

# Anotação Semântica Baseada em Ontologia aplicada em Imagens Médicas

Juliana Wolf Pereira<sup>1</sup>, Marcela Xavier Ribeiro<sup>1</sup>

<sup>1</sup> Universidade Federal de São Carlos (UFSCar) – SP – Brasil

juliana.wolf@ufms.br, marcelaxr@ufscar.br

**Abstract.** *Mammograms allow for the early diagnosis of breast cancer, the most common type of cancer among women in Brazil and around the world. In this doctoral research, the MUSA method was developed to classify and semantically annotate mammography images based on the fusion of multimodal information, providing a fuller image annotation than the current state of the art. The approach includes text mining, image mining, and ontology engineering processes. The image mining process's results for classifying lesions as mass or calcification were more than 92% accurate, reaching better results than the literature. The results also demonstrate that the AnotaMammo ontology adequately performed the semantic enrichment of the classification. In addition, it adequately performed the fusion of multimodal information. Finally, the MUSA method adds information to make the result more semantic and interpretable, thus reducing the semantic gap.*

**Resumo.** *Mamografias permitem o diagnóstico precoce do câncer de mama, o tipo de câncer mais comum entre mulheres no Brasil e no mundo. Nesta pesquisa de doutorado, foi desenvolvido o método MUSA com o objetivo de classificar e anotar semanticamente imagens de mamografia, a partir da fusão de informações multimodais, fornecendo uma anotação mais completa da imagem do que o atual estado da arte. Para isso, a abordagem engloba um processo de mineração de texto, um processo de mineração de imagens, e um processo de engenharia de ontologias. Os resultados do processo de mineração de imagem superaram ou se compararam com estudos publicados na literatura, atingindo mais de 92% de acurácia na classificação de lesões como massa ou calcificação. Os resultados demonstram ainda que a ontologia AnotaMammo desempenhou apropriadamente o enriquecimento semântico da classificação, além de ter realizado adequadamente a fusão das informações multimodais. Por fim, o método MUSA agrega informações para tornar o resultado mais semântico, mais interpretável, reduzindo assim o gap semântico.*

## 1. Contexto e Motivação

O câncer de mama é o tipo de câncer mais comum entre as mulheres no Brasil e no mundo, atingindo cerca de 2,3 milhões de novos casos no mundo no ano de 2020. A mamografia é um dos principais exames de imagem para o diagnóstico precoce do câncer de mama. O desenvolvimento de soluções computacionais inovadoras podem contribuir com a interpretação dessas imagens, reduzindo o *gap* semântico e melhorando a interpretabilidade dos resultados.

Para isso, diferentes modalidades de informação sobre a imagem podem ser integradas para fornecer informações adicionais, além das obtidas por características visuais da imagem. Por exemplo, o conjunto de informações textuais provenientes de relatórios médicos. As informações conceituais relacionadas ao domínio dos achados em mamografia. Usar adequadamente essas informações, pode ajudar a enriquecer semanticamente os métodos de auxílio ao diagnóstico, melhorando a interpretação dos resultados.

Este trabalho de doutorado lida com a semântica e a multimodalidade de informações na tarefa de classificação e anotação de imagens de mamografia, fornecendo uma anotação mais completa da imagem do que o atual estado da arte.

A fusão das informações ocorre por meio de artefatos semânticos, como os axiomas e as regras semânticas implementadas na ontologia de anotação. As seguintes informações multimodais são analisadas: (i) características visuais do conteúdo da imagem e classificações obtidas por um processo *end-to-end deep learning*; (ii) características contextuais, obtidas por meio de informações presentes nos laudos e descrições das imagens; e (iii) características conceituais, obtidas por meio da ontologia de domínio que define a estrutura semântica do conhecimento.

## 2. Objetivo e Contribuições

O objetivo geral desta pesquisa de doutorado é propor um método para a classificação e anotação semântica de imagens de mamografia a partir de informações multimodais. Por meio do método proposto busca-se prover o enriquecimento semântico dos resultados de classificação com vistas a produzir uma anotação mais completa da imagem, melhorando sua interpretabilidade e reduzindo o *gap* semântico.

As principais contribuições desta pesquisa de doutorado são:

O método **MUSA** (*Unified Method of Semantic Annotation*) é uma proposta para classificar e anotar semanticamente imagens médicas. A partir da mineração de dados de imagem e de texto, e da engenharia de ontologia, ocorre a construção dos modelos que possibilitam a classificação e anotação semântica. O método propõe a fusão de informações multimodais com a vantagem de melhorar a interpretabilidade do resultado da mineração ao incluir novas informações semânticas ao resultado da classificação das características visuais [Pereira and Ribeiro 2021]. O MUSA é composto por:

- Processo de mineração de texto para lidar com os dados textuais presentes nos laudos e registros médicos. O processo utilizado nesta pesquisa se baseia em uma matriz *word-context* para o cálculo de similaridade [Levy et al. 2015]. O objetivo do processo é identificar recursos para a geração de regras semânticas, geradas pelo cômputo da coocorrência e similaridade entre pares de palavras presentes em um mesmo laudo.
- Processo de mineração de imagens para classificar imagens de mamografia a partir das características visuais. O processo de mineração de imagens consiste em analisar e classificar as ROIs (*Regions of Interest*) de imagens de mamografia. Para isso, o processo engloba uma estratégia *end-to-end deep learning*, com diferentes arquiteturas. A abordagem inclui o procedimento de aprendizado por transferência (*transfer learning*), por meio do ajuste fino (*fine-tuning*) e a definição de hiperparâmetros (*hyperparameter*) [Pereira and Ribeiro 2022].

- Processo engenharia de ontologias. Para a construção da ontologia AnotaMammo, é utilizada a metodologia *Ontology Development 101*[Noy et al. 2001] e os princípios de melhores práticas para a construção de ontologias de *Basic Formal Ontology* [Arp et al. 2015].
- Ontologia **AnotaMammo**, ou modelo estruturado de conhecimento. AnotaMammo é composta pela ontologia de anotação, a ontologia de domínio e os artefatos semânticos responsáveis pela fusão multimodal de informação.

### 3. Resultados

#### 3.1. Bases de Dados

As bases de dados utilizadas foram as seguintes: *Curated Breast Imaging Subset of DDSM* (CBIS-DDSM); *Categorized Digital Database for Low energy and Subtracted Contrast Enhanced Spectral Mammography images* (CDD-CESM); MAMMOSET e Vienna.

#### 3.2. Mineração de Imagem

O processo de mineração de imagem deste trabalho tem por objetivo analisar e classificar as ROIs de mamografia. Ele pode ser adaptado para outro tipo de imagem ou dado.

##### Classificação Massa/Calcificação

Os resultados de classificação utilizando diferentes arquiteturas podem ser vistos nas tabelas 1 e 2. Na tabela 1 o modelo criado pela arquitetura EfficientNetV2S apresenta os melhores resultados entre as arquiteturas. O *Ensemble - Averaging* é o melhor resultado. Quando comparado com outras abordagens o conjunto proposto apresenta resultados consistentes, como pode ser visto na tabela 2.

**Tabela 1. Acurácia(ACC) e AUC**

Model	Test ACC	AUC
Densenet121	0.8929	0.966
EfficientNet2VS	0.9167	0.964
Xception	0.8839	0.956
<i>Ensemble - Voting</i>	0.9196	<b>0.976</b>
<i>Ensemble - Averaging</i>	<b>0.9256</b>	<b>0.976</b>

**Tabela 2. Comparação**

Model	Accuracy
<i>[Khan et al. 2019]</i>	0.9373
<i>[Wang et al. 2016]</i>	0.8970
<i>[Agarwal and Carson 2015]</i>	0.8700
<i>Ensemble - Averaging</i>	<b>0.9256</b>

##### Classificação Benigno/Maligno

Para a classificação dos ROIs com a classe benigno ou maligno, optou-se por utilizar somente a arquitetura EfficientNetV2S. Na tabela 3 é possível observar os valores de precisão, revocação e *F1-Score* para cada uma das classes.

##### Composição dos modelos Massa/Calcificação e Benigno/Maligno

Foi analisado um modelo composto pela combinação dos modelos da arquitetura EfficientNetV2S para classificação de massa/calcificação e benigno/maligno. Essa composição combina as classes como: massa benigna, massa maligna, calcificação benigna e calcificação maligna. Na tabela 4 são apresentados os resultados. A classe massa benigna obteve a melhor precisão entre as quatro classes, no valor de 0.7660. A classe calcificação benigna obteve melhor revocação e *F1-Score* com valores de 0.8679 e 0.7480, respectivamente. O valor da revocação da classe calcificação maligna é de apenas 33%. A acurácia da composição sobre o conjunto de teste foi de 0.6577.

**Tabela 3. Resultados de classificação para benigno e maligno**

Modelo	Classe	Precision	Recall	F1-Score
EfficientNetV2S	Benign	0.7650	0.8174	0.7903
	Malign	0.6078	0.5299	0.5662
Test Accuracy	Test Loss	Validation Accuracy	Validation Loss	AUC
0.7173	0.5503	0.7402	0.4978	0.765

**Tabela 4. Resultados de classificação**

Classe	Precision	Recall	F1-Score
<i>Mass benign</i>	<b>0.7660</b>	0.6372	0.6957
<i>Mass malign</i>	0.5634	0.6061	0.5839
<i>Calcification benign</i>	0.6571	<b>0.8679</b>	<b>0.7480</b>
<i>Calcification malign</i>	0.5484	0.3333	0.4146
<b>Accuracy</b>	<b>0.6577</b>		

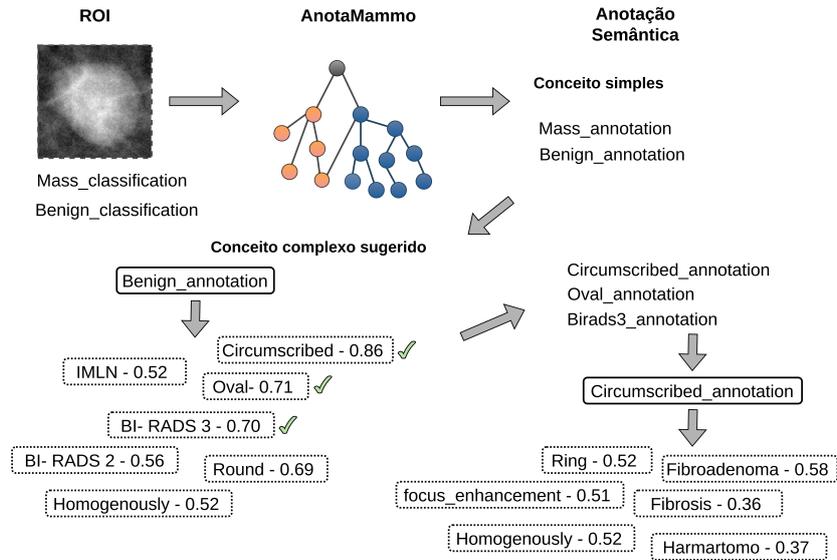
### 3.3. Anotação Semântica

A AnotaMammo é a ontologia que possibilita a anotação semântica das imagens médicas. Na figura 1 um exemplo de uma imagem classificada como massa e benigno. Inicialmente, são inseridos na AnotaMammo a imagem e as classificações obtidas. Em seguida, as primeiras anotações que a imagem recebe são os conceitos simples conforme a classificação. Nesse caso, a imagem recebe a anotação dos conceitos simples *mass\_annotation* e *benign\_annotation*. Logo após, os conceitos complexos similares à anotação são sugeridos conforme as anotações iniciais. No exemplo ilustrado, são sugeridos os termos complexos para *benign\_annotation*, como *circumscribed* com 0.86 de similaridade, *oval* com 0.71 de similaridade e *Birads 3* com 0.70 de similaridade. Ao selecionar uma anotação a ser incluída na imagem, outras sugestões de conceitos complexos são propostas. Por exemplo, ao anotar a imagem com o conceito complexo *circumscribed*, são sugeridos os conceitos complexos *fibroadenoma* com 0.58 de similaridade, *ring* com similaridade de 0.52 e *fibrosis* com 0.36. As sugestões de conceitos complexos que foram selecionadas são de fato anotadas na imagem. Essa seleção pode ser realizada pelo especialista médico. A título de exemplo, os conceitos complexos selecionados foram aqueles que constavam nos relatórios médicos utilizados nesta pesquisa de doutorado.

#### Exemplo de anotação de indivíduo na AnotaMammo

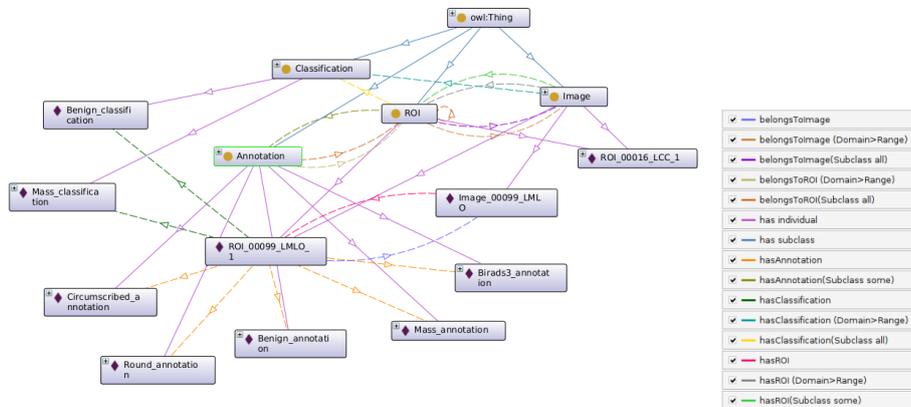
Na figura 2 é apresentado o resultado da anotação do indivíduo ROI\_00099\_LMLO\_1 com conceitos simples e conceitos complexos. Também pode-se observar as relações entre classes e indivíduos. Os indivíduos são identificados por um losango roxo. As linhas contínuas indicam que o indivíduo pertence a uma classe, ou entre duas classes que indica a relação de subclasse. As linhas pontilhadas indicam as propriedades. As cores diferenciam as propriedades e podem ser consultadas na legenda.

Na parte inferior da figura 2, o ROI\_00099\_LMLO\_1 *belongsToImage* Image\_00099. Possui a classificação *mass\_classification* e *benign\_classification*. E,



**Figura 1. Processo de Anotação Semântica**  
 Fonte: Elaborada pela autora.

possui as anotações de conceito simples *mass\_annotation* e *benign\_annotation*. Além das anotações dos conceitos complexos, *circumscribed\_annotation*, *round\_annotation* e *Birads3\_annotation*.



**Figura 2. Anotação Semântica pela AnotaMammo do ROI\_00099\_LMLO\_1. Anotações dos conceitos simples massa e benigno, e anotações dos conceitos complexos *circumscribed*, *round* e *Birads 3***  
 Fonte: Elaborada pela autora.

#### 4. Discussão

O método MUSA foi proposto com o objetivo de classificar e anotar semanticamente imagens médicas, utilizando fusão de informações multimodais. O método integrou diferentes processos para atingir o objetivo. O processo de mineração de texto foi responsável por estabelecer as características contextuais, a partir de relações de similaridade e coocorrência entre pares de palavras presentes em um mesmo laudo. O processo

de mineração de imagem foi responsável por classificar a imagem de mamografia. A abordagem utilizada é uma estratégia *end-to-end deep learning*, e inclui o aprendizado por transferência, por meio do ajuste fino e definição de hiperparâmetros. O processo de engenharia de ontologias foi responsável pela construção da AnotaMammo, composta pela ontologia de anotação, a ontologia de domínio e os artefatos semânticos.

Para a classificação de *mass/calcification* a arquitetura EfficientNetV2S apresentou os melhores resultados, obtendo mais de 91% de acurácia sobre o conjunto de teste. O *ensemble-averaging* obteve acurácia superior a 92%, resultados similares e até melhores quando comparados com outros trabalhos da literatura. Para classificação de *benign/malign* a taxa de acurácia obtida foi de 71%. Os resultados obtidos com a combinação dos dois modelos para classificação de quatro classes, a acurácia foi de 65%. As classes inferidas pelo processo de classificação são utilizadas como termos iniciais para o processo de anotação semântica das imagens.

Por fim, foram apresentados os resultados obtidos com o processo de anotação semântica da imagem. A partir dos termos iniciais da classificação são realizadas as primeiras anotações de conceitos simples nas imagens. Em seguida, conceitos complexos são sugeridos e conforme são selecionados como relevantes pelo especialista de domínio, novos conceitos complexos são sugeridos. Os resultados demonstraram que a AnotaMammo permitiu enriquecer semanticamente os termos iniciais provenientes da classificação da imagem, além de propiciar a fusão das informações multimodais.

## Referências

- Agarwal, V. and Carson, C. (2015). Using deep convolutional neural networks to predict semantic features of lesions in mammograms. *C23 In Course Project Reports*.
- Arp, R., Smith, B., and Spear, A. D. (2015). *Building ontologies with basic formal ontology*. Mit Press.
- Khan, H. N., Shahid, A. R., Raza, B., Dar, A. H., and Alquhayz, H. (2019). Multi-view feature fusion based four views model for mammogram classification using convolutional neural network. *IEEE Access*, 7:165724–165733.
- Levy, O., Goldberg, Y., and Dagan, I. (2015). Improving distributional similarity with lessons learned from word embeddings. *Transactions of the association for computational linguistics*, 3:211–225.
- Noy, N. F., McGuinness, D. L., et al. (2001). *Ontology development 101: A guide to creating your first ontology*.
- Pereira, J. W. and Ribeiro, M. X. (2021). Semantic annotation and classification of mammography images using ontologies. In *2021 IEEE 34th International Symposium on Computer-Based Medical Systems (CBMS)*, pages 378–383. IEEE.
- Pereira, J. W. and Ribeiro, M. X. (2022). Hyperparameter for deep learning applied in mammogram image classification. In *2022 IEEE 35th International Symposium on Computer-Based Medical Systems (CBMS)*, pages 90–95. IEEE.
- Wang, J., Yang, X., Cai, H., Tan, W., Jin, C., and Li, L. (2016). Discrimination of breast cancer with microcalcifications on mammography by deep learning. *Scientific reports*, 6(1):27327.