teixeira, F.; Montenegro, J. L. Z.; Costa, C. A.; Righi, R. R.	2019	IEEE
PS19	Explainable machine learning for breast cancer diagnosis	Brito-Sarracino, T.; Santos, M. R.; Antunes, E. F.; Santos, I. B. A.; Kasmanas, J. C.; Carvalho, A. C. P. L. F.	2019	IEEE
PS20	Meta-data construction for selection of breast tissue biopsy slides image classifier to identify ductal carcinoma	Marin, L. F.; Silva, A. C.; Bandeira, J. O.	2019	IEEE
PS21	Texture CNN for histopathological image classification	Matos, J.; Britto Jr., A. S.; Oliveira, L. E. S.; Koerich, A. L.	2019	IEEE
PS22	Method of histopathological diagnosis of mammary nodules through deep learning algorithm	Kuiava, V. A.; Kuiava, E. L.; Rodriguez, R.; Beck, A. E.; Rodriguez, J. P. M.; Chielle, E. O.	2019	Scopus
PS23	Decision support for breast cancer detection: classification improvement through feature selection	Fogliatto, F. S.; Anzanello, M. J.; Soares, F.; Brust-Renck, P. G.	2019	Scopus
PS24	Double transfer learning for breast cancer histopathologic image classification	Matos, J.; Britto Jr., A. S.; Oliveira, L. E. S.; Koerich, A. L.	2019	IEEE
PS25	A novel deep learning based framework for the detection and classification of breast cancer using transfer learning	Khan, S.; Islam, N.; Jan, Z.; Din, I. U.; Rodrigues, J. J. P. C.	2019	Scopus
PS26	Multiple instance learning for histopathological breast cancer image classification	Sudharshan, P. J.; Petitjean, C.; Spanhol, F.; Oliveira, L. E.; Heutte, L.; Honeine, P.	2019	Scopus
PS27	Automatic classification of breast lesions using transfer learning	Silva Neto, R. P.; Carvalho Filho, A. O.	2019	IEEE
PS28	Breast cancer diagnosis through active learning in content-based image retrieval	Bressan, R. S.; Bugatti, P. H.; Saito, P. T. M.	2019	Scopus

Tabela 6 – Estudos primários remanescentes

(conclusão)

ID	Título	Autor	Ano	Fonte
PS29	Diagnosis of breast tissue in mammography images based local feature descriptors	Matos, C. E. F.; Souza, J. C.; Diniz, J. O. B.; Braz Junior, G.; Paiva, A. C.; Almeida, J. D. S.; Rocha, S. V.; Silva, A. C.	2019	Scopus
PS30	A computational method for breast abnormality detection using thermographs	Silva, L. F.; Seixas, F. L.; Fontes, C. A. P.; Muchaluat-SAADE, D. C.; Conci, A.	2020	IEEE
PS31	O ² PF: oversampling via optimum-path forest for breast cancer detection	Passos, L. A.; Jodas, D. S.; Ribeiro, L. C. F.; Pinheiro, T.; Papa, J. P.	2020	IEEE
PS32	Transfer learning and fine tuning in breast mammogram abnormalities classification on CBIS-DDSM database	Falconi, L. G.; Pérez, M.; Aguilar, W. G.; Conci, A.	2020	Scopus
PS33	Breast lesion classification in ultrasound images using deep convolutional neural network	Zeimarani, B.; Costa, M. G. F.; Nurani, N. Z.; Bianco, S. R.; Pereira, W. C. A.; Costa Filho, C. F. F.	2020	IEEE
PS34	Breast cancer diagnosis from histopathological images using textural features and CBIR	Carvalho, E. D.; Carvalho Filho, A. O.; Silva, R. R. V.; Araújo, F. H. D.; Diniz, J. O. B.; Silva, A. C.; Paiva, A. C.; Gattass, M.	2020	Scopus
PS35	A comparative study of linear discriminant analysis and an artificial neural network performances in breast cancer diagnosis	Pereira, G. B. G.; Fernandes, L. P.; Souza Neto, J. M. R.; Braz, H. D. M.; Sauer, L. S.	2020	IEEE
PS36	Evaluation of transfer learning of pre-trained CNNs applied to breast cancer detection on infrared images	Chaves, E.; Gonçalves, C. B.; Albertini, M. K.; Lee, S.; Jeon, G.; Fernandes, H. C.	2020	Scopus
PS37	BreastNet: breast cancer categorization using convolutional neural networks	Santos, C. F. G.; Afonso, L. C. S.; Pereira, C. R.; Papa, J. P.	2020	IEEE
PS38	Analysis of features for breast cancer recognition in different magnifications of histopathological images	Carvalho, R. H. O.; Martins, A. S.; Neves, L. A.; Nascimento, M. Z.	2020	IEEE
PS39	Combining genetic algorithms and SVM for breast cancer diagnosis using infrared thermography	Resmini, R.; Silva, L.; Araujo, A. S.; Medeiros, P.; Muchaluat-Saade, D.; Conci, A.	2021	Scopus
PS40	Breast cancer diagnosis using thermal image analysis: a data-driven approach based on swarm intelligence and supervised learning for optimized feature selection	Macedo, M.; Santana, M.; Santos, W. P.; Menezes, R.; Bastos-Filho, C.	2021	Scopus
PS41	A hybrid methodology for breast screening and cancer diagnosis using thermography	Resmini, R.; Silva, L. F.; Medeiros, P. R. T.; Araujo, A. S.; Muchaluat-Saade, D. C.; Conci, A.	2021	Scopus

Fonte: O autor (2022).

Já a Tabela 7, a seguir, demonstra as notas obtidas por cada estudo nos critérios de qualidade pré-estabelecidos. Trabalhos que possuem a avaliação “baixa” foram retirados desta pesquisa.

Tabela 7 – Avaliação dos critérios de qualidade, Q1, Q2, Q3, Q4 e Q5, definidos na seção 3.2.6

ID	Q1	Q2	Q3	Q4	Q5	Nota	Avaliação
PS1	1	1	1	1	0,5	4,5	Alta
PS2	1	1	1	1	0,5	4,5	Alta
PS3	1	1	1	1	0	4	Alta
PS4	1	1	1	1	0,5	4,5	Alta
PS5	1	1	1	1	0,5	4,5	Alta
PS6	0	0	1	1	0	2	Baixa
PS7	1	1	1	1	0	4	Alta
PS8	1	1	1	1		4	Alta
PS9	1	0,5	1	1	0	3,5	Alta
PS10	1	1	1	1	1	5	Alta
PS11	1	1	1	1	1	5	Alta
PS12	1	1	1	1	1	5	Alta
PS13	1	0,5	1	1	0	3,5	Alta
PS14	1	0,5	1	1	0,5	4	Alta
PS15	1	1	1	1	0	4	Alta
PS16	1	1	1	1	0	4	Alta
PS17	1	1	1	1	1	5	Alta
PS18	1	1	1	1	0	4	Alta
PS19	1	1	1	1	0	4	Alta
PS20	1	1	1	1	1	5	Alta
PS21	1	1	1	1	0	4	Alta
PS22	1	1	1	1	1	4	Alta
PS23	1	1	1	1	1	1	Alta
PS24	1	1	1	1	1	5	Alta
PS25	1	1	1	1	0	4	Alta
PS26	1	0,5	1	1	1	4,5	Alta
PS27	1	1	1	1	0,5	4,5	Alta
PS28	0	0	1	1	0	2	Baixa
PS29	1	1	1	1	1	5	Alta
PS30	1	0,5	1	1	0,5	4	Alta
PS31	1	1	1	1	0,5	4,5	Alta
PS32	1	1	1	1	1	5	Alta
PS33	1	1	1	1	1	5	Alta
PS34	1	1	1	1	1	5	Alta
PS35	0,5	0	1	0,5	0	2	Baixa
PS36	1	1	1	1	1	5	Alta
PS37	1	1	1	1	0	4	Alta
PS38	1	1	1	1	0,5	4,5	Alta
PS39	1	1	1	1	0,5	4,5	Alta
PS40	1	1	1	1	0	4	Alta
PS41	1	0,5	1	1	1	4,5	Alta

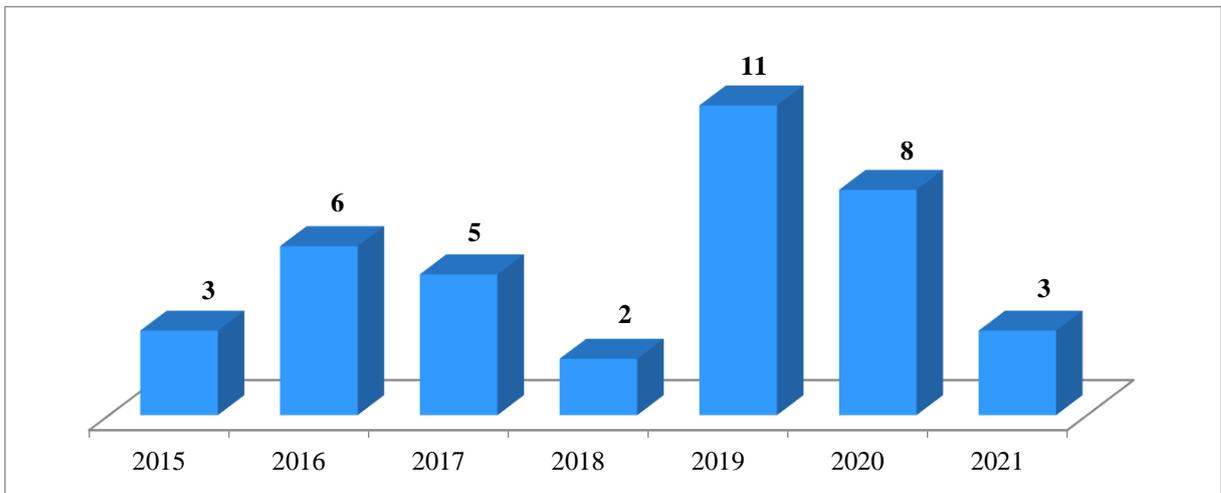
Fonte: O autor (2022).

4.2 VISÃO GERAL DOS ESTUDOS

4.2.1 Publicações por ano

Buscando analisar apenas dados e informações de estudos mais recentes, a pesquisa feita nas bibliotecas digitais foi limitada aos últimos 7 anos, de 2015 até 2021, conforme indicado no critério de inclusão CI2 e no critério de exclusão CE2. A distribuição do conjunto final de estudos selecionados ao longo dos anos é mostrada na Figura 5.

Figura 5 – Total de publicações por ano que foram analisadas



Fonte: O autor (2022).

É evidente que o ano de 2019 é o que apresenta o maior número de publicações sobre o assunto abordado nesta pesquisa, no entanto os outros anos não seguem um padrão, tornando difícil sua análise.

4.2.2 Mapeamento das evidências

Esta seção busca responder às questões de pesquisa citadas anteriormente, obtidas a partir do estudo sistemático da literatura.

4.2.2.1 QSP1: Quais são as técnicas de aprendizado de máquina usadas atualmente para diagnosticar o câncer de mama?

A Tabela 8, a seguir, mostra as técnicas mais citadas nos trabalhos selecionados.

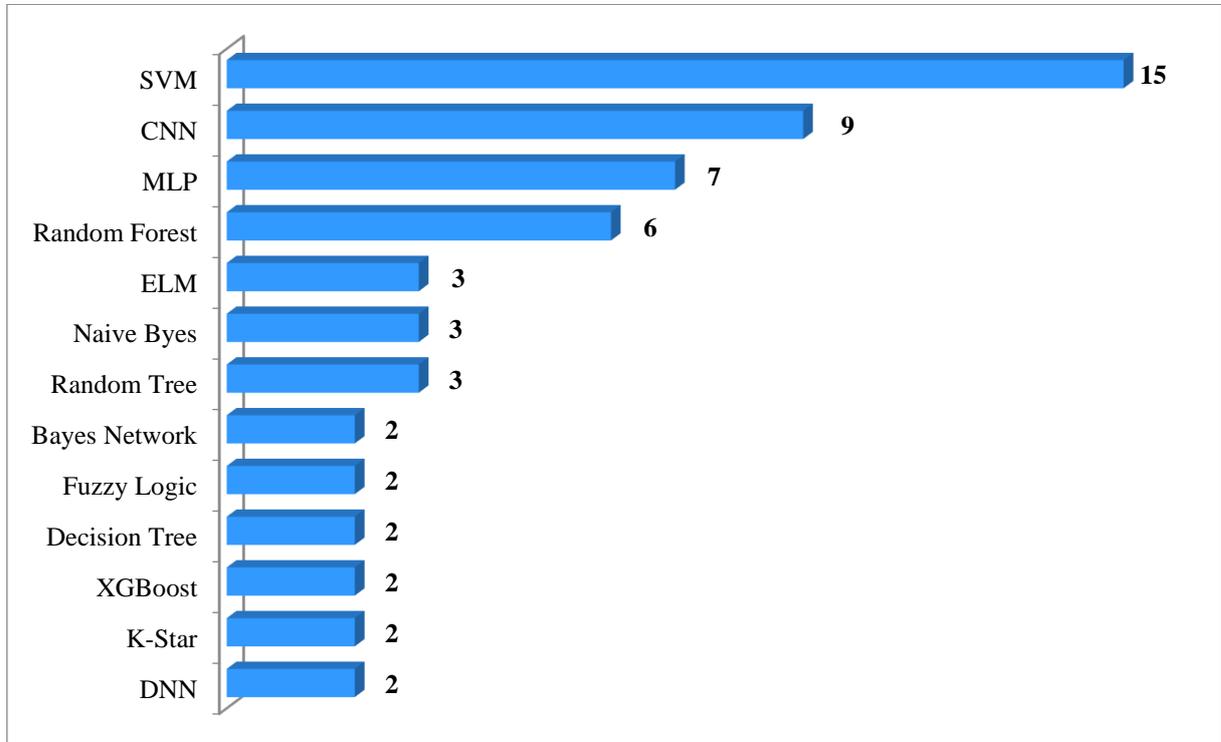
Tabela 8 – Técnicas mais utilizadas nos estudos analisados

Técnicas	Trabalhos
Support Vector Machine	PS3, PS5, PS7, PS10, PS11, PS12, PS17, PS18, PS24, PS27, PS29, PS34, PS39, PS40 e PS41
Convolutional Neural Network	PS9, PS16, PS20, PS21, PS22, PS25, PS33, PS36 e PS40
Multilayer Perceptron	PS8, PS9, PS17, PS18, PS20, PS34 e PS40
Random Forest	PS17, PS18, PS27, PS29, PS38 e PS40
Extreme Learning Machines	PS10, PS17 e PS40
Naive Bayes	PS17, PS20 e PS40
Random Tree	PS17, PS34 e PS40
Bayes Network	PS17 e PS40
Fuzzy logic	PS1 e PS13
Decision Tree	PS18 e PS19
XGBoost	PS27 e PS34
K-Star	PS30 e PS41
Morphological Extreme Learning machines	PS2
Logistic Regression	PS4
Neural Networks	PS7
A Deep Convolutional Activation Feature	PS12
Artificial Neural Network	PS14
Knowledge Tree J48	PS17 e PS30
Deep Neural Network	PS18 e PS37
k-Nearest Neighbor	PS23
Linear discriminant analysis	PS23
Probabilistic Neural Network	PS23
Multiple Instance Learning	PS26
Adaboost	PS29
Optimum-Path Forest Algorithm	PS31
Fine-tuning	PS32
Sequential Minimal Optimization	PS38
mELM	PS40
ELM sigmoid	PS40

Fonte: O autor (2022).

A Figura 6 aponta as principais técnicas utilizadas nos trabalhos selecionados.

Figura 6 – Principais técnicas utilizadas nos estudos analisados



Fonte: O autor (2022).

As citações descritas a seguir foram extraídas dos estudos selecionados na Tabela 6:

“In this work, we propose Fuzzy Morphological Extreme Learning Machines, with hidden layer kernel based on nonlinear morphological operators of erosion and dilation.” (PS1).

“In this work, we propose Morphological Extreme Learning Machines, with hidden layer kernel based on nonlinear morphological operators of erosion and dilation.” (PS2).

“This paper is divided as follows: in Section 3 we present the methodology used to classify the regions of interest extracted from mammographic images as mass and non-mass, using taxonomic indexes for feature extraction and a support vector machine for classification.” (PS3).

“In this paper, we employ the recently proposed Kaizen Programming (KP) approach with LR to construct high-quality nonlinear combinations of the original features resulting in new sets of features.” (PS4).

“In this work, we study the relevance of these variables on our dataset and also investigate alternatives for the SVM model used by MammoClass by training our data using Inductive Logic Programming (ILP) [24]...” (PS5).

“This study evaluated the performance of support vector machines (SVM) with different kernels combinations, and neural networks with different stop criteria, for classifying breast cancer nodules.” (PS7).

“... the most expressive features were defined to the morphological description of the finding, generating the input data to the neural Multilayer Perceptron (MLP) classifier.” (PS8).

“We propose a method based on the extraction of image patches for training the CNN and the combination of these patches for final classification.” (PS9).

“We used the following network architectures: Multilayer Perceptron’s (MLP), Extreme Learning Machines (ELM), and Support Vector Machines (SVM).” (PS10).

“For this classification, a Support Vector Machine (SVM) was used and trained based on already classified diagnosis from two databases.” (PS11).

“... we present an evaluation of DeCaf features for BC recognition, in order to better understand how they compare to the other approaches...” (PS12).

“This paper presents new hybrid fuzzy clustering algorithms.” (PS13).

“We implement an artificial neural network (ANN) for classification in three classes: normal, benign and cancer using leave one out technique.” (PS14).

“... the support vector machine (SVM) is used to classify ROIs in whether mass or non-mass.” (PS15).

“It was developed a supervised breast cancer detection methodology based on Convolutional Neural Networks (CNNs), which was never used for classifying infrared breast images.” (PS16).

“The classifiers used were Bayes Network, Naive Bayes, Support Vector Machines (SVM), Knowledge Tree J48, Multi-Layer Perceptron (MLP), Random Forest, Random Tree, and Extreme Learning Machines (ELM).” (PS17).

“We present six different classification methods: Multilayer Perceptron, Decision Tree, Random Forest, Support Vector Machine and Deep Neural Network for evaluation...” (PS18).

“Further, Decision Tree induction algorithms were used to create models that are able to differentiate between Malignant and Benign breast tumors from breast mass images.” (PS19).

“Third, Classifier Validation, in this step, each of four classification methods is executed and compared, using the Training Image Dataset as input data for CNN and the features extracted in the previous step for the MLP and NB methods.” (PS20).

“[...] we use an alternative architecture based on the texture CNN proposed by Andrearczyk and Whelan [9].” (PS21).

“The deep learning technique with convolutional neural network training was applied through the open source TensorFlow library.” (PS22).

“Observations of a training set were iteratively categorized into malignant and benign cases through 3 classification techniques: k-Nearest Neighbor, linear discriminant analysis, and probabilistic neural network.” (PS23).

“This work proposes a classification approach for breast cancer histopathologic images (HI) that uses transfer learning to extract features from HI using an Inception-v3 CNN pre-trained with ImageNet dataset. We also use transfer learning on training a support vector machine (SVM) classifier ...” (PS24).

“In the proposed framework, features from images are extracted using pre-trained CNN architectures...” (PS25).

“We propose a weakly supervised learning framework and investigate the relevance of Multiple Instance Learning (MIL) for computer-aided diagnosis of breast cancer patients[...].” (PS26).

“Na terceira etapa, foram utilizados os classificadores: Support Vector Machine (SVM), Random Forest e o eXtreme Gradient Boost (XGBoost) [...]” (PS27).

“Finally, the features are used as input for the Support Vector Machine (SVM), Adaptive Boosting (Adaboost) and Random Forests (RF) classifiers to differentiate malignant and benign masses.” (PS29).

“We used the following network architectures: Multilayer Perceptron’s (MLP), Extreme Learning Machines (ELM), and Support Vector Machines (SVM).” (PS30).

“Therefore this paper proposes the O2PF, a data oversampling method based on the unsupervised Optimum-Path Forest Algorithm.” (PS31).

“[...] Fine Tuning (FT) is used in order to address the over fitting problem and improve previous results on the CBIS-DDSM dataset.” (PS32).

“[...] we use a custom-built CNN with a few hidden layers and apply regularization techniques to improve the performance.” (PS33).

“The classifiers used were the most robust ones according to the existing literature: XGBoost, random forest, multilayer perceptron, and support vector machine.” (PS34).

“This work uses convolutional neural networks in a database of 440 infrared images of 88 patients, classifying them into two classes: normal and pathology.” (PS36).

“At a glance, magnified breast masses images are resized to 128×128 resolution and fed to deep neural networks that are responsible for learning features and classifying each sample into eight categories.” (PS37).

“The attribute set was employed to obtain the feature vectors which were evaluated as inputs to the random forest and sequential minimal optimization algorithms.” (PS38).

“This work proposes an ensemble method for selecting models and features by combining a Genetic Algorithm (GA) and the Support Vector Machine (SVM) classifier to diagnose breast cancer.” (PS39).

“... we test the diagnosis of eleven classifiers: BayesNet, NaiveBayes, MLP, SMO/SVM, J48, Random Forest, Random Tree, CNN, ELM sigmoid, mELM dilatation and mELM erosion.” (PS40).

“We used the following network architectures: Multilayer Perceptron’s (MLP), Extreme Learning Machines (ELM), and Support Vector Machines (SVM).” (PS41).

Os dados da Tabela 8 e da Figura 6 mostram que as técnicas mais utilizadas são SVM e CNN, sendo citadas em 14 e 10 estudos, respectivamente. Outro fato observado é que alguns estudos fizeram apenas a análise de uma técnica de ML, não realizando uma comparação com outros classificadores.

4.2.2.2 QSP2: Quais são as métricas de avaliação?

Segundo a seção 3.2.7, com base nos estudos selecionados, foi possível extrair dados e identificar as métricas de avaliação utilizadas, como pode ser visto na Tabela 9 e na Figura 7, a seguir.

Tabela 9 – Métricas de avaliação mais utilizadas nos estudos analisados

(continua)

Métrica	Trabalhos
Accuracy	PS3, PS4, PS7, PS8, PS9, PS10, PS12, PS15, PS16, PS17, PS18, P19, PS20, PS21, PS23, PS24, PS25, PS26, PS27, PS29, PS30, PS31, PS32, PS33, PS34, PS36, PS37, PS38, PS39 e PS41
Sensitivity	PS3, PS7, PS15, PS20, PS21, PS22, PS23, PS27, PS29, PS30, PS34, PS35, PS38, PS40 e PS41
Specificity	PS3, PS7, PS15, PS20, PS21, PS22, PS23, PS27, PS29, PS30, PS34, PS35, PS38, PS40 e PS41
Area Under the ROC Curve (AUC)	PS5, PS7, PS8, PS11, PS20, PS27, PS30, PS32, PS33, PS34, PS38, PS39, PS40 e PS41
F1 Score	PS18, PS19, PS25, PS29, PS31, PS32 e PS37
Precision	PS5, PS16, PS25, PS29, PS34 e PS37
Kappa Index	PS1, PS2, PS5, PS17 e PS27
Recall	PS19, PS25 e PS31

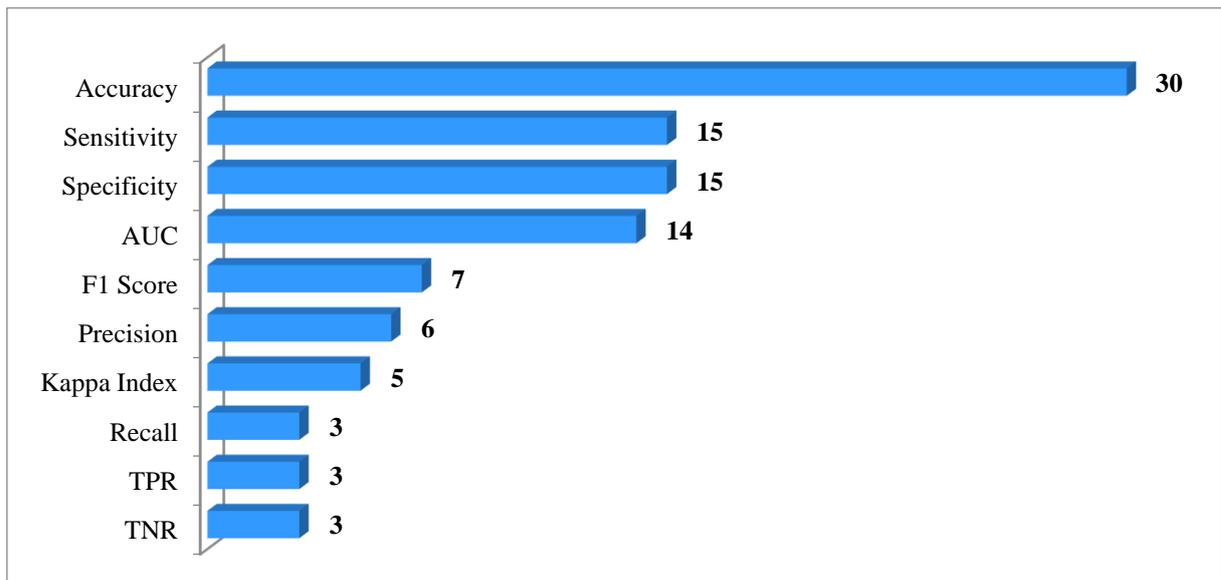
Tabela 9 – Métricas de avaliação mais utilizadas nos estudos analisados

(conclusão)

Métrica	Trabalhos
True Positive Rate (TPR)	PS5, PS14 e PS37
True Negative Rate (TNR)	PS5, PS14 e PS37
False Positive Rate (FPR)	PS14 e PS15
Overall Accuracy	PS1
F-measure	PS5
False Negative Rate (FFR)	PS14
Log loss	PS18
High Accuracy Values (ACC)	PS11
Positive predictive value	PS23
Negative predictive value	PS23
Matthews Correlation Coefficient	PS37

Fonte: O autor (2022).

Figura 7 – Métricas de avaliação mais utilizadas nos estudos analisados



Fonte: O autor (2022).

4.2.2.3 QSP3: Quais são as técnicas que mostraram melhor desempenho em contextos específicos?

Segundo a seção 3.2.7, com base nos estudos selecionados, foi possível identificar as técnicas que apresentaram o melhor desempenho em seus cenários específicos, como pode ser visto na Tabela 10, a seguir:

Tabela 10 – Técnicas que mostraram melhor desempenho nos estudos analisados

Técnicas	Trabalhos
Convolutional Neural Network	PS9, PS16, PS20, PS21, PS22, PS25, PS33 e PS36
Support Vector Machine	PS3, PS5, PS10, PS11, PS15, PS24, PS27, PS34 e PS39
Fuzzy logic	PS1 e PS13
Multilayer Perceptron	PS8 e PS17
K-star	PS30 e PS41
Morphological Extreme Learning machines	PS2
Logistic Regression	PS4
Neural Networks	PS7 e PS14
A Deep Convolutional Activation Feature	PS12
Deep Neural Network	PS18 e PS37
Decision Tree	PS19
Probabilistic Neural Network	PS23
Multiple Instance Learning	PS26
Adaboost	PS29
Optimum-Path Forest Algorithm	PS31
Fine-tuning	PS32
Random Forest	PS38
mELM	PS40

Fonte: O autor (2022).

Convolutional Neural Network

“Our experimental results obtained on the BreakHis dataset showed improved accuracy obtained by CNN when compared to traditional machine learning models trained on the same dataset but with state of the art texture descriptors.” (PS9).

“Our proposal obtained 98% of accuracy for static protocol and 95% for dynamic protocol.” (PS16).

“When comparing the performance of the different classification methods tested in this work, it is possible to affirm that the two CNN-based methods have a better performance, however it is necessary to consider the implications of the specificity and sensitivity results before selecting the best one.” (PS20).

“The experimental results on the BreakHis dataset have show that the proposed texture CNN achieves almost 90% of accuracy for classifying benign and malignant tissues.” (PS21).

“For the differentiation between benign (normal breast, fibrocystic alteration, and fibroadenoma) and malignant conditions (in situ, invasive no special type and invasive lobular type carcinomas) the system obtained maximum sensitivity of 78.7% and specificity of 95.8% for differentiation of malignant conditions. For benign conditions, the maximum sensitivity was 82.6% and the specificity was 97.4%. There was no statistical difference in sensitivity and specificity between MobileNet and Inception ($p = 0.74$).” (PS22).

“It has been observed that the proposed framework gives excellent results regarding accuracy without training from scratch which improves classification efficiency.” (PS25).

“... we achieved an overall accuracy of 85.98% for tumor classification, and the AUC equal to 0.94. After applying image augmentation and regularization, the accuracy and the AUC increased to 92.05% and 0.97, respectively. Using a pre-trained model, we achieved an overall accuracy of 87.07% and an AUC equal to 0.96.” (PS33).

“The best results were obtained using CNNs VGG-16 and VGG-19, both with 20 epochs. VGG-16 reached 77.5% AC, 85% SE, and 70% SP, while VGG-19 reached 77.5% AC, 90% SE, and 65% SP.” (PS36).

Support Vector Machine

“The proposed methodology successfully classified the masses and non-masses, with an average accuracy of 98.88%.” (PS3).

“We explored alternatives to our best SVM classifier and have shown that it is possible to obtain more interpretable classifiers with the same performance on the test set.” (PS5).

“Our proposal could achieve the best results employing feature extraction with wavelets Symlet 8 and SVM networks with linear kernels, reaching an average accuracy of 94.11%.” (PS10).

“The best results reached are 94.87% of accuracy and were obtained from the analysis between patients whose breasts were diagnosed with cancer or normal from the set of images of the database 2.” (PS11).

“The best results were found in case of dense breast tissue, resulting in a sensitivity of 97.52%, specificity of 92.28%, accuracy of 94.82%, false positives rate per image of 0.38 and free-curve receiver operating characteristic of 0.98.” (PS15).

“The proposed approach outperforms the state-of-the-art in three out of the four magnification factors of the breast cancer dataset.” (PS24).

“A arquitetura ResNet50 atingiu o melhor resultado dentre os algoritmos usados neste trabalho, alcançando valores acima de 78% nas métricas de avaliação, com a utilização do classificador SVM com kernel Polynomial.” (PS27).

“... where the best result was obtained with SVM, with 97.5% accuracy, 97% precision, 98.3% sensitivity, and 94.7% specificity.” (PS34).

“Our evaluation demonstrates that the approach presents a significant contribution to the early diagnosis of breast cancer, presenting results with 94.79% Area Under the Receiver Operating Characteristic Curve and 97.18% of Accuracy.” (PS39).

Fuzzy logic

“Results showed that the use of fuzzy morphological kernels improved the classification rate for most of scenarios and, for the better cases, when using Wavelets and Haralick, the results were better with fuzzy morphological kernels.” (PS1).

“Furthermore, we used SFCKM to obtain the initial cluster centers of GG-kMeans, which provided 96.57% of classification accuracy. This was the best classification accuracy obtained in this work.” (PS13).

Multilayer Perceptron

“The accuracy achieved during training with simulated images was 94.2%, producing an AUC of 0.92. To evaluating the data generalization, the classification was performed with a group of unknown images to the system, both to simulators and to clinical trials, resulting in an accuracy of 90% and 81%, respectively.” (PS8).

“The best result was obtained when we associated Haralick and Zernike attributes extractors. In this situation, 73.38% of the instances were correctly classified using MLP as the classifier, resulting in a Kappa index of 0.6007 when the percentage split approach was used, and we obtained the maximum value of 76.01% correctly classified instances and Kappa of 0.6402, also using MLP.” (PS17).

K-Star

“The best results are achieved by K-Star classifier, obtaining an accuracy equal to 98.57%.” (PS30).

“The K-Star classifier achieved accuracy of 99%.” (PS41).

Morphological Extreme Learning machines

“Results showed that the use of morphological kernels improved the classification rate for most of scenarios and for the better cases, when using Wavelets and Haralick, the results were better with morphological kernels.” (PS2).

Logistic Regression

“Results for comparison are shown in Table III in which one may observe that results obtained by KP are equal or better than those from the literature.” (PS4).

Neural Networks

“The best results obtained for accuracy and area under ROC curve were 96.98% and 0.980, respectively, both with neural networks using the whole set of features.” (PS7).

“The set of images for training and testing the ANN, are taken from the Digital Database for Screening Mammography (DDSM). Results show that the percentage of correct classification occurs in average for 84.72% of the data set.” (PS14).

A Deep Convolutional Activation Feature

“From the results we can observe that these features are a viable alternative for a fast creation of image recognition systems using deep learning, and this system can perform better than systems using visual feature descriptors.” (PS12).

Deep Neural Network

“As we showed in result sections, DNN classifier has a great performance in accuracy level (92%), indicating better results in relation to traditional models.” (PS18).

“Experimental results showed that the proposed approach outperformed the techniques compared in this work.” (PS37).

Decision Tree

“The result shows Classification and Regression Trees achieved an accuracy of 96% in predicting breast cancer.” (PS19).

Probabilistic Neural Network

“The highest average accuracy (99.17%) was yielded by the PNN technique when applied to a proportion training to testing of 90% to 10%.” (PS23).

Multiple Instance Learning

“In particular, the MIL allows to obtain comparable or better results than conventional (single instance) classification without the need to label all the images.” (PS26).

Adaboost

“Based on the results shown in the article, we conclude that the best methodology to be applied in the medical routine is: logarithmic enhancement techniques (Image enhancement), SIFT-LBP (Features descriptor), BOF (Features Representation) and AdaBoost (Classifier), that reached 100% sensitivity, 99.65% accuracy and 99.24% specificity.” (PS29).

Optimum-Path Forest Algorithm

“... showed that the O2PF approach demonstrated similar or superior results when compared to the baseline methods already proposed in the literature.” (PS31).

Fine-tuning

“Our results show that Fine Tuning achieves the best classifier performance in VGG16 with AUC value of 0.844 in the CBIS-DDSM dataset.” (PS32).

Random Forest

“The best classification rate was obtained with RF classifier extracted from the images without the feature selection. The approach presented an AUC of 0.997 and AC of 97.6% at a magnification of 200x.” (PS38).

mELM

“When combining the features extractors (Haralick and Zernike) we found the best result overall for both accuracy and kappa statistic displayed in Fig. 17 (also available in Table A.6 – Appendix). Using all features, we obtained an accuracy very close to 90% and kappa of 0.9 using mELM for classification.” (PS40).

Para avaliar o desempenho das técnicas, foram usadas apenas métricas automatizadas, como as supracitadas. Quase nenhum estudo possuía especialista da área da saúde para validar o sistema.

4.2.2.4 QSP4: Como e quais dados foram coletados?

Segundo a seção 3.2.7, com base nos estudos selecionados, foi possível identificar os bancos de dados utilizados nos estudos selecionados, como pode ser visto na Tabela 11.

Tabela 11 – Base de dados em que foram extraídas as informações dos estudos analisados

(continua)

Banco de dados	Trabalhos
BreaKHis	PS9, PS12, PS20, PS21, PS24, PS26 e PS38
Digital Database for Screening Mammography (DDSM)	PS3, PS14, PS15, PS20, PS27 e PS29
Wisconsin Diagnostics Breast Cancer (WDBC)	PS4, PS13, PS18, PS19, PS23 e PS31
Mastology Research with Infrared Image (DMR)	PS16, PS30, PS39 e PS41
IRMA	PS1, PS2 e PS10
Não especificado	PS5, PS11 e PS22
National Cancer Institute (INCa, Rio de Janeiro, Brazil).	PS7 e PS33
University Hospital of the Federal University of Pernambuco	PS17 e PS39
UCSB Bio-Segmentation Benchmark	PS20 e PS25
Group of Innovation in Medical Instrumentation and Ultrasound (GIIMUS) from University of Sao Paulo, Brazil.	PS8
Lung Image Database Consortium	PS20
ImageNet	PS24
CRC	PS24
LRH hospital Peshawar	PS25
CBIS-DDSM	PS32
Breast Cancer Histology Challenge (BACH) 2018	PS33

Tabela 11 – Base de dados em que foram extraídas as informações dos estudos analisados

(conclusão)

Banco de dados	Trabalhos
Computer Science Department of the Fluminense Federal University	PS36
BancoWeb Database of the LAPIMO laboratory	PS37
MammoTherm	PS40

Fonte: O autor (2022).

As citações descritas a seguir foram extraídas dos estudos selecionados na Tabela 6.

“Our proposal was evaluated using the IRMA [26] [27] [28] database, which was developed from a project performed by Aachen University (RWTH Aachen).” (PS1).

“Our proposal was evaluated using the IRMA [26] [27] [28] database, which was developed from a project performed by Aachen University (RWTH Aachen).” (PS2).

“The Digital Database for Screening Mammography (DDSM) was used in this work for the acquisition of mammograms.” (PS3).

“In this work, we evaluate the classification accuracy on the Wisconsin Diagnostics Breast Cancer (WDBC) dataset.” (PS4).

“We used the same dataset and settings used in [21]: 348 consecutive breast masses that underwent image guided core biopsies performed between October 2005 and December 2007 on 328 female subjects. Each one of the 348 cases refers to a breast nodule retrospectively classified according to the BIRADS system.” (PS5).

“[...] 100 US breast tumor images were acquired from 100 patients of the National Cancer Institute (INCa, Rio de Janeiro, Brazil).” (PS7).

“The phantom images were acquired from tests performed by the Group of Innovation in Medical Instrumentation and Ultrasound (GIIMUS) from University of Sao Paulo, Brazil.” (PS8).

“In this paper, we conduct some preliminary experiments using the deep learning approach to classify breast cancer histopathological images from BreakHis [...]” (PS9).

“We used 355 images of fatty breast tissue of IRMA database [...]” (PS10).

“The database 1 has 164 images. From database 2, 80 images, 40 with cancer and 40 normal, was used. Table II shows them.” (PS11).

“In this section, we present an extensive experimental evaluation on the BreakHis dataset [...]” (PS12).

“This section briefly describes Principal Component Analysis and the dataset, Wisconsin Breast Cancer, used in this work.” (PS13).

“The mammographic data used by us were taken from the DDSM [10] [23].” (PS14).

“In summary, the first step consist of the images acquisition that was obtained from the Digital Database for Screening Mammography (DDSM).” (PS15).

“The infrared images used in this work belongs to the Database for Mastology Research with Infrared Image – DMR [9].” (PS16).

“The thermographic images used in this study were acquired at Hospital das Clinicas da Universidade Federal de Pernambuco (University Hospital of the Federal University of Pernambuco, HC-UFPE, Brazil).” (PS17).

“For this work, we used at University of Wisconsin Hospital database which is composed of thirty values which characterize the properties of the nucleus of the breast mass.” (PS18).

“The Wisconsin breast cancer dataset [8] was obtained from the University of Wisconsin Hospitals, Madison from Dr. William H. Wolberg.” (PS19).

“In this work four datasets of medical images are used The BreakHis dataset The UCSB Bio-Segmentation Benchmark dataset The Digital Database for Screening Mammography (DDSM) The Lung Image Database Consortium (LIDC-IDRI).” (PS20).

“The experimental results on the BreakHis dataset...” (PS21).

“For the development of the software database, 110 slides from the Path Presenter site were used, of which 5,298 images were captured. A total of 759 breast images were obtained without pathological changes; 316 with fibrocystic changes; 633 with fibroadenomas; 930 with carcinomas in situ; 1,350 with invasive carcinoma of no special type; 1,310 with invasive lobular carcinoma.” (PS22).

“The effectiveness of this feature selection strategy was evaluated against the commonly used Wisconsin Breast Cancer Database – WBCD...” (PS23).

“The first dataset is ImageNet and it is used for feature representation transfer. The second dataset is CRC and it provides structural information (texture) about the tissue types of histopathologic images. Finally, the target domain is to classify histopathologic images from the BreakHis dataset into two classes, malign and benign.” (PS24).

“... the first one is a standard benchmark data set [39], and the other is developed locally at LRH hospital Peshawar, Pakistan.” (PS25).

“The experiments are conducted on the public BreakHis dataset...” (PS26).

“Para compor a base de dados utilizada nesse trabalho, foram selecionadas imagens do arquivo da DDSM, por ser de fácil acesso e aberta ao público.” (PS27).

“In this work, it was used the public database DDSM (Digital Database for Screening Mammography) [32].” (PS29).

“The DIT images used in this work are available at the Database for Mastology Research with Infrared Image (DMR-IR) [...]” (PS30).

“Experiments were conducted over two sets of three databases each. The first set comprises three datasets for breast cancer detection, i.e., the Wisconsin Breast Cancer Database, which is composed of the datasets Prognostic, Diagnostic I, and Diagnostic II. The second set is composed of general purpose datasets for medical issues. All of them are unbalanced, binary, and were obtained from the UCI repository [25].” (PS31).

“In the present study, as well as our previous work, we use the Curated Breast Imaging Subset of DDSM (CBIS-DDSM)[4]...” (PS32).

“The images were obtained at the Cancer National Institute (INCa, Rio de Janeiro, Brazil)...” (PS33).

“The Breast Cancer Histology Challenge (BACH) 2018 dataset is composed of hematoxylin and eosin (H&E) stained breast histological microscopic and whole slide images.” (PS34).

“This work uses a database composed of infrared images of 88 patients with and without cancer (has-cancer and cancer-free, respectively) collected by the Computer Science Department of the Fluminense Federal University (IC/UFF).” (PS36).

“The original BancoWeb Database of the LAPIMO laboratory [13]...” (PS37).

“The dataset is composed of microscopic biopsy images of benign and malignant tumors, available from Spanhol et al [9] (BreakHis).” (PS38).

“We used the thermal images available at the Database for Mastology Research with Infrared Image (DMR-IR) (The Database for Mastology Research with Infrared Image) and the private thermal image database of the Federal University of Pernambuco (UFPE).” (PS39).

“The MammoTherm dataset is available in GitHub’s Biomedical-Computing-UFPE repository under GPL-3 License.1 A.” (PS40).

“The images used in this work are available at the DMR-IR database.” (PS41).

Nota-se que as bases de dados de imagens mais utilizadas foram: BreakHis (8), *Digital Database for Screening Mammography* (6) e *Wisconsin Diagnostics Breast Cancer* (6). Considerando as bases de dados nacionais, os destaques são o Instituto Nacional do Câncer e a Universidade Federal de Pernambuco, com duas citações cada. Entretanto,

ambos os estudos que utilizaram a base de dados do INCA, PS33 e PS36, citaram como limitação da pesquisa o número limitado de dados para o treinamento do modelo.

O PS5 utiliza a base de dados de outro estudo:

“We used the same dataset and settings used in [21]: 348 consecutive breast masses that underwent image guided core biopsies performed between October 2005 and December 2007 on 328 female subjects. Each one of the 348 cases refers to a breast nodule retrospectively classified according to the BIRADS system.” (PS5).

Os trabalhos PS11 e PS22 não citam o nome do banco de dados que foi utilizado no estudo, porém informam suas características:

“The database 1 has 164 images. From database 2, 80 images, 40 with cancer and 40 normal, was used. Table II shows them.” (PS11).

“For the development of the software database, 110 slides from the Path Presenter site were used, of which 5,298 images were captured. A total of 759 breast images were obtained without pathological changes; 316 with fibrocystic changes; 633 with fibroadenomas; 930 with carcinomas in situ; 1,350 with invasive carcinoma of no special type; 1,310 with invasive lobular carcinoma” (PS22).

4.2.2.5 QSP5: Quais são os conjuntos de modelagem e validação que foram utilizados? (ambiente experimental)

Segundo a seção 3.2.7, com base nos estudos selecionados, foi possível identificar os ambientes de modelagem e validação, como pode ser visto na Tabela 12.

Tabela 12 – Ambientes de modelagem e validação utilizados nos estudos analisados

(continua)

ID	Ambiente de modelagem e validação
PS1	10 k-fold cross-validation
PS2	10 k-fold cross-validation
PS3	Divididos em dois grupos, treino e teste, com proporções de 20% e 80%, 40% e 60%, 50% e 50%, 60% e 40%, 80% e 20%
PS4	10 k-fold cross-validation
PS5	Divididos em dois grupos, treino e teste, com proporções não explicitadas no estudo
PS7	4 k-fold cross-validation
PS8	Divididos em dois grupos, treino e teste, com proporções de 70% e 30%
PS9	Divididos em dois grupos, treino e teste, com proporções de 70% e 30%
PS10	10 k-fold cross-validation
PS11	4 k-fold cross-validation & divididos em dois grupos, treino e teste, com proporções de 70% e 30%

Tabela 12 – Ambientes de modelagem e validação utilizados nos estudos analisados

(conclusão)

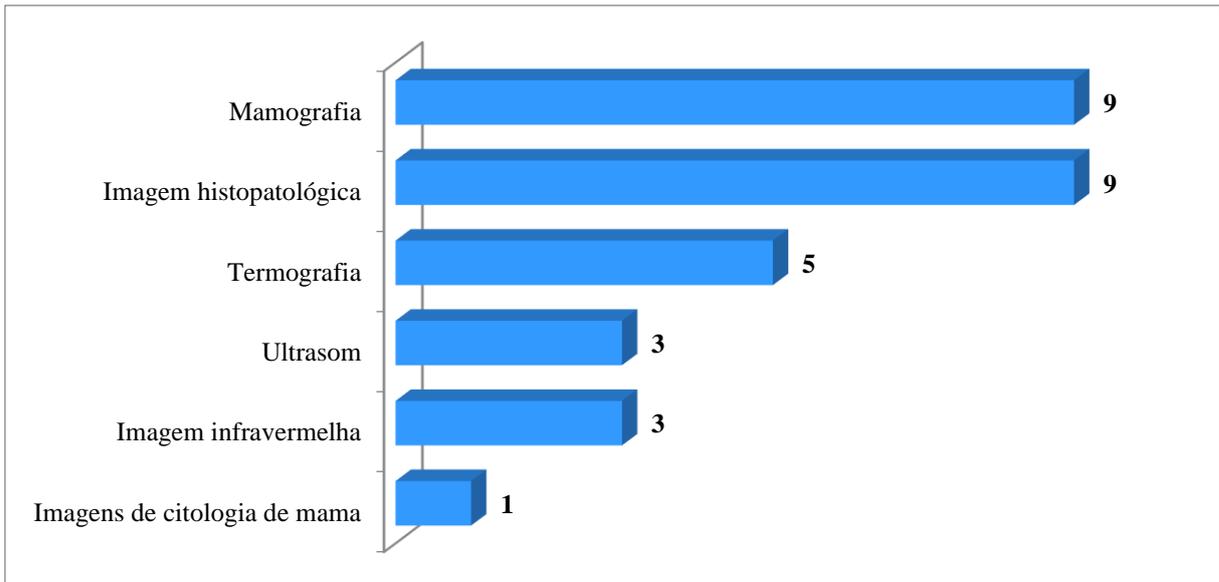
ID	Ambiente de modelagem e validação
PS12	N/A
PS13	N/A
PS14	Leave-one-out
PS15	Divididos em dois grupos, treino e teste, com proporções de 20% e 80%, 40% e 60%, 60% e 40%, 80% e 20%
PS16	Divididos em dois grupos, treino e teste, com proporções não explicitadas no estudo
PS17	Divididos em dois grupos, treino e teste, com proporções de 75% e 25%
PS18	Divididos em dois grupos, treino e teste, com proporções de 70% e 30%
PS19	Divididos em dois grupos, treino e teste, com proporções de 80% e 20%
PS20	Divididos em dois grupos, treino e teste, com proporções de 70% e 30%
PS21	Divididos em dois grupos, treino e teste, com proporções de 70% e 30% & Treino e validação, com proporções de 85% e 15%
PS22	Divididos em dois grupos, treino e teste, com proporções não explicitadas no estudo
PS23	Divididos em dois grupos, treino e teste, com proporções de 60% e 40%
PS24	Divididos em dois grupos, treino e teste, com proporções de 70% e 30%
PS25	Divididos em dois grupos, treino e teste, com proporções de 75% e 25%
PS26	Divididos em dois grupos, treino e teste, com proporções de 70% e 30%
PS27	Cross-Validation
PS29	Divididos <u>em</u> dois grupos, treino e teste, com proporções de 70% e 30%, 80% e 20%, 90% e 10%
PS30	10 k-fold cross-validation
PS31	Divididos em três grupos, treino, validação e teste, com proporções de 70%, 15% e 15%
PS32	Divididos em três grupos, treino, validação e teste, com proporções de 70%, 10% e 10%
PS33	5-fold cross-validation
PS34	10 k-fold cross-validation
PS36	Divididos em dois grupos, treino e validação, com proporções de 80% e 20%
PS37	Divididos em dois grupos, treino e teste, com proporções de 80% e 20%
PS38	10-fold cross-validation
PS39	N/A
PS40	10-fold cross-validation & divididos em dois grupos, treino e teste, com proporções de 75% e 25%
PS41	10-fold cross-validation

Fonte: O autor (2022).

4.2.2.6 QSP6: De quais exames as informações foram retiradas?

De acordo com a seção 3.2.7, com base nos estudos selecionados, foi possível identificar as abordagens mais utilizadas, como pode ser visto na Figura 8.

Figura 8 – Exames mais utilizados nos estudos analisados



Fonte: O autor (2022).

O INCA recomenda o exame de mamografia para o diagnóstico do câncer de mama. Além disso, o exame é popular em razão da campanha “Outubro Rosa”, que incentiva a mulheres a realizar o exame.

4.2.3 Limitações da pesquisa e ameaça à validade

Esta pesquisa se limitou a quatro bases diferentes (Scopus, ACM, AISel e IEEE Xplore), contudo existem outras diversas bibliotecas digitais renomadas que poderiam agregar informações ao trabalho. Além disso, alguns estudos não puderam ser acessados, pois não eram conteúdos gratuitos.

5 CONCLUSÃO E TRABALHOS FUTUROS

5.1 CONCLUSÕES

Este estudo buscou identificar as características das técnicas de inteligência artificial desenvolvidas por brasileiros, que auxiliam no diagnóstico de câncer de mama. Para isso, foi realizado estudo sistemático da literatura brasileira sobre o tema, no qual foram analisados trabalhos publicados entre 2015 e 2021. As pesquisas foram realizadas nas bibliotecas digitais Scopus, ScienceDirect, ACM e IEEE Xplore, utilizando palavras-chave e seus sinônimos. Foram extraídos 3.258 estudos, porém, após a aplicação de alguns filtros, o número final de artigos a serem analisados foi 38. Buscou-se responder a tais perguntas: “Quais são as técnicas de aprendizado de máquina usadas atualmente para diagnosticar o câncer de mama?”, “Quais são as métricas de avaliação?”, “Quais são as técnicas que mostraram melhor desempenho em contextos específicos?”, “Como e quais dados foram coletados?”, “Quais são os conjuntos de modelagem e validação que foram utilizados? (ambiente experimental)” e “De quais exames as informações foram retiradas?”.

SVM e CNN são as técnicas mais utilizadas entre as IAs que foram citadas nos trabalhos analisados. Além disso, foram as técnicas que mostraram melhor desempenho em seus cenários específicos. Os dados, na sua maioria, foram extraídos de bases de dados de imagens estrangeiras, sendo elas: *BreaKHis*, *Digital Database for Screening Mammography* e *Wisconsin Diagnostics Breast Cancer*. Das bases nacionais, os bancos de dados mais utilizados foram o Instituto Nacional do Câncer e a Universidade Federal de Pernambuco.

Alguns trabalhos não fizeram estudos comparativos, sendo avaliada e analisada apenas uma técnica. Por isso, não foi possível definir qual é o melhor classificador para aquele contexto específico. Além disso, poucos estudos foram validados com especialistas da área da saúde. Alguns trabalhos que utilizaram base de dados nacionais citaram como limitação da pesquisa o número limitado de dados para o treinamento do modelo.

Existem diversos estudos sobre o uso de inteligência artificial no auxílio de diagnóstico de câncer de mama. Todavia, há uma falta de revisão sistemática da literatura brasileira sobre o assunto. Este trabalho fornece uma visão geral sobre os artigos publicados por brasileiros sobre as técnicas de *machine learning* para a classificação do câncer de mama.

5.2 TRABALHOS FUTUROS

Com base no trabalho realizado, os seguintes direcionamentos de pesquisa são propostos:

- limitar a pesquisa apenas para estudos que utilizam bases de dados nacionais;
- estender a pesquisa para um período de uma década;
- ampliar a pesquisa para mais bibliotecas digitais;
- desenvolver estudo comparativo entre as técnicas SVM e CNN na detecção e classificação do câncer de mama, utilizando uma base de dados nacional.

REFERÊNCIAS

AMARAL, L. A. M. **PRAXIS**: um referencial para o planeamento de sistemas de informação. 1994. Tese (Doutorado em Sistemas de Informação) – Universidade do Minho, Braga, 1994. Disponível em: <https://repositorium.sdum.uminho.pt/handle/1822/49>. Acesso em: 28 fev. 2022.

ARAÚJO, A. S.; CONCI, A.; MONTENEGRO, A. A.; RESMINI, R.; ARAÚJO, C.; LEBON, F. Computer aided diagnosis for breast diseases based on infrared images. *In*: INTERNATIONAL CONFERENCE ON COMPUTER SYSTEMS AND APPLICATIONS, 14., 2017, Hammamet. **Proceedings** [...]. Piscataway, NJ: IEEE, 2017. p. 172-177. DOI: <https://doi.org/10.1109/AICCSA.2017.188>. Disponível em: <https://ieeexplore.ieee.org/document/8308281>. Acesso em: 26 fev. 2022.

AZEVEDO, W. W.; LIMA, S. M. L.; FERNANDES, I. M. M.; ROCHA, A. D. D.; CORDEIRO, F. R.; SILVA-FILHO, A. G.; SANTOS, W. P. Fuzzy morphological extreme learning machines to detect and classify masses in mammograms. *In*: INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, 2015, Istanbul. **Proceedings** [...]. Piscataway, NJ: IEEE, 2015a. p. 1-8. DOI: <https://doi.org/10.1109/FUZZ-IEEE.2015.7337975>. Disponível em: <https://ieeexplore.ieee.org/document/7337975>. Acesso em: 26 fev. 2022.

AZEVEDO, W. W.; LIMA, S. M. L.; FERNANDES, I. M. M.; ROCHA, A. D. D.; CORDEIRO, F. R.; SILVA-FILHO, A. G.; SANTOS, W. P. Morphological extreme learning machines applied to detect and classify masses in mammograms. *In*: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2015, Killarney. **Proceedings** [...]. Piscataway, NJ: IEEE, 2015b. p. 1-8. DOI: <https://doi.org/10.1109/IJCNN.2015.7280774>. Disponível em: <https://ieeexplore.ieee.org/document/7280774>. Acesso em: 26 fev. 2022.

BAFFA, M. F. O.; LATTARI, L. G. Convolutional neural networks for static and dynamic breast infrared imaging classification. *In*: CONFERENCE ON GRAPHICS, PATTERNS AND IMAGES, 31., 2018, Curitiba. **Proceedings** [...]. Piscataway, NJ: IEEE, 2018. p. 174-181. DOI: <https://doi.org/10.1109/SIBGRAP.2018.00029>. Disponível em: <https://ieeexplore.ieee.org/document/8614326>. Acesso em: 26 fev. 2022.

BRERETON, P.; KITCHENHAM, B. A.; BUDGEN, D.; TURNER, M.; KHALIL, M. Lessons from applying the systematic literature review process within the software engineering domain. **Journal of Systems and Software**, New York, v. 80, n. 4, p. 571-583, Apr. 2007. DOI: <https://doi.org/10.1016/j.jss.2006.07.009>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016412120600197X>. Acesso em: 28 fev. 2022.

BRESSAN, R. S.; BUGATTI, P. H.; SAITO, P. T. M. Breast cancer diagnosis through active learning in content-based image retrieval. **Neurocomputing**, Amsterdam, v. 357, p. 1-10, Sept. 2019. DOI: <https://doi.org/10.1016/j.neucom.2019.05.041>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S092523121930726X>. Acesso em: 26 fev. 2022.

BRITO-SARRACINO, T.; SANTOS, M. R.; ANTUNES, E. F.; SANTOS, I. B. A.; KASMANAS, J. C.; CARVALHO, A. C. P. L. F. Explainable machine learning for breast

cancer diagnosis. *In*: BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS, 8., 2019, Salvador. **Proceedings** [...]. Piscataway, NJ: IEEE, 2019. p. 681-686. DOI: <https://doi.org/10.1109/BRACIS.2019.00124>. Disponível em: <https://ieeexplore.ieee.org/document/8923961>. Acesso em: 26 fev. 2022.

CARVALHO, D.; PINHEIRO, P. R.; PINHEIRO, M. C. D. A hybrid model to support the early diagnosis of breast cancer. **Procedia Computer Science**, Amsterdam, v. 91, p. 927-934, 2016. DOI: <https://doi.org/10.1016/j.procs.2016.07.112>. Disponível em: <https://www.science-direct.com/science/article/pii/S1877050916313059>. Acesso em: 26 fev. 2022.

CARVALHO, E. D.; CARVALHO FILHO, A. O.; SILVA, R. R. V.; ARAÚJO, F. H. D.; DINIZ, J. O. B.; SILVA, A. C.; PAIVA, A. C.; GATTASS, M. Breast cancer diagnosis from histopathological images using textural features and CBIR. **Artificial Intelligence in Medicine**, Amsterdam, v. 105, May 2020. DOI: <https://doi.org/10.1016/j.artmed.2020.101845>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0933365719306621>. Acesso em: 26 fev. 2022.

CARVALHO, R. H. O.; MARTINS, A. S.; NEVES, L. A.; NASCIMENTO, M. Z. Analysis of features for breast cancer recognition in different magnifications of histopathological images. *In*: INTERNATIONAL CONFERENCE ON SYSTEMS, SIGNALS AND IMAGE PROCESSING, 2020, Niteroi. **Proceedings** [...]. Piscataway, NJ: IEEE, 2020. p. 39-44. DOI: <https://doi.org/10.1109/IWSSIP48289.2020.9145129>. Disponível em: <https://ieeexplore.ieee.org/document/9145129>. Acesso em: 26 fev. 2022.

CHAVES, E.; GONÇALVES, C. B.; ALBERTINI, M. K.; LEE, S.; JEON, G.; FERNANDES, H. C. Evaluation of transfer learning of pre-trained CNNs applied to breast cancer detection on infrared images. **Applied Optics**, Washington, DC, v. 59, n. 17, p. E23-E28, 2020. DOI: <https://doi.org/10.1364/ao.386037>. Disponível em: <https://opg.optica.org/ao/abstract.cfm?uri=ao-59-17-E23>. Acesso em: 26 fev. 2022.

COUTINHO, P. H. S.; CHAGAS, T. P. Proposal of new hybrid fuzzy clustering algorithms: application to breast cancer dataset. *In*: LATIN AMERICAN CONFERENCE ON COMPUTATIONAL INTELLIGENCE, 2017, Arequipa. **Proceedings** [...]. Piscataway, NJ: IEEE, 2017. p. 1-6. DOI: <https://doi.org/10.1109/LA-CCI.2017.8285679>. Disponível em: <https://ieeexplore.ieee.org/document/8285679>. Acesso em: 26 fev. 2022.

FALCONI, L. G.; PÉREZ, M.; AGUILAR, W. G.; CONCI, A. Transfer learning and fine tuning in breast mammogram abnormalities classification on CBIS-DDSM database. **Advances in Science, Technology and Engineering Systems Journal**, Walnut, CA, v. 5, n. 2, p. 154-165, 2020. DOI: <http://dx.doi.org/10.25046/aj050220>. Disponível em: <https://astesj.com/v05/i02/p20/>. Acesso em: 26 fev. 2022.

FERREIRA, P.; DUTRA, I.; SALVINI, R.; BURNSIDE, E. Interpretable models to predict breast cancer. *In*: INTERNATIONAL CONFERENCE ON BIOINFORMATICS AND BIOMEDICINE, 2016, Shenzhen. **Proceedings** [...]. Piscataway, NJ: IEEE, 2016. p. 1507-1511. DOI: <https://doi.org/10.1109/BIBM.2016.7822745>. Disponível em: <https://ieeexplore.ieee.org/document/7822745>. Acesso em: 26 fev. 2022.

FOGLIATTO, F. S.; ANZANELLO, M. J.; SOARES, F.; BRUST-RENCK, P. G. Decision support for breast cancer detection: classification improvement through feature selection.

Cancer Control, Thousand Oaks, CA, v. 26, n. 1, 1073274819876598, 2019. DOI: <https://doi.org/10.1177/1073274819876598>. Disponível em: <https://journals.sagepub.com/doi/10.1177/1073274819876598>. Acesso em: 26 fev. 2022.

GOMES, D. S. Inteligência artificial: conceitos e aplicações. **Olhar Científico**, Ariquemes, v. 1, n. 2, p. 234-246, ago./dez. 2010. Disponível em: https://www.professores.uff.br/screspo/wp-content/uploads/sites/127/2017/09/ia_intro.pdf. Acesso em: 28 fev. 2022.

IBM. **Machine learning e ciência de dados com IBM Watson**. Armonk, NY: IBM, [2019]. Disponível em: <https://www.ibm.com/br-pt/analytics/machine-learning>. Acesso em: 28 fev. 2022.

INSTITUTO NACIONAL DE CÂNCER. Tipos de câncer: câncer de mama. **INCA**, Rio de Janeiro, 2 set. 2021. Disponível em: <https://www.inca.gov.br/tipos-de-cancer/cancer-de-mama/>. Acesso em: 25 jan. 2022.

KHAN, S.; ISLAM, N.; JAN, Z.; DIN, I. U.; RODRIGUES, J. J. P. C. A novel deep learning based framework for the detection and classification of breast cancer using transfer learning. **Pattern Recognition Letters**, Amsterdam, v. 125, p. 1-6, July 2019. DOI: <https://doi.org/10.1016/j.patrec.2019.03.022>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0167865519301059>. Acesso em: 26 fev. 2022.

KITCHENHAM, B.; CHARTERS, S. **Guidelines for performing systematic literature reviews in software engineering**: versão 2.3: EBSE Technical Report EBSE-2007-01. Keele: Keele University; Durham: University of Durham, 9 July 2007. Disponível em: <http://citeseerx.ist.psu.edu/viewdoc/download?jsessionid=54C23681D0C78A0018B8C767065F7ADA?doi=10.1.1.117.471&rep=rep1&type=pdf>. Acesso em: 25 jan. 2022.

KUIAVA, V. A.; KUIAVA, E. L.; RODRIGUEZ, R.; BECK, A. E.; RODRIGUEZ, J. P. M.; CHIELLE, E. O. Method of histopathological diagnosis of mammary nodules through deep learning algorithm. **Jornal Brasileiro de Patologia e Medicina Laboratorial**, Rio de Janeiro, v. 55, n. 6, p. 620-632, Nov./Dec. 2019. DOI: <https://doi.org/10.5935/1676-2444.20190055>. Disponível em: <https://www.scielo.br/j/jbpml/a/9hLQhwMKCSqHrXwy5NwtRRL/>. Acesso em: 26 fev. 2022.

LIMA, S. M. L.; SILVA-FILHO, A. G.; SANTOS, W. P. Detection and classification of masses in mammographic images in a multi-kernel approach. **Computer Methods and Programs in Biomedicine**, New York, v. 134, n. C, p. 11-29, Oct. 2016. DOI: <https://doi.org/10.1016/j.cmpb.2016.04.029>. Disponível em: <https://dl.acm.org/doi/10.1016/j.cmpb.2016.04.029>. Acesso em: 26 fev. 2022.

MACEDO, M.; SANTANA, M.; SANTOS, W. P.; MENEZES, R.; BASTOS-FILHO, C. Breast cancer diagnosis using thermal image analysis: a data-driven approach based on swarm intelligence and supervised learning for optimized feature selection. **Applied Soft Computing**, Amsterdam, v. 109, 107533, Sept. 2021. DOI: <https://doi.org/10.1016/j.asoc.2021.107533>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1568494621004567>. Acesso em: 26 fev. 2022.

MARCOMINI, K. D.; CARNEIRO, A. A. O.; SCHIABEL, H. Application of artificial neural network models in segmentation and classification of nodules in breast ultrasound digital

images. **International Journal of Biomedical Imaging**, New York, v. 2016, 7987212, 2016. DOI: <https://doi.org/10.1155/2016/7987212>. Disponível em: <https://www.hindawi.com/journals/ijbi/2016/7987212/>. Acesso em: 26 fev. 2022.

MARIN, L. F.; SILVA, A. C.; BANDEIRA, J. O. Meta-data construction for selection of breast tissue biopsy slides image classifier to identify ductal carcinoma. *In: BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS, 8., 2019, Salvador. Proceedings [...]*. Piscataway, NJ: IEEE, 2019. p. 729-734. DOI: <https://doi.org/10.1109/BRACIS.2019.00131>. Disponível em: <https://ieeexplore.ieee.org/document/8923725>. Acesso em: 26 fev. 2022.

MATOS, C. E. F.; SOUZA, J. C.; DINIZ, J. O. B.; BRAZ JUNIOR, G.; PAIVA, A. C.; ALMEIDA, J. D. S.; ROCHA, S. V.; SILVA, A. C. Diagnosis of breast tissue in mammography images based local feature descriptors. **Multimedia Tools and Applications**, Hingham, MA, v. 78, n. 10, p. 12961-12986, May 2019. DOI: <https://doi.org/10.1007/s11042-018-6390-x>. Disponível em: <https://link.springer.com/article/10.1007/s11042-018-6390-x>. Acesso em: 26 fev. 2022.

MATOS, J.; BRITTO JR., A. S.; OLIVEIRA, L. E. S.; KOERICH, A. L. Double transfer learning for breast cancer histopathologic image classification. *In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2019, Budapest. Proceedings [...]*. Piscataway, NJ: IEEE, 2019a. p. 1-8. DOI: <https://doi.org/10.1109/IJCNN.2019.8852092>. Disponível em: <https://ieeexplore.ieee.org/document/8852092>. Acesso em: 26 fev. 2022.

MATOS, J.; BRITTO JR., A. S.; OLIVEIRA, L. E. S.; KOERICH, A. L. Texture CNN for histopathological image classification. *In: INTERNATIONAL SYMPOSIUM ON COMPUTER-BASED MEDICAL SYSTEMS, 32., 2019, Cordoba. Proceedings [...]*. Piscataway, NJ: IEEE, 2019b. p. 580-583. DOI: <https://doi.org/10.1109/CBMS.2019.00120>. Disponível em: <https://ieeexplore.ieee.org/document/8787445>. Acesso em: 26 fev. 2022.

MELO, V. V. Breast cancer detection with logistic regression improved by features constructed by Kaizen programming in a hybrid approach. *In: CONGRESS ON EVOLUTIONARY COMPUTATION, 2016, Vancouver, BC. Proceedings [...]*. Piscataway, NJ: IEEE, 2016. p. 16-23. DOI: <https://doi.org/10.1109/CEC.2016.7743773>. Disponível em: <https://ieeexplore.ieee.org/document/7743773>. Acesso em: 26 fev. 2022.

NASCIMENTO, C. D. L.; SILVA, S. D. S.; SILVA, T. A.; PEREIRA, W. C. A.; COSTA, M. G. F.; COSTA FILHO, C. F. F. Breast tumor classification in ultrasound images using support vector machines and neural networks. **Research on Biomedical Engineering**, Rio de Janeiro, v. 32, n. 3, p. 283-292, Sept. 2016. DOI: <https://doi.org/10.1590/2446-4740.04915>. Disponível em: <https://www.scielo.br/j/reng/a/3qzxTpPnVPHLVqSXFcyR4JN/>. Acesso em: 26 fev. 2022.

OLIVEIRA, F. S. S.; CARVALHO FILHO, A. O.; SILVA, A. C.; PAIVA, A. C.; GATTASS, M. Classification of breast regions as mass and non-mass based on digital mammograms using taxonomic indexes and SVM. **Computers in Biology and Medicine**, New York, v. 57, p. 42-53, Feb. 2015. DOI: <https://doi.org/10.1016/j.combiomed.2014.11.016>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0010482514003357>. Acesso em: 26 fev. 2022.

PASSOS, L. A.; JODAS, D. S.; RIBEIRO, L. C. F.; PINHEIRO, T.; PAPA, J. P. O²PF: oversampling via optimum-path forest for breast cancer detection. *In: INTERNATIONAL SYMPOSIUM ON COMPUTER-BASED MEDICAL SYSTEMS*, 33., 2020, Rochester, MN. **Proceedings** [...]. Piscataway, NJ: IEEE, 2020. p. 498-503. DOI: <https://doi.org/10.1109/CBMS49503.2020.00100>. Disponível em: <https://ieeexplore.ieee.org/document/9183010>. Acesso em: 26 fev. 2022.

PEREIRA, G. B. G.; FERNANDES, L. P.; SOUZA NETO, J. M. R.; BRAZ, H. D. M.; SAUER, L. S. A comparative study of linear discriminant analysis and an artificial neural network performances in breast cancer diagnosis. *In: IEEE ANDESCON*, 2020, Quito. **Proceedings** [...]. Piscataway, NJ: IEEE, 2020. p. 1-6. DOI: <https://doi.org/10.1109/ANDESCON50619.2020.9272057>. Disponível em: <https://ieeexplore.ieee.org/document/9272057>. Acesso em: 26 fev. 2022.

PÉREZ, M.; BENALCAZAR, M. E.; TUSA, E.; RIVAS, W.; CONCI, A. Mammogram classification using back-propagation neural networks and texture feature descriptors. *In: IEEE SECOND ECUADOR TECHNICAL CHAPTERS MEETING*, 2017, Salinas. **Proceedings** [...]. Piscataway, NJ: IEEE, 2017. p. 1-6. DOI: <https://doi.org/10.1109/ETCM.2017.8247515>. Disponível em: <https://ieeexplore.ieee.org/document/8247515>. Acesso em: 26 fev. 2022.

RESMINI, R.; SILVA, L. F.; MEDEIROS, P. R. T.; ARAUJO, A. S.; MUCHALUAT-SAADE, D. C.; CONCI, A. A hybrid methodology for breast screening and cancer diagnosis using thermography. **Computers in Biology and Medicine**, New York, v. 135, 104553, Aug. 2021. DOI: <https://doi.org/10.1016/j.combiomed.2021.104553>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0010482521003474>. Acesso em: 26 fev. 2022.

RESMINI, R.; SILVA, L.; ARAUJO, A. S.; MEDEIROS, P.; MUCHALUAT-SAADE, D.; CONCI, A. Combining genetic algorithms and SVM for breast cancer diagnosis using infrared thermography. **Sensors**, Basel, v. 21, n. 14, 4802, July 2021. DOI: <https://doi.org/10.3390/s21144802>. Disponível em: <https://www.mdpi.com/1424-8220/21/14/4802>. Acesso em: 26 fev. 2022.

SANTANA, M. A.; PEREIRA, J. M. S.; SILVA, F. L.; LIMA, N. M.; SOUSA, F. N.; ARRUDA, G. M. S.; LIMA, R. C. F.; SILVA, W. W. A.; SANTOS, W. P. Breast cancer diagnosis based on mammary thermography and extreme learning machines. **Research on Biomedical Engineering**, Rio de Janeiro, v. 34, n. 1, p. 45-53, Mar. 2018. DOI: <https://doi.org/10.1590/2446-4740.05217>. Disponível em: <https://www.scielo.br/j/reng/a/mbbLQP6KTnRMb5FyPJXpC4M/>. Acesso em: 26 fev. 2022.

SANTOS, C. F. G.; AFONSO, L. C. S.; PEREIRA, C. R.; PAPA, J. P. BreastNet: breast cancer categorization using convolutional neural networks. *In: INTERNATIONAL SYMPOSIUM ON COMPUTER-BASED MEDICAL SYSTEMS*, 33., 2020, Rochester, MN. **Proceedings** [...]. Piscataway, NJ: IEEE, 2020. p. 463-468. DOI: <https://doi.org/10.1109/CBMS49503.2020.00094>. Disponível em: <https://ieeexplore.ieee.org/document/9183055>. Acesso em: 26 fev. 2022.

SAS INSTITUTE. **Machine learning**: o que é e qual sua importância? São Paulo: SAS Institute, [2021]. Disponível em: https://www.sas.com/pt_br/insights/analytics/machine-learning.html. Acesso em: 28 fev. 2022.

SILVA NETO, O. P.; SILVA, A. C.; PAIVA, A. C.; GATTASS, M. Automatic mass detection in mammography images using particle swarm optimization and functional diversity indexes. **Multimedia Tools and Applications**, Hingham, MA, v. 76, n. 18, p. 19263-19289, Sept. 2017. DOI: <https://doi.org/10.1007/s11042-017-4710-1>. Disponível em: <https://link.springer.com/article/10.1007/s11042-017-4710-1>. Acesso em: 26 fev. 2022.

SILVA NETO, R. P.; CARVALHO FILHO, A. O. Automatic classification of breast lesions using transfer learning. **IEEE Latin America Transactions**, Piscataway, NJ, v. 17, n. 12, p. 1964-1969, Dec. 2019. DOI: <https://doi.org/10.1109/TLA.2019.9011540>. Disponível em: <https://ieeexplore.ieee.org/document/9011540>. Acesso em: 26 fev. 2022.

SILVA, L. F.; SEIXAS, F. L.; FONTES, C. A. P.; MUCHALUAT-SAADE, D. C.; CONCI, A. A computational method for breast abnormality detection using thermographs. *In*: INTERNATIONAL SYMPOSIUM ON COMPUTER-BASED MEDICAL SYSTEMS, 33., 2020, Rochester, MN. **Proceedings** [...]. Piscataway, NJ: IEEE, 2020. p. 469-474. DOI: <https://doi.org/10.1109/CBMS49503.2020.00095>. Disponível em: <https://ieeexplore.ieee.org/document/9183286>. Acesso em: 26 fev. 2022.

SILVA, R. A. C. Inteligência artificial aplicada a ambientes de engenharia de *software*: uma visão geral. **INFOCOMP Journal of Computer Science**, Lavras, v. 4, n. 4, p. 27-37, 2005. Disponível em: <https://infocomp.dcc.ufla.br/index.php/infocomp/article/view/109>. Acesso em: 28 fev. 2022.

SPANHOL, F. A.; CAVALIN, P. R.; OLIVEIRA, L. S.; PETITJEAN, C.; HEUTTE, L. Deep features for breast cancer histopathological image classification. *In*: INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS, 2017, Banff, AB. **Proceedings** [...]. Piscataway, NJ: IEEE, 2017. p. 1868-1873. DOI: <https://doi.org/10.1109/SMC.2017.8122889>. Disponível em: <https://ieeexplore.ieee.org/document/8122889>. Acesso em: 26 fev. 2022.

SPANHOL, F. A.; OLIVEIRA, L. S.; PETITJEAN, C.; HEUTTE, L. Breast cancer histopathological image classification using convolutional neural networks. *In*: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2016, Vancouver, BC. **Proceedings** [...]. Piscataway, NJ: IEEE, 2016. p. 2560-2567. DOI: <https://doi.org/10.1109/IJCNN.2016.7727519>. Disponível em: <https://ieeexplore.ieee.org/document/7727519>. Acesso em: 26 fev. 2022.

SUDHARSHAN, P. J.; PETITJEAN, C.; SPANHOL, F.; OLIVEIRA, L. E.; HEUTTE, L.; HONEINE, P. Multiple instance learning for histopathological breast cancer image classification. **Expert Systems with Applications**, Amsterdam, v. 117, p. 103-111, Mar. 2019. DOI: <https://doi.org/10.1016/j.eswa.2018.09.049>. Disponível em: <https://www.science-direct.com/science/article/abs/pii/S0957417418306262>. Acesso em: 26 fev. 2022.

SUNG, H.; FERLAY, J.; SIEGEL, R. L.; LAVERSANNE, M.; SOERJOMATARAM, I.; JEMAL, A.; BRAY, F. Global Cancer Statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. **CA: A Cancer Journal for**

Clinicians, Hoboken, NJ, v. 71, n. 3, p. 209-249, May/June 2021. DOI: <https://doi.org/10.3322/caac.21660>. Disponível em: <https://acsjournals.onlinelibrary.wiley.com/doi/epdf/10.3322/caac.21660>. Acesso em: 28 fev. 2022.

TEIXEIRA, F.; MONTENEGRO, J. L. Z.; COSTA, C. A.; RIGHI, R. R. An analysis of machine learning classifiers in breast cancer diagnosis. *In: LATIN AMERICAN COMPUTING CONFERENCE*, 45., 2019, Panama City. **Proceedings** [...]. Piscataway, NJ: IEEE, 2019. p. 1-10. DOI: <https://doi.org/10.1109/CLEI47609.2019.235094>. Disponível em: <https://ieeexplore.ieee.org/document/9073953>. Acesso em: 26 fev. 2022.

ZEIMARANI, B.; COSTA, M. G. F.; NURANI, N. Z.; BIANCO, S. R.; PEREIRA, W. C. A.; COSTA FILHO, C. F. F. Breast lesion classification in ultrasound images using deep convolutional neural network. **IEEE Access**, Piscataway, NJ, v. 8, p. 133349-133359, 2020. DOI: <https://doi.org/10.1109/ACCESS.2020.3010863>. Disponível em: <https://ieeexplore.ieee.org/document/9145538>. Acesso em: 26 fev. 2022.