

COMPARAÇÃO DO USO DE VARIÁVEIS CONTÍNUAS E VARIÁVEIS INTERVALARES NA CLASSIFICAÇÃO DE PATOLOGIAS EM TERMOGRAMAS DE MAMA

Marcus Costa de Araújo, DEMEC-UFPE, marcus.araujo@ufpe.br

Rita de Cássia Fernandes Lima, DEMEC-UFPE, ritaflima@yahoo.com

Renata Maria Cardoso Rodrigues de Souza, CIN-UFPE, rmcrs@cin.ufpe.br

Resumo. A termografia tem surgido como um método potencial para auxiliar na detecção precoce do câncer de mama. Estudos recentes envolvendo o uso da termografia como técnica de triagem têm gerado interesse crescente, especialmente nos casos em que a mamografia é limitada, como para pacientes jovens que apresentam tecido mamário denso. O objetivo deste trabalho é avaliar a viabilidade da utilização de dados intervalares sob a ótica da análise dos dados simbólicos (SDA) para classificar anomalias mamárias (maligno, benigno e cisto) a fim de detectar o câncer de mama. Duas abordagens são comparadas para a tarefa de classificação de anormalidades de mama a partir da termografia. Na primeira, são usadas variáveis contínuas e um classificador de distância mínima; na segunda abordagem um classificador baseado em dados intervalares é utilizado. A primeira abordagem obteve 18% de taxa de erro de classificação, com 85% de sensibilidade para a classe maligno. A segunda abordagem atingiu 20% de taxa de erro de classificação com 100% de sensibilidade para a classe maligno.

Palavras chave: Termografia. Detecção do Câncer de Mama. Classificação. Dados simbólicos.

1. INTRODUÇÃO

Um grande número de aplicações de engenharia vem sendo utilizado para auxiliar em procedimentos ou diagnósticos médicos, seja de forma direta ou indireta. A detecção do câncer merece destaque dentre as áreas da medicina onde se aplicam técnicas de engenharia como meio de diagnóstico. Recentemente, vem-se utilizando a termografia para auxílio ao diagnóstico de algumas formas da doença, entre elas o câncer de mama.

A termografia surgiu como um método potencial para melhorar a eficiência da detecção precoce de doenças na mama quando aplicada em conjunto com outras técnicas de diagnóstico (Kapoor et al., 2012). A detecção do câncer pela termografia baseia-se no princípio de que as temperaturas em torno do nódulo mamário (benigno ou maligno) são maiores do que as do tecido saudável (Acharya et al., 2014). Atualmente, a mamografia é o mais importante método de diagnóstico por imagens dentre as técnicas utilizadas para detecção do câncer de mama. O exame consiste da emissão de feixes de Raios-X de baixa dosagem, gerando uma imagem da mama. No entanto, mamas jovens, por possuírem tecido glandular denso, geram pouco contraste aos Raios-X e são mais suscetíveis aos efeitos da radiação (Hayward, 1987). Por esta razão, pacientes jovens não são indicadas para mamografia e, portanto, são encaminhadas a outros tipos de diagnóstico, como ultrassonografia e a termografia. Todos esses exames devem ser acompanhados de biópsia e análise patológica para confirmação do câncer em um nódulo existente.

Recentemente, técnicas de aprendizagem de máquina tem sido utilizadas como ferramenta para problemas de classificação variados, incluindo-se a detecção do câncer. Um problema de classificação consiste em alocar uma observação individual em uma das C possíveis classes ω_i , $i = 1, \dots, C$; i.e., dada uma observação individual descrita por um vetor de atributos $\mathbf{x}$, deseja-se alocar este objeto para uma das C classes existentes. Para este fim, uma regra de decisão divide o espaço de entrada ou espaço de características, definido em função das variáveis de entrada, em C regiões distintas Ω_i , $i = 1, \dots, C$, rotuladas de acordo com a regra de classificação. Aloca-se um vetor de entrada $\mathbf{x}$ para a classe ω_i quando ele pertence à região Ω_i dentro do espaço de características (Hastie et al., 2009).

Diversos estudos vêm sendo conduzidos no sentido de classificar a patologia mamária por meio de imagens de termografia (Acharya et al., 2014; Francis e Sasikala, 2013; Krawczyk et al., 2012; Tan et al., 2007; Tang e Ding, 2005; Ng et al., 2005). Todos esses trabalhos utilizaram variáveis contínuas associadas a diferentes técnicas de aprendizagem de máquina para classificar as imagens termográficas de mama em "câncer" e "não câncer". Mais recentemente, Araújo et al. (2016) utilizaram variáveis intervalares para descrever e classificar patologias de mama. Num trabalho anterior, Araújo et al. (2014) utilizaram variáveis contínuas obtidas a partir de um conjunto de variáveis intervalares de temperatura das mamas medidas na termografia para classificar diferentes patologias de mama.

Na imagem termográfica, cada mama é representada como uma matriz de temperaturas onde cada pixel da imagem representa um único valor de temperatura. Se assumirmos que uma região da mama pode ser representada por um grupo de temperaturas, podemos considerar que as temperaturas das mamas no termograma apresentam comportamento de natureza intervalar. Quando a imagem termográfica é analisada como um grupo de temperaturas, em oposição a uma observação pontual, é possível considerar a variabilidade amostral intrínseca ao grupo de temperaturas em questão.

A proposta deste trabalho é fazer uma comparação entre a aplicação das variáveis contínuas apresentadas por Araújo et al. (2014) e das variáveis intervalares apresentadas por Araújo et al. (2016) para a tarefa de classificação de distúrbios de mama (tumor maligno, tumor benigno e cisto).

2. MATERIAIS E MÉTODOS

A metodologia deste trabalho pode ser dividida nas seguintes etapas:

1. Seleção das pacientes e aquisição das imagens termográficas;
2. Pré-processamento da imagem termográfica;
3. Extração de características contínuas e intervalares;
4. Etapa de classificação.

2.1. Seleção das pacientes e aquisição das imagens termográficas

As imagens termográficas tratadas no presente trabalho foram obtidas a partir de uma câmera termográfica FLIR S45. Os voluntários das quais foram tomadas as imagens concordaram em participar da pesquisa por meio da assinatura do Termo de Consentimento Livre e Esclarecido (TCLE), documento obrigatório exigido pelo projeto cadastrado no Ministério da Saúde do Brasil sob o Registro CEP/CCS/UFPE N_279/05 e aprovado pelo Comitê de Ética da Universidade Federal de Pernambuco.

As imagens termográficas foram colhidas de um grupo heterogêneo e composto por 50 pacientes voluntários. O universo a ser examinado é formado por pacientes do Ambulatório de Mastologia da Clínica Ginecológica do Departamento Materno-Infantil do Hospital das Clínicas da UFPE que apresentaram diagnóstico conclusivo. Os 50 pacientes selecionados apresentaram suspeita de distúrbio mamário, comprovado por exame clínico e exames de imagem, como ultrassom e mamografia; e exame patológico quando necessário. Todos os pacientes foram submetidos ao protocolo de aquisição de imagens descrito em (Bezerra et al., 2013a; Bezerra et al., 2013,b). A amostra estudada estava dividida entre as seguintes classes: 14 casos de malignidade, 19 casos de nódulo benigno e 17 casos de cisto.

2.2. Pré-processamento da imagem termográfica

O pré-processamento da imagem termográfica consiste da segmentação da região das mamas no termograma e do posterior tratamento morfológico realizado sobre cada uma das imagens segmentadas das mamas. Para o processo de segmentação das mamas foi desenvolvido uma ferramenta de segmentação manual por meio do Matlab. A segmentação manual foi escolhida devido à existência de uma grande variação anatômica observada entre pacientes. Essa variabilidade anatômica causou erros de segmentação em ferramentas automáticas desenvolvidas para esse fim (Motta, 2010).

O processo desenvolvido para a segmentação manual da mama no termograma consiste em: extrair a matriz de temperaturas T da imagem termográfica a partir do software comercial FLIR QuickReport; esta matriz é previamente convertida em formato de planilha de texto e então é importada para o Matlab, podendo ser visualizada como uma imagem comum; em seguida, a região de interesse é selecionada criando-se um objeto que encapsula uma elipse interativa sobre uma imagem. É possível ajustar o tamanho e a posição da elipse de forma manual usando o mouse. Assim, obtém-se a imagem segmentada das mamas sobre a matriz de temperaturas T ; após a seleção da área de interesse, despreza-se o restante da imagem. Após a etapa de segmentação da imagem termográfica (Fig. 1,a), um processamento morfológico foi realizado sobre as regiões das mamas (Fig. 1,b). O objetivo do uso do processamento morfológico é determinar os máximos locais de temperatura com relação às temperaturas da vizinhança na imagem segmentada das mamas (Araujo et al., 2014; Araujo et al., 2016).




Figura 1 - Etapas do processo de pré-processamento da imagem térmica; a) segmentação manual das mamas; b) processamento morfológico.

Após a etapa de pré-processamento da imagem termográfica obtém-se quatro matrizes de temperaturas (MD, ME, MMD e MME). Duas matrizes de temperatura são referentes à etapa de segmentação das mamas, correspondendo às

matrizes de temperatura da mama direita (MD) e mama esquerda (ME); e duas matrizes referentes ao processamento morfológico aplicado a cada uma das imagem segmentada das mamas (MMD e MME).

2.3. Extração de características contínuas e intervalares

Nesta seção são mostradas as duas abordagens propostas no presente trabalho para a extração de características. Ambas utilizam as matrizes segmentadas de temperatura de cada mama e suas respectivas matrizes morfológicas como dados de entrada, i.e., as matrizes MD, ME, MMD e MME. A primeira metodologia proposta (abordagem 1) baseia-se em extrair variáveis contínuas, que são obtidas a partir de medidas de dissimilaridade intervalar definidas por Diday e Noirhomme-Fraiture (2008), das matrizes de entrada (MD, ME, MMD e MME). Essas variáveis contínuas são então usadas como vetor de entrada para o processo de classificação.

Na segunda abordagem (abordagem 2) são usados os intervalos de temperatura referentes às quatro matrizes de entrada, MD, ME, MMD e MME. Essas variáveis intervalares são usadas como vetor de entrada para um classificador que usa como proposta uma variação da distância de Mahalanobis baseada em intervalos.

Para a determinação das variáveis contínuas e intervalares, cada mama foi representada graficamente por meio de suas temperaturas mínimas e máximas (Fig. 2). Na Figura 2, Y_{MD} representa os dados da mama direita e Y_{ME} representa os dados da mama esquerda; a_{MD} e a_{ME} correspondem às temperaturas mínimas das mamas direita e esquerda, respectivamente; e b_{MD} e b_{ME} correspondem aos valores máximos de temperatura encontrados para as mamas direita e esquerda, respectivamente. Os dados das matrizes MMD e MME também foram representados graficamente por meio de seus valores máximos e mínimos (Fig. 3). Essas representações (Fig. 2 e Fig. 3) foram utilizadas para a determinação das variáveis contínuas e intervalares.




Figura 2 - Representação gráfica dos intervalos de temperatura para a mama direita e mama esquerda de um mesmo paciente.




Figura 3 - Representação gráfica dos intervalos de temperatura morfológicos para a mama direita e esquerda de um mesmo paciente.

2.3.1. Extração de características contínuas

Esta etapa baseia-se em extrair variáveis contínuas, obtidas a partir de medidas de dissimilaridade intervalar definidas por Diday e Noirhomme-Fraiture (2008) a partir das matrizes de entrada (MD, ME, MMD e MME) e das representações gráficas dos dados de temperatura e morfológico. Da representação gráfica de temperatura (Fig. 2) foram selecionados as variáveis que correspondem às distâncias α , β e K , i.e., correspondem à distância entre às temperaturas mínimas das mamas esquerda e direita, à distância correspondente às temperaturas máximas entre as mamas esquerda e direita e à maior distância entre as temperaturas mínimas e máximas das mamas, respectivamente. Da representação morfológica, foi utilizada apenas β_M que corresponde à distância entre os valores morfológicos máximos obtidos para cada mama. Assim, obtém-se o vetor de variáveis contínuas $w = (\alpha, \beta, K, \beta_M)$.

2.3.2. Extração de características intervalares

Nesta segunda abordagem são extraídos os intervalos de temperatura referentes às quatro matrizes de entrada, MD, ME, MMD e MME e das representações gráficas dos dados de temperatura e morfológico. Essas variáveis intervalares são usadas como vetor de entrada para um classificador de distância mínima, que usa como função de proximidade uma variação da distância de Mahalanobis baseada em intervalos. Em uma imagem termográfica, um intervalo de temperatura pode ser definido a partir das temperaturas contidas na região de interesse. É possível escrever o intervalo como $\hat{y} = [Tmin, Tmax]$ onde $Tmin$ representa a temperatura mínima obtida sobre a região de interesse e $Tmax$ a temperatura máxima obtida sobre a região de interesse. Dessa forma, cada matriz de entrada dá origem a uma variável intervalar, gerando um vetor de características intervalar de quatro dimensões $\hat{y}$ que pode ser definido como

$$\hat{y} = (a, b, c, d)$$

onde

- $a = [a_{MD}, b_{MD}]$;
- $b = [a_{ME}, b_{ME}]$;
- $c = [\min(a_{MD}, a_{ME}), \max(b_{MD}, b_{ME})]$;
- $d = [\min\{b_{MMD}, b_{MME}\}, \max\{b_{MMD}, b_{MME}\}]$.

e a_{MD} , b_{MD} , a_{ME} , b_{ME} , b_{MMD} e b_{MME} referentes aos valores mínimos e máximos das mamas obtidos das Fig. 2 e Fig. 3.

2.4. Etapa de classificação.

Neste ponto, as extrações de características propostas foram usadas como vetor de entrada para um classificador de distância mínima baseado na distância de Mahalanobis. O classificador de distância mínima para dados contínuos aloca um padrão desconhecido x para a classe ω_i baseado na minimização de uma distância entre um padrão x e um protótipo u_i de uma classe no espaço de características. Este método traz a vantagem de ser independente da distribuição dos dados, dependendo somente dos elementos de treino de cada classe. O protótipo u_i usado para representar a classe ω_i consiste no vetor de médias dos elementos pertencentes à classe. Para os dados intervalares, foi utilizado uma distância de Mahalanobis parametrizada para intervalos, definida em Araújo et al. (2016).

3. RESULTADOS E DISCUSSÕES

A fim de avaliar o resultado do processo de classificação, para cada metodologia proposta, é necessário que o classificador seja testado a partir de indivíduos que não foram apresentados durante a fase de treino. Quando o tamanho da amostra é pequeno ou moderado, caso da amostra estudada neste trabalho, pode-se utilizar de técnicas específicas como validação cruzada K-fold, Leave-one-Out e Bootstrap (SOUZA, 1999). Neste trabalho, cada abordagem sugerida foi avaliada a partir do critério de validação cruzada Leave-One-Out, onde um único indivíduo é usado para teste, enquanto que o restante das amostras é utilizada para treino. O processo é repetido até que todos os indivíduos sejam usados como amostra de teste. Por fim, os dados foram avaliados quanto à taxa de erro de classificação e quanto aos índices de sensibilidade e especificidade para cada classe.

A sensibilidade e especificidade são medidas estatísticas do desempenho de uma tarefa de classificação. A sensibilidade representa a proporção de indivíduos pertencentes a uma determinada classe, devidamente identificados como tal e a especificidade representa a proporção de amostras negativas para uma dada classe, devidamente identificados como tal. Na área médica, a sensibilidade e especificidade desempenham um papel importante, pois estão intimamente relacionados com os conceitos dos erros estatísticos do tipo I e tipo II. Embora estas medidas estejam relacionadas com um teste de classificação binária, é possível generalizar este conceito para um problema com mais do que duas classes, ou seja, para a i -ésima classe, a sensibilidade e especificidade podem ser calculadas como

$$Sen(i) = \frac{VP_i}{VP_i + FN_i} \quad (1)$$

onde:

$Sen(i)$ = Sensibilidade para a classe ω_i

VP_i = Verdadeiro positivo para a classe ω_i ;

FN_i = Falso Negativo para a classe ω_i .

$$Spe(i) = \frac{VN_i}{VN_i + FP_i} \quad (2)$$

onde:

$Spe(i)$ = Especificidade para a classe ω_i

VN_i = Verdadeiro negativo para a classe ω_i ;

FP_i = Falso positivo para a classe ω_i .

A taxa de erro de classificação, por sua vez, pode ser definida da seguinte forma para um número n de indivíduos:

$$Erro = \frac{1}{n} \sum_{i=1}^C FN_i \quad (3)$$

A Tabela 1 exibe a sensibilidade e especificidade para as três classes obtidas por meio da classificação dos termogramas de mama utilizando variáveis contínuas. A Tabela 2 exibe a matriz de confusão referente a esta classificação. A taxa de acertos foi de 78%, com destaque para a classe benigno.

Tabela 1 - Sensibilidade e especificidade obtidas utilizando variáveis contínuas.

Classe	Sensibilidade	Especificidade
Benigno	0,78	0,96
Maligno	0,85	0,86
Cisto	0,82	0,90

Tabela 2 - Matriz de confusão da classificação com variáveis contínuas.

Classe	Classe Predita			Total
	Benigno	Maligno	Cisto	
Benigno	15	2	2	19
Maligno	1	12	1	14
Cisto	0	3	14	17
Total	16	17	17	50

A classe que representa a malignidade é, sem dúvida, o grupo de maior importância para a predição. Um falso negativo ou o erro tipo I para este grupo pode levar o paciente a óbito. Por este motivo, a sensibilidade para esta classe representa um parâmetro crucial na avaliação do processo de classificação. Por meio do classificador intervalar desenvolvido por Araujo et al., (2016), foi possível otimizar os parâmetros de classificação com a intenção de maximizar a sensibilidade ao nódulo maligno. Os resultados estão apresentados nas Tabelas 3 e 4.

Tabela 3 - Sensibilidade e especificidade obtidas utilizando o classificador intervalar.

Classe	Sensibilidade	Especificidade
Benigno	0,74	1
Maligno	1	0,75
Cisto	0,71	0,97

Tabela 4 - Sensibilidade e especificidade obtidas utilizando o classificador intervalar.

Classe	Classe Predita			Total
	Benigno	Maligno	Cisto	
Benigno	14	4	1	19
Maligno	0	14	0	14
Cisto	0	5	12	17
Total	14	23	13	50

Pode-se observar das Tabelas 3 e 1 que com a utilização do classificador intervalar foi possível superar a sensibilidade ao tumor maligno obtida por meio das variáveis contínuas. No entanto, esta melhora de sensibilidade para a classe benigna refletiu numa menor sensibilidade às demais classes, proporcionando uma taxa de erro ligeiramente maior para este classificador. A taxa de erro global para o classificador utilizando variáveis contínuas foi de 18%, enquanto que a taxa de erro global para o classificador intervalar foi de 20%.

4. CONCLUSÃO

Neste trabalho foram comparadas duas abordagens distintas para a classificação do câncer de mama a partir de imagens termográficas. Uma primeira, baseada em variáveis contínuas de temperatura e uma segunda abordagem

baseada em dados intervalares de temperaturas obtidos do termograma da mama. Os resultados foram comparados a partir do classificador de distância mínima, utilizando a distância de Mahalanobis como parâmetro. O estudo demonstrou que os dados de intervalos de temperatura podem ser usados com segurança para representar imagens termográficas já que eles englobam a variabilidade intrínseca de cada ponto de temperatura no termograma. Considerando os resultados obtidos em ambas as abordagens, pode-se sugerir que a termografia pode ser usada como uma ferramenta complementar para a detecção precoce do câncer de mama. Uma abordagem baseada em uma análise binária do tipo "câncer" e "não-câncer" pode se favorecer das sensibilidades encontradas para a Classe Maligno para a Abordagem 2 da metodologia proposta neste trabalho. As sensibilidades encontradas para o nódulo fazem da metodologia desenvolvida uma ferramenta de grande valia para rastreamento e/ou detecção precoce de câncer de mama, principalmente na análise de termogramas de pessoas residentes em localidades afastadas dos grandes centros urbanos, onde a população tem pouco acesso a outras formas de diagnóstico.

5. REFERÊNCIAS

- ACHARYA, R.U.; NG, E.Y.K.; SREE, S.V.; CHUA, C.K.; CHATTOPADHYAY, S. Higher order spectra analysis of breast thermograms for the automated identification of breast cancer. **Expert Systems**, v. 31, n. 1, p. 37 – 47, 2014.
- ARAÚJO, M.C.; LIMA, R.C.F.; SOUZA, R.M.C.R., Interval symbolic feature extraction for thermography breast cancer detection, **Expert Systems with Applications**, 41:6728–6737, (2014).
- ARAÚJO, M.C.; SOUZA, R.M.C.R.; LIMA, R.C.F., An interval prototype classifier based on a parameterized distance applied to breast thermographic images, **Medical & Biological Engineering & Computing**, 2016.
- BEZERRA, L.; OLIVEIRA, M. M.; ROLIM, T. L.; CONCI, A.; SANTOS, F. G. S.; LYRA, P. R. M.; LIMA, R. C. F. Estimation of breast tumor thermal properties using infrared images. **Signal Processing**, v. 93, p. 2851–2863, 2013.
- BEZERRA, L. A.; OLIVEIRA, M. M.; ARAÚJO, M. C.; VIANA, M. J. A.; SANTOS, L. C.; SANTOS, F. G. S.; ROLIM, T. L.; LYRA, P. R. M.; LIMA, R. C. F.; BORSCHARTT, T. B.; RESMINI, R.; CONCI, A. Infrared imaging for breast cancer detection with proper selection of properties: From acquisition protocol to numerical simulation. In: NG, E. Y. K.; ACHARYA, U. R.; RANGAYYAN, R. M.; SURI, J. S. (Ed.). **Multimodality Breast Imaging: Diagnosis and Treatment**. [S.l.]: SPIE PRESS, 2013. v. 1.
- DIDAY, E.; NOIRHOMME-FRAITURE, M. **Symbolic Data Analysis and the SODAS Software**. England: John Wiley and Sons, 2008.
- FRANCIS, S. V.; SASIKALA, M. Automatic detection of abnormal breast thermograms using asymmetry analysis of texture features. **Journal of Medical Engineering & Technology**, v. 37, n. 1, p. 17–21, 2013.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning**. 2nd. ed. USA: Springer, 2009.
- HAYWARD, J. Uma visão global do problema. In: MONTORO, A.F.; FILHO, O.G.; FERREIRA, C.A.; VALENTE, C.A.; PETRILLI, C.; POSSIK, R.A.; MÉLEGA, J.M. (Ed.). **Alternativas Diagnósticas e Terapêuticas no Câncer de Mama**. São Paulo: BRADEPCA/CNPQ, 1987. cap. 1, p. 3–11.
- KAPOOR, P.; PRASAD, S.V.A.V.; PATNI, S. Image Segmentation and Asymmetry Analysis of Breast Thermograms for Tumor Detection. **International Journal of Computer Applications**, v. 50, n. 9, p. 40-45, 2012.
- KRAWCZYK, B.; SCHAEFER, G.; WOZNIAK, M. Breast thermogram analysis using a cost-sensitive multiple classifier system. In: **Proceedings of the IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI 2012)**. Hong Kong and Shenzhen, China: [s.n.], 2012. p. 507–510.
- MOTTA, L. S. **Obtenção automática da região de interesse em termogramas frontais da mama para o auxílio a detecção precoce de doenças**. Dissertação (Mestrado) — Universidade Federal Fluminense, 2010.
- NG, E.Y.K.; KEE, E.; ACHARYA, R.U. Advanced technique in breast thermography analysis. **Proceedings of the IEEE Engineering in Medicine and Biology 27th Annual Conference**, Shangay, China, 2005.
- SOUZA, R.M.C.R., **Classificação de imagens SAR baseada em uma abordagem simbólica**. Dissertação (Mestrado) — Universidade Federal de Pernambuco, Recife, 1999.
- TAN, T.; QUEK, C.; NG, G.; NG, E. A novel cognitive interpretation of breast câncer thermography with complementary learning fuzzy neural memory structure. **Expert Systems with Applications**, 2007.
- TANG, X.; DING, H. Asymmetry analysis of breast thermograms with morphological image segmentation. **Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference**, Shangay, China, p. 1680–1683, 2005.

6. AGRADECIMENTOS

Os autores agradecem à CAPES e ao CNPq pelo apoio financeiro para a pesquisa

7. RESPONSABILIDADE PELAS INFORMAÇÕES

OS autores são os únicos responsáveis pelas informações incluídas neste trabalho.