

Classificação de Doença Hepática Gordurosa Não Alcoólica em Imagens Térmicas usando *Temporal Convolutional Networks*

Marcos Vinícius de Sousa Farias¹, Italo Francyles Santos da Silva¹,
Aristófanés Corrêa Silva¹, Henrique Manoel de Araújo Martins Filho²,
Anselmo Cardoso Paiva¹

¹Núcleo de Computação Aplicada – Universidade Federal do Maranhão (UFMA)
Av. dos Portugueses, 1966 - Vila Bacanga, São Luís - MA, 65080-805

²Alchimia

Rua Mar. Castelo Branco 31, Olho D'água, São Luís, MA, Brasil, 65065-090

{marvinfar852, francyles, ari, paiva}@nca.ufma.br
hmartinsfilho@globo.com

Abstract. *Among the existing liver pathologies, Non-Alcoholic Fatty Liver Disease (NAFLD) is the one that affects the largest portion of the world's population, approximately 2 billion people. NAFLD has considerable chances of progressing to more severe clinical conditions, such as fibrosis and liver cirrhosis, representing serious risks to the lives of patients. Thus, it is vital that its detection be done in an agile, accurate and preferably non-invasive way, with the use of thermal images being a highly supported method in this area. The present work presents the development of a model for classifying NAFLD from time series in thermographs. Temporal Convolutional Networks combined with image processing strategies were used in the composition of the proposal.*

Resumo. *Dentre as patologias hepáticas existentes, a Doença Hepática Gordurosa Não Alcoólica (DHGNA) é aquela que afeta a maior parcela da população mundial, aproximadamente 2 bilhões de pessoas. A DHGNA possui chances consideráveis de evoluir para quadros clínicos mais graves, como fibrose e cirrose hepática, representando sérios riscos à vida dos pacientes. Desse modo, é vital que sua detecção seja feita de maneira ágil, precisa e preferencialmente não invasiva, sendo a utilização de imagens térmicas um método de grande respaldo nesse âmbito. O presente trabalho apresenta o desenvolvimento de um modelo de classificação de DHGNA a partir de séries temporais em termografias. Foram utilizadas Temporal Convolutional Networks aliadas a estratégias de processamento de imagens na composição da proposta.*

1. Introdução

Com cerca de 40% da população mundial estando obesa ou com sobrepeso, a Doença Hepática Gordurosa Não Alcoólica (DHGNA) vem se tornando um problema de saúde de crescimento alarmante, afetando aproximadamente 25% da população adulta no mundo [Schwabe et. al, 2020]. Sua ocorrência se dá em indivíduos que não possuem um histórico de consumo alcoólico significativo e geralmente está relacionada a síndromes metabólicas

[Cotrim et. al 2016]. Em resumo, a DHGNA é uma patologia frequente, em geral assintomática, mas de amplo espectro e potencial de evolução para cirrose e carcinoma hepatocelular, trazendo sérios riscos à saúde dos pacientes.

Segundo Santana et. al (2021), para o diagnóstico da DHGNA, a biópsia hepática continua sendo o exame mais específico para avaliar a natureza e a gravidade da infiltração gordurosa no fígado. No entanto, seu custo e o potencial de complicações levaram a um interesse no desenvolvimento de novos métodos não invasivos para a prática clínica. Nesse sentido, termografias são amplamente utilizadas como método pródromo de detecção, pois, para o espectro de patologias que a DHGNA enxerga, é comum que padrões irregulares de temperatura sejam gerados sobre a área da pele que cobre o fígado [Farooq and Corcoran 2020].

No cenário da análise de imagens via métodos computacionais, as *Convolutional Neural Networks* (CNN) tem sido utilizadas de maneira vasta para tarefas de classificação de imagens. Esse tipo de rede vem atingindo resultados bastante expressivos em algumas pesquisas relacionadas à área médica [Yadav and Jadhav 2019]. Nesse âmbito, o estudo realizado por Zuluaga-Gomes et.al (2020) busca desenvolver uma nova metodologia de detecção de câncer de mama com base em imagens térmicas. Seus resultados demonstraram um alto índice de acerto, provando assim a eficácia de CNNs nessa proposta. Os autores foram capazes de alcançar métricas de 92% para acurácia, 94% para precisão e 92% para F1-score. Pinto et. al (2021) aplicaram em seu trabalho uma combinação de técnicas de processamento de imagens térmicas com a CNN AlexNet. O objetivo era a classificação dos pacientes como portadores de DHGNA ou não, demonstrando resultados excelentes com todas as métricas atingindo valores superiores a 90%.

A partir das CNNs, tivemos o recente advento das *Temporal Convolutional Networks* (TCNs), que são modelos capazes de superar as adversidades encontradas na captura de padrões utilizando uma hierarquia de filtros temporais convolucionais [Lea et. al 2017]. Sua capacidade de reconhecer estruturas em dados sequenciais é notável, sendo bastante utilizada para problemas dessa natureza.

Tendo conhecimento da importância de medidas para diagnósticos precoces para detecção de DHGNA, seu amplo impacto ao redor do mundo [Younossi et. al 2017] e a alta taxa de mortalidade associada a essa patologia [Cotrim et. al 2016], o presente trabalho propõe um modelo de classificação de imagens térmicas através de suas características temporais visando o diagnóstico da DHGNA. Para esse fim, utilizou-se uma rede Temporal Convolutional aliada a técnicas de pré-processamento.

2. Materiais e Método

Nesta Seção, são apresentadas informações sobre a base de dados utilizada, bem como o aprofundamento acerca do método proposto para a classificação de imagens térmicas.

2.1. Base de Imagens

O *dataset* de termografias utilizado no presente trabalho foi adquirido no LIT - Laboratório de Imagem Térmica da Clínica Alchimia, localizada na Rua Marechal Castelo Branco 31, Olho D' Água, São Luís - MA. As imagens foram capturadas através de um termógrafo de sensor infravermelho FLIR - Modelo S650C. Durante 15 minutos os pacientes passaram por um processo de aclimatização, em temperatura ambiente de 23°C

e umidade relativa do ar de 65%. São capturadas em média 5 imagens por paciente, de modo que cada fotografia é realizada com um breve intervalo de tempo em relação às demais. O diagnóstico desses pacientes para a DHGNA foi realizado pelo especialista através de ultrassonografia da região abdominal.

2.2. Método Proposto

A Figura 1 elucida graficamente as diversas etapas que dão forma a este trabalho, desde o pré-processamento, transformação das imagens em séries temporais e classificação. Estas etapas serão discutidas com maior profundidade no decorrer desta Seção.

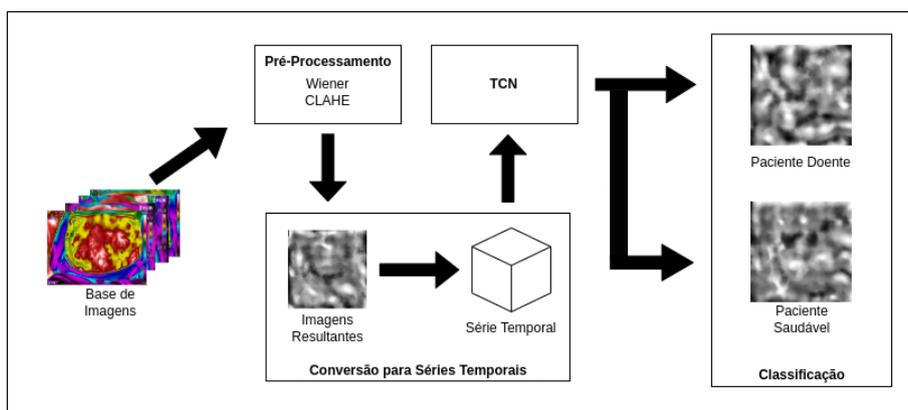


Figura 1. Visão geral do método proposto.

Como passo inicial deste método, devem ser extraídas as regiões de interesse (ROIs) que representam os dados que queremos. Segundo Ozougwu (2017) e Brioschi et al. (2006), a região hepática é localizada no quadrante superior direito do abdômen. Essas regiões foram extraídas através do software especializado *FLIR Tools*. Durante essa etapa foram geradas imagens de dimensão 200x200 com o auxílio de um especialista (Figura 2). Essas imagens tentam captar da melhor maneira a região hepática para cada paciente, visto que há diferenças fisiológicas entre eles. As ROIs delimitadas foram exportadas como tabelas de temperaturas, onde cada elemento da tabela corresponde à temperatura do pixel de mesma posição na imagem delimitada.

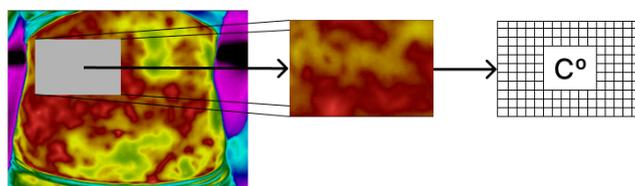


Figura 2. Extração da ROI realizada na imagem anterior

2.2.1. Pré-Processamento

Após a coleta das ROIs como tabelas de temperatura, as mesmas foram transformadas em imagens térmicas com escala de cinza a partir da Equação 1. Os valores *oldMin* e

$oldMax$ representam a menor e maior temperatura entre todas as imagens da base, respectivamente. $NewMin$ e $newMax$ referem-se aos valores de máximo e mínimo da nova escala para qual estamos transformando nossas imagens (0 e 255).

$$f(t) = \frac{(t * 1000 - oldMin) * (newMax - newMin)}{(oldMax - oldMin)} + newMin \quad (1)$$

Após esse passo foram realizados procedimentos para evidenciar características que tornem a classificação mais acurada. Foram aplicadas as técnicas de remoção de ruído Wiener [Wahab et al. 2018] e equalização de histograma adaptativa CLAHE [Zuluaga-Gomez et al. 2020]. Realizada a etapa de pré-processamento, as imagens resultantes (Figura 3) serão submetidas para as próximas etapas do método proposto.

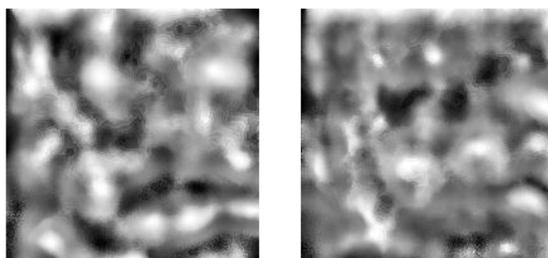


Figura 3. Imagens resultantes do pré-processamento. Exemplos de um paciente doente (direita) e um saudável (esquerda)

2.2.2. Conversão para Séries Temporais e Classificação

A TCN é uma arquitetura de redes neurais profundas proposta por [Lea et. al 2017]. Sua proposta visa superar os modelos neurais utilizados para detecção de padrões em dados temporais até então, como a rede *Long Short Term Memory* (LSTM). Para isso, eles buscam superar o problema de desaparecimento de gradiente enfrentado por outras redes ao tentar admitir longas séries temporais como entrada. Em seu artigo, duas arquiteturas são apresentadas, aquela utilizada nesse trabalho é a *Dilated-TCN*.

A presente proposta se baseia no aspecto temporal da base de imagens e na capacidade da TCN de capturar as características que a passagem do tempo evidencia nesses dados. Para alimentar a rede com nossos dados, primeiramente se realiza uma operação de *flatten* (achatamento) na imagem, de modo que ela se torne unidimensional. Foram utilizadas três imagens por paciente em cada entrada da rede, de modo que as imagens escolhidas capturem da melhor maneira a passagem do tempo. Visando essa característica, foram escolhidas as imagens que representam o início, meio e fim da sequência temporal. Por exemplo, se tivermos um paciente com 5 imagens, estas seriam as imagens 1, 3 e 5, respectivamente. Após a escolha dos dados, estes são concatenados verticalmente em uma matriz de dimensões 3 x 40000, sendo 3 o número de imagens (*timesteps*) e 40000 a representação unidimensional da imagem de 200x200 (após o *flatten*). Finalizando essa etapa, as matrizes foram armazenadas sequencialmente em um vetor tridimensional, onde cada uma delas representa um índice nesse "bloco tridimensional". A Figura 4 demonstra graficamente o arranjo que foi realizado com os dados.

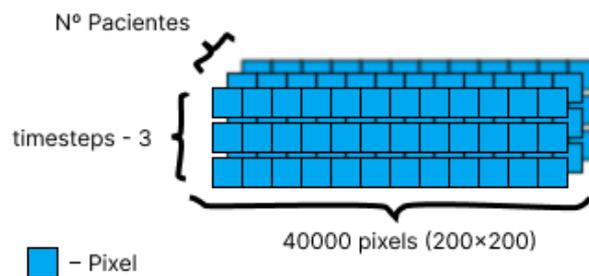


Figura 4. Conversão das imagens em séries temporais e preparação dos dados de entrada da rede TCN.

3. Resultados e Discussão

Foi realizado um procedimento de *Data Augmentation* para expandir o tamanho original de nossa base, cuja quantidade original era de 113 imagens de pacientes com DHGNA e 132 de pacientes saudáveis. Esse número foi expandido através da realização de *flips* verticais, horizontais e rotações de 90° nas imagens, passando assim para 452 de pacientes com DHGNA e 528 saudáveis. Para o treinamento, a base foi dividida utilizando a proporção 60:20:20, em que 60% dos pacientes vão para o treino, 20% para validação e 20% para teste. A rede foi treinada por 200 épocas utilizando a função de perda *binary crossentropy* e otimizador *adam*. Foram utilizadas as bibliotecas TensorFlow¹ (versão 2.11) e OpenCV² (versão 4.6.0). Encerrada esta etapa, foram extraídas as métricas de avaliação, cujos resultados foram uma Acurácia de 72%, Sensibilidade de 79%, Especificidade de 67% e Precisão de 65%.

Esses números apontam uma melhor capacidade de detecção dos pacientes com DHGNA, visto que a sensibilidade é o índice de resultado mais significativo. Em contraste, a precisão apresenta o pior valor, o que nos leva a constatar que um grande número de falsos positivos está sendo gerado. Essa relação se mantém no trabalho de Pinto et. al (2021), onde sua precisão alcançou um valor de 91%, enquanto sua acurácia foi de 96% e sua especificidade de 97%. Podemos então, supor que algumas imagens da base apresentam maior dificuldade de classificação, seja pela maneira como a extração da região hepática se deu, ou pelo resultado das técnicas de pré-processamento aplicadas. A alta dimensionalidade que os dados apresentam também pode contribuir para a dificuldade na classificação, onde uma possível solução seria a divisão das sequências temporais em patches.

4. Conclusão

Após a obtenção das métricas, podemos analisar as falhas e méritos desse trabalho, assim como as propostas para o melhoramento do método proposto. O modelo atualmente apresenta resultados promissores, apesar de menos expressivos que outros trabalhos. Um ponto relevante nesse contexto é o fato de que a base de imagens utilizada neste trabalho ainda está em expansão, não possuindo um número tão abrangente de dados para uso. Finalmente, estudos adicionais se fazem necessários para determinar a usabilidade

¹<https://www.tensorflow.org/>

²<https://opencv.org/>

de modelos convolucionais temporais na predição da DHGNA em pacientes através de termografias.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, Fundação de Amparo a Pesquisa do Maranhão (FAPEMA), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Empresa Brasileira de Serviços Hospitalares (Ebsers) Brazil (Proc. 409593/2021-4).

5. Referências

Brioschi, M. L., Yeng, L. T., Colman, D., Silva, F. M. M., and Teixeira, M. J. (2006). Imagiologia infravermelha no estudo avançado da dor de origem visceral.

Cotrim, H. P., Parise, E. R., Figueiredo-Mendes, C., Galizzi-Filho, J., Porta, G., and Oliveira, C. P. (2016). Nonalcoholic fatty liver disease brazilian society of hepatology consensus. *Arquivos de gastroenterologia*.

Farooq, M. A. and Corcoran, P. (2020). Infrared imaging for human thermography and breast tumor classification using thermal images. In *2020 31st Irish Signals and Systems Conference (ISSC)*, pages 1–6. IEEE

Lea, C., Flynn, M. D., Vidal, R., Reiter, A., Hager, G. D. (2017). Temporal convolutional networks for action segmentation and detection. In *proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.

Ozougwu, J. C. (2017). Physiology of the liver. *International Journal of Research in Pharmacy and Biosciences*, 4(8):13–24

Santana, J. T., Mota, A. V. H., Gonzaga, Y. H. G., Gomes, R. M. O. P., Melo, L. C., Noronha, V. F. C. M., Santos, A. C. O. L., de Jesus, J. B., Lima, S. O., and Cruz, J. F. (2021). Perfil metabólico e antropométrico dos pacientes obesos e não obesos portadores de esteatose hepática não alcoólica. *Revista Eletrônica Acervo Saúde*, 13(2):e5525–e5525.

Schwabe, R. F., Tabas, I., and Pajvani, U. B. (2020). Mechanisms of fibrosis development in nonalcoholic steatohepatitis.

Wahab, A. A., Salim, M., Yunus, J., and Ramlee, M. H. (2018). Comparative evaluation of medical thermal image enhancement techniques for breast cancer detection. *Journal of Engineering and Technological Sciences*.

Yadav, S. S. and Jadhav, S. M. (2019). Deep convolutional neural network based medical image classification for disease diagnosis.

Younossi, Zobair, et al. "Global burden of NAFLD and NASH: trends, predictions, risk factors and prevention." *Nature reviews Gastroenterology & hepatology* 15.1(2018)

Zuluaga-Gomez, J., Al Masry, Z., Benagoune, K., Meraghni, S., and Zerhouni, N. (2020). A cnn-based methodology for breast cancer diagnosis using thermal images. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging Visualization*.