

Caracterização do Tecido Tireoidiano por Meio da Análise de Imagens Hiperespectrais Utilizando Aprendizagem Profunda

Matheus de Freitas Oliveira Baffa¹, Joaquim Cezar Felipe¹

¹Departamento de Computação e Matemática
Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto
Universidade de São Paulo (USP)
14040-900 – Ribeirão Preto – SP – Brazil

mbaffa@alumni.usp.br, jfelipe@ffclrp.usp.br

Abstract. *Thyroid tissue classification is essential for identifying cellular anomalies in biopsies, aiding in the diagnosis of thyroid pathologies. Unlike traditional computer vision approaches, this thesis proposes a novel method based on the interaction of light with the tissue, represented by intensity spectra modeled as hyperspectral images. Six approaches were evaluated, including traditional and deep learning methods, with emphasis on one-dimensional convolutional neural networks, which achieved 97.60% accuracy. The results demonstrate superior efficiency in detecting pathologies compared to conventional analyses, highlighting the potential for advancements in modern pathology.*

Resumo. *A tipificação de tecidos tireoidianos é essencial para identificar anomalias celulares em biópsias, contribuindo para o diagnóstico de patologias da tireoide. Diferente das abordagens tradicionais de visão computacional, esta tese propõe uma metodologia inovadora baseada na interação da luz com o tecido, representada por espectros de intensidades, modelados como imagens hiperespectrais. Foram avaliadas seis abordagens, incluindo métodos tradicionais e profundos, com destaque para redes neurais convolucionais unidimensionais, que atingiram 97,60% de acurácia. Os resultados demonstram eficiência superior na detecção de patologias em comparação com análises convencionais, destacando o potencial para avanços na patologia moderna.*

1. Introdução

O câncer de tireoide é um tumor maligno que se origina nas células da glândula tireoide, uma estrutura localizada na região anterior do pescoço, responsável pela produção de hormônios essenciais para a regulação do metabolismo. De acordo com o último censo do [Instituto Nacional do Cancer 2022], foram estimados 4.820 novos casos de câncer de tireoide no Brasil em 2022, sendo 760 em homens e 4.060 em mulheres, o que o torna o terceiro tipo de tumor mais frequente em mulheres nas regiões Sudeste e Nordeste.

Apesar de, na maioria dos casos, o prognóstico ser favorável devido ao crescimento lento e à alta taxa de cura, o diagnóstico precoce ainda representa um desafio, especialmente em casos de variantes mais agressivas, como o carcinoma anaplásico [Limaiem et al. 2025]. A análise histopatológica, que consiste no exame microscópico de tecidos de biópsia, é o método padrão para o diagnóstico de câncer de tireoide. A crescente incidência da doença e a necessidade de métodos diagnósticos precisos reforçam a

importância de pesquisas que explorem novas abordagens para auxiliar na caracterização e no tratamento do câncer de tireoide.

Neste sentido, sistemas de visão computacional têm sido desenvolvidos para auxiliar os patologistas na análise de imagens histológicas. Embora os métodos tradicionais de visão computacional obtenham bons desempenhos na classificação de tecidos tireoidianos, eles frequentemente apresentam limitações em amostras que possuem mais de um tipo de diagnóstico, uma situação comum em biópsias. Além disso, a elevada variabilidade morfológica entre as amostras, especialmente quando se considera diferenças interpacientes, representa um desafio significativo, tornando a classificação ainda mais complexa e evidenciando a necessidade de abordagens mais robustas e generalizáveis.

Assim, surgem as imagens hiperespectrais (*hyperspectral imaging - HSI*), geradas a partir da captura de informações em múltiplas bandas do espectro eletromagnético. As imagens hiperespectrais têm a capacidade de representar, em cada pixel, um espectro de intensidade que reflete a interação da luz com o tecido biológico, permitindo a análise detalhada de características moleculares que não são perceptíveis em imagens convencionais [Hollas 2004].

A análise de imagens hiperespectrais apresenta uma dificuldade inerente devido à sua alta complexidade, resultante do grande volume de informações geradas. Em apenas um *voxel* que compõe a imagem hiperespectral, mais de 500 canais espectrais podem ser mensurados, criando um conjunto de dados de alta dimensionalidade que desafia as técnicas tradicionais de aprendizagem de máquina.

Na literatura, diversos estudos, como os de [Pathak et al. 2023, Liu et al. 2023, Du et al. 2023], utilizam métodos ópticos, como reflexão e espectroscopia Raman para a geração de espectros no intervalo visível de 450 a 900 nm. No entanto, métodos ópticos ainda pouco explorados, como a absorbância na faixa infravermelha (Micro-FTIR), surgem como alternativas promissoras, especialmente por permitir a aquisição de imagens no espectro infravermelho, uma faixa não visível que ainda não foi amplamente estudada.

Desta forma, este trabalho parte da hipótese de que é possível caracterizar e diferenciar o tecido tireoidal em câncer, saudável e bário utilizando a técnica de absorção no espectro infravermelho por meio do Micro-FTIR. A fim de validar essa hipótese e lidar com a alta complexidade dos dados hiperespectrais, o objetivo deste estudo é investigar e desenvolver metodologias avançadas de visão computacional, baseadas em técnicas de aprendizagem profunda, para analisar imagens hiperespectrais de tecidos tireoidianos.

Este trabalho adota uma abordagem multiclasse, classificando as amostras em três categorias, sendo elas câncer, saudável e bário, a partir de uma análise a nível de *voxel* (espectro), permitindo a geração de mapas de classificação que identificam precisamente as regiões do tecido doente. Para isso, seis métodos de classificação foram desenvolvidos e avaliados: dois aplicados a imagens digitais das lâminas coradas com hematoxilina e eosina (H&E) e quatro aplicados a imagens hiperespectrais. A combinação dessas abordagens visa explorar o potencial das imagens hiperespectrais no diagnóstico de patologias tireoidianas e comparar seu desempenho com métodos tradicionais baseados em imagens histológicas convencionais.

2. Materiais e Métodos

O desenvolvimento deste trabalho foi estruturado em três etapas principais: aquisição do material histológico e das imagens hiperespectrais, pré-processamento dos dados e classificação. Nesta seção, cada uma dessas etapas será descrita em detalhes.

2.1. Aquisição do Material Histológico e das Imagens Hiperespectrais

O material histológico analisado neste estudo foi adquirido da empresa Biomax Inc., com três lâminas específicas: uma contendo tecido cancerígeno, uma com tecido tireoidiano saudável e outra com tecido de bório. Foram obtidas 240 amostras, igualmente distribuídas entre as lâminas, com diâmetros variando de 1,0 a 1,5 mm. O diagnóstico inicial foi realizado pela Biomax com a avaliação de dois patologistas e, posteriormente, confirmado por mais dois especialistas, sendo um da Faculdade de Medicina de Ribeirão Preto (FMRP-USP) e outro do Departamento de Patologia do Hospital das Clínicas de Ribeirão Preto.

As imagens digitais foram geradas com um microscópio Olympus BX61VS, utilizando uma objetiva de 40x para melhor detalhamento das estruturas celulares. Cada uma das 240 amostras foi digitalizada, totalizando 80 imagens para cada classe de diagnóstico, sendo posteriormente utilizadas na análise baseada em visão computacional.

Os espectros hiperespectrais foram adquiridos em cortes paralelos às amostras coradas com H&E, empregando o sistema *Perkin Elmer Spotlight 400*. As medições, realizadas em ambiente com umidade controlada abaixo de 5%, abrangeram a faixa de 778 a 1800 nm, com espaçamento de 2 nm, resultando em *voxels* com 512 canais espectrais. Essa abordagem permite a análise da intensidade de absorção da radiação infravermelha e a construção de mapas de classificação que identificam, com precisão, as regiões afetadas no tecido.

2.2. Pré-Processamento dos Dados

O pré-processamento foi realizado por meio de duas *pipelines* distintas, uma para as imagens de H&E e outra para as imagens hiperespectrais. O objetivo do pré-processamento das imagens de H&E foi realçar a coloração, dada a baixa intensidade observada em algumas amostras. Já a pipeline para as imagens hiperespectrais buscou remover componentes irrelevantes, como o colóide e o sangue, otimizando a análise espectral.

2.2.1. Pipeline de Processamento das Imagens de H&E

Inicialmente, foram recortadas as regiões de interesse com a orientação de um patologista especializado em tecidos tireoidianos, garantindo a seleção de áreas relevantes para o diagnóstico. Em seguida, foi aplicada a técnica de normalização *contrast limited adaptive histogram equalization* (CLAHE) de forma independente a cada canal no espaço de cores RGB. O CLAHE, ao limitar o contraste nas regiões homogêneas, evita a amplificação de ruídos e preserva detalhes importantes da estrutura tecidual, o que contribui para uma análise mais eficiente das amostras.

2.2.2. Pipeline de Processamento das Imagens Hiperespectrais

A segmentação das regiões celulares foi realizada em cinco etapas. Primeiramente, selecionou-se a frequência de 1624 nm, que apresentou melhor diferenciação entre os tecidos, para a geração de uma imagem em tons de cinza com normalização MinMax ajustada para o intervalo [0, 255]. Posteriormente, a imagem foi transformada para o domínio da frequência utilizando a Transformada Rápida de Fourier (FFT) e aplicado um filtro passa-alta para destacar as bordas. Na sequência, realizou-se uma limiarização com valor limite definido em 127, seguida de uma etapa de abertura morfológica para refinar a segmentação. Por fim, o conjunto de voxels hiperespectrais foi normalizado com o *Standard Scaler* e submetido a um processo de *data augmentation* com ruído gaussiano, aplicado exclusivamente à base de teste, visando aumentar a variabilidade e a capacidade de generalização do modelo.

2.3. Metodologias de Classificação

Foram desenvolvidas seis metodologias de classificação, sendo duas voltadas para as imagens de H&E e quatro para os dados hiperespectrais. Para a análise das imagens de H&E, foi implementada uma CNN inspirada na arquitetura VGG-11, adaptada para o contexto deste estudo, com o objetivo de identificar padrões morfológicos relevantes. Além disso, foram extraídas 93 características radiométricas, abrangendo estatísticas de primeira ordem (*FirstOrder*) e texturas derivadas de matrizes como *gray-level co-occurrence matrix* (GLCM), *gray-level run length matrix* (GLRLM), *gray-level size zone matrix* (GLSZM), *gray-level dependence matrix* (GLDM) e *neighborhood gray tone difference matrix* (NGTDM). Essas características foram normalizadas com *standard scaler* e utilizadas para treinar uma rede neural densa de 12 camadas, configurada a partir de experimentos de ablação.

Para a análise dos sinais hiperespectrais, foram avaliadas quatro abordagens distintas. O primeiro método consiste em um *benchmark* com 11 algoritmos tradicionais de aprendizagem de máquina, incluindo árvore de decisão, máquinas de vetores suporte e XGBoost, utilizando as configurações padrão das respectivas bibliotecas. Além disso, foram implementadas três arquiteturas de redes neurais profundas: uma rede densa totalmente conectada (FCNN), uma rede neural convolucional unidimensional (1D-CNN) e uma rede recorrente (LSTM-RNN). As redes foram desenvolvidas no TensorFlow, com parâmetros ajustados por experimentação. O objetivo das metodologias foi classificar os voxels hiperespectrais, gerando mapas que permitem identificar, com precisão, as regiões de tecido associadas a cada classe: câncer, saudável e bário.

3. Experimentos e Resultados

Os experimentos foram realizados utilizando a abordagem de *k-fold cross-validation*, com $k = 10$, visando uma avaliação robusta e confiável dos modelos. Para cada um dos seis métodos desenvolvidos, foram calculadas as métricas de desempenho: acurácia, precisão, sensibilidade, especificidade e a área sob a curva ROC (AUC). Essa estratégia permite uma análise abrangente, reduzindo o impacto da variabilidade dos dados e assegurando uma estimativa consistente da capacidade preditiva dos modelos.

3.1. Resultados

A análise das imagens de H&E utilizando a CNN customizada apresentou resultados satisfatórios, com acurácia, precisão e revocação de 88,73%, além de uma AUC de 94,41%, indicando uma boa capacidade do modelo em distinguir as diferentes classes teciduais. Por sua vez, a metodologia baseada na extração de características radiômicas obteve um desempenho ainda melhor, alcançando 91,94% de acurácia, 92,08% de sensibilidade, 96,00% de especificidade, 93,09% de precisão e uma AUC de 97,33%. Esses resultados demonstram a eficácia das abordagens propostas para a caracterização de tecidos tireoidianos a partir de imagens histológicas tradicionais.

A análise das imagens hiperespectrais revelou resultados expressivos tanto com os métodos tradicionais quanto com as abordagens baseadas em aprendizado profundo. Entre os algoritmos tradicionais, o melhor desempenho foi obtido pela SVM de base radial, que alcançou uma acurácia de 92,59%, sensibilidade de 92,78%, especificidade de 93,62%, precisão de 93,62% e uma AUC de 98,19%.

Já entre os modelos de aprendizagem profunda, a CNN 1D destacou-se com o melhor desempenho, obtendo uma acurácia de 97,60%, sensibilidade de 97,60% e uma especificidade de 97,60%. A LSTM-RNN também apresentou resultados robustos, com 96,88% de acurácia e uma AUC de 98,87%, enquanto a FCNN alcançou 93,66% de acurácia e uma AUC de 98,62%. Esses resultados indicam o potencial das abordagens baseadas em aprendizado profundo na análise de imagens hiperespectrais, superando o desempenho das técnicas tradicionais. A Tabela 1 contém a média dos resultados da validação cruzada de cada método.

Tabela 1. Resultados gerais obtidos nas seis análises propostas.

Classificador	Imagen	Acurácia	Precisão	Sen.	Esp.	AUC
VD-CNN	H&E	88,73%	88,73%	88,73%	-	94,41%
Radiomica	H&E	91,94%	92,08%	96,00%	97,33%	93,09%
SVM Radial	HSI	92,59%	92,78%	93,62%	93,62%	98,19%
FCNN	HSI	93,66%	93,84%	93,47%	96,93%	98,62%
LSTM-RNN	HSI	96,88%	96,90%	96,87%	98,45%	98,87%
CNN 1D	HSI	97,60%	97,69%	97,60%	97,60%	99,61%

Fonte: Elaborado pelo autor.

3.2. Discussão

Os resultados obtidos neste estudo indicam que a análise hiperespectral apresentou desempenho superior em relação à análise das imagens de H&E. A CNN 1D destacou-se entre todas as metodologias avaliadas, alcançando a maior acurácia devido à sua capacidade de representar com eficiência os espectros hiperespectrais e extrair características relevantes para a diferenciação entre as classes de tecido.

A LSTM-RNN também apresentou resultados expressivos, evidenciando o potencial das arquiteturas de aprendizado profundo que conseguem explorar a estrutura sequencial dos dados espetrais. Esses modelos demonstraram ser mais apropriados do que abordagens tradicionais e generalistas, que não aproveitam adequadamente as características específicas dos sinais hiperespectrais.

Entretanto, a implementação clínica das imagens hiperespectrais apresenta desafios adicionais, uma vez que sua aquisição depende de equipamentos específicos, como o especlômetro, diferentemente da análise baseada em H&E, que utiliza equipamentos comuns nos laboratórios de patologia. Além disso, o custo computacional da análise hiperespectral é significativamente maior, devido à alta dimensionalidade e complexidade dos dados. Por exemplo, enquanto a CNN para as imagens de H&E consumiu cerca de 6 GB de RAM, a CNN 1D para os dados hiperespectrais utilizou 16 GB, a FCNN 24 GB e a LSTM-RNN exigiu 77 GB.

Por fim, o método proposto pode ser aplicado a outros tipos de tecidos, desde que seja desenvolvido um protocolo de pré-processamento adequado para cada caso. No tecido tireoidiano, o objetivo foi a remoção do colóide, uma estrutura não encontrada em tecidos como os da mama e da boca, que podem exigir abordagens específicas para garantir a qualidade da análise e a correta caracterização dos tecidos.

4. Conclusão

Os resultados deste estudo confirmam a hipótese inicial, demonstrando que a análise hiperespectral com o Micro-FTIR, aliada a técnicas de aprendizado profundo, foi capaz de diferenciar com precisão o tecido tireoidiano nas classes câncer, saudável e bário. A CNN 1D obteve o melhor desempenho, com 97,60% de acurácia, destacando o potencial dessa abordagem. Apesar dos desafios operacionais e computacionais, os achados indicam que a metodologia proposta é uma alternativa promissora para aplicações diagnósticas. Em trabalhos futuros, é possível estudar ainda mais técnicas avançadas de aprendizagem profunda e, bem como, abordar a coleta de dados utilizando equipamentos de menor custo.

Referências

- Du, J., Tao, C., Xue, S., and Zhang, Z. (2023). Joint diagnostic method of tumor tissue based on hyperspectral spectral-spatial transfer features. *Diagnostics*, 13(12):2002.
- Hollas, J. M. (2004). *Modern spectroscopy*. John Wiley & Sons.
- Instituto Nacional do Cancer (2022). Câncer de tireoide. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/tireoide>. Acessado em 13 de fev. de 2025.
- Limaiem, F., Kashyap, S., Naing, P. T., et al. (2025). *Anaplastic Thyroid Cancer*. Stat-Pearls Publishing, Treasure Island (FL). [Atualizado em 29 out. 2024]. Disponível em: <https://www.ncbi.nlm.nih.gov/books/NBK538179/>. Acesso em: 13 fev. 2025.
- Liu, X., Wang, M., Zhang, K., Zhang, H., and Lai, Y. (2023). Diagnostic strategy for malignant and benign thyroid nodules smaller than 10 mm based on surface-enhanced raman spectroscopy and machine learning. *Chemical Engineering Journal*, 471:144794.
- Pathak, P., Chalopin, C., Zick, L., Köhler, H., Pfahl, A., Rayes, N., Gockel, I., Neumuth, T., Melzer, A., Jansen-Winkel, B., et al. (2023). Spectral similarity measures for in vivo human tissue discrimination based on hyperspectral imaging. *Diagnostics*, 13(2):195.