

Segmentação de Região Auricular em Imagens Termográficas para Aplicações Médicas em Cardiologia

Gabriella Pompeu Domingos Nunes¹, Elaine F. Rangel Seixas¹, Flávio Luiz Seixas¹,
Leonardo de Souza Moreira Alves², Claudio Tinoco Mesquita²

¹ Instituto de Computação – Universidade Federal Fluminense (UFF)
Niterói – RJ – Brasil

² Faculdade de Medicina – Universidade Federal Fluminense (UFF)
Niterói – RJ – Brasil

gpdnunes@id.uff.br, {elaine.seixas,fseixas}@midia.com.uff.br,
{alves_leonardo,claudiotinocomesquita}@id.uff.br

Abstract. *Infrared thermography is a promising non-invasive technique for analyzing microvascular perfusion, with potential applications in identifying coronary artery disease (CAD). However, its analysis still relies on manual and subjective processes. This work proposes a deep learning-based method for the automatic segmentation of the auricular region in thermographic images, enabling standardized thermal feature extraction. The approach uses a U-Net architecture and is evaluated using IoU, Dice, and accuracy metrics. Results show high accuracy (96.24%), with moderate IoU (0.3750) and Dice (0.5258), indicating limitations in boundary precision. Nevertheless, extracted thermal features showed low variability across samples.*

Resumo. *A termografia infravermelha é uma técnica promissora para análise não invasiva da perfusão microvascular, com potencial aplicação na identificação da doença arterial coronariana (DAC), mas que ainda depende de processos manuais e subjetivos para sua análise. Este trabalho propõe um método baseado em aprendizado profundo para segmentação automática do pavilhão auricular em imagens termográficas, permitindo a extração padronizada de características térmicas. A abordagem utiliza a arquitetura U-Net e é avaliada com as métricas IoU, Dice e acurácia. Os resultados indicam alta acurácia (96,24%), com valores moderados de IoU (0,3750) e Dice (0,5258), refletindo limitações na precisão das bordas. Ainda assim, as medidas térmicas extraídas apresentaram baixa variabilidade entre as amostras.*

1. Introdução

As doenças cardiovasculares continuam sendo a principal causa de mortalidade global, o que exige o desenvolvimento de métodos diagnósticos mais acessíveis e não invasivos [World Health Organization 2021]. A doença arterial coronariana (DAC) apresenta elevada relevância epidemiológica, sendo reconhecida como uma das principais manifestações das doenças cardiovasculares, que permanecem entre as principais causas de mortalidade no mundo. Além disso, a DAC frequentemente é identificada tardiamente [Ferreira and Machado 2025, Banerjee et al. 2019, Groenewegen et al. 2024].

Nesse contexto, a termografia infravermelha surge como uma alternativa promissora, permitindo a análise da perfusão cutânea sem contato físico [Ring and Ammer 2012]. Evidências recentes sugerem que padrões térmicos faciais podem conter informações relevantes para a identificação de doença arterial coronariana, enquanto estudos fisiológicos indicam que a temperatura do pavilhão auricular é influenciada pela perfusão local e pela regulação vasomotora autonômica [Kung et al. 2024, Tang and Sato 2025, Yli-Harja et al. 2025]. Em conjunto, esses achados apontam que a região auricular pode constituir uma área de interesse para investigações futuras sobre alterações microvasculares associadas à DAC.

Apesar do potencial clínico, a análise dessas imagens ainda é predominantemente manual, o que limita sua escalabilidade e reprodutibilidade. Técnicas de inteligência artificial, especialmente redes neurais convolucionais, oferecem uma solução para automatizar esse processo [Ronneberger et al. 2015].

O objetivo deste trabalho é desenvolver e avaliar um modelo de segmentação automática da região de interesse em imagens termográficas auriculares. A metodologia envolve a construção de um pipeline baseado em U-Net, o treinamento supervisionado com máscaras anotadas manualmente e a avaliação quantitativa por meio de métricas de sobreposição.

O restante do artigo está organizado da seguinte forma: a Seção II apresenta trabalhos relacionados, a Seção III descreve a metodologia experimental, a Seção IV apresenta os resultados e discussão, e a Seção V apresenta conclusões e trabalhos futuros.

2. Trabalhos Relacionados

2.1. Termografia Infravermelha em Aplicações Médicas

A termografia infravermelha é uma técnica não invasiva e sem contato que permite mapear a distribuição térmica da superfície corporal por meio da radiação infravermelha emitida pela pele, fornecendo indiretamente informações sobre processos fisiológicos subjacentes, como alterações de perfusão sanguínea, inflamação e atividade metabólica [Lahiri et al. 2012, Fernández-Cuevas et al. 2015]. Sua aplicação na medicina tem sido amplamente investigada em diferentes contextos, incluindo a oncologia, especialmente em estudos voltados ao apoio à detecção precoce de câncer de mama, a neurologia, para avaliação de alterações autonômicas, e a reumatologia, para análise de processos inflamatórios articulares e acompanhamento de doenças reumáticas [Mashekova et al. 2022, Motta et al. 2010, Shimizu et al. 2023, Branco et al. 2022, Loarce-Martos et al. 2019].

2.2. Termografia e Doenças Cardiovasculares

No contexto das doenças cardiovasculares, a termografia tem sido explorada como ferramenta auxiliar na avaliação da perfusão periférica e das disfunções microvasculares [Ring and Ammer 2012]. A literatura sugere que alterações térmicas cutâneas podem refletir mudanças fisiológicas relacionadas à perfusão, ao equilíbrio hemodinâmico e à regulação autonômica. Estudos recentes demonstram que a temperatura cutânea também pode refletir alterações perfusionais e hemodinâmicas em outras condições cardiovasculares, como insuficiência cardíaca aguda descompensada [Atamañuk et al. 2025], bem como em doenças vasculares periféricas

[Huang et al. 2011]. Além disso, trabalhos na literatura de computação aplicada mostram que a temperatura facial e cutânea é influenciada pela atividade do sistema nervoso autônomo, reforçando que distribuições térmicas podem carregar informação fisiológica relevante além da dimensão puramente vascular [Shimizu et al. 2023]. Em conjunto, esses achados sustentam o uso da termografia como ferramenta complementar para investigar alterações hemodinâmicas e autonômicas associadas a condições cardiovasculares, incluindo a DAC, ainda que a integração direta desses fatores em um único modelo clínico permaneça pouco explorada.

Particularmente, o pavilhão auricular pode ser considerado uma região de interesse fisiológico devido à sua vascularização superficial e ao potencial de refletir alterações na perfusão cutânea. Embora a literatura ainda seja escassa quanto à demonstração direta de correlações entre assimetrias térmicas auriculares e a presença de DAC, estudos prévios em cardiologia mostram que padrões térmicos corporais e faciais podem estar associados a alterações cardiovasculares clinicamente relevantes. Kung *et al.* (2024) demonstraram a viabilidade do uso de informações térmicas faciais obtidas por termografia infravermelha sem contato, combinadas com aprendizado de máquina, para predição de DAC. Além disso, Huang *et al.* (2011) mostraram que a termografia pode detectar alterações térmicas associadas à perfusão em pacientes de alto risco de doença arterial periférica. Em conjunto, esses achados não comprovam ainda uma associação específica entre temperatura auricular e DAC, mas sustentam a investigação do pavilhão auricular como uma região anatômica promissora para estudos futuros sobre biomarcadores térmicos relacionados à perfusão periférica e à doença cardiovascular.

Além disso, o chamado sinal de Frank, uma prega diagonal no lóbulo da orelha, tem sido associado a alterações ateroscleróticas sistêmicas, reforçando a relevância clínica da região auricular como biomarcador periférico [Gakovic et al. 2023]. A integração entre análises morfológicas e térmicas pode, portanto, fornecer informações complementares para a triagem cardiovascular.

2.3. Segmentação de Imagens Médicas com Deep Learning

A segmentação de imagens médicas é uma etapa fundamental em pipelines de análise computacional, permitindo a identificação automática de regiões de interesse para posterior extração de características. Nesse contexto, redes neurais convolucionais (CNNs) têm se destacado como a abordagem dominante nos últimos anos.

A arquitetura U-Net, proposta por Ronneberger *et al.* (2015), tornou-se um padrão de referência na segmentação biomédica devido à sua capacidade de capturar informações contextuais e preservar detalhes espaciais por meio de conexões de skip. Extensões da U-Net, como o Attention U-Net e o U-Net++, foram propostas para melhorar a precisão da segmentação por meio de mecanismos de atenção e estratégias de fusão multiescala mais flexíveis [Ronneberger et al. 2015, Zhou et al. 2019]. Essas modificações têm se mostrado particularmente úteis em tarefas de segmentação médica, nas quais baixo contraste, bordas pouco definidas e grande variabilidade morfológica tornam a delimitação das estruturas mais desafiadora [Garcea et al. 2023]. Além disso, estratégias como data augmentation e mecanismos de balanceamento de classes são frequentemente empregadas para lidar com conjuntos de dados limitados e desbalanceados, uma situação recorrente em aplicações médicas [Tajbakhsh et al. 2020].

2.4. Segmentação em Imagens Termográficas

A segmentação de imagens térmicas apresenta desafios adicionais em comparação com imagens convencionais no espectro visível. Estudos mostram que imagens infravermelhas tendem a apresentar menor contraste, menos textura, bordas mais borradas e menor resolução de detalhes, o que dificulta a delimitação precisa de estruturas anatômicas [Meng et al. 2025]. Além disso, a termografia é influenciada por um conjunto amplo de fatores ambientais, individuais e técnicos, o que pode introduzir variabilidade adicional na temperatura registrada e comprometer a padronização da aquisição [Fernández-Cuevas et al. 2015]. Em aplicações médicas, essas características tornam a identificação automática de regiões de interesse particularmente desafiadora, exigindo estratégias de processamento e segmentação capazes de lidar com baixo contraste estrutural e com a sensibilidade da imagem térmica às condições de aquisição.

2.5. Lacuna Científica

Apesar do potencial da termografia e dos avanços em aprendizado profundo, observa-se uma lacuna significativa na literatura na interseção entre análise termográfica auricular, segmentação automática com deep learning e aplicação em diagnóstico cardiovascular. Em particular, há uma ausência de estudos que integrem a segmentação automática da orelha à extração de métricas térmicas quantitativas voltadas à avaliação clínica. Este trabalho busca contribuir para preencher essa lacuna ao propor uma abordagem baseada em U-Net para a segmentação da região auricular em imagens térmicas, estabelecendo uma base para análises futuras mais avançadas, como a modelagem de biomarcadores térmicos associados a condições cardiovasculares e metabólicas.

3. Metodologia Experimental

Esta seção descreve o pipeline proposto para segmentação automática da região de interesse (ROI) em imagens termográficas do pavilhão auricular. O método foi estruturado como um fluxo sequencial de etapas, desde a aquisição e anotação dos dados até a extração de características térmicas. A Figura 1 apresenta uma visão geral do pipeline desenvolvido, destacando as principais etapas do processo.

Após o treinamento da U-Net, a sequência de segmentação do pavilhão auricular passa pela seguinte sequência de processamento:

- A) Entrada da imagem termográfica;
- B) Pré-processamento e normalização;
- C) Segmentação via U-Net;
- D) Geração da máscara da ROI;
- E) Extração de pixels pertencentes à ROI;
- F) Cálculo de estatísticas térmicas (média, mínima e máxima).

3.1. Base de Dados e Anotação

O conjunto de dados é composto por pares (x_i, y_i) , onde x_i representa uma imagem térmica e $y_i \in \{0, 1\}^{H \times W}$ a máscara correspondente, com H indicando a altura e W a largura da imagem em pixels. Foram utilizadas 86 imagens térmicas, divididas em 73 imagens para treinamento e 13 imagens para teste e validação. As imagens foram capturadas pelos autores, com utilização de câmera FLIR, em consultório, sendo uma




Figura 1. Pipeline completo do sistema proposto para segmentação da região auricular em imagens termográficas e extração de características térmicas.

imagem da lateral esquerda da face e outra da lateral direita da face, totalizando 43 pacientes participantes da pesquisa, registrada em projeto submetido ao Comitê de Ética em Pesquisa (CEP) sob o número CAAE: 34008920.7.0000.5289.

As anotações foram realizadas manualmente com a ferramenta *LabelMe*, sendo posteriormente convertidas do formato JSON em máscaras binárias. O conjunto foi dividido em subconjuntos de treinamento e teste, garantindo independência estatística entre os dados.

3.2. Pré-processamento

As imagens foram submetidas às seguintes transformações:

- Redimensionamento para dimensões fixas (H, W), sendo H a altura e W a largura da imagem em pixels;
- Normalização para o intervalo $[0, 1]$:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

em que x é o valor original do pixel, x' é o valor normalizado, e $x_{\min}$ e $x_{\max}$ correspondem, respectivamente, aos valores mínimo e máximo dos pixels da imagem;

- Interpolação bilinear para imagens e *nearest neighbor* para máscaras;
- Conversão para tensores.

Adicionalmente, técnicas de *data augmentation* foram aplicadas, incluindo rotações, flips horizontais e variações de intensidade, com o objetivo de aumentar a robustez do modelo.

3.3. Arquitetura do Modelo

Foi utilizada a arquitetura U-Net [Ronneberger et al. 2015], composta por um *encoder* e um *decoder* simétricos. O *encoder* realiza a extração hierárquica de características por meio de operações convolucionais:

$$h_l = \sigma(W_l * h_{l-1} + b_l) \quad (2)$$

em que l indica o índice da camada da rede neural; h_l é a saída, ou mapa de características, da camada l ; h_{l-1} representa a saída da camada anterior; W_l denota os pesos, ou filtros convolucionais, aprendidos na camada l ; b_l representa o viés; $*$ indica a operação de convolução; e σ corresponde à função de ativação ReLU, responsável por introduzir não linearidade ao modelo.

O *decoder* reconstrói a segmentação utilizando operações de *upsampling* e conexões de atalho (*skip connections*):

$$\hat{y} = f_\theta(x) \quad (3)$$

em que x representa a imagem térmica de entrada; f_θ é a função aprendida pelo modelo de segmentação; θ denota o conjunto de parâmetros treináveis da rede neural, incluindo pesos e vieses; e $\hat{y}$ corresponde à máscara binária estimada pelo modelo para a região de interesse.

Essas conexões permitem preservar detalhes espaciais relevantes para uma segmentação precisa.

3.4. Função de Perda

A função de perda utilizada foi a *Binary Cross-Entropy* com *logits*:

$$\mathcal{L}_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (4)$$

em que $\mathcal{L}_{BCE}$ representa o valor da função de perda; N corresponde ao número total de pixels avaliados; i indica o índice de cada pixel; $y_i \in \{0, 1\}$ representa o valor real da máscara no pixel i ; $\hat{y}_i$ representa a probabilidade predita para o pixel i após a aplicação da função sigmoide; e $\log$ denota o logaritmo natural.

3.5. Treinamento

O treinamento foi realizado utilizando o otimizador *Adam*, com atualização iterativa dos parâmetros:

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} \mathcal{L} \quad (5)$$

em que t indica a iteração do treinamento; θ_t representa os parâmetros do modelo na iteração atual; θ_{t+1} corresponde aos parâmetros após a atualização; η é a taxa de aprendizado; $\mathcal{L}$ representa a função de perda; e $\nabla_{\theta} \mathcal{L}$ indica a direção de maior variação da perda em relação aos parâmetros do modelo, sendo usada para ajustar os pesos de forma a reduzir o erro de predição.

Os principais hiperparâmetros utilizados foram:

- *Learningrate* (controla a magnitude das atualizações dos parâmetros): 1×10^{-4} ;
- *Batchsize* (número de imagens processadas antes de cada atualização): 16;
- Número de épocas (quantas vezes o modelo percorre todo o conjunto de treinamento): 40;
- Otimizador (método de otimização adaptativo baseado nos gradientes da função de perda): Adam.

O treinamento foi conduzido em um ambiente com suporte a GPU, o que resultou em maior eficiência computacional.

3.6. Métricas de Avaliação

O desempenho do modelo foi avaliado utilizando três métricas principais:

3.6.1. Intersection over Union (IoU)

A métrica *Intersection over Union* (IoU) mede a sobreposição entre a máscara predita e a real. Ela é definida como a razão entre a área comum às duas máscaras e a área total coberta por ambas:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (6)$$

em que A representa a máscara predita, B a máscara real, $A \cap B$ a região corretamente sobreposta entre elas, e $A \cup B$ a união das regiões marcadas em ambas as máscaras. Valores próximos de 1 indicam maior concordância entre a predição e a referência.

3.6.2. Dice Coefficient

O coeficiente Dice avalia a similaridade entre a máscara predita e a máscara real, considerando a proporção de sobreposição entre ambas:

$$Dice = \frac{2|A \cap B|}{|A| + |B|} \quad (7)$$

em que A representa a máscara predita, B a máscara real, $A \cap B$ a região de sobreposição entre elas, e $|A|$ e $|B|$ correspondem ao número de pixels positivos em cada máscara. O valor varia de 0 a 1, sendo 1 a correspondência perfeita entre a predição e a referência.

3.6.3. Acurácia

A acurácia mede a proporção de pixels corretamente classificados pelo modelo em relação ao total de pixels avaliados. Em tarefas de segmentação binária, ela considera tanto os pixels corretamente identificados como região de interesse quanto os corretamente identificados como fundo.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

em que *TP* (*True Positives*) representa os pixels da região de interesse corretamente classificados pelo modelo; *TN* (*True Negatives*) representa os pixels de fundo corretamente classificados; *FP* (*False Positives*) representa os pixels de fundo incorretamente classificados como região de interesse; e *FN* (*False Negatives*) representa os pixels da região de interesse incorretamente classificados como fundo.

Essas métricas permitem avaliar tanto a qualidade da sobreposição quanto o desempenho global do modelo.

3.7. Implementação

A implementação foi realizada em Python, utilizando bibliotecas amplamente adotadas:

- PyTorch/TensorFlow para aprendizado profundo;
- NumPy para operações numéricas;
- OpenCV para processamento de imagens;
- Matplotlib para visualização.

O código foi estruturado de forma modular, o que permite a reprodutibilidade e a extensão futura do pipeline.

4. Resultados e Discussão

4.1. Resultados Quantitativos

A Tabela 1 apresenta os resultados médios e os desvios-padrão das métricas de avaliação da segmentação, bem como as estatísticas térmicas extraídas da região de interesse (ROI).

Tabela 1. Resultados médios ($\pm$ desvio padrão) das métricas de segmentação

Métrica	Média	Desvio Padrão
IoU	0,3750	0,1538
Dice	0,5258	0,1765
Accuracy	0,9624	0,0130
Temp Mean (°C)	30,8861	0,9460
Temp Min (°C)	27,8358	1,0411
Temp Max (°C)	35,6324	0,9990

Observa-se que a acurácia global foi elevada (96,24%), enquanto as métricas de sobreposição (IoU e Dice) apresentaram valores moderados. Nesse contexto, as métricas de sobreposição são mais informativas para avaliar a qualidade da segmentação. O valor de IoU obtido (0,3750) indica uma sobreposição fraca entre a máscara predita e a de referência, enquanto o Dice também evidencia um desempenho moderado. Esse resultado sugere que, embora grande parte da imagem seja corretamente classificada como fundo, a delimitação da ROI auricular ainda apresenta limitações relevantes, o que pode comprometer a extração de pixels puramente auriculares e, consequentemente, a confiabilidade das análises térmicas subsequentes.




Figura 2. Comparação qualitativa entre a máscara real (à esquerda), a máscara predita (no centro) e a sobreposição na imagem original (à direita).

4.2. Resultados Qualitativos da Segmentação

A Figura 2 apresenta um exemplo qualitativo da segmentação. São mostradas: (a) a máscara de referência (anotação manual), (b) a máscara predita pelo modelo U-Net e (c) a sobreposição da máscara predita sobre a imagem termográfica original.

Visualmente, o modelo captou a estrutura geral do pavilhão auricular, preservando sua forma característica. No entanto, observa-se imprecisão nas bordas, especialmente em regiões de menor contraste térmico, o que resulta em falsos positivos e falsos negativos.

4.3. Análise das Características Térmicas

A Figura 3 apresenta a variação das temperaturas média, mínima e máxima extraídas da ROI ao longo das imagens do conjunto de teste.




Figura 3. Variação das temperaturas média, mínima e máxima extraídas da ROI em cada imagem do conjunto de teste.

A temperatura média apresentou baixa variabilidade (desvio padrão $\approx 0,95^{\circ}\text{C}$), indicando consistência térmica entre as amostras. Em contrapartida, as temperaturas mínima e máxima apresentaram maior dispersão, refletindo heterogeneidade térmica local e possíveis variações na perfusão microvascular.

4.4. Discussão dos Resultados

Os resultados indicam que a arquitetura U-Net é capaz de segmentar automaticamente a região auricular em imagens termográficas, com desempenho satisfatório. A discrepância entre a alta acurácia e os valores mais baixos de IoU e Dice reforça a importância de utilizar métricas de sobreposição em problemas desbalanceados.

A análise qualitativa demonstra que, apesar das limitações de precisão das bordas, que pode incluir ruído térmico de regiões adjacentes (falsos positivos), a segmentação é suficientemente robusta para permitir a extração de características térmicas relevantes. A estabilidade das medidas térmicas sugere que a abordagem tem potencial para aplicações clínicas, especialmente na construção de biomarcadores associados a condições cardiovasculares.

A melhoria da precisão da segmentação constitui um passo essencial para aumentar a confiabilidade dessas medidas e é um ponto central para trabalhos futuros.

5. Conclusão e Trabalhos Futuros

Este trabalho foi motivado pela crescente demanda por métodos não invasivos, acessíveis e automatizados para análise de imagens médicas no contexto da saúde cardiovascular. A termografia infravermelha destaca-se como uma técnica promissora, capaz de capturar rapidamente variações térmicas associadas à perfusão microvascular, sem contato físico. No entanto, apesar de seu potencial diagnóstico, a análise dessas imagens ainda é predominantemente realizada manualmente e subjetivamente, o que limita sua reprodutibilidade, escalabilidade e aplicação em cenários clínicos reais.

Diante desse cenário, o objetivo deste estudo foi desenvolver e avaliar um método baseado em aprendizado profundo para segmentar automaticamente a região do pavilhão auricular em imagens termográficas, visando possibilitar a extração de características térmicas potencialmente associadas à identificação da doença arterial coronariana (DAC).

A metodologia proposta consistiu na construção de um pipeline de processamento que envolveu anotação manual das regiões de interesse, pré-processamento das imagens, treinamento de um modelo de segmentação baseado na arquitetura U-Net e avaliação por meio de métricas quantitativas de sobreposição (IoU, Dice) e de desempenho global (acurácia). A partir das regiões segmentadas, também foram extraídas estatísticas térmicas, como as temperaturas média, mínima e máxima.

Os resultados obtidos demonstraram que o modelo é capaz de identificar a região auricular com consistência, apresentando alta acurácia (96,24%), embora com valores moderados de IoU (0,3750) e Dice (0,5258), indicando limitações na precisão das bordas. Ainda assim, a análise das características térmicas revelou estabilidade entre as amostras, sugerindo que a segmentação obtida é suficiente para sustentar a extração de informações quantitativas relevantes.

Como trabalhos futuros, destacam-se três direções principais: (i) o aprimoramento da etapa de segmentação por meio de arquiteturas mais robustas ou estratégias de balanceamento de classes, visando melhorar as métricas de sobreposição; (ii) a extração de descritores térmicos mais avançados dentro da região segmentada, como gradientes e padrões espaciais de distribuição de temperatura; e (iii) a investigação da relação entre esses padrões térmicos e condições clínicas específicas, como hipertensão arterial e

doença arterial coronariana, com o objetivo de desenvolver biomarcadores digitais para apoio ao diagnóstico. Essas direções reforçam o potencial da integração entre termografia e inteligência artificial como ferramentas promissoras para aplicações em saúde digital.

Referências

- Atamañuk, A. N., Gandino, I. J., Miranda, M. N., Cardozo, L. M., Escalante, S. E., Villalba, C., Abalovich Bernal, D., Ross, G., Perna, E., and Delgado, D. (2025). Artificial intelligence-enabled analysis of thermography to diagnose acute decompensated heart failure. *JACC: Advances*, 4(7):101888.
- Banerjee, R., Ghose, A., Sinha, A., Pal, A., and Mandana, K. (2019). A multi-modal approach for non-invasive detection of coronary artery disease. In *Adjunct proceedings of the 2019 ACM international joint conference on pervasive and ubiquitous computing and proceedings of the 2019 ACM international symposium on wearable computers*, pages 543–550.
- Branco, J. H., Branco, R. L., Siqueira, T. C., de Souza, L. C., Dalago, K. M., and Andrade, A. (2022). Clinical applicability of infrared thermography in rheumatic diseases: A systematic review. *Journal of thermal biology*, 104:103172.
- Fernández-Cuevas, I., Marins, J. C. B., Lastras, J. A., Carmona, P. M. G., Cano, S. P., García-Concepción, M. Á., and Sillero-Quintana, M. (2015). Classification of factors influencing the use of infrared thermography in humans: A review. *Infrared Physics & Technology*, 71:28–55.
- Ferreira, D. C. and Machado, A. M. C. (2025). Classificação de doença arterial coronariana através de redes neurais profundas. In *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*, pages 116–127. SBC.
- Gakovic, B., Neskovic, S. A., Vranic, I., Grujicic, K., Mijatovic, S., Ljubojevic, A., and Stankovic, I. (2023). The relationship of diagonal earlobe crease (Frank's sign) and obstructive coronary artery disease in patients undergoing coronary angiography. *Wiener klinische Wochenschrift*, 135(23):667–673.
- Garcea, F., Serra, A., Lamberti, F., and Morra, L. (2023). Data augmentation for medical imaging: A systematic literature review. *Computers in biology and medicine*, 152:106391.
- Groenewegen, A., Zwartkruis, V. W., Rienstra, M., Zuithoff, N. P., Hollander, M., Koffijberg, H., Oude Wolcherink, M., Cramer, M. J., van der Schouw, Y. T., Hoes, A. W., et al. (2024). Diagnostic yield of a proactive strategy for early detection of cardiovascular disease versus usual care in adults with type 2 diabetes or chronic obstructive pulmonary disease in primary care in the Netherlands (RED-CVD): a multicentre, pragmatic, cluster-randomised, controlled trial. *The Lancet Public Health*, 9(2):e88–e99.
- Huang, C.-L., Wu, Y.-W., Hwang, C.-L., Jong, Y.-S., Chao, C.-L., Chen, W.-J., Wu, Y.-T., and Yang, W.-S. (2011). The application of infrared thermography in evaluation of patients at high risk for lower extremity peripheral arterial disease. *Journal of vascular surgery*, 54(4):1074–1080.

- Kung, M., Zeng, J., Lin, S., Yu, X., Liu, C., Shi, M., Sun, R., Yuan, S., Lian, X., Su, X., et al. (2024). Prediction of coronary artery disease based on facial temperature information captured by non-contact infrared thermography. *BMJ Health & Care Informatics*, 31(1):e100942.
- Lahiri, B. B., Bagavathiappan, S., Jayakumar, T., and Philip, J. (2012). Medical applications of infrared thermography: a review. *Infrared physics & technology*, 55(4):221–235.
- Loarce-Martos, J., Bachiller-Corral, J., Cuevas, I. F., Quintana, M. S., and Díaz, M. V. (2019). Utility of infrared thermography for the evaluation of rheumatoid arthritis. *Annals of the Rheumatic Diseases*, 78:313–314.
- Mashekova, A., Zhao, Y., Ng, E. Y., Zarikas, V., Fok, S. C., and Mukhmetov, O. (2022). Early detection of the breast cancer using infrared technology—a comprehensive review. *Thermal science and engineering progress*, 27:101142.
- Meng, Z., Han, K., He, Y., He, Y., Li, X., and Zou, Y. (2025). Modeling detail feature connections for infrared image enhancement. *Neurocomputing*, 639:130200.
- Motta, L. S., Conci, A., Lima, R. C., and Diniz, E. M. (2010). Automatic segmentation on thermograms in order to aid diagnosis and 2d modeling. In *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*, pages 1610–1619. SBC.
- Ring, E. and Ammer, K. (2012). Infrared thermal imaging in medicine. *Physiological measurement*, 33(3):R33–R46.
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, pages 234–241. Springer.
- Shimizu, M., Matsumoto, Y., Itakura, N., Mito, K., and Mizuno, T. (2023). Evaluation of methods for estimating autonomic nervous activity using a web camera. *Artificial Life and Robotics*, 28(4):718–725.
- Tajbakhsh, N., Jeyaseelan, L., Li, Q., Chiang, J. N., Wu, Z., and Ding, X. (2020). Embracing imperfect datasets: A review of deep learning solutions for medical image segmentation. *Medical image analysis*, 63:101693.
- Tang, B. and Sato, W. (2025). Ear thermal imaging for emotion sensing. *Scientific Reports*, 15(1):41571.
- World Health Organization (2021). Cardiovascular diseases (cvds).
- Yli-Harja, O., Pakarinen, T., Peltola, E., Hämäläinen, M., Vehkaoja, A., and Oksala, N. (2025). The utility of infrared thermography and hyperspectral imaging in peripheral artery disease: A systematic review. *Heart, Lung and Circulation*.
- Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N., and Liang, J. (2019). Unet++: Redesigning skip connections to exploit multiscale features in image segmentation. *IEEE transactions on medical imaging*, 39(6):1856–1867.