



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA
CURSO DE ENGENHARIA DE NAVAL

MAYARA GLEYCE DA SILVA NERY SATURNINO

**ESTIMATIVA DE PARÂMETROS TERMOFÍSICOS A PARTIR DE
TERMOGRAFIA POR INFRAVERMELHO UTILIZANDO ALGORITMO DE
INTELIGÊNCIA ARTIFICIAL**

RECIFE

2025

MAYARA GLEYCE DA SILVA NERY SATURNINO

**ESTIMATIVA DE PARÂMETROS TERMOFÍSICOS A PARTIR DE
TERMOGRAFIA POR INFRAVERMELHO UTILIZANDO ALGORITMO DE
INTELIGÊNCIA ARTIFICIAL**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Naval da Universidade Federal de Pernambuco, Departamento de Engenharia Mecânica – DEMEC do Centro de Tecnologia e Geociências, como requisito para obtenção do título de Engenheira Naval.

Orientadora: Profa. Dra. Luciete Alves Bezerra.

RECIFE
2025

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Saturnino, Mayara Gleyce da Silva Nery.

Estimativa de parâmetros termofísicos a partir de termografia por infravermelho utilizando algoritmo de inteligência artificial / Mayara Gleyce da Silva Nery Saturnino. - Recife, 2025.

70 p. : il., tab.

Orientador(a): Luciete Alves Bezerra

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Engenharia Naval - Bacharelado, 2025.

Inclui referências, apêndices, anexos.

1. Rede neural artificial. 2. Otimização por exame de partículas . 3. Câncer de mama. 4. Parâmetros termofísicos. I. Bezerra, Luciete Alves . (Orientação). II. Título.

620 CDD (22.ed.)

MAYARA GLEYCE DA SILVA NERY SATURNINO

**ESTIMATIVA DE PARÂMETROS TERMOFÍSICOS A PARTIR DE
TERMOGRAFIA POR INFRAVERMELHO UTILIZANDO ALGORITMO DE
INTELIGÊNCIA ARTIFICIAL**

Trabalho de Conclusão de Curso apresentado à
Universidade Federal de Pernambuco, como
requisito para a obtenção do título de Bacharel
em Engenharia Naval.

Aprovado em: 18/08/2025.

BANCA EXAMINADORA

Prof.^o. Dra. Luciete Alves Bezerra (Orientador)
Universidade Federal de Pernambuco

Prof.^o. Dr. José Claudino de Lira Júnior (Examinador Interno)
Universidade Federal de Pernambuco

Prof.^o. Dra. Rita de Cássia Fernandes de Lima (Examinador Externo)
Universidade Federal de Pernambuco

Dedico este trabalho aos meus pais, que sempre se esforçaram para que eu pudesse me dedicar aos estudos, mesmo diante das dificuldades. Ao meu esposo, com todo o meu amor, por ter caminhado comigo em todas as fases dessa jornada.

AGRADECIMENTOS

Agradeço primeiramente a Deus. Sem Ele, nada disso teria sido possível. Foi Ele quem me sustentou com força, saúde e sabedoria ao longo de todos esses anos de graduação.

Aos meus pais, agradeço profundamente pelo apoio incondicional. Não apenas pelo suporte financeiro, mas também pelo encorajamento constante, pelas palavras de motivação e por sempre acreditarem em mim, mesmo nos momentos mais difíceis.

Ao meu irmão, que tanto amo, agradeço por sua presença e ajuda em momentos de grande cansaço e exaustão.

Ao meu marido, que acompanhou toda essa jornada desde o início, sendo namorado, noivo e esposo durante a graduação, sou imensamente grata por todo amor, paciência, apoio e companheirismo que me ofereceu em cada etapa.

Agradeço também aos amigos que fiz durante a graduação, que tornaram essa caminhada mais leve e significativa. Em especial, Lígia, Lorena, Rian, José e Miguel, pelo apoio acadêmico, pelas trocas de conhecimento e pelos momentos vividos que tornaram a experiência mais rica.

Meus agradecimentos vão também aos amigos de vida, que mesmo fora da universidade estiveram comigo em todos os momentos, oferecendo escuta, palavras de encorajamento e muito carinho.

À minha orientadora, professora Luciete, expresso meu profundo agradecimento pela paciência, atenção e incentivo constante. Sua orientação foi fundamental para o desenvolvimento e amadurecimento deste trabalho.

Sou grata aos professores do curso de Engenharia Naval por todo o conhecimento compartilhado, pela dedicação e pelo papel essencial em minha formação acadêmica.

Agradeço ainda ao CNPq pelo apoio financeiro durante o período de Iniciação Científica, que possibilitou a construção desta pesquisa.

Por fim, a todos que, de alguma forma, contribuíram para a realização deste trabalho, direta ou indiretamente, deixo registrada aqui minha mais sincera gratidão.

RESUMO

O câncer de mama permanece como uma das principais causas de mortalidade entre mulheres em todo o mundo. A detecção e o diagnóstico precoce são cruciais para aumentar as chances de sucesso no tratamento, reduzindo, assim, as taxas de mortalidade. Este trabalho propõe uma metodologia para estimar propriedades termofísicas de tumores mamários utilizando imagens termográficas e algoritmos de inteligência artificial, com ênfase no uso de redes neurais artificiais (RNA) e otimização por enxame de partículas (PSO). A partir de imagens termográficas e simulações numéricas, foram analisadas as temperaturas máxima, mínima e média da mama e do tumor na superfície, com o objetivo de prever a condutividade térmica dos tecidos. As simulações numéricas, realizadas no software ANSYS, modelaram a distribuição de temperatura nas mamas com tumores, considerando propriedades específicas e condições de contorno adequadas. O processo de otimização com PSO ajustou a arquitetura da RNA para minimizar o erro quadrático médio no treinamento. O modelo desenvolvido foi capaz de estimar a condutividade térmica dentro dos limites esperados, apresentando erros aceitáveis em relação aos valores de referência. Estes resultados sugerem que a combinação de RNA e PSO tem potencial para aprimorar as tecnologias de diagnóstico por imagem termográfica, contribuindo para melhor estimativa de parâmetros dos tecidos da mama. Juntamente com outras técnicas, como de classificação, pode-se contribuir para a detecção precoce do câncer de mama a partir de imagens por infravermelho.

Palavras-chave: rede neural artificial; otimização por enxame de partículas; câncer de mama; parâmetros termofísicos.

ABSTRACT

Breast cancer remains one of the leading causes of mortality among women worldwide. Early detection and diagnosis are crucial to increase treatment success rates and, consequently, reduce mortality rates. This study proposes a methodology to estimate the thermophysical properties of breast tumors using thermographic images and artificial intelligence algorithms, with an emphasis on artificial neural network (ANN) and particle swarm optimization (PSO). Based on thermographic images and numerical simulations, the maximum, minimum, and average temperatures of the breast and tumor were analyzed to predict the thermal conductivity of the tissues. The numerical simulations, performed using ANSYS software, modeled the temperature distribution in breasts with tumors, considering specific properties and appropriate boundary conditions. The PSO optimization process adjusted the ANN architecture to minimize the mean squared error during training. The developed model was able to estimate the thermal conductivity within the expected limits, presenting acceptable errors compared to reference values. These results suggest that the combination of ANN and PSO can be a useful tool to complement non-invasive breast cancer diagnoses, contributing to the early detection of tumors and, consequently, increasing treatment success rates.

Keywords: neural artificial network; particle swarm optimization; breast cancer; thermophysical parameters.

LISTA DE FIGURAS

Figura 1 - Rede Neural Artificial.....	16
Figura 2 - Rede Neural Profunda.....	27
Figura 3 - Arquitetura de um <i>Perceptron</i>	28
Figura 4 - Geometrias substitutas. (a) Semiesfera (b) Fantoma (c) Prótese de silicone (d) Prótese de silicone ajustada a paciente.....	33
Figura 5 - Curva de perfil de uma paciente pelo <i>SpaceClaim</i>	34
Figura 6 - Formato das próteses mamárias analisadas por Melo (2019).	35
Figura 7 - Técnica utilizada para o dimensionamento da geometria substituta. (a) Imagem frontal da paciente posicionada atrás de uma grade metálica, com a linha de referência (MH) traçada na altura do mamilo para definição da largura da mama. (b) Aplicação da medida obtida pela reta (MH) no ajuste da base torácica da prótese.	36
Figura 8 - Geometria tridimensional obtida após a combinação das curvas de perfil e frontal.	37
Figura 9 - Sobreposição da geometria tridimensional à imagem termográfica da paciente.	37
Figura 10 - Representação dos sistemas de localização anatômica da mama. (a) Sistema de quadrantes: QSE, QSI, QII e QIE. (b) Sistema de relógio.	38
Figura 11 - Fluxograma da metodologia, integrando a simulação numérica e a rotina computacional (RNA + PSO).	39
Figura 12 - Geometria substituta da mama esquerda com a adição do nódulo.	44
Figura 13 - Malha da geometria da mama esquerda. (a) Geometria completa. (b) Plano de corte com refinamento.	45
Figura 14 - Distribuição de temperatura (°C) na superfície da mama esquerda – Paciente 01.	46
Figura 15 - Geometria substituta da mama direita com a adição do tumor.	47
Figura 16 - Malha da geometria da mama direita. (a) Geometria completa. (b) Plano de corte com refinamento.	48
Figura 17 - Distribuição de temperatura (°C) na superfície da mama direita – Paciente 01.	49
Figura 18 - Termograma da Paciente 02 com a região do tumor em destaque.	53
Figura 19 - Termograma da Paciente 03 com a região do tumor em destaque.	55
Figura 20 - Termograma da Paciente 04 com a região do nódulo em destaque.	57
Figura 21 - QR Code para acesso direto à planilha eletrônica dos dados.	70

LISTA DE TABELAS

Tabela 1 - Medidas dos eixos das próteses.....	35
Tabela 2 - Classificação da qualidade da malha segundo a métrica Skewness.....	40
Tabela 3 - Estudo de convergência de malha: Mama esquerda – Paciente 01.....	44
Tabela 4 - Estudo de convergência de malha: Mama direita – Paciente 01.....	47
Tabela 5 - Temperaturas máxima, mínima e média na superfície, resultantes da variação da condutividade térmica da mama e do tumor.....	50
Tabela 6 - Estimativa da condutividade térmica – Mama esquerda Paciente 01.	52
Tabela 7 - Estimativa da condutividade térmica – Mama direita Paciente 01.	52
Tabela 8 - Estimativas da condutividade térmica para a Paciente 02.....	53
Tabela 9 - Comparação da condutividade térmica para a Paciente 02.	54
Tabela 10 - Estimativas da condutividade térmica para a Paciente 03.....	55
Tabela 11 - Comparação da condutividade térmica para a paciente 03.	56
Tabela 12 - Estimativas da condutividade térmica para a Paciente 04.....	57
Tabela 13 - Comparação da condutividade térmica para a paciente 04.	58

LISTA DE SÍMBOLOS

Q_P	(W/m ³)	Calor de perfusão
Q_m	(W/m ³)	Calor de metabólico
c_t	(J/kg°C)	Calor específico do tecido
T_t	(°C)	Temperatura do tecido local
t	(s)	Tempo
k_t	(W/m°C)	Condutividade térmica do tecido
c_b	(J/kg°C)	Calor específico do sangue
T_a	(°C)	Temperatura do sangue arterial
T_v	(°C)	Temperatura do sangue venoso
C	(W dia/m ³)	Constante $3,27 \times 10^6$
D	(m)	Diâmetro do tumor
$\bar{T}$	(°C)	Temperatura prescrita
h	(W/ m ² °C)	Coefficiente de transferência de calor por convecção
T_∞	(°C)	Temperatura ambiente
S_ϕ	(W/m ³)	Termo de fonte
k_{mama}	(W/m°C)	Condutividade térmica da mama
k_{tumor}	(W/m°C)	Condutividade térmica do tumor

Subscritos

b	-	Sangue
a	-	Sangue arterial
v	-	Venoso
t	-	Tecido

Sobrescrito

l	-	Limite inferior
u	-	Limite superior

Símbolos gregos

ρ_t	(kg/m ³)	Massa específica do tecido
ρ_b	(kg/m ³)	Massa específica do sangue
∇	-	Operador Gradiente
ω_t	(s ⁻¹)	Taxa de perfusão sanguínea do tecido
τ	(s)	Tempo para duplicação do tumor
η	(m)	Vetor normal unitário
ϕ_g	-	Parâmetro Social do PSO
ϕ_p	-	Parâmetro Cognitivo do PSO
ω	-	Fator de Constrição do PSO
Γ_ϕ	-	Coeficiente de difusão

SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	Motivação	15
1.2	Objetivos.....	17
1.3	Estrutura do trabalho	17
2	REVISÃO BIBLIOGRÁFICA	18
3	FUNDAMENTAÇÃO TEÓRICA	21
3.1	Equação da Biotransferência de Calor.....	21
3.2	Problema Inverso de Transferência de Calor	24
3.3	Redes Neurais Artificiais.....	25
3.4	Algoritmo de Otimização por Enxame de Partículas (PSO)	29
3.5	Método dos Volumes Finitos.....	31
4	METODOLOGIA.....	32
4.1	Geometria da mama.....	33
4.2	Simulação numérica	38
4.3	Rotina computacional integrando PSO e RNA	41
5	RESULTADOS E DISCUSSÃO	43
5.1	Análise Termográfica da Paciente 01	43
5.1.1	Simulação na mama esquerda.....	43
5.1.2	Simulação na mama direita.....	46
5.2	Base de dados para treinamento do modelo	49
5.3	Estimativas de parâmetros termofísicos com IA	51
5.3.1	Paciente 01	52
5.3.2	Paciente 02.....	52
5.3.3	Paciente 03.....	54
5.3.4	Paciente 04.....	56
5.4	Discussão geral dos resultados	58

6	CONCLUSÃO.....	59
6.1	Perspectivas para trabalhos futuros	60
	APÊNDICE A - ROTINA COMPUTACIONAL: PSO+RNA	66
	ANEXO A – PLANILHA ELETRÔNICA COM O BANCO DE DADOS DAS SIMULAÇÕES TÉRMICAS.....	70

1 INTRODUÇÃO

O câncer de mama permanece como uma das principais causas de morbidade e mortalidade entre as mulheres em todo o mundo (ZACCARA CUNHA ARAÚJO *et al.*, 2024). A detecção e o diagnóstico precoce são essenciais para reduzir a mortalidade, uma vez que intervenções iniciais apresentam maior probabilidade de sucesso no tratamento. Diante desse cenário, há uma crescente demanda por métodos diagnósticos que não apenas detectem a doença em estágios iniciais, mas também sejam acessíveis e de baixo risco para as pacientes.

A termografia tem sido amplamente investigada como ferramenta complementar no diagnóstico precoce de alterações fisiológicas, permitindo uma análise qualitativa capaz de auxiliar na validação de suspeitas médicas ainda não confirmadas por outros métodos diagnósticos. Esse recurso se torna ainda mais relevante quando combinado com ferramentas computacionais, como o processamento de imagens térmicas, análises estatísticas e algoritmos de inteligência artificial (IA).

A principal vantagem de utilizar imagens por infravermelho para o diagnóstico precoce de distúrbios mamários, inclusive como uma abordagem de rastreio, antes do surgimento dos sintomas, consiste no fato de ser uma técnica não invasiva e não expõe a paciente à radiação ionizante, uma vez que apenas capta a radiação infravermelha da pele, contrário ao exame da mamografia, onde a mama é exposta aos raios-X, que são prejudiciais à saúde (BEZERRA, 2013).

De acordo com Bezerra (2013, apud HU *et al.*, 2004; VIANA, 2010; OLIVEIRA, 2012; LAHIRI *et al.*, 2012), o *Food and Drug Administration* (FDA), que pertence ao Departamento de Saúde e Serviços Humanos dos Estados Unidos, autorizou em 1983 a utilização de imagens termográficas como método auxiliar na detecção do câncer. Desde então, a pesquisa em torno dessa tecnologia avançou, especialmente com o aumento da capacidade de processamento computacional, o que possibilitou a análise quantitativa de dados termográficos.

Estudos como os de Ng e Sudarshan (2001, 2004) ressaltam o potencial da termografia, especialmente quando associada a simulações numéricas, como uma ferramenta complementar à mamografia na detecção do câncer de mama. Tal abordagem pode contribuir para reduzir a ocorrência de falsos positivos associados ao uso da termografia no diagnóstico da doença.

Nesse contexto, as imagens termográficas também têm sido utilizadas para validar simulações numéricas tridimensionais, com o intuito de aprimorar a compreensão das anormalidades presentes no tecido mamário. Para desenvolver um modelo numérico mais fiel à realidade, é essencial conhecer as propriedades termofísicas dos diferentes tipos de tecidos da mama, bem como as alterações presentes, além de identificar os parâmetros que impactam de maneira significativa a distribuição da temperatura. A principal dificuldade na determinação dos perfis de temperatura da mama está relacionada à incerteza ou à falta de valores reais dos parâmetros termofísicos de alguns tecidos (BEZERRA *et al.*, 2020; DIN *et al.*, 2022; CIVILIBAL; CEVIK; BOZKURT, 2023; CHEN *et al.*, 2021).

A determinação das propriedades dos materiais é um problema recorrente na engenharia, e o problema inverso de transferência de calor oferece uma solução eficiente para esse tipo de análise (ÖZISIK; ORLANDE, 2000; SILVA NETO; MOURA NETO, 2005). Segundo Kim *et al.* (2003), o método inverso é vantajoso em comparação a métodos experimentais tradicionais, pois permite a estimativa sem a necessidade de preparação específica da amostra.

Nos problemas de transferência de calor, a solução geralmente envolve a minimização de uma função objetivo, caracterizando um problema de otimização. O propósito do método de otimização é identificar valores para os parâmetros desconhecidos que minimizem essa função por meio de um processo iterativo. Nesse contexto, o algoritmo de otimização busca estimar os parâmetros de forma a reduzir a discrepância entre os valores experimentais medidos e os obtidos numericamente (BEZERRA, 2013).

1.1 Motivação

Nos últimos anos, o uso de métodos de otimização em problemas inversos tem ganhado destaque, especialmente com a adoção de algoritmos evolucionários e estocásticos. Entre os métodos estocásticos mais utilizados estão os algoritmos genéticos, o *Simulated Annealing* (SA) (Recozimento Simulado), a *Ant Colony Optimization* (ACO) (Otimização por Colônia de Formigas) e a *Particle Swarm Optimization* (PSO) (Otimização por Enxame de Partículas) (ZHU *et al.*, 2022; LU; WANG, 2023).


Embora esses métodos sejam eficazes na convergência para mínimos ou máximos globais, uma desvantagem é a necessidade de um grande número de avaliações da função objetivo, o que pode ser inviável em determinadas circunstâncias (COLAÇO; ORLANDE; DULIKRAVICH, 2006).

O algoritmo PSO, inspirado no comportamento coletivo de enxames, tem se mostrado eficiente em diversas aplicações de engenharia. Nesse algoritmo, partículas (soluções) exploram o espaço de busca influenciadas por suas melhores posições individuais e pela melhor posição global alcançada. A cada iteração, as partículas atualizam suas posições com base em componentes vetoriais que combinam velocidade, experiência individual e coletiva, buscando otimizar a função objetivo (GÜNAL; AKPINAR, 2023).

Paralelamente, houve um avanço significativo no campo da IA, especialmente em relação ao aprendizado de máquina. Ferramentas como redes neurais artificiais (RNA) e métodos de otimização têm sido cada vez mais aplicadas na análise de grandes volumes de dados, incluindo imagens. Estudos recentes indicam que na análise de imagens médicas, a pesquisa atual se concentra na aplicação de modelos de aprendizado profundo (*Deep Learning*) (PRAMANIK; PRAMANIK; SARKAR, 2023).

As RNA constituem um método de aprendizado de máquina inspirado no funcionamento do cérebro humano, que aprende por meio de experiências (HAYKIN, 2001). Estudos demonstraram que o cérebro é constituído por uma densa rede de neurônios interligados por sinapses, que transmitem impulsos nervosos entre si. De maneira análoga, uma RNA é composta por uma rede de unidades de processamento organizadas em camadas, recebendo múltiplos valores de entrada e gerando uma única saída, conforme ilustrado na Figura 1 - Rede Neural Artificial. Este método mostra-se amplamente eficaz em problemas de regressão e classificação (HAYKIN, 2001).

Figura 1 - Rede Neural Artificial.



Nesse contexto, este Trabalho de Conclusão de Curso propõe uma metodologia que integra RNA e o algoritmo de PSO para estimar parâmetros termofísicos de tecidos mamários, a partir de imagens termográficas, melhorando a acurácia dos modelos numéricos que simulam o comportamento térmico da mama. Assim, o presente estudo insere-se em uma área de interface entre engenharia, inteligência artificial e diagnóstico por imagem.

Além disso, fundamenta-se em princípios clássicos da Engenharia, como transferência de calor, simulação numérica e métodos de otimização, igualmente aplicáveis à Engenharia Naval. Dessa forma, a pesquisa aqui apresentada reforça como os métodos de engenharia podem ser adaptados e aplicados em contextos multidisciplinares, oferecendo suporte ao avanço de tecnologias na área da saúde e evidenciando o papel do engenheiro naval na resolução de problemas complexos que ultrapassam os limites tradicionais do setor marítimo.

1.2 Objetivos

O objetivo deste TCC é desenvolver uma metodologia para estimar propriedades termofísicas de tumores mamários a partir de imagens termográficas, utilizando técnicas de aprendizagem de máquina. Com o intuito de alcançar o objetivo geral, foram estabelecidos os seguintes objetivos específicos:

- Simular numericamente alterações térmicas em tecidos mamários utilizando o software ANSYS.
- Desenvolver uma metodologia baseada em inteligência artificial para estimativa de parâmetros termofísicos da mama e de nódulos mamários a partir de imagens por infravermelho.
- Coletar e realizar o pré-processamento de dados para o treinamento e validação da rede neural artificial.
- Implementar uma rotina computacional integrando a RNA ao algoritmo PSO.
- Efetuar estimativas dos parâmetros termofísicos e comparar com os resultados obtidos com aqueles reportados por Bezerra *et al.* (2020).

1.3 Estrutura do trabalho

Este trabalho está organizado em seis capítulos. No Capítulo 1, apresenta-se a introdução ao tema, destacando-se a motivação, os objetivos e a organização do texto.

O Capítulo 2 é dedicado à revisão bibliográfica, com foco na aplicação da termografia infravermelha na área da saúde, especialmente no diagnóstico de alterações mamárias. São

discutidos trabalhos relevantes que integram modelagem computacional, problemas inversos, aprendizado de máquina e algoritmos de otimização.

O Capítulo 3 aborda a fundamentação teórica necessária para o desenvolvimento do estudo, incluindo a equação da Biotransferência de calor de Pennes, o problema inverso de transferência de calor, os conceitos relacionados às redes neurais artificiais, o algoritmo de otimização por enxame de partículas e o método dos volumes finitos utilizado para a discretização das equações.

No Capítulo 4, descreve-se a metodologia adotada, abrangendo a modelagem geométrica da mama, a realização da simulação numérica no software ANSYS, bem como a implementação da rotina computacional que integra PSO e RNA para a estimativa dos parâmetros termofísicos.

O Capítulo 5 apresenta os resultados obtidos, incluindo a análise das distribuições térmicas simuladas, a avaliação dos parâmetros estimados e a discussão sobre o desempenho do método utilizado.

Por fim, o Capítulo 6 traz as conclusões do trabalho, ressaltando os principais achados e contribuições, além de sugerir perspectivas para investigações futuras relacionadas ao tema.

2 REVISÃO BIBLIOGRÁFICA

A partir dos avanços na aplicação da termografia infravermelha no diagnóstico médico, estudos têm buscado integrar essa tecnologia a métodos computacionais para extrair informações quantitativas sobre alterações fisiológicas associadas a distúrbios mamários. O trabalho de Bezerra (2013) destaca-se nesse contexto ao propor uma metodologia para estimativa de parâmetros termofísicos de tecidos da mama a partir de imagens térmicas, utilizando técnicas de simulação numérica acopladas à resolução de problemas inversos. Por meio do software FLUENT™, fundamentado no Método dos Volumes Finitos, a autora modela tridimensionalmente o tecido mamário e aplica o método de Programação Quadrática Sequencial (SQP) para minimizar a discrepância entre os dados simulados e os experimentais. A abordagem permitiu identificar propriedades como condutividade térmica e perfusão sanguínea, além de apresentar aplicabilidade prática com dados reais do Hospital das Clínicas da Universidade Federal de Pernambuco (UFPE).

Complementarmente, Torres-Galván et al. (2022) propuseram o uso de redes neurais convolucionais profundas (CNNs), com transferência de aprendizado, para classificar

termogramas mamários em normais e anormais. A arquitetura ResNet-101 obteve alta sensibilidade, sugerindo que a termografia infravermelha pode ser integrada de forma eficaz como ferramenta auxiliar na triagem de câncer de mama. Ainda no domínio da classificação, Allugunti (2021) propôs um sistema de diagnóstico assistido por computador (CAD) capaz de classificar pacientes em três categorias (câncer, não câncer e benigno), com bons resultados utilizando CNNs, máquinas de vetores de suporte (SVM) e Floresta Aleatória (Random Forest). Esses estudos ilustram o avanço das técnicas de aprendizado de máquina na interpretação de imagens térmicas para apoio ao diagnóstico precoce.

No que tange à formulação e resolução de problemas inversos, trabalhos anteriores já haviam apontado seu valor na estimativa de propriedades térmicas a partir de dados de superfície. Jiang, Zhan e Loew (2010) investigaram a viabilidade numérica da resolução do problema inverso na termografia mamária, estimando condutividade, perfusão sanguínea e geração de calor metabólico em diferentes tecidos. O estudo demonstrou que, mesmo sob ruído moderado, é possível obter estimativas estáveis e úteis para fins diagnósticos. Da mesma forma, Mital e Pidaparti (2008) propuseram uma metodologia híbrida baseada em redes neurais artificiais e algoritmos genéticos para estimar profundidade, diâmetro e geração de calor de tumores em modelos bidimensionais, com bons resultados mesmo na presença de ruído.

Outra contribuição relevante é a de Mitra e Balaji (2010), que utilizaram simulações com o Método dos Elementos Finitos para gerar vetores de temperatura da superfície da mama, os quais foram usados para treinar redes neurais capazes de estimar, com alta precisão, o tamanho e a posição de tumores. Esse método, ao combinar modelagem biotérmica e inteligência artificial, mostrou-se promissor para a análise de termogramas em ambientes clínicos simulados.

No campo da análise de dados térmicos com ferramentas estatísticas e de inteligência artificial (IA), o trabalho de Ng e Kee (2008) apresentou uma abordagem integrada envolvendo regressão, redes neurais do tipo *Radial Basis Function* (RBFN) e análise de *Receiver Operating Characteristic* (ROC) (Características Operacionais do Receptor) para classificar imagens térmicas da mama. O modelo alcançou 100 % de sensibilidade e quase 81 % de acurácia geral, destacando-se como alternativa não invasiva para detecção de câncer em estágios iniciais. Já Acharya et al. (2012) combinaram extração de textura e classificação via SVM, alcançando bons índices de acurácia, sensibilidade e especificidade, reforçando o potencial diagnóstico da termografia como complemento à mamografia.

No contexto da otimização de arquiteturas de RNAs, o trabalho de Brandão (2023) apresenta uma contribuição altamente relevante, especialmente por sua similaridade metodológica com a proposta deste TCC. A autora desenvolveu um modelo de previsão da pressão de falha em dutos corroídos, utilizando uma RNA cuja estrutura foi otimizada com o algoritmo PSO. A aplicação do PSO permitiu identificar configurações de rede com menor erro quadrático médio e maior coeficiente de determinação, demonstrando ganhos significativos em relação a modelos não otimizados. O destaque desse estudo está na abordagem sistemática da calibração de hiperparâmetros, no uso de dados simulados e na integração eficiente entre RNA e PSO.

De forma complementar, Santos (2024) comparou o desempenho de diferentes algoritmos evolutivos — PSO, *Greedy Randomized Adaptive Search Procedure* (GRASP) (uma metaheurística que combina construção de soluções com busca em vizinhança para escapar de ótimos locais) e Optuna (biblioteca de otimização de hiperparâmetros desenvolvida em Python, conhecida por sua flexibilidade e eficiência). O autor observou que a escolha do método de otimização influencia diretamente a acurácia dos modelos e o tempo de execução. O algoritmo GRASP foi aprofundado por Silva (2024), que o aplicou na calibração de hiperparâmetros de redes neurais para previsão de falhas em dutos com defeitos axissimétricos. Embora o domínio de aplicação seja distinto, o estudo de Silva reforça a importância de estratégias de otimização inteligentes em problemas preditivos com múltiplas variáveis e elevada complexidade computacional.

Nesse mesmo sentido, Machado (2025) aplicou RNAs otimizadas por PSO para modelar a desativação energética em leitos de adsorção de gás natural, utilizando dados gerados por simulação em ambiente industrial. Mesmo com dados reduzidos, como os provenientes da distribuição representativa de tamanho de poros (PSD representativa), os modelos obtiveram desempenho comparável ou superior àqueles baseados em conjuntos mais complexos. Essa abordagem corrobora o potencial do PSO como ferramenta eficiente para otimizar arquiteturas de RNA em sistemas com múltiplas variáveis, inclusive na presença de dados limitados.

Outros trabalhos oferecem suporte metodológico adicional. Por exemplo, Li et al. (2021) aplicaram PSO em redes neurais do tipo *backpropagation* para classificação de eletrocardiogramas, destacando a capacidade do modelo em lidar com ruído e variações fisiológicas. Já Zhang (2019) e Hao et al. (2018) utilizaram modelos híbridos PSO+RNA para

previsão em cadeias logísticas e reciclagem veicular, respectivamente, demonstrando o potencial desses algoritmos em sistemas complexos e não lineares.

A revisão apresentada evidencia uma tendência clara na literatura: a integração entre termografia infravermelha, modelagem computacional e inteligência artificial constitui um campo fértil para a estimativa de parâmetros termofísicos. A partir da fundamentação nos problemas inversos, somada às inovações nos métodos de aprendizado de máquina e otimização, constrói-se uma base metodológica para o desenvolvimento de sistemas de apoio ao diagnóstico do câncer de mama. Nesse cenário, o uso de RNAs otimizadas por metaheurísticas como o PSO destaca-se como alternativa promissora.

3 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os fundamentos teóricos necessários para o desenvolvimento da metodologia proposta neste trabalho, com foco na estimativa de parâmetros termofísicos aplicados à detecção de anormalidades em tecidos mamários por meio de imagens térmicas e algoritmo de inteligência artificial. São abordados os conceitos de transferência de calor, problema inverso, redes neurais artificiais, otimização por enxame de partículas e o método dos volumes finitos, compondo a base teórica para a modelagem e implementação da proposta.

3.1 Equação da Biotransferência de Calor

A transferência de calor em seres vivos tem sido investigada por meio de diversos modelos. Entre os principais modelos propostos na literatura, destacam-se o modelo da condutividade térmica efetiva, o modelo de Pennes, o modelo de Wulff, o de Klinger, o de Chen e Holmes, o modelo dos vasos emparelhados e o modelo de Weinbaum, Jiji e Lemons (BEZERRA, 2013). Neste trabalho, adotou-se o modelo de Pennes, amplamente utilizado em razão de sua formulação simplificada.

O modelo de Pennes, apresentado originalmente em 1948, descreve a distribuição temporal e espacial da temperatura em tecidos vivos. Sua formulação considera, além da condução de calor, os efeitos metabólicos e o fluxo sanguíneo arterial como fontes internas de geração de energia térmica. Desde sua publicação, essa equação tem sido amplamente empregada em estudos envolvendo a simulação de processos térmicos em sistemas biológicos, como apontado por Bezerra (2013, apud SUDARSHAN *et al.*, 1999; NG; SUDARSHAN, 2001b; GUIMARÃES, 2003; GONZÁLEZ, 2007; SILVA, 2011).

A *Bioheat Transfer Equation* (BHTE) (Equação da Biotransferência de Calor) é uma modificação da equação clássica da condução de calor, acrescida de termos que representam a geração de calor por perfusão sanguínea (Q_p) e por metabolismo celular (Q_m), além de eventuais fontes externas. A BHTE, desempenha um papel central na compreensão da transferência de calor nos tecidos biológicos, fornecendo uma estrutura matemática para modelar e prever como o calor é distribuído e dissipado dentro do corpo humano.

De acordo com Bezerra et al. (2020), a equação é obtida através de um rigoroso balanço energético, levando em conta a geração local de calor, a condução térmica e o armazenamento de energia nos tecidos. No processo de modelagem, são desprezados os efeitos de origem química, elétrica, física e nuclear, assumindo-se um meio biológico homogêneo, isotrópico e com propriedades constantes (densidade, calor específico e condutividade térmica) para cada tipo de tecido (BEZERRA, 2013). Para um tecido isolado, a equação é expressa por:

$$\rho_t c_t \frac{\partial T_t}{\partial t} = \nabla \cdot (k_t \nabla T_t) + Q_p + Q_m \quad (3.1)$$

onde, ρ_t é a densidade do tecido, c_t é o calor específico do tecido, T_t é a temperatura local do tecido, t é o tempo, k_t é a condutividade térmica do tecido, Q_p é a taxa volumétrica de geração de calor devido à perfusão sanguínea, Q_m é a taxa volumétrica de geração de calor metabólico e ∇ é o operador nabla (diferencial).

A taxa de geração de calor por perfusão sanguínea, pode ser modelada por meio de uma expressão que considera a taxa de perfusão do tecido, a densidade e o calor específico do sangue, bem como a diferença entre a temperatura arterial e a temperatura local do tecido. Segundo Diller (1982), essa relação pode ser expressa como:

$$Q_p = \omega_t \rho_b c_b (T_a - T_v) \quad (3.2)$$

em que ω_t é a taxa de perfusão sanguínea do tecido ((m³/s) de sangue/m³ de tecido), ρ_b é a densidade do sangue, c_b é o calor específico do sangue, T_a é a temperatura do sangue arterial e T_v é a temperatura do sangue venoso deixando o tecido.

Pennes (1948) propôs que a taxa de transferência de calor por perfusão volumétrica pode ser considerada proporcional à diferença entre a temperatura do sangue arterial e a temperatura do tecido local (T_t), admitindo-se que o sangue venoso atinja equilíbrio térmico com o tecido

ao qual irriga (WISSLER, 1998). Dessa forma, o modelo considera $T_v \approx T_t$, o que simplifica o termo de perfusão (CHARNY, 1992).

A taxa de perfusão ω_t é uma propriedade específica de cada tipo de tecido e desempenha papel fundamental na dissipação ou acúmulo de calor, sobretudo em regiões tumorais (BEZERRA, 2013).

A geração de calor metabólico Q_m , por sua vez, também se relaciona diretamente com as características da massa tumoral. Modelos empíricos descritos na literatura associam Q_m ao tempo de duplicação tumoral τ , por meio de uma função hiperbólica. Segundo Bezerra (2013, apud GAUTHERIE, 1980; OSMAN; AFIFY, 1988; MITRA; BALAJI, 1992; NG; SUDARSHAN, 2001b), esse relacionamento pode ser descrito pela expressão:

$$Q_m \tau = C \quad (3.3)$$

onde C é uma constante com valor aproximado de $3,27 \times 10^6$ W dia/m³ e τ é o tempo necessário para que o volume tumoral dobre de tamanho. O tempo τ , por sua vez, pode ser obtido a partir de uma função exponencial do diâmetro D do tumor, conforme a equação:

$$D = 0,01e^{[0,002134(\tau-50)]} \quad (3.4)$$

Essas equações permitem estimar Q_m de forma individualizada para cada paciente, com base em dados clínicos obtidos por exames de imagem, como ultrassonografias. Neste estudo, o nódulo pode ser considerado como uma esfera ou um cilindro, dependendo dos dados obtidos nos exames.

Para resolver a equação da biotransferência de calor apresentada anteriormente, foram impostas as seguintes condições de contorno e inicial, conforme descrito por Bezerra (2013):

1. Foi aplicada uma condição de contorno de Dirichlet na parede torácica, na qual uma temperatura prescrita $\bar{T}$ é especificada para esta região:

$$T = \bar{T} \quad (3.5)$$

2. Foi aplicada uma condição de contorno de Cauchy ou Robin, também conhecida como condição de contorno mista, na superfície externa da mama, onde ocorre a transferência de calor por convecção para o ambiente.

$$-k_t \frac{\partial T_t}{\partial \eta} = h(T_t - T_\infty) \quad (3.6)$$

nessa equação, η representa o vetor normal unitário, T_∞ é a temperatura ambiente e h é o coeficiente de transferência de calor por convecção, para o qual foi adotado o valor de 13,5 W/m² °C (BEZERRA, 2013).

A condição inicial $\overline{T_o}$, foi atribuída a mesma temperatura adotada para a parede torácica, logo:

$$T = \overline{T_o} \quad (3.7)$$

onde considerou-se a temperatura inicial a 37°C.

Por último, as hipóteses e considerações adotadas para a simulação do problema proposto (BEZERRA, 2013) foram as seguintes:

1. A superfície da mama realiza troca de calor por convecção com o ambiente externo.
2. A transferência de calor dentro da mama ocorre por condução.
3. A temperatura prescrita na região torácica foi estabelecida como sendo igual a 37°C.
4. A temperatura do sangue foi assumida como sendo 37°C.
5. Para as simulações realizadas, a mama foi modelada utilizando um modelo simplificado com duas regiões distintas em termos de propriedades termofísicas: o tecido mamário e o tecido tumoral.
6. As simulações foram realizadas em regime permanente.
7. As propriedades termofísicas foram consideradas constantes em cada região do domínio.

3.2 Problema Inverso de Transferência de Calor

Existem diversas abordagens para resolver problemas inversos, incluindo métodos de otimização, variacionais, redes neurais artificiais, métodos Bayesianos e mínimos quadrados. Geralmente, para problemas de transferência de calor, a solução é obtida através da minimização de uma função objetivo, ou seja, por meio de um problema de otimização. O objetivo do método de otimização é encontrar valores para os parâmetros desconhecidos que minimizem a função objetivo de maneira iterativa. Nesse contexto, um algoritmo de otimização busca estimar os parâmetros desconhecidos de forma a reduzir ao mínimo a discrepância entre os valores experimentais medidos e os calculados numericamente (BEZERRA, 2013).

Métodos evolucionários e estocásticos, inspirados em processos naturais, têm se destacado por sua capacidade de escapar de ótimos locais e alcançar soluções globais. Entretanto, esses métodos apresentam uma limitação importante, decorrente do grande número de vezes que a função objetivo precisa ser avaliada, o que pode tornar seu uso inviável em determinadas aplicações (COLAÇO; ORLANDE; DULIKRAVICH, 2006). Exemplos de métodos estocásticos incluem algoritmos genéticos, SA, ACO e PSO (ZHU et al., 2022; LU; WANG, 2023).

O termo otimização pode ser definido como o estudo de problemas em que se busca o melhor resultado para uma função através da escolha dos valores de variáveis dentro de um conjunto viável. A otimização é a minimização ou maximização de uma função sujeita a restrições sobre as variáveis. A formulação do problema de otimização a ser resolvido pode ser descrita matematicamente pela seguinte expressão:

$$\text{Min}_x F(x) = \sum_{l=1}^M [Tcal_l(x) - Texp_l]^2 \quad (3.8)$$

sujeito a:

$$k_i^l \leq k_i \leq k_i^u \quad (3.9)$$

onde o k^l é o Limite inferior para a condutividade térmica, o k^u é o Limite superior para a condutividade térmica.

3.3 Redes Neurais Artificiais

As redes neurais são desenvolvidas com o objetivo de reproduzir, de forma artificial, o funcionamento do cérebro humano na realização de tarefas específicas, sendo implementadas por meio de componentes eletrônicos ou simuladas em computadores digitais (HAYKIN, 2001). As RNAs são uma rede interligada de neurônios artificiais (CATARINO, 2025). O modelo simplificado de um neurônio foi proposto por McCulloch e Pitts (1943), cuja estrutura tenta simular as realidades biológicas que acontecem dentro de uma célula do sistema nervoso (RAUBER, 2005).

De acordo com Catarino (2025), a proposta de McCulloch e Pitts apresenta um modelo lógico-matemático de um neurônio artificial capaz de processar sinais binários e gerar uma saída com base na soma ponderada das entradas. O funcionamento desse neurônio envolve três elementos principais: as entradas (dendritos), o processamento (corpo celular) e a saída

(axônio), buscando reproduzir, de maneira simplificada, os mecanismos sinápticos encontrados nos neurônios biológicos.

Cada entrada em um neurônio artificial é associada a um peso, o qual representa a intensidade da contribuição dessa entrada para o resultado final. Esses pesos podem ser excitatórios ou inibitórios, sendo ajustados durante o processo de aprendizagem da rede. A soma ponderada dessas entradas, conhecida como função soma ou junção aditiva, gera um valor que será comparado a um limiar para determinar se o neurônio será ativado (CATARINO, 2025).


Um elemento essencial ao funcionamento das RNAs é a função de ativação, que define se o resultado da função soma será transmitido para as camadas seguintes da rede. Essa função simula o comportamento das sinapses biológicas, permitindo que apenas neurônios com estímulos suficientemente fortes sejam ativados. Isso torna possível o processamento paralelo e distribuído das informações, característica fundamental para representar a complexidade do cérebro humano (CATARINO, 2025). Diferentes funções de ativação podem ser utilizadas conforme a complexidade da rede e a natureza do problema a ser tratado, tornando a modelagem das RNAs bastante versátil.

A partir do modelo de neurônio artificial, desenvolveram-se as redes neurais, compostas por múltiplos neurônios interligados em camadas. Uma RNA típica é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. As camadas ocultas são responsáveis pelo processamento e aprendizado dos dados, e quanto maior o número de camadas, maior é a capacidade de aprendizagem da rede. Os neurônios em cada camada se comunicam apenas com os neurônios das camadas adjacentes, mantendo a organização sequencial do fluxo de dados. Essa arquitetura permite à RNA adaptar sua estrutura de acordo com a complexidade do problema, podendo aumentar sua capacidade computacional por meio da adição de camadas ou neurônios (CATARINO, 2025).

Quando uma RNA possui duas ou mais camadas ocultas, ela é classificada como uma RNA profunda, que pode ser empregada em diversas situações complexas (CATARINO, 2025). Embora já existissem anteriormente redes neurais recorrentes, que conseguem processar séries temporais e gerar previsões com base em dados históricos, assim como convolucionais, que são redes neurais profundas que processam dados que se encontram em formato de matriz, foi apenas em 2006 que o termo Aprendizado Profundo (ou *deep learning*) passou a ser utilizado, a partir dos trabalhos de Geoffrey Hinton e Ruslan Salakhutdinov (CATARINO, 2025).

Esse conceito marcou o surgimento de uma nova vertente no aprendizado de máquina, inserida no campo da inteligência artificial, caracterizada pelo uso de redes neurais artificiais com múltiplas camadas ocultas, diferenciando-se das demais estruturas vistas até então (CATARINO, 2025). A Figura 2 ilustra a estrutura básica de uma rede neural profunda, composta por camadas de entrada, ocultas e de saída.

Figura 2 - Rede Neural Profunda.




Fonte: Autor, 2025.

O *Perceptron* é a arquitetura mais simples de RNA, sendo capaz de resolver apenas problemas linearmente separáveis (ROSENBLATT, 1958). O modelo concebido por Rosenblatt, conhecido como *Perceptron*, foi construído sobre os fundamentos lançados por McCulloch e Pitts (1943) e pelas contribuições de Von Neumann sobre sistemas formais e circuitos lógicos. A inovação do *Perceptron* esteve na incorporação de um mecanismo de aprendizado por meio da atribuição e do ajuste de pesos às entradas, possibilitando que o sistema artificial fosse capaz de reconhecer padrões lineares de forma supervisionada (CATARINO, 2025).

A estrutura do *Perceptron* é composta por elementos bem definidos: (i) a camada de entrada, que recebe os dados em formato numérico; (ii) os pesos associados a cada entrada, ajustáveis durante o treinamento; (iii) a função soma ponderada, que calcula o valor total de entrada com base nos pesos; (iv) a função de ativação, que determina se o valor resultante é suficiente para ativar o neurônio; e (v) a camada de saída, que retorna a classificação final.

(HAYKIN, 2001). A Figura 3 ilustra a arquitetura de um *Perceptron*, incluindo seus componentes fundamentais.

Figura 3 - Arquitetura de um *Perceptron*.



Fonte: Adaptado de CATARINO, 2025.

O elemento central que permite essa tomada de decisão binária no *Perceptron* é a função de ativação. Dentre os diversos tipos de funções utilizadas, uma das mais simples e pioneiras é a função do tipo degrau (*Heaviside Step Function*), que determina a ativação com base em um limiar (CATARINO, 2025). Caso o resultado da soma ponderada (potencial de ativação) seja igual ou superior a zero, o neurônio é ativado (saída 1); caso contrário, permanece inativo (saída 0).

Apesar de sua simplicidade, a função de ativação do tipo degrau é limitada na resolução de problemas mais complexos, pois não é contínua nem diferenciável. Ainda assim, foi essencial no desenvolvimento inicial das redes neurais, especialmente em tarefas de classificação linearmente separáveis (CATARINO, 2025).

Para problemas mais complexos, é utilizado o *Perceptron* Multicamada (MLP), ele representa uma evolução significativa em relação ao *Perceptron* simples, permitindo a resolução de problemas não lineares por meio da interconexão de múltiplas camadas de neurônios artificiais. Segundo Catarino (2025), essa arquitetura é composta por três camadas principais: entrada, oculta e saída.

Um dos avanços fundamentais para o MLP foi o desenvolvimento do algoritmo de retropropagação (*backpropagation*), proposto por Rumelhart, Hinton e Williams em 1986, que permite ajustar os pesos sinápticos com base no erro calculado entre a saída prevista e a desejada. Esse método utiliza o gradiente descendente para minimizar o erro, dividindo-se em duas etapas: a propagação direta (*forward pass*), em que os dados são processados sequencialmente, e a propagação reversa (*backward pass*), que retroalimenta os erros para otimização dos parâmetros (CATARINO, 2025).

A eficácia do MLP depende criticamente da escolha das funções de ativação, que introduzem não linearidades ao modelo. Conforme Catarino (2025), funções como a sigmoide, apresentada na Equação 3.10 – que mapeia saídas entre 0 e 1 – e a tangente hiperbólica presente na Equação 3.11 ($\tanh$) – com valores entre -1 e 1 – foram amplamente utilizadas, mas apresentam limitações como o problema de gradientes *vanishing* em valores extremos. A função *Rectified Linear Unit* (ReLU) apresentada na Equação 3.12, proposta por Nair e Hinton em 2010, tornou-se predominante em redes profundas devido à sua simplicidade computacional e eficiência ao retornar zero para entradas negativas e o próprio valor para positivas, evitando saturação (CATARINO, 2025).

$$f(x) = \frac{1}{(1 + e^{-x})} \quad (3.10)$$

$$\sigma(x) = \tanh(x) \quad (3.11)$$

$$\varphi(u) = u, \text{ se } u \geq 0 \\ 0, \text{ se } u < 0 \quad (3.12)$$

Outros parâmetros também são adotados no uso da RNA, entre esses parâmetros, destacam-se as épocas (*epochs*), que correspondem ao número de vezes em que todo o conjunto de dados de treinamento é processado pela rede, completando um ciclo completo de aprendizado (BRANDÃO, 2023). Esse processo iterativo se repete continuamente até que um dos critérios estabelecidos para interrupção seja alcançado, como a convergência do erro ou um número máximo pré-definido de ciclos.

3.4 Algoritmo de Otimização por Enxame de Partículas (PSO)

O avanço da computação natural nas últimas décadas tem sido impulsionado pelo desenvolvimento do processamento paralelo, o que viabilizou a implementação de algoritmos mais sofisticados, capazes de realizar buscas eficientes em hiperespaços complexos

(SENGUPTA; BASAK; PETERS, 2018). Entre os diversos métodos propostos nessa área, destaca-se o PSO (KENNEDY; EBERHART, 2002).

O algoritmo PSO, uma metaheurística inspirada no comportamento coletivo de animais, como bandos de pássaros, que colaboram entre si na busca por recursos ou abrigo, agindo de forma coordenada para atingir um objetivo comum. O PSO baseia-se na observação de que indivíduos em um grupo podem compartilhar informações e aprender uns com os outros para melhorar seu desempenho coletivo. Aplicado à otimização, esse comportamento se traduz na movimentação de partículas (possíveis soluções) dentro de um espaço de busca multidimensional, guiadas por suas próprias experiências e pelas informações obtidas de suas vizinhas (LINS *et al.*, 2012).

A dinâmica do PSO envolve iterações sucessivas, nas quais as partículas ajustam suas posições com base em suas melhores soluções individuais e nas melhores soluções encontradas por seus pares. Esse processo colaborativo é conduzido por diferentes estruturas de conexão entre as partículas, conhecidas como topologias. As duas principais são: (i) a topologia global (*gbest*), onde todas as partículas se comunicam entre si, e (ii) a topologia local (*lbest*), em que cada partícula interage apenas com um número limitado de vizinhas (LINS *et al.*, 2012). A escolha da topologia influencia diretamente a forma como a informação é propagada pelo enxame e, conseqüentemente, o desempenho do algoritmo na busca por soluções ótimas.

Na abordagem *gbest*, cada partícula i percorre um espaço de busca com n dimensões, cada uma representando uma variável de decisão. A posição de cada partícula é representada por um vetor $s_i = [s_{i1}, s_{i2}, \dots, s_{in}]$, e sua velocidade por $v_i = [v_{i1}, v_{i2}, \dots, v_{in}]$, onde $i = 1, 2, \dots, S$, sendo S o número total de partículas. Cada partícula mantém ainda um vetor $p_i = [p_{i1}, p_{i2}, \dots, p_{in}]$, que armazena a melhor posição visitada por ela durante a busca, enquanto o vetor $g = [g_1, g_2, \dots, g_n]$ guarda a melhor posição global encontrada pelo enxame até o momento.

A movimentação das partículas ocorre por meio da atualização de suas velocidades e posições a cada iteração $q = 1, 2, \dots, I$. Inicialmente, as posições s_i e velocidades v_i são atribuídas aleatoriamente, respeitando os limites definidos pelo problema. Após cada atualização, é necessário verificar se os novos valores permanecem dentro dos limites do espaço de busca. Caso contrário, são corrigidos para os valores mínimos permitidos, conforme as restrições impostas pelo modelo. A equação utilizada para a correção das posições fora dos limites corresponde à Equação 3.13.

$$s_{ij} = s_{min} \text{ para } s_{ij} < s_{min} \quad (3.13)$$

A atualização das velocidades é influenciada por dois componentes principais: o cognitivo, representado pelo parâmetro ϕ_p , que orienta a partícula com base em sua melhor posição anterior; e o social, ϕ_g , que direciona a partícula em direção à melhor solução encontrada pelo grupo. Essa atualização é feita segundo a Equação 3.14, enquanto a nova posição da partícula, calculada com base na velocidade ajustada, é definida pela Equação 3.15.

Além disso, utiliza-se um fator de restrição ω , comumente adotado como $\omega = 0,729843$, conforme sugerido por Bratton e Kennedy (2007), com o objetivo de evitar oscilações excessivas e garantir a convergência do algoritmo. Os parâmetros ϕ_p e ϕ_g , por sua vez, geralmente assumem o valor 2,05, também definidos com base em estudos de convergência do algoritmo (BRATTON; KENNEDY, 2007).

$$v_{ij}(q+1) = v_{ij}(q) + \phi_p r_1 (p_{ij}(q) - s_{ij}(q)) + \phi_g r_2 (g_j(q) - s_{ij}(q)) \quad (3.14)$$

$$s_{ij}(q+1) = s_{ij}(q) + \omega v_{ij}(q+1) \quad (3.15)$$

Assim, o PSO se configura como uma ferramenta robusta e eficiente para a resolução de problemas de otimização não linear, oferecendo boa capacidade de exploração do espaço de soluções e convergência rápida, especialmente quando os parâmetros são adequadamente ajustados.

3.5 Método dos Volumes Finitos

O método numérico adotado para transformar as equações governantes em equações algébricas passíveis de solução computacional é o Método dos Volumes Finitos (MVF). Essa abordagem fundamenta-se na integração das equações diferenciais sobre volumes de controle que compõem a malha de discretização do domínio físico. O resultado desse processo são equações discretizadas que asseguram a conservação das propriedades físicas dentro de cada volume de controle. Essa técnica está intimamente associada ao conceito de fluxo entre regiões vizinhas (FORTUNA, 2000).

A quantificação do fluxo líquido de uma propriedade qualquer ϕ (como massa ou energia) que atravessa as superfícies do volume de controle por unidade de tempo é obtida pela integração ao longo dessas fronteiras, considerando-se a diferença entre as quantidades que

entram e saem do volume. Os mecanismos de transporte responsáveis por esse fluxo são, em geral, classificados em dois tipos: convectivos e difusivos (BEZERRA, 2013).

Os fluxos convectivos originam-se da velocidade do fluido e são geralmente expressos pela relação $\rho\phi\vec{v}$, em que ρ representa a densidade, $\vec{v}$ é o vetor velocidade do fluido e ϕ a propriedade transportada (FORTUNA, 2000). Já os fluxos difusivos resultam de gradientes ϕ , sendo usualmente representados por $\Gamma_\phi\nabla\phi$, onde Γ_ϕ corresponde ao coeficiente de difusão, não necessariamente uniforme, e ϕ indica a grandeza sendo difundida (FORTUNA, 2000; MALISKA, 1995).

Ao considerar uma propriedade genérica ϕ , e levando em conta os mecanismos convectivo e difusivo, bem como possíveis geração ou consumo internos, a variação temporal da quantidade de ϕ em um volume de controle V pode ser descrita da seguinte maneira: Taxa de variação temporal de ϕ em V é igual a entrada líquida de ϕ em V mais a produção líquida de ϕ em V (BEZERRA, 2013).

A entrada líquida de ϕ é obtida a partir do balanço entre os fluxos convectivo e difusivo através das fronteiras de V . Esta contribuição líquida é computada por meio da integração desses fluxos sobre a superfície que delimita o volume de controle, conforme indicado na equação 3.16. Por sua vez, a produção líquida interna corresponde à diferença entre a geração e o consumo da propriedade ϕ dentro do volume, sendo representada por um termo fonte (BEZERRA, 2013).

De forma geral, podemos expressar uma lei da conservação resolvida nos programas de Dinâmica dos Fluidos Computacional (CFD) da seguinte forma:

$$\frac{\partial\rho\phi}{\partial t} + \nabla \cdot (\rho\phi\vec{v}) = \nabla\Gamma_\phi\nabla\phi + S_\phi \quad (3.16)$$

onde, o primeiro termo da equação representa a taxa de armazenamento, o termo $(\nabla \cdot (\rho\phi\vec{v}))$ é o fluxo convectivo, o termo $(\nabla\Gamma_\phi\nabla\phi)$ é o fluxo difusivo e S_ϕ é o termo de fonte ou sumidouro.

4 METODOLOGIA

Este capítulo descreve as etapas adotadas para a construção da metodologia proposta. Inicialmente, é apresentada a definição da geometria simplificada da mama, seguida da modelagem matemática baseada na equação da biotransferência de calor. Em sequência, o


procedimento de simulação numérica por meio do MVF, utilizando o software ANSYS. Posteriormente, aborda-se o desenvolvimento da RNA e sua integração com o algoritmo PSO, que é responsável por ajustar automaticamente os hiperparâmetros da rede.

4.1 Geometria da mama

Na tentativa de se obter uma reconstrução mais fiel da geometria da mama, diferentes geometrias substitutas foram utilizadas pelo Laboratório de análises térmicas e termográficas em engenharia biomecânica da UFPE. Conforme descrito por Melo (2019), em uma primeira abordagem, foi utilizada uma semiesfera como forma simplificada da mama, conforme ilustrado na Figura 4(a). Posteriormente, houve a substituição dessa geometria por um fantoma de dorso feminino, representado na Figura 4(b), seguindo o modelo descrito por Santos et al. (2009). Com o avanço da pesquisa, Viana (2010) propôs uma metodologia capaz de gerar representações tridimensionais mais realistas, baseadas em próteses de silicone, conforme demonstrado nas Figuras 4(c) e 4(d).

Figura 4 - Geometrias substitutas. (a) Semiesfera (b) Fantoma (c) Prótese de silicone (d)

Prótese de silicone ajustada a paciente.



Fonte: Adaptado de BEZERRA, 2013.


Em continuidade a essa evolução, uma colaboração com a Universidade Federal Fluminense (UFF) possibilitou melhorias significativas na modelagem geométrica tridimensional. Segundo Melo (2019), Viana (2016) incorporou informações obtidas por meio de imagens termográficas, utilizando a variação de temperatura para extrair curvas anatômicas relevantes, como a da prega inframamária e o perfil da mama, o que permitiu uma aproximação ainda maior da geometria real do corpo feminino.

Embora o modelo desenvolvido por Viana (2016) tenha representado um avanço significativo na construção de geometrias substitutas para simulações térmicas, algumas limitações ainda foram identificadas. De acordo com Melo (2019), em determinados casos, a simulação numérica não pôde ser conduzida para algumas pacientes devido a dificuldades relacionadas à conformação da geometria ou a falhas na etapa de geração de malha, considerada fundamental para a viabilidade da simulação.

Para contornar essa dificuldade, Melo (2019) sugeriu a utilização do software *SpaceClaim*, que foi adotado no presente estudo com o objetivo de extrair a curva de perfil da paciente e ajustá-la à curva frontal correspondente à prótese da marca Ortho Pauher. A extração foi realizada com o auxílio da ferramenta *spline*, a qual possibilita a interligação de pontos da geometria por meio de curvas suavizadas, geradas a partir de funções polinomiais.

Neste trabalho, adotou-se a metodologia proposta por Melo (2019) para extração do perfil mamário a partir das imagens termográficas laterais das pacientes. Utilizando a ferramenta *spline*, foi possível construir a curva de contorno trecho a trecho, posicionando pontos ao longo da região limite da mama, o que possibilitou um ajuste mais preciso da geometria. Essa curva, representativa do perfil individual de cada paciente, está ilustrada na Figura 5, originalmente apresentada por Melo (2019). Após a definição da curva, procedeu-se ao seu dimensionamento, de forma a compatibilizá-la com o tamanho real da mama.

Figura 5 - Curva de perfil de uma paciente pelo *SpaceClaim*.



Fonte: MELO, 2019.


Com base na metodologia descrita por Melo (2019), as dimensões das próteses utilizadas foram determinadas inicialmente por meio de medições diretas com o auxílio de um escalímetro 1:1 da marca Trident e de esquadros, sendo um escaleno e um isósceles. As medidas dos eixos principais de cada prótese estão sistematizadas na Tabela 1. A partir desses dados, Melo (2019) construiu a superfície da parede torácica de cada prótese, conforme exemplificado na Figura 6. Melo (2019) observou que as dimensões das próteses apresentam entre si uma proporcionalidade geométrica, o que permitiu, no presente estudo, a aplicação de interpolação linear como ferramenta para ajuste dimensional dos modelos em função das características individuais de cada paciente.

Tabela 1 - Medidas dos eixos das próteses.

Número da prótese	Eixo menor (mm)	Eixo maior (mm)
1	107	150
4	124	174
8	151	212
9	158	222
12	167	235

Fonte: MELO, 2019.


Figura 6 - Formato das próteses mamárias analisadas por Melo (2019).



Fonte: MELO, 2019.

Para adaptar a geometria gerada às dimensões reais da mama da paciente, procedeu-se ao traçado de uma linha horizontal, denominada MH, na imagem termográfica frontal. Essa linha foi posicionada na altura do mamilo da paciente e determinada com base na referência de uma grade metálica composta por quadrados com lado de 75 mm, colocada à frente do corpo durante a captação das imagens. A Figura 7 ilustra essa correspondência utilizada no dimensionamento.

Figura 7 - Técnica utilizada para o dimensionamento da geometria substituta. (a) Imagem frontal da paciente posicionada atrás de uma grade metálica, com a linha de referência (MH) traçada na altura do mamilo para definição da largura da mama. (b) Aplicação da medida obtida pela reta (MH) no ajuste da base torácica da prótese.




Fonte: MELO, 2019.

Com a parede torácica previamente dimensionada, a curva de perfil extraída da imagem lateral da paciente (Figura 5) pôde ser ajustada aos limites do eixo vertical da geometria. Para a geração do volume tridimensional final, foi necessário incorporar uma segunda curva, posicionada no plano horizontal, de forma a permitir a construção da base da mama. Seguindo a metodologia proposta por Melo (2019), optou-se por utilizar uma semi-elipse, cujo eixo menor foi igualado à medida da reta MH, já definida anteriormente. A combinação da curva de perfil com essa segunda curva foi suficiente para a formação da geometria substituta. Detalhes adicionais sobre a definição e aplicação dessa curva podem ser consultados diretamente em Melo (2019).

A Figura 8 apresenta a geometria tridimensional obtida a partir da combinação da curva de perfil da paciente com a curva horizontal no plano frontal, conforme metodologia descrita


anteriormente. A forma gerada busca representar o volume mamário, respeitando as proporções individuais extraídas das imagens termográficas. Para validar visualmente o resultado, a Figura 9 mostra a geometria final sobreposta à imagem termográfica frontal da paciente.

Figura 8 - Geometria tridimensional obtida após a combinação das curvas de perfil e frontal.



Fonte: Autor, 2025.

Figura 9 - Sobreposição da geometria tridimensional à imagem termográfica da paciente.




Fonte: Autor, 2025.

Para o posicionamento do nódulo na geometria mamária, foram utilizadas as informações extraídas dos exames de imagem, em especial os dados fornecidos por ultrassonografia, que indicam dimensões, profundidade e relação com o mamilo e a pele. A fim de garantir um posicionamento anatômico coerente, adotaram-se dois sistemas de referência

comumente empregados na prática clínica: o sistema de quadrantes e o sistema de relógio, ambos com centro no mamilo.

O sistema de quadrantes divide a mama em quatro regiões: quadrante superior externo (QSE), quadrante superior interno (QSI), quadrante inferior externo (QIE) e quadrante inferior interno (QII), sendo o QSE a região mais acometida por distúrbios, por concentrar a maior quantidade de tecido glandular mamário (BEZERRA, 2013). Já o sistema de relógio, também centrado no mamilo, subdivide a mama em doze setores equivalentes às horas de um relógio, oferecendo maior precisão na localização angular do nódulo. A representação gráfica desses sistemas pode ser observada na Figura 10.

Figura 10 - Representação dos sistemas de localização anatômica da mama. (a) Sistema de quadrantes: QSE, QSI, QII e QIE. (b) Sistema de relógio.




Fonte: BEZERRA, 2013.

4.2 Simulação numérica

Para realizar as simulações numéricas, foi utilizado o software ANSYS Fluent, reconhecido por sua robustez e precisão nas análises CFD. O Fluent baseia-se no método dos volumes finitos, no qual as equações governantes são convertidas em equações algébricas possibilitando a resolução numérica. A sequência de etapas da metodologia adotada é apresentada no fluxograma da Figura 11, abrangendo desde a coleta dos dados até a utilização dos resultados na rotina computacional.

Figura 11 - Fluxograma da metodologia, integrando a simulação numérica e a rotina computacional (RNA + PSO).



Fonte: Autor, 2025.

Inicialmente, a geometria tridimensional da mama foi construída e posteriormente importada para o módulo *Mesh* do ANSYS Workbench, para a geração da malha computacional. Nesse processo, aplicou-se o recurso *Sizing*, com duas configurações distintas: uma voltada para a superfície da mama e outra para a região tumoral. Essa abordagem permitiu o refinamento localizado da malha, assegurando maior precisão nas regiões com maior complexidade geométrica e maior variação térmica.

A avaliação da qualidade da malha foi realizada com base na métrica *Skewness*, amplamente adotada em análises CFD para identificar distorções angulares nas células da

malha. De acordo com a documentação do ANSYS (2025), valores de Skewness próximos de zero indicam malhas de excelente qualidade, enquanto valores próximos de 1 apontam para células excessivamente distorcidas. A Tabela 2 apresenta a classificação qualitativa da malha de acordo com o valor de Skewness.

Tabela 2 - Classificação da qualidade da malha segundo a métrica Skewness.

Valor de Skewness	Qualidade da Malha
0 – 0,25	Excelente
0,25 – 0,5	Boa
0,5 – 0,8	Aceitável
> 0,8	Ruim (pode causar erro)

Fonte: Adaptado de ANSYS Inc., 2025.

Durante o processo de verificação, buscou-se manter a maior parte dos elementos dentro da faixa “boa” ou “excelente”. Com a malha considerada satisfatória, as simulações foram conduzidas no ANSYS Fluent.

O modelo físico empregado considerou a transferência de calor no tecido mamário com a presença de um nódulo tumoral, sendo utilizados termos de fonte adicionais para representar fenômenos biológicos como a perfusão sanguínea e a geração de calor metabólico. Tais termos foram incorporados ao solver por meio da implementação de funções definidas pelo usuário *User-Defined Functions* (UDFs), conforme metodologia descrita por Bezerra (2013). A Equação 4.1 representa o termo de fonte que foi utilizado para modelar a transferência de calor em cada região do domínio.

$$S = Q_m + \omega \rho_b c_b (T_a - T) \quad (4.1)$$

em que Q_m representa a taxa de geração de calor metabólico, ω a taxa de perfusão sanguínea, ρ_b e c_b a densidade e o calor específico do sangue, respectivamente, e T_a e T as temperaturas arteriais e local do tecido. Para mais detalhes sobre a implementação das UDFs, recomenda-se a consulta ao trabalho de Bezerra (2013).

A etapa posterior à simulação consistiu na realização do teste de convergência, essencial para garantir que os resultados obtidos fossem independentes da malha e estáveis do ponto de vista numérico. Finalmente, os resultados simulados foram analisados com base nos parâmetros térmicos extraídos para cada região de interesse.

4.3 Rotina computacional integrando PSO e RNA

O treinamento de uma RNA envolve a apresentação de um conjunto de dados de entrada com suas respectivas saídas desejadas, conhecido como conjunto de treinamento. Durante este processo, a rede ajusta os pesos das conexões entre os neurônios com o objetivo de minimizar uma função de erro, que mede a diferença entre as saídas previstas pela rede e os valores desejados. Esse ajuste dos pesos é geralmente realizado por meio de algoritmos de otimização, como o gradiente descendente, combinados com a técnica de retropropagação do erro.

No presente trabalho, empregou-se o algoritmo PSO para otimizar a arquitetura da RNA, especificamente a quantidade de neurônios na camada oculta. O PSO inicia seu processo distribuindo aleatoriamente as partículas no espaço de busca. A cada iteração, as partículas atualizam suas velocidades e posições considerando duas informações principais: a melhor posição já visitada pela partícula e a melhor posição já encontrada globalmente pelo enxame. O movimento de cada partícula é influenciado por três componentes: o fator de inércia, que regula a contribuição da velocidade anterior; o componente cognitivo, que incentiva o retorno à melhor posição individual; e o componente social, que direciona a partícula em direção à melhor solução coletiva do grupo.

Esses fatores podem ser ajustados empiricamente ou por meio de técnicas adaptativas para melhorar o desempenho do PSO em diferentes problemas. Neste estudo, foi desenvolvido um modelo de RNA otimizado com o PSO, cujo objetivo é prever a condutividade térmica da mama e do tumor, com base em dados de temperatura obtidos por simulações numéricas da distribuição térmica na mama.

As restrições de limite, também conhecidas como restrições geométricas, estabelecem limites superiores e inferiores para as variáveis de projeto. Estas restrições são expressas na forma $x_l \leq x \leq x_u$ (BEZERRA, 2013). No procedimento de otimização, o valor de limite utilizado para a condutividade térmica (W/m°C) foi de:

$$0,24 \leq k_{mama} \leq 0,72 \quad (4.2)$$

$$0,24 \leq k_{\text{tumor}} \leq 0,72 \quad (4.3)$$

O conjunto de dados utilizado compreende três variáveis de entrada, correspondentes às temperaturas máxima, mínima e média, e uma variável de saída, que representa a condutividade térmica da mama e do tumor. Inicialmente, os dados são carregados de um arquivo em formato CSV e segmentados em subconjuntos de treinamento e teste, garantindo que 80% dos dados sejam reservados para treinamento e 20% para teste.

Em seguida, os dados de entrada e saída são normalizados para o intervalo $[0,1]$, de forma a melhorar a estabilidade e a eficiência do processo de treinamento. Para fins de interpretação física, as previsões geradas pela RNA são posteriormente reescaladas para o intervalo de condutividade térmica real (0,24 a 0,72 W/(m°C)).

O algoritmo PSO implementado utilizando a biblioteca *pyswarm*, foi configurado com um tamanho de enxame de 10 partículas. O parâmetro a ser otimizado foi exclusivamente o número de neurônios na camada oculta da RNA, variando entre 5 e 100 neurônios, visando minimizar o Erro Quadrático Médio (MSE) obtido no conjunto de teste. O processo de otimização foi conduzido até a convergência do algoritmo. Em cada iteração do PSO, a rede neural é treinada com 100 épocas e um tamanho de lote de 10, sendo avaliada posteriormente para definir a qualidade da solução.

De forma geral, o fluxo metodológico adotado neste trabalho pode ser descrito conforme os seguintes passos:

1. **Carregamento dos dados:** Os dados de temperaturas máxima, mínima e média são carregados de um arquivo CSV e preparados para serem usados como entrada no modelo.
2. **Divisão do conjunto de dados:** separação em subconjuntos de treinamento (80%) e teste (20%).
3. **Normalização dos dados:** Tanto os dados de entrada quanto os de saída são normalizados no intervalo $[0,1]$ para melhorar a eficiência e a precisão do treinamento.
4. **Construção do modelo de RNA:** composto por uma camada de entrada de três neurônios (correspondente às variáveis de temperatura), uma camada oculta com número de neurônios ajustado dinamicamente pelo PSO, e uma camada de saída com função de ativação sigmoide, i.e., uma função matemática usada frequentemente como função de ativação em RNA, adequada à saída normalizada.

5. **Otimização com PSO:** ajuste automático da quantidade de neurônios da camada oculta, visando a minimização do erro quadrático médio. Durante esse processo, o modelo é treinado e reavaliado em cada iteração.
6. **Treinamento do modelo:** Após a otimização, o modelo com o número ideal de neurônios é treinado com 100 épocas e avaliado com base no conjunto de teste.
7. **Avaliação do desempenho:** O desempenho da RNA é avaliado utilizando o MSE no conjunto de teste, verificando o quanto o modelo conseguiu prever corretamente os valores de condutividade.
8. **Previsão final:** O modelo final, após ser treinado, realiza previsões para novos dados de entrada, e as saídas são reescaladas para o intervalo da condutividade térmica.

Dessa forma, a abordagem proposta possibilita estimar a condutividade térmica tanto da mama quanto do tumor, empregando um modelo de RNA otimizado por PSO, o qual ajusta dinamicamente sua arquitetura para garantir o menor erro possível no processo de predição. A rotina computacional desenvolvida em linguagem Python está apresentada no Apêndice A deste trabalho.

5 RESULTADOS E DISCUSSÃO


Esta seção apresenta e analisa os resultados obtidos a partir das simulações numéricas e das estimativas realizadas por meio de técnicas de inteligência artificial. Inicialmente, são apresentados os dados clínicos e a modelagem computacional, seguidos pelos estudos de convergência numérica e pelos perfis de temperatura simulados para a Paciente 01. Posteriormente, é descrito o banco de dados utilizado no treinamento do modelo. Por fim, são discutidas as estimativas dos parâmetros termofísicos, comparando os resultados obtidos com valores de referência e dados da literatura. As análises visam validar a metodologia proposta.

5.1 Análise Termográfica da Paciente 01

5.1.1 Simulação na mama esquerda

A paciente 01 de 44 anos teve seu diagnóstico efetuado através de exame clínico, ultrassonografia e mamografia. A mama esquerda apresenta predomínio de tecido fibroglandular, sendo identificados pequenos cistos localizados no quadrante inferior lateral, medindo o maior 0,7 x 0,6 cm. Usando os dados fornecidos pelo exame ultrassonografia foi possível posicionar o nódulo no volume da mama usado para a simulação numérica. O nódulo está situado às 4 horas, a aproximadamente 0,7 cm de distância da superfície da pele. A Figura 12 ilustra a geometria substituta da mama com a inserção do nódulo.

Figura 12 - Geometria substituta da mama esquerda com a adião do ndulo.



Fonte: Autor, 2025.

Para discretizar o domnio do problema analisado, optou-se por utilizar malhas tetradricas no estruturadas. As condies de contorno, discretizadas conforme descrito na Seo 3.1, incluram uma temperatura ambiente constante de 26,8 C. O valor do calor metablico calculado foi de 24.954 W/m³. Com o objetivo de alcanar a soluo numrica do problema, foi realizado um estudo de convergncia da soluo, apresentado na Tabela 3, analisando para este caso, cinco malhas tetradricas.

Tabela 3 - Estudo de convergncia de malha: Mama esquerda – Paciente 01.


Malha	Nmero de Ns	Nmero de Elementos	Temperatura mxima (C)
1	259.429	1.398.430	35,5
2	366.829	2.040.952	35,8
3	790.288	4.575.780	35,9
4	1.115.668	6.523.414	36,0
5	1.387.777	8.152.666	36,0

Fonte: Autor, 2025.

A primeira malha apresentou uma temperatura máxima no tumor de $35,5^{\circ}\text{C}$. Comparando a segunda malha com a anterior, a diferença de temperatura foi de $0,3^{\circ}\text{C}$. A diferença da quarta malha para a segunda foi de $0,2^{\circ}\text{C}$, e não houve variação da quarta para a quinta malha. Sendo assim, a malha escolhida foi a quarta, pois não houve modificações na temperatura calculada e o tempo de processamento foi menor. A malha escolhida tem 1.115.668 nós, 6.523.414 elementos e uma qualidade Skewness de 0,22917, ficando dentro da faixa excelente. A Figura 13 apresenta a malha da geometria e o plano de corte evidenciando o refinamento no tumor.

Figura 13 - Malha da geometria da mama esquerda.


(a) Geometria completa. (b) Plano de corte com refinamento.



Fonte: Autor, 2025.

A Figura 14, mostra a distribuição de temperatura na superfície da mama. A análise envolve o cálculo do perfil estacionário de temperatura na mama com a presença de um nódulo.

Figura 14 - Distribuição de temperatura (°C) na superfície da mama esquerda – Paciente 01.




Fonte: Autor, 2025.

A temperatura máxima obtida por meio da simulação numérica foi de 36,0°C, localizada acima da posição do nódulo. Os resultados obtidos estão em concordância com as informações encontradas na literatura disponível e com o comportamento térmico esperado para um volume que contém uma fonte de calor.

5.1.2 Simulação na mama direita

A mama direita apresentou, conforme exame de ultrassonografia, um nódulo sólido hipoecoico, de contornos irregulares e espiculados, medindo 2,3 x 1,7 x 2,7 cm, localizado às 11 horas, a cerca de 1,2 cm da superfície da pele. Utilizando os dados obtidos por imagem, foi possível posicionar o nódulo na geometria substituta da mama empregada na simulação numérica. A Figura 15 apresenta a geometria com o tumor inserido para a simulação.

Figura 15 - Geometria substituta da mama direita com a adição do tumor.



Fonte: Autor, 2025.

A malha utilizada foi também tetraédrica e não estruturada. As condições de contorno foram implementadas conforme especificado na Seção 3.1, com uma temperatura ambiente constante de 26,8 °C. Para o nódulo, foi calculado um valor de calor metabólico igual a 4.684,8 W/m³. Visando garantir a confiabilidade da solução numérica, conduziu-se um estudo de convergência, cujos resultados estão apresentados na Tabela 4, considerando cinco diferentes malhas tetraédricas.

Tabela 4 - Estudo de convergência de malha: Mama direita – Paciente 01.


Malha	Número de Nós	Número de Elementos	Temperatura máxima (°C)
1	205.779	1.145.088	35,9
2	278.602	1.580.244	36,2
3	485.017	2.814.880	36,4
4	1.663.193	9.832.199	36,7
5	1.947.329	11.565.488	36,7

Fonte: Autor, 2025.

Na primeira malha, foi registrada uma temperatura máxima de $35,9^{\circ}\text{C}$ na região tumoral. Ao comparar a segunda malha com a anterior, observou-se uma diferença de $0,3^{\circ}\text{C}$. Entre a terceira e a segunda malha, a variação foi de $0,2^{\circ}\text{C}$; da terceira para a quarta, novamente $0,3^{\circ}\text{C}$; e da quarta para a quinta, não houve alteração na temperatura obtida. Diante disso, a quarta malha foi selecionada por garantir estabilidade na solução numérica com menor tempo de processamento. Essa malha contém 1.663.193 nós, 9.832.199 elementos e apresenta qualidade Skewness de 0,22862, caracterizada como excelente. A Figura 16 apresenta a visualização da malha com e sem plano de corte.

Figura 16 - Malha da geometria da mama direita.


(a) Geometria completa. (b) Plano de corte com refinamento.



Fonte: Autor, 2025.

A Figura 17, mostra a distribuição de temperatura na superfície da mama. A análise envolve o cálculo do perfil estacionário de temperatura na mama com a presença de um tumor.

Figura 17 - Distribuição de temperatura (°C) na superfície da mama direita – Paciente 01.



Fonte: Autor, 2025.

A simulação numérica indicou uma temperatura máxima de 36,7 °C, situada acima da região tumoral. Esses resultados mostram coerência tanto com os dados disponíveis na literatura quanto com o comportamento térmico previsto para volumes que apresentam uma fonte de calor.

5.2 Base de dados para treinamento do modelo

Para o treinamento e otimização do modelo, foi utilizado um conjunto de dados obtido por meio de simulações numéricas. Nessas simulações, variou-se uma das propriedades térmicas (condutividade térmica, calor específico ou densidade) tanto da mama quanto do tumor. A partir dessas variações, foram registrados os valores de temperatura máxima, mínima

e média, tanto em um ponto específico quanto na superfície da mama e do tumor. Os dados utilizados foram provenientes da simulação de uma paciente com tumor maligno.

Os dados gerados a partir dessas simulações foram organizados em uma planilha eletrônica, disponibilizada para consulta no Anexo A, a fim de garantir a transparência e a reprodutibilidade dos resultados. Embora a planilha contenha todos os cenários simulados, neste trabalho é apresentada a Tabela 5 que sintetiza os efeitos da variação da condutividade térmica da mama e do tumor. Essa tabela inclui o valor de temperatura máxima, mínima e média obtidos na superfície da região simulada.

Tabela 5 - Temperaturas máxima, mínima e média na superfície, resultantes da variação da condutividade térmica da mama e do tumor.

Condutividade Térmica (W/m°C)	Temperatura obtida na superfície da mama (°C)					
	k_{mama}			k_{tumor}		
	Máxima	Mínima	Média	Máxima	Mínima	Média
0,061	33,8055	28,0425	29,4347	34,5041	30,9610	32,5830
0,0901	34,1886	28,6063	30,1427	34,5090	30,9638	32,6533
0,121	34,4121	29,0345	30,6684	34,5127	30,9662	32,7053
0,15	34,5478	29,3452	31,0452	34,5154	30,9680	32,7428
0,18	34,6494	29,6070	31,3564	34,5930	30,9694	32,7735
0,21	34,7358	29,8271	31,6160	34,6830	30,9707	32,7992
0,241	34,8055	30,0227	31,8441	34,7615	30,9717	32,8215
0,27	34,8593	30,1837	32,0292	34,8259	30,9728	32,8407
0,301	34,9147	30,3356	32,2044	34,8869	30,9739	32,8592
0,33	34,9597	30,4614	32,3515	34,9376	30,9748	32,8744
0,36	35,0008	30,5805	32,4896	34,9842	30,9754	32,8879
0,39	35,0382	30,6902	32,6142	35,0279	30,9763	32,9016

Condutividade Térmica (W/m°C)	Temperatura obtida na superfície da mama (°C)					
	k_{mama}			k_{tumor}		
	Máxima	Mínima	Média	Máxima	Mínima	Média
0,421	35,0766	30,7958	32,7338	35,0685	30,9769	32,9137
0,45	35,1087	30,8882	32,8366	35,1049	30,9779	32,9256
0,48	35,1399	30,9785	32,9362	35,1399	30,9785	32,9362
0,51	35,1702	31,0638	33,0284	35,1729	30,9792	32,9463
0,541	35,2006	31,1479	33,1185	35,2049	30,9798	32,9561
0,57	35,2272	31,2230	33,1976	35,2334	30,9805	32,9651
0,601	35,2549	31,3004	33,2786	35,2623	30,9812	32,9742
0,63	35,2786	31,3696	33,3495	35,2881	30,9819	32,9825
0,66	35,3028	31,4391	33,4201	35,3135	30,9826	32,9908
0,69	35,3274	31,5061	33,4869	35,3367	30,9830	32,9976
0,721	35,3521	31,5730	33,5525	35,3607	30,9837	33,0055
0,75	35,3744	31,6339	33,6115	35,3825	30,9844	33,0128
0,78	35,3975	31,6957	33,6710	35,4040	30,9852	33,0201
0,81	35,4183	31,7550	33,7266	35,4247	30,9860	33,0272
0,8401	35,4403	31,8139	33,7823	35,4453	30,9867	33,0342

Fonte: Autor, 2025.

5.3 Estimativas de parâmetros termofísicos com IA

A partir deste ponto, o valor mencionado como valor de referência corresponde aos dados encontrados na literatura. Após o processo de treinamento e otimização, o modelo final demonstrou ser capaz de prever a condutividade térmica da mama e do tumor dentro dos limites esperados, comprovando a eficácia da metodologia proposta. Para validação, foram realizados testes com quatro pacientes diagnosticadas com diferentes tipos de nódulos mamários,

incluindo lesões benignas e malignas, sendo os resultados comparados tanto aos valores de referência da literatura quanto aos dados experimentais descritos em Bezerra *et al.* (2020).

5.3.1 Paciente 01

Para a Paciente 01, os resultados obtidos para a mama esquerda, juntamente com o erro em relação aos valores de referência, estão apresentados na Tabela 6 e para a mama direita na Tabela 7.

Tabela 6 - Estimativa da condutividade térmica – Mama esquerda Paciente 01.

	Valor de Referência	Estimados	Erro (%)
k_{mama} (W/m°C)	0,48	0,573	16,24
k_{tumor} (W/m°C)	0,48	0,580	17,20

Fonte: Autor, 2025.

Tabela 7 - Estimativa da condutividade térmica – Mama direita Paciente 01.

	Valor de Referência	Estimados	Erro (%)
k_{mama} (W/m°C)	0,48	0,557	13,75
k_{tumor} (W/m°C)	0,48	0,589	18,51

Fonte: Autor, 2025.


A análise dos dados estimados para a Paciente 01 revela que o modelo foi capaz de prever os valores da condutividade térmica com erros relativos variando entre 13,75% e 18,51%. Observa-se que os valores estimados para a condutividade térmica da mama e do tumor são superiores aos valores de referência, apesar disso, os erros são considerados aceitáveis, dado o nível de complexidade do sistema e as simplificações adotadas.

5.3.2 Paciente 02

A Paciente 02, de 49 anos, foi diagnosticada por meio de exame clínico, ultrassonografia e mamografia, com um nódulo sólido na mama esquerda. O tumor está localizado no quadrante superior externo, medindo 1,7 x 0,8 cm, a uma profundidade de 1,6 cm da pele, a Figura 18

apresenta o termograma da paciente 02. A temperatura máxima registrada foi de 35,27 °C e a troca de calor por convecção entre a superfície da mama e o ambiente foi considerada a 27,4 °C.

Figura 18 - Termograma da Paciente 02 com a região do tumor em destaque.



Fonte: BEZERRA, 2013.

A Tabela 8 apresenta os valores de condutividade térmica estimados para a mama e para o tumor da Paciente 02. A Tabela 9 traz a comparação entre esses valores e os dados fornecidos por Bezerra *et al.* (2020).

Tabela 8 - Estimativas da condutividade térmica para a Paciente 02.

	Valor de Referência	Estimados	Erro (%)
k_{mama} (W/m°C)	0,48	0,545	11,86
k_{tumor} (W/m°C)	0,48	0,553	13,21

Fonte: Autor, 2025.

Tabela 9 - Comparação da condutividade térmica para a Paciente 02.

	Valor de Referência	Bezerra <i>et al.</i> (2020)	Estimados
k_{mama} (W/m°C)	0,48	0,467	0,545
k_{tumor} (W/m°C)	0,48	0,614	0,553


Fonte: Autor, 2025.

Os resultados da Paciente 02 seguem a tendência observada anteriormente, com estimativas acima dos valores de referência, com erros de 11,86% para a mama e 13,21% para o tumor. Nos dados apresentados por Bezerra *et al.* (2020), a condutividade térmica da mama está abaixo dos valores reportados na literatura, enquanto a condutividade do tumor apresentou um valor superior ao esperado. Em contrapartida, os valores estimados pela otimização estão todos acima dos encontrados na literatura. Esses desvios, embora presentes, ainda se mantêm dentro de limites aceitáveis para a metodologia empregada.

5.3.3 Paciente 03

A Paciente 03, com 54 anos, foi diagnosticada com carcinoma ductal invasivo na mama esquerda, por meio de exames clínicos, ultrassonografia, mamografia e biópsia. Foram identificados dois tumores malignos no quadrante superior da mama esquerda. O primeiro tumor mede 2,8 cm x 2,2 cm, localizado na posição correspondente às 2 horas, a uma profundidade de 0,6 cm da superfície da mama. O segundo tumor tem dimensões de 2,8 cm x 1,6 cm, também às 2 horas, localizado a 0,8 cm de profundidade, a Figura 19 mostra o termograma da paciente 03. A temperatura máxima registrada foi de 34,64°C e a troca de calor por convecção entre a superfície da mama e o ambiente a 28,0 °C.

Figura 19 - Termograma da Paciente 03 com a região do tumor em destaque.



Fonte: BEZERRA, 2013.

A seguir, são apresentadas as estimativas da condutividade térmica, Tabela 10, bem como a comparação com os dados de Bezerra *et al.* (2020), Tabela 11.

Tabela 10 - Estimativas da condutividade térmica para a Paciente 03.

	Valor de Referência	Estimados	Erro (%)
k_{mama} (W/m°C)	0,48	0,539	10,92
k_{tumor} (W/m°C)	0,48	0,507	5,33

Fonte: Autor, 2025.

Tabela 11 - Comparação da condutividade térmica para a paciente 03.

	Valor de Referência	Bezerra <i>et al.</i> (2020)	Estimados
k_{mama} (W/m°C)	0,480	0,422	0,539
k_{tumor} (W/m°C)	0,480	0,497	0,507


Fonte: Autor, 2025.

Para a Paciente 03, os erros relativos observados foram os menores entre todos os casos estudados, com destaque para o valor estimado da condutividade térmica do tumor, com erro de apenas 5,33%, isso sugere que o modelo foi particularmente eficaz neste caso. Nos dados apresentados por Bezerra *et al.* (2020), a condutividade térmica da mama foi inferior aos valores reportados na literatura, enquanto a do tumor mostrou-se superior às referências encontradas. Em comparação, os valores estimados através da otimização apresentaram-se consistentemente acima dos registrados na literatura para ambos os casos.

5.3.4 Paciente 04

A Paciente 04, de 27 anos, foi diagnosticada com fibroadenoma na mama esquerda por meio de exames clínicos, ultrassonografia, mamografia e biópsia. O nódulo está localizado no quadrante inferior externo da mama esquerda, com dimensões de 2,3 cm x 1,5 cm, posicionado às 4 horas e a uma profundidade de 0,9 cm da superfície da pele, a Figura 20 ilustra o termograma da paciente 04. A temperatura máxima registrada foi de 35,20°C e a transferência de calor por convecção entre a superfície da mama e o ambiente a 27,0 °C.

Figura 20 - Termograma da Paciente 04 com a região do nódulo em destaque.



Fonte: BEZERRA, 2013.

As Tabelas 12 e 13 apresentam, respectivamente, as estimativas da condutividade térmica e a comparação com os dados da literatura.

Tabela 12 - Estimativas da condutividade térmica para a Paciente 04.

	Valor de Referência	Estimados	Erro (%)
k_{mama} (W/m°C)	0,480	0,561	14,38
k_{tumor} (W/m°C)	0,480	0,565	15,00

Fonte: Autor, 2025.

Tabela 13 - Comparação da condutividade térmica para a paciente 04.

	Valor de Referência	Bezerra <i>et al.</i> (2020)	Estimados
k_{mama} (W/m°C)	0,480	0,483	0,561
k_{tumor} (W/m°C)	0,480	0,500	0,565

Fonte: Autor, 2025.

No caso da Paciente 04, observa-se que os valores estimados pelo modelo também superaram os valores de referência, apresentando erros em torno de 14% a 15%. A concordância entre os valores estimados e os dados de Bezerra *et al.* (2020) indica que o modelo tende a superestimar os parâmetros térmicos, mas ainda dentro de limites aceitáveis.

5.4 Discussão geral dos resultados

Os resultados obtidos para as quatro pacientes analisadas demonstram que o modelo proposto, baseado em inteligência artificial, é capaz de estimar parâmetros termofísicos com boa precisão, apresentando erros médios variando entre 5% e 18%. Esses valores são considerados satisfatórios para estudos iniciais e indicam que a metodologia aplicada possui potencial para aplicações clínicas e computacionais. As simulações numéricas, quando associadas às estimativas geradas pela inteligência artificial, mostraram coerência com os dados de referência disponíveis na literatura, ainda que apresentem certa margem de erro.

Observa-se uma tendência à superestimação dos valores estimados, o que pode estar relacionado ao ajuste dos parâmetros durante o processo de treinamento do modelo. Essa característica, no entanto, não compromete a utilidade da abordagem, pois os resultados permanecem dentro de limites aceitáveis. A comparação com os dados de Bezerra *et al.* (2020) reforça a validade da metodologia adotada e destaca a importância da calibração contínua dos modelos numéricos. Além disso, a metodologia utilizada para estimar a condutividade térmica mostrou-se consistente e adequada, ainda que dependa da ampliação do conjunto de dados para aprimoramento da performance do modelo.

6 CONCLUSÃO

O presente trabalho teve como principal objetivo desenvolver uma metodologia para a estimativa de propriedades termofísicas de tumores mamários, utilizando imagens termográficas combinadas com simulações numéricas e algoritmos de inteligência artificial, como redes neurais artificiais e otimização por enxame de partículas.

A partir da revisão da literatura, verificou-se que a termografia, uma técnica não invasiva e livre de radiação ionizante, mostra-se promissora como ferramenta complementar na detecção precoce do câncer de mama. A integração dessa técnica com modelos computacionais permitiu a simulação da distribuição de temperatura em mamas com presença de tumores, servindo como base para a estimativa de parâmetros térmicos relevantes.

As simulações numéricas, realizadas com o software ANSYS, possibilitaram a análise do comportamento térmico em diferentes casos clínicos. Os resultados mostraram-se compatíveis com os dados da literatura e com o comportamento esperado de tecidos com tumores. Além disso, foram coletados e pré-processados os dados necessários para o treino e validação de uma rede neural artificial, integrada a uma rotina computacional com o algoritmo PSO.

Com base nesses dados, o modelo de inteligência artificial foi capaz de estimar a condutividade térmica da mama e do tumor com erro relativo entre 5% e 18%, valores considerados satisfatórios para aplicações iniciais. Ainda que tenha sido observada uma tendência à superestimação dos parâmetros estimados, os resultados permaneceram dentro de limites aceitáveis, não comprometendo a aplicabilidade da metodologia.

A comparação dos resultados obtidos com os dados experimentais de Bezerra *et al.* (2020) e valores de referência da literatura reforça a validade da abordagem proposta, destacando que essa abordagem pode complementar os métodos tradicionais de diagnóstico, desde que adequadamente calibrada e ajustada a partir de uma base de dados mais abrangente.

A integração entre modelagem computacional, termografia e algoritmos de inteligência artificial mostrou-se promissora, fornecendo base para o aprimoramento de ferramentas diagnósticas mais precisas e acessíveis, com potencial de aplicação em ambientes clínicos e acadêmicos.

6.1 Perspectivas para trabalhos futuros

Com base nos resultados obtidos e nas limitações identificadas ao longo desta pesquisa, apresentam-se, a seguir, algumas direções que podem ser exploradas em trabalhos futuros:

- Ampliação da base de dados utilizada para treinamento e validação: Recomenda-se o uso de um conjunto mais extenso e diversificado de casos clínicos, incluindo diferentes faixas etárias, tipos de tecidos mamários, e distintas naturezas de tumores (benignos e malignos), a fim de aumentar a robustez do modelo proposto.
- Aprimoramento da metodologia de otimização: Sugere-se a exploração de outras técnicas de otimização, como algoritmos genéticos e métodos híbridos, visando a melhoria da acurácia das estimativas dos parâmetros termofísicos.

Essas perspectivas visam consolidar a proposta desenvolvida neste trabalho como uma ferramenta de apoio ao diagnóstico por imagem, com potencial de impacto positivo tanto na rotina clínica quanto na pesquisa científica voltada à prevenção e ao diagnóstico precoce do câncer de mama.

REFERÊNCIAS

- ACHARYA, U. R. et al. Thermography based breast cancer detection using texture features and Support Vector Machine. **Journal of medical systems**, v. 36, n. 3, p. 1503–1510, 2012.
- ALLUGUNTI, V. R. Breast cancer detection based on thermographic images using machine learning and deep learning algorithms. **International Journal of Engineering in Computer Science**, v. 4, n. 1, p. 49–56, 2022.
- ANSYS INC. **Skewness**. Disponível em: https://ansyshelp.ansys.com/public/account/secured?returnurl=/Views/Secured/corp/v251/en/wb_msh/msh_skewness.html>. Acesso em: 28 jun. 2025. Acesso restrito.
- BEZERRA, L. A. **Estimativa de parâmetros termofísicos da mama e de distúrbios mamários a partir de termografia por infravermelho utilizando técnicas de otimização**. Recife, PE: Universidade Federal de Pernambuco, 2013.
- BEZERRA, L. A. et al. An empirical correlation to estimate thermal properties of the breast and of the breast nodule using thermographic images and optimization techniques. **International journal of heat and mass transfer**, v. 149, n. 119215, p. 119215, 2020.
- BRANDÃO, B. C. **Otimização por enxame de partículas de rede neural artificial para previsão de pressão de falha em dutos corroídos**. Recife, Brazil: Universidade Federal de Pernambuco, 2023.
- BRATTON, D.; KENNEDY, J. **Defining a standard for particle swarm optimization**. 2007 IEEE Swarm Intelligence Symposium. **Anais...IEEE**, 2007.
- CATARINO, M. H. **Redes Neurais**. Rio de janeiro, RJ: Freitas Bastos Editora, 2025.
- CHARNY, C. K. Mathematical models of bioheat transfer. Em: **CHO, Y. I., ed. Advances in Heat Transfer: Bioengineering Heat Transfer**. Academic Press, 1992. p. v. 22, 19-155.
- CHEN, H. et al. Predicting the thermophysical properties of skin tumor based on the surface temperature and deep learning. **International journal of heat and mass transfer**, v. 180, n. 121804, p. 121804, 2021.

CIVILIBAL, S.; CEVIK, K. K.; BOZKURT, A. A deep learning approach for automatic detection, segmentation and classification of breast lesions from thermal images. **Expert systems with applications**, v. 212, n. 118774, p. 118774, 2023.

COLAÇO, M. J.; ORLANDE, H. R. B.; DULIKRAVICH, G. S. Inverse and optimization problems in heat transfer. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, v. 28, n. 1, p. 1–24, 2006.

DILLER, K. R. Modeling of bioheat transfer processes at high and low temperatures. Em: **CHO, Y. I., ed., Advances in Heat Transfer: Bioengineering Heat Transfer**. [s.l.] Academic Press, 1992. p. v. 22, 157-357.

DIN, N. M. U. et al. Breast cancer detection using deep learning: Datasets, methods, and challenges ahead. **Computers in biology and medicine**, v. 149, n. 106073, p. 106073, 2022.

FORTUNA, A. DE O. **Técnicas computacionais para dinâmica dos fluidos: conceitos básicos e aplicações**. São Paulo: Edusp, 2000.

GÜNAL, Ö.; AKPINAR, M. Solving the laminar boundary layer problem in heat transfer with heuristic optimization techniques. **Heliyon**, v. 9, n. 6, p. e16955, 2023.

HAO, H. et al. Forecasting the number of end-of-life vehicles using a hybrid model based on grey model and artificial neural network. **Journal of cleaner production**, v. 202, p. 684–696, 2018.

HAYKIN, S. O. **Redes neurais: princípios e prática**. 2. ed. Bookman Editora, 2001.

JIANG, L.; ZHAN, W.; LOEW, M. H. **A numerical study of the inverse problem of breast infrared thermography modeling**. (R. C. Molthen, J. B. Weaver, Eds.) Medical Imaging 2010: Biomedical Applications in Molecular, Structural, and Functional Imaging. **Anais...SPIE**, 2010.

KENNEDY, J.; EBERHART, R. **Particle swarm optimization**. Proceedings of ICNN'95 - International Conference on Neural Networks. **Anais...IEEE**, 2002.

KIM, S. K. et al. Inverse estimation of thermophysical properties for anisotropic composite. **Experimental thermal and fluid science**, v. 27, n. 6, p. 697–704, 2003.

LI, G. et al. A particle swarm optimization improved BP neural network intelligent model for electrocardiogram classification. **BMC medical informatics and decision making**, v. 21, n. Suppl 2, p. 99, 2021.

LINS, I. D. et al. A particle swarm-optimized support vector machine for reliability prediction. **Quality and reliability engineering international**, v. 28, n. 2, p. 141–158, 2012.

LU, D.; WANG, C. Three-dimensional temperature field inversion calculation based on an artificial intelligence algorithm. **Applied thermal engineering**, v. 225, n. 120237, p. 120237, 2023.

MACHADO, M. A. Q. **Otimização da adsorção de gás natural em tanque de combustível veicular através de redes neurais artificiais e carbonos ativados**. Fortaleza, Ceará: Universidade Federal do Ceará, 2025.

MALISKA, C. R. **Transferência de Calor e Mecânica dos Fluidos Computacional**. Rio de janeiro: Ed. LTC, 1995.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115–133, 1943.

MELO, J. R. F. DE. **Metodologia para desenvolvimento de geometria tridimensional de mama e seu uso na estimativa de parâmetros termofísicos usando imagens termográficas**. Recife, PE: Universidade Federal de Pernambuco, 2019.

MITAL, M.; PIDAPARTI, R. M. Breast tumor simulation and parameters estimation using evolutionary algorithms. **Modelling and Simulation in Engineering**, v. 2008, n. 1, p. 1–6, 2008.

MITRA, S.; BALAJI, C. A neural network based estimation of tumour parameters from a breast thermogram. **International journal of heat and mass transfer**, v. 53, n. 21–22, p. 4714–4727, 2010.

NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. Em: **Proceedings of the 27th international conference on machine learning (ICML-10)**. p. 807–814.

NG, E. Y. K.; KEE, E. C. Advanced integrated technique in breast cancer thermography. **Journal of medical engineering & technology**, v. 32, n. 2, p. 103–114, 2008.

NG, E. Y.; SUDHARSAN, N. M. Effect of blood flow, tumour and cold stress in a female breast: a novel time-accurate computer simulation. **Proceedings of the Institution of Mechanical Engineers. Part H, Journal of engineering in medicine**, v. 215, n. 4, p. 393–404, 2001.

NG, E. Y.-K.; SUDHARSAN, N. M. Computer simulation in conjunction with medical thermography as an adjunct tool for early detection of breast cancer. **BMC cancer**, v. 4, n. 1, p. 17, 2004.

ÖZISIK, M. N.; ORLANDE, H. R. B. **Inverse heat transfer: Fundamentals and applications**. Boca Raton, FL, USA: CRC Press, 2000.

PRAMANIK, R.; PRAMANIK, P.; SARKAR, R. Breast cancer detection in thermograms using a hybrid of GA and GWO based deep feature selection method. **Expert systems with applications**, v. 219, n. 119643, p. 119643, 2023.

RAUBER, T. W. **Redes neurais artificiais**. Vitória: Universidade Federal do Espírito Santo, 2005.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386–408, 1958.

SANTOS, L. G. B. DOS. **Análise de confiabilidade de dutos submarinos corroídos utilizando redes neurais**. Recife, PE: Universidade Federal de Pernambuco, 2024.

SANTOS, L. C. et al. Development os a computacional tool for parametric analysis influences in position and size of breast tumor in temperature profiles. **Annals of IX Congresso Iberoamericano of Ingeniería Mecânica.**, n. Islas Canarias, Spain, 2009.

SENGUPTA, S.; BASAK, S.; PETERS, R. A. Particle Swarm Optimization: A survey of historical and recent developments with hybridization perspectives. **Machine learning and knowledge extraction**, v. 1, n. 1, p. 157–191, 2018.

SILVA, S. M. DA. **Otimização de hiperparâmetro de uma rede neural artificial por GRASP reativo para previsão de falha em dutos corroídos**. Recife, PE: Universidade Federal de Pernambuco, 2024.

SILVA NETO, A. J.; MOURA NETO, F. D. **Problemas inversos: conceitos fundamentais e aplicações**. Rio de janeiro: Ed. UERJ, 2005.

TORRES-GALVÁN, J. C. et al. Deep convolutional neural networks for classifying breast cancer using infrared thermography. **Quantitative infra red thermography journal**, v. 19, n. 4, p. 283–294, 2022.

VIANA, M. J. A. **Simulação do perfil de temperatura na mama através de geometria substituta obtida a partir de prótese mamária externa**. Recife, PE: Universidade Federal de Pernambuco, 2010.

VIANA, M. J. A. **Reconstrução tridimensional da mama feminina a partir de imagens médicas por infravermelho com auxílio de geometrias substitutas**. Recife, PE: Universidade Federal de Pernambuco, 2016.

WISSLER, E. H. Pennes' 1948 paper revisited. **Journal of applied physiology (Bethesda, Md.: 1985)**, v. 85, n. 1, p. 35–41, 1998.

ZACCARA CUNHA ARAÚJO, I. M. et al. TERAPIAS DIANA Y BIOMARCADORES EN EL CÁNCER DE MAMA: REVISIÓN BIBLIOGRÁFICA. **RECIMA21 - Revista Científica Multidisciplinar - ISSN 2675-6218**, v. 5, n. 5, p. e555293, 2024.

ZHANG, Y. Application of improved BP neural network based on e-commerce supply chain network data in the forecast of aquatic product export volume. **Cognitive systems research**, v. 57, p. 228–235, 2019.

ZHU, F. et al. A deep learning method for estimating thermal boundary condition parameters in transient inverse heat transfer problem. **International journal of heat and mass transfer**, v. 194, n. 123089, p. 123089, 2022.

APÊNDICE A - ROTINA COMPUTACIONAL: PSO+RNA

No presente apêndice, apresenta-se a rotina computacional desenvolvida em Python, integrando PSO e RNA para estimativa dos parâmetros termofísicos.

```
import numpy as np
import pandas as pd
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Input
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler, LabelEncoder
from sklearn.metrics import mean_squared_error
from pyswarm import pso

# Carregamento dos dados
df = pd.read_csv('.csv')

# Filtro para os dados da 'Mama' e 'Tumor' com base na coluna 'Propriedade' do
arquivo .csv
df_mama = df[df['Propriedade'].str.contains('Mama', case=False)]
df_tumor = df[df['Propriedade'].str.contains('Tumor', case=False)]

# Separando as entradas (X) e saídas (Y) para Mama e Tumor
X_mama = df_mama[['TMAX', 'TMIN', 'TMED']].values
Y_mama = df_mama['Propriedade'].values

X_tumor = df_tumor[['TMAX', 'TMIN', 'TMED']].values
Y_tumor = df_tumor['Propriedade'].values

# Codificar a coluna de saída (Propriedade)
label_encoder = LabelEncoder()
Y_mama_encoded = label_encoder.fit_transform(Y_mama)
Y_tumor_encoded = label_encoder.fit_transform(Y_tumor)

# Dividindo os dados em treino e teste para Mama
X_train_mama, X_test_mama, Y_train_mama, Y_test_mama = train_test_split(
    X_mama, Y_mama_encoded, test_size=0.2, random_state=42)

# Dividindo os dados em treino e teste para Tumor
X_train_tumor, X_test_tumor, Y_train_tumor, Y_test_tumor = train_test_split(
    X_tumor, Y_tumor_encoded, test_size=0.2, random_state=42)

# Normalizando os dados de entrada para Mama e Tumor
scaler_X_mama = MinMaxScaler()
X_train_mama = scaler_X_mama.fit_transform(X_train_mama)
X_test_mama = scaler_X_mama.transform(X_test_mama)
```

```

scaler_X_tumor = MinMaxScaler()
X_train_tumor = scaler_X_tumor.fit_transform(X_train_tumor)
X_test_tumor = scaler_X_tumor.transform(X_test_tumor)

# Normalizando os dados de saída (Y) para o intervalo [0, 1] usando MinMaxScaler
scaler_Y_mama = MinMaxScaler(feature_range=(0, 1))
Y_train_mama = scaler_Y_mama.fit_transform(Y_train_mama.reshape(-1, 1))
Y_test_mama = scaler_Y_mama.transform(Y_test_mama.reshape(-1, 1))

scaler_Y_tumor = MinMaxScaler(feature_range=(0, 1))
Y_train_tumor = scaler_Y_tumor.fit_transform(Y_train_tumor.reshape(-1, 1))
Y_test_tumor = scaler_Y_tumor.transform(Y_test_tumor.reshape(-1, 1))

# Função para criar o modelo RNA
def create_model(num_neurons):
    model = Sequential()
    model.add(Input(shape=(X_train_mama.shape[1],)))
    model.add(Dense(num_neurons, activation='relu'))
    model.add(Dense(num_neurons // 2, activation='relu'))
    model.add(Dense(1, activation='sigmoid')) # Saída com ativação sigmoid
    model.compile(optimizer='adam', loss='mse')
    return model

# Função de avaliação para o PSO
def pso_evaluate(params):
    num_neurons = int(params[0])
    model = create_model(num_neurons)

    # Treinamento do modelo
    model.fit(X_train_mama, Y_train_mama, epochs=100, batch_size=10, verbose=0)

    # Avaliação do modelo
    predictions = model.predict(X_test_mama)
    # Reescalando as previsões para o intervalo [0.24, 0.72]
    predictions_rescaled = 0.24 + (0.72 - 0.24) * predictions
    mse = mean_squared_error(Y_test_mama, predictions_rescaled)
    return mse

# Definir limites para os parâmetros (número de neurônios)
lb = [5] # Limite inferior
ub = [100] # Limite superior

# Otimização por PSO para Mama
print("Iniciando a otimização por PSO para Mama")
optimal_params_mama, optimal_loss_mama = pso(pso_evaluate, lb, ub, swarmsize=10,
maxiter=20)
print(f'Otimização concluída! Parâmetros ótimos para Mama: {optimal_params_mama}')

# Treinando o modelo final para Mama com os melhores parâmetros

```

```

print("Treinando o modelo final para Mama com os melhores parâmetros")
final_model_mama = create_model(int(optimal_params_mama[0]))
final_model_mama.fit(X_train_mama, Y_train_mama, epochs=100, batch_size=10,
verbose=1)

# Avaliando o desempenho final para Mama
print("Modelo treinado para Mama! Avaliando o desempenho final")
final_predictions_mama = final_model_mama.predict(X_test_mama)
final_predictions_rescaled_mama = 0.24 + (0.72 - 0.24) * final_predictions_mama #
Reescalando as previsões
Y_test_rescaled_mama = scaler_Y_mama.inverse_transform(Y_test_mama) # Reverter
normalização dos dados reais
final_mse_mama = mean_squared_error(Y_test_rescaled_mama,
final_predictions_rescaled_mama)
print(f'MSE final para Mama: {final_mse_mama}')

# Função para fazer previsões em novos dados
def fazer_predicoes(model, scaler_X, novos_dados):
    # Normalizando os novos dados de entrada
    novos_dados_normalizados = scaler_X.transform(novos_dados)

    # Fazendo previsões com o modelo treinado
    predicoes = model.predict(novos_dados_normalizados)

    # Reescalando as previsões para o intervalo [0.24, 0.72]
    predicoes_rescaled = 0.24 + (0.72 - 0.24) * predicoes

    return predicoes_rescaled

# Para o Tumor
def pso_evaluate_tumor(params):
    num_neurons = int(params[0])
    model = create_model(num_neurons)

    # Treinamento do modelo
    model.fit(X_train_tumor, Y_train_tumor, epochs=100, batch_size=10, verbose=0)

    # Avaliação do modelo
    predictions = model.predict(X_test_tumor)
    predictions_rescaled = 0.24 + (0.72 - 0.24) * predictions
    mse = mean_squared_error(Y_test_tumor, predictions_rescaled)
    return mse

# Otimização por PSO para Tumor
print("Iniciando a otimização por PSO para Tumor ")
optimal_params_tumor, optimal_loss_tumor = pso(pso_evaluate_tumor, lb, ub,
swarmsize=10, maxiter=20)
print(f'Otimização concluída! Parâmetros ótimos para Tumor:
{optimal_params_tumor}')

```

```

# Treinando o modelo final para Tumor
print("Treinando o modelo final para Tumor com os melhores parâmetros")
final_model_tumor = create_model(int(optimal_params_tumor[0]))
final_model_tumor.fit(X_train_tumor, Y_train_tumor, epochs=100, batch_size=10,
verbose=1)

# Avaliando o desempenho final para Tumor
print("Modelo treinado para Tumor! Avaliando o desempenho final")
final_predictions_tumor = final_model_tumor.predict(X_test_tumor)
final_predictions_rescaled_tumor = 0.24 + (0.72 - 0.24) * final_predictions_tumor
Y_test_rescaled_tumor = scaler_Y_tumor.inverse_transform(Y_test_tumor)
final_mse_tumor = mean_squared_error(Y_test_rescaled_tumor,
final_predictions_rescaled_tumor)
print(f'MSE final para Tumor: {final_mse_tumor}')

# Fazendo previsões para novos dados de Mama e Tumor
novos_dados_mama = np.array([[ , ]])
novos_dados_tumor = np.array([[ , ]])

predicoes_mama = fazer_predicoes(final_model_mama, scaler_X_mama,
novos_dados_mama)
predicoes_tumor = fazer_predicoes(final_model_tumor, scaler_X_tumor,
novos_dados_tumor)

print(f'Valores estimados da condutividade para Mama:\n{predicoes_mama}')
print(f'Valores estimados da condutividade para Tumor:\n{predicoes_tumor}')

```

ANEXO A – PLANILHA ELETRÔNICA COM O BANCO DE DADOS DAS SIMULAÇÕES TÉRMICAS

A planilha eletrônica que contém os dados do banco de dados utilizados como entrada no código computacional deste trabalho está disponível para consulta pública no seguinte endereço eletrônico:

<https://docs.google.com/spreadsheets/d/1pyDLbjTA6mLTbAoQgxzKaEfHb9Q8MRTe/edit?usp=sharing&ouid=117055318246812965479&rtpof=true&sd=true>.

Ou, alternativamente, pode-se acessar a planilha escaneando o QR Code abaixo:

Figura 21 - QR Code para acesso direto à planilha eletrônica dos dados.



Fonte: Autor, 2025.