

Análise de Imagens de Termografia Dinâmica para Classificação de Alterações na Mama Usando Séries Temporais

Felipe Andrade

Departamento de Ciência da Computação
Universidade Federal do Maranhão
São Luis, Maranhão
Email: felipejordaopinheiro@gmail.com

Anselmo Paiva

Departamento de Ciência da Computação
Universidade Federal do Maranhão
São Luis, Maranhão
Email: anselmo.c.paiva@gmail.com

Aristófanos Correa

Departamento de Engenharia Elétrica
Universidade Federal do Maranhão
São Luis, Maranhão
Email: ari@dee.ufma.br

Abstract—With the increase in the number of cases of breast cancer in the last years, the need for auxiliary techniques for the detection of the disease is evident. Dynamic thermography can be used as an auxiliary method to the gold standard, the mammography screening. The thermography exam takes advantage of the fact that the lesions present a higher temperature than the healthy neighboring tissues. In this work, we propose a methodology for the transformation of thermal signals into time series, from which features for the classification task will be extracted. In the paper we compare the K-Star and Support Vector Machine classifiers with results of 95.8% accuracy, 93.6% sensitivity and 95.9% specificity.

Resumo—Com o aumento do número de casos de câncer de mama nos últimos anos, percebe-se a necessidade de técnicas auxiliares para a detecção da doença. A termografia dinâmica pode ser usada como método auxiliar ao padrão ouro, o exame de mamografia. O exame termográfico aproveita o fato que as lesões apresentam uma temperatura mais elevada do que os tecidos saudáveis vizinhos. Nesse trabalho iremos propor uma metodologia para transformação dos sinais térmicos em séries temporais, onde serão extraídas características para a tarefa de classificação. No trabalho comparamos os classificadores K-Star e Máquina de Vetores de Suporte obtendo resultados de 95.8% de acurácia, 93.6% de sensibilidade e 95.9% de especificidade.

I. INTRODUÇÃO

Segundo os dados do Instituto Nacional do Câncer, o câncer de mama foi o responsável por cerca de 28% dos novos casos de câncer no último ano, sendo o segundo tipo de câncer que mais atinge as mulheres no Brasil. Apesar disso, quando detectado em estágios iniciais, o tratamento é relativamente eficaz. Atualmente a detecção do câncer de mama é feita pela mamografia de rastreamento, o padrão ouro entre os exames disponíveis. Porém o exame de mamografia apresenta seus pontos negativos, como alto índices de falsos positivos e a exposição da paciente a radiação ionizante [1]. Dessa forma, percebe-se a necessidade de outras metodologias que deem suporte ao diagnóstico da doença.

A termografia infravermelha dinâmica é uma técnica de triagem não invasiva, barata e rápida que pretende registrar a radiação emitida pela superfície da pele da paciente ao longo de um período de tempo. As variações de temperatura

do tecido canceroso em relação ao tecido vizinho saudável se dá pelo processo de angiogênese. Por esse processo o tumor estimula a criação de novos vasos sanguíneos para sua alimentação. Com mais vasos alimentando o tumor a temperatura da região se mostra superior [2]. Kayserlingk et al. [3] reportou em seu trabalho que a sensibilidade para a detecção de câncer do tipo carcinoma ductal é significativamente melhorada quando combinado o exame de mamografia com a imagem térmica. A sensibilidade ao combinar essas duas técnicas foi de 95%.

O trabalho tem por objetivo a classificação, do conjunto de termogramas, em saudáveis ou anômalos. Dessa forma, apresentaremos uma metodologia envolvendo o processamento dos termogramas para criação de séries temporais, a extração de características dessas séries e a classificação desses exames.

II. REVISÃO BIBLIOGRÁFICA

Vários outros trabalhos envolvendo imagens térmicas foram conduzidos nos últimos anos. Nessa seção apresentaremos os resultados finais obtidos pelos trabalhos mais significativos envolvendo a mesma base de dados que será usada.

No trabalho de [4] e [5] foram usadas medidas estatísticas como características para classificação da paciente. No trabalho desenvolvido por [6], foi feito o agrupamento de regiões similares e extração de características sobre essas regiões. Essas características foram classificadas produzindo os resultados representativos do estado da arte para esse base de dados. O resultados podem ser observados na Tabela I.

Tabela I
COMPARAÇÃO DE RESULTADOS

	Acurácia	Sensibilidade	Especificidade
Silva [6]	100%	100%	100%
Borchart [5]	88.2%	91.9%	78.6%
Lessa [4]	85%	87%	83%

III. MATERIAIS E MÉTODO

A. Base de Dados

Os termogramas usados nesse trabalho foram obtidos a partir da técnica de Termografia Infravermelha Dinâmica. Esses exames pertencem a Database for Mastology Research with Infrared Image (DMR-IR) [7] e foram adquiridas no Hospital Antônio Pedro da Universidade Federal Fluminense (HUAP-UFF) ¹. Durante o protocolo de captura, as pacientes são posicionadas em pé em uma sala a 22°C com os braços posicionados acima da cabeça e um fluxo de ar constante direcionado a região das mamas. Quando a temperatura central da paciente atingir 30,5°C, o fluxo de ar é desligado e 20 termogramas são capturados com um intervalo de 15 segundos entre eles. Esse protocolo resultou em 32 exames saudáveis e 33 anômalos confirmados por biópsia.

B. Pré-processamento

A etapa de pré-processamento tem o objetivo converter os termogramas capturados para um formato que facilite a análise das informações relevantes ao problema. As subseções abaixo apresentam essas etapas na ordem que foram aplicadas. Os resultados de cada etapa são ilustrados na Figura 1.

1) *Conversão dos Termogramas para Matrizes de Temperatura:* Devido ao fato das imagens originais possuírem informações adicionais inclusas pelo software da câmera, como logomarca e marcações, as imagens são convertidas para matrizes de temperatura, contendo apenas as informações de temperatura da paciente [5].

2) *Conversão dos Valores de Temperaturas para Escala de Cinza:* O resultado da etapa anterior gera uma imagem onde os valores de pixel são temperaturas compreendidas no intervalo de aproximadamente 20° a 35°. Nessa etapa foi feita a normalização desses valores pro intervalo de 0 a 255, melhorando a visualização para a etapa de segmentação manual e o espaço de valores compreendido na imagem para a etapa de registro.

3) *Segmentação e Separação das Mamas:* Foi feita a segmentação manual da região das mamas com objetivo de excluir os ombros e região do tórax do termograma. Após essa etapa foi feita a separação em mama em esquerda e direita para que seja feita a análise individual. Como na etapa seguinte a imagem será registrada, a segmentação é feita apenas na primeira imagem da série e a mascara criada servirá para as próximas imagens. Ao final da separação temos 130 casos, sendo 86 mamas saudáveis e 44 anômalas, e para cada mama temos a informação de 20 tempos capturados em sequência.

4) *Registro das Imagens:* Durante o protocolo de aquisição por causa de movimentos involuntários as imagens devem ser registradas. Por esse motivo, a etapa de registro visa alinhar as imagens capturadas de forma a compensar esses movimentos involuntários. O registro é feito considerando o primeiro termograma como o a imagem de referência e os outros 19 serão

imagens sensíveis, que passarão pelo processo de alinhamento. Foi usado o registro deformável por informação mútua, que usa a intensidade de pixel para o cálculo das transformações [6].

C. Construção das Séries

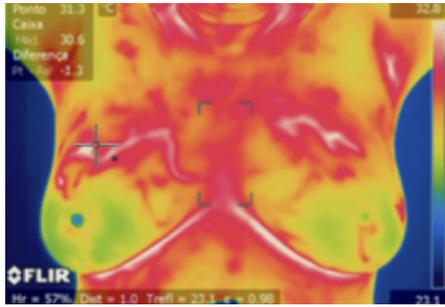
Após as etapas descritas na seção de pré-processamento anterior, teremos 130 casos(2 por paciente) com 20 termogramas capturados em intervalos de 15 segundos. O objetivo da construção da série é analisar o comportamento individual da região de uma mama, por vez, durante o reaquecimento corporal. O primeiro passo é converter todos esses termogramas, que se apresentam na forma de matriz, para um vetor unidimensional. Usamos o padrão da linha, que concatena linhas da matriz subsequentes. No segundo passo conectamos os vetores do passo anterior na mesma ordem que os termogramas foram capturados, criando assim uma série temporal de uma mama. Esse processo está ilustrado na Figura 2.

D. Extração de Características

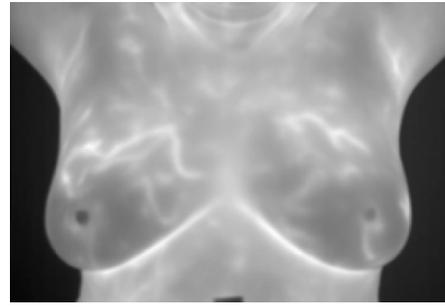
Nessa etapa pretendemos extrair características que representem as diferenças entre os padrões saudáveis e anômalos encontrados nas séries. As características aqui exploradas foram previamente usadas para análise de anomalias em séries temporais de eletroencefalograma nos trabalhos [8] e [9].

- Comprimento da Linha: Descreve a soma das diferenças entre consecutivos pontos da série.
- Área sob a curva: Descreve a área positiva normalizada sob a curva.
- Energia Média: Descreve a energia média em todos os pontos da série.
- Amplitude média dos vales: Mede a amplitude média dos vales pelo logaritmo do quadrado da amplitude para cada vale.
- Amplitude média dos picos: Mede a amplitude média dos picos pelo logaritmo do quadrado da amplitude para cada pico.
- Média: Medida estatística da média de uma sequência de valores.
- Desvio padrão: Medida estatística do desvio padrão de uma sequência de valores.
- Assimetria: Medida de forma que indica a quantidade e direção da inclinação da curva.
- Curtose: Medida de forma que descreve mudanças no pico central da curva.

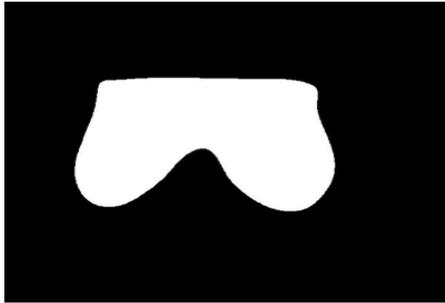
¹Projeto aprovado no Comitê de Ética, registrados da Plataforma Brasil do Ministério da Saúde para pesquisa sob o CAE 01042812.0.0000.5243, aprovado pelo parecer número 31646.



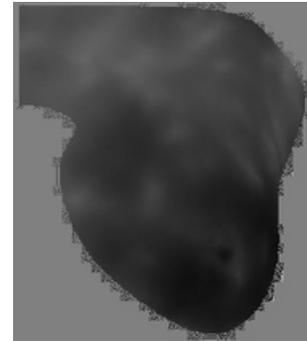
(a) Imagem original gerada pela câmera térmica



(b) Matriz de temperatura convertida para escala de cinza



(c) Resultado da segmentação da região das mamas



(d) Mama esquerda resultado da separação

Figura 1. Ilustrações das etapas do pré-processamento

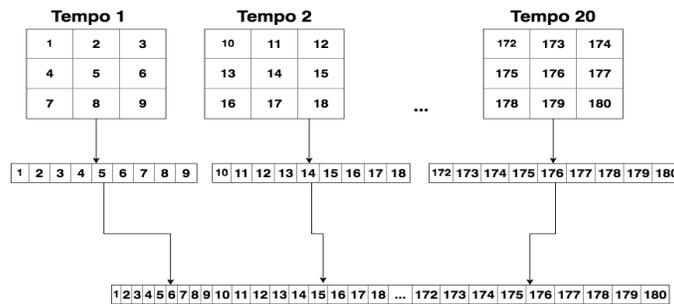


Figura 2. Processo de criação da série

E. Classificação

As características extraídas na etapa anterior serão usadas como as entradas dos classificadores para o treinamento. Esses modelos, depois de treinados, serão funções que poderão prever sob novas entradas. Os classificadores usados serão brevemente descritos abaixo:

1) *Máquina de Vetores de Suporte (MVS)*: A MVS é um dos modelos mais estudados e utilizados na área de aprendizado de máquina. É uma técnica de aprendizado supervisionado que pode ser usado tanto para problemas de classificação como para regressão. O treinamento da MVS pretende maximizar as margens do hiperplano que separa as classes. No nosso treinamento usamos o kernel "Radial Basis Function (RBF)" [10].

2) *K-Star*: O K-Star é um classificador baseado em distância entrópica em que a decisão de classe de uma instância de teste é baseada na maioria de K instâncias mais próximas [11].

IV. RESULTADOS E DISCUSSÃO

Para a realização dos experimentos, após a extração das características, fizemos a normalização desses valores para o intervalo [0,1] e o balanceamento ponderado para as classes, dessa forma um acerto para uma classe que tem menos instâncias disponíveis para o treino vale mais que um acerto para a classe com mais.

Também fizemos a seleção de características usando a ferramenta Weka com o método de busca BeFirst e avaliação de atributos SubsetEval [12]. Para o primeiro teste usando as

séries a seleção retornou, a energia média e a amplitude média dos picos como os atributos que melhor separam esses dados.

Para a validação desses testes também usamos a validação cruzada com 10 folds. Os resultados da classificação das séries originais estão agrupados na Tabela II.

Tabela II
RESULTADO DOS TESTES COM AS SÉRIES ORIGINAIS

	K-Star	MVS
Acurácia	68.1%	65.8%
Sensibilidade	62%	60.2%
Especificidade	86.1%	84.71%

Os resultados apresentados na Tabela II mostram que as características não foram capazes de mapear os padrões saudáveis e anômalos em razão da quantidade de informações contida por série e pelo fato do padrão de anomalia não ser o mesmo para os diversos tempos das séries.

Para contornar esse problema, adicionamos uma etapa de re amostragem presente em trabalhos similares [8] [13]. A re amostragem foi feita dividindo a série original em janelas de 2 tempos. Desta forma, uma série dará origem a 10 novas que possuirão o mesmo rótulo da primeira. Outros tamanhos de janela foram testados e a de tamanho 2 obteve os melhores resultados. Teremos 1300 séries para o novo teste.

As características do segundo teste passaram pelos mesmos processos do teste anterior, porém retornaram atributos diferentes na seleção de características. Para o segundo teste os atributos selecionados foram: Energia média, Comprimento da linha, Desvio padrão, Assimetria e Curtose. Os resultados desse teste estão agrupados na Tabela III.

Tabela III
RESULTADO DOS TESTES COM AS SÉRIES RE-AMOSTRADAS

	K-Star	MVS
Acurácia	95.8%	91%
Sensibilidade	93.6%	85%
Especificidade	95.9%	91%

Com base nos resultados da Tabela III, percebemos que os classificadores tiveram resultados significativamente melhores em comparação com o primeiro teste. No segundo teste vemos que a performance do classificador baseado em distância entropica foi ligeiramente melhor do que a MVS. Percebemos também que a sensibilidade obteve resultados elevados, o que é particularmente significativo para aplicações na área de saúde, pois ela indica a capacidade do classificador de detectar a classe positiva que representa a anomalia.

Queremos colocar em perspectiva que o trabalho aqui apresentado teve resultados próximos aos melhores resultados usando essa mesma base [6], porém ao contrario desses trabalhos, podemos prover ao especialista uma análise individual de cada mama, o que implica em maior flexibilidade.

V. CONCLUSÃO

O trabalho desenvolvido até esse ponto, apresenta uma metodologia automática de avaliação de um conjunto temporal de imagens térmicas. Os resultados obtidos por essa metodologia são significativos e podem auxiliar a decisão de diagnóstico do especialista. Para a próxima etapa desse trabalho pretendemos comparar esses resultados com uma abordagem de classificação usando uma rede neural recorrente do tipo Long Short Term Memory(LSTM) onde as características não precisam ser extraídas antes do treinamento, deixando essa tarefa para a própria rede.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro da Fundação de Amparo a Pesquisa e Desenvolvimento Científico do estado do Maranhão(FAPEMA).

REFERÊNCIAS

- [1] INCA, “Câncer de Mama,” 2017, http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/mama/cancer_mama.
- [2] Gerasimova, E., Audit, B., Roux, S. G., Khalil, A., Argoul, F., Naimark, O., and Arneodo, A., “Multifractal analysis of dynamic infrared imaging of breast cancer,” *EPL*, vol. 104, no. 6, p. 68001, 2013. [Online]. Available: <https://doi.org/10.1209/0295-5075/104/68001>
- [3] J. Keyserlingk, P. Ahlgren, E. Yu, and N. Belliveau, “Infrared imaging of the breast: Initial reappraisal using high-resolution digital technology in 100 successive cases of stage i and ii breast cancer,” *The Breast Journal*, vol. 4, no. 4, pp. 245–251, 1998. [Online]. Available: <http://dx.doi.org/10.1046/j.1524-4741.1998.440245.x>
- [4] V. Lessa and M. Marengoni, “Applying artificial neural network for the classification of breast cancer using infrared thermographic images,” vol. 9972, pp. 429–438, 09 2016.
- [5] T. Borchardt, “Uma análise de imagens termográficas para classificação de alteração na mama,” Ph.D. dissertation, Universidade Federal Fluminense, 2013.
- [6] L. Silva, “Uma análise híbrida para detecção de anomalias da mama usando séries temporais de temperatura,” Ph.D. dissertation, Universidade Federal Fluminense, 2015.
- [7] L. Silva, D. C. M. Saade, G. Sequeiros Olivera, A. Silva, A. Paiva, R. S. Bravo, and A. Conci, “A new database for breast research with infrared image,” vol. 4, pp. 92–100, 03 2014.
- [8] D. Wulsin, J. Gupta, R. Mani, J. Blanco, and B. Litt, “Modeling electroencephalography waveforms with semi-supervised deep belief nets: fast classification and anomaly measurement,” *Journal of neural engineering*, vol. 8, no. 3, p. 036015, 2011.
- [9] S. M. R. Islam, A. Sajol, X. Huang, and K. L. Ou, “Feature extraction and classification of eeg signal for different brain control machine,” in *Electrical Engineering and Information Communication Technology (ICEEICT), 2016 3rd International Conference on*. IEEE, 2016, pp. 1–6.
- [10] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, and B. Scholkopf, “Support vector machines,” *IEEE Intelligent Systems and their applications*, vol. 13, no. 4, pp. 18–28, 1998.
- [11] J. G. Cleary and L. E. Trigg, “K*: An instance-based learner using an entropic distance measure,” in *In Proceedings of the 12th International Conference on Machine Learning*. Morgan Kaufmann, 1995, pp. 108–114.
- [12] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I. H. Witten, “The weka data mining software: An update,” *SIGKDD Explor. Newsl.*, vol. 11, no. 1, pp. 10–18, Nov. 2009. [Online]. Available: <http://doi.acm.org/10.1145/1656274.1656278>
- [13] Z. C. Lipton, D. C. Kale, C. Elkan, and R. C. Wetzel, “Learning to diagnose with LSTM recurrent neural networks,” *CoRR*, vol. abs/1511.03677, 2015. [Online]. Available: <http://arxiv.org/abs/1511.03677>