

CLASSIFICAÇÃO AUTOMÁTICA DE IMAGENS COM AMOSTRAS BIOLÓGICAS UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Guilherme Grecco Bononi (PIBIC/CNPq/FA/UEM), Yandre Maldonado e Gomes da Costa (Orientador), Franklin César Flores (Coorientador). E-mail: yandre@din.uem.br.

Universidade Estadual de Maringá, Departamento de Informática, Maringá, PR.

Área e subárea do conhecimento: Ciências Exatas e da Terra, Ciência da Computação /Metodologia e Técnicas da Computação.

Palavras-chave: Deep Learning; Timo; Rim.

RESUMO

Este projeto abordou a classificação de imagens histopatológicas em dois cenários distintos, provenientes do Laboratório de Plasticidade Neural Entérica da UEM: a identificação de corpúsculos renais em amostras de indivíduos com câncer e a distinção de tecido do timo de ratos saudáveis e estressados. Foi realizada uma comparação sistemática entre a abordagem clássica de visão computacional, baseada em características handcrafted, e uma metodologia de aprendizado profundo (Deep Learning) com a arquitetura EfficientNetV2-B0. Todos os experimentos foram validados com um rigoroso protocolo Leave-One-Group-Out (LOGO) para garantir a generalização dos resultados. Para a base do rim, o Deep Learning superou os métodos handcrafted (acurácia de 90,43% vs 85,39%). Na base do timo, o Deep Learning alcançou 87,66%, superando o teto de performance dos métodos clássicos de 80,86%. Os resultados validam um protocolo metodológico robusto e generalizável para a classificação de imagens histopatológicas.

INTRODUÇÃO

A análise quantitativa de imagens histopatológicas é um pilar da pesquisa pré-clínica, mas enfrenta desafios como a alta variabilidade visual dentro das classes e as diferenças sutis entre elas. Tradicionalmente, a classificação automatizada utilizava características projetadas manualmente (handcrafted) para capturar propriedades visuais específicas. Mais recentemente, o campo passou por uma mudança de paradigma em direção ao Deep Learning, onde as Redes Neurais Convolucionais (CNNs) aprendem a extrair características relevantes diretamente dos dados brutos, frequentemente alcançando o estado da arte (LeCun et al., 1989). O presente trabalho se insere neste contexto, propondo o desenvolvimento de um protocolo de classificação para dois conjuntos de imagens biológicas. O primeiro conjunto contém imagens de corpúsculos renais para distinguir entre indivíduos

saudáveis e com câncer, enquanto o segundo é composto por amostras de timo de ratos saudáveis e submetidos a estresse intenso. O objetivo central é comparar de forma sistemática as abordagens handcrafted e de Deep Learning para determinar a metodologia mais eficaz para estes cenários.

MATERIAIS E MÉTODOS

Ambos os conjuntos de dados foram fornecidos pelo Laboratório de Plasticidade Neural Entérica da UEM. A base de rim consiste em 280 imagens de 14 indivíduos (sete saudáveis e sete com câncer) (CARVALHO et al., 2022). A base de timo é composta por 169 imagens de 12 animais (saudáveis e com artrite induzida por estresse). Para a validação, foi empregada a estratégia de validação cruzada Leave-One-Group-Out (LOGO). Cada experimento completo foi repetido de 3 a 5 vezes, com os resultados reportados como média e desvio padrão.

Abordagem com Características Handcrafted

Para a base do rim, o Pipeline 1 utilizou o descritor de textura Local Binary Patterns (LBP) em escala de cinza (Ojala et al., 2002), com classificação por Support Vector Machine (SVM) (Vapnik, 1998). O Pipeline 2 explorou a informação de cor com deconvolução H&E, extraíndo características LBP dos canais H&E e classificando-as com Random Forest. Para a base do timo, o melhor método foi um único pipeline que usou a imagem achatada (flattened), normalizada com StandardScaler e classificada por Random Forest.

Abordagem com Aprendizado Profundo (Deep Learning)

A segunda abordagem utilizou a arquitetura EfficientNetV2-B0, pré-treinada na base de dados ImageNet (Tan e Le, 2021). O modelo foi ajustado (fine-tuned) em fases e utilizou aumento de dados (data augmentation) em tempo real. Para a base do rim, as imagens completas foram usadas, pois a extração de ROI falhou. Para a base do timo, a extração de ROI foi um passo crucial e foi realizada com sucesso, isolando a área tecidual relevante do fundo da imagem. O treinamento na base do timo também utilizou pesos de classe e um agendador de taxa de aprendizado para otimizar o desempenho.

RESULTADOS E DISCUSSÃO

A análise dos resultados demonstrou a superioridade inequívoca da abordagem de Deep Learning sobre os métodos handcrafted em ambos os cenários. Para a base do rim, a metodologia handcrafted atingiu um teto de acurácia de $85,39\% \pm 0,88\%$. O modelo de CNN superou este resultado, alcançando uma acurácia média de

90,43%±1,18%. Na base do timo, os métodos handcrafted atingiram um desempenho estável de 80,86%±0,51% , enquanto o protocolo de Deep Learning, após refinamento, obteve uma acurácia média final de 87,66%±2,28%.

A pesquisa revelou que a necessidade de pré-processamento, como a extração de ROI, é dependente do dataset. Na base do rim, a extração falhou, e a CNN se saiu melhor com as imagens completas, provando sua capacidade de focar nas regiões relevantes implicitamente. Em contraste, na base do timo, a remoção da extração de ROI degradou significativamente o desempenho, de 83,24% para 78,75%. A maior contribuição do trabalho é a validação de um protocolo de Deep Learning generalizável, que se provou eficaz e transferível entre os diferentes contextos histopatológicos.

CONCLUSÕES

Este projeto cumpriu seus objetivos ao realizar uma investigação sistemática sobre a classificação automática de imagens histopatológicas. Foi demonstrada a superioridade da abordagem de Deep Learning baseada em uma CNN EfficientNetV2-B0 em comparação aos métodos clássicos com características handcrafted. O trabalho estabeleceu novos benchmarks de performance de 90,43% de acurácia para a base do rim e 87,66% para a base do timo, ambos validados sob um protocolo rigoroso que assegura a generalização para novos indivíduos. A principal contribuição é a consolidação de um protocolo de Deep Learning ponta-a-ponta, eficaz e transferível, que serve como base sólida para futuras pesquisas em análise de patologia digital.

AGRADECIMENTOS

Agradeço à Fundação Araucária pela bolsa de estudos e fomento à pesquisa científica. Ao meu orientador, Prof. Dr. Yandre Maldonado e coorientador, Prof. Dr. Franklin Cesar, pelos ensinamentos compartilhados ao longo da pesquisa.

REFERÊNCIAS

CARVALHO, M. F. T. et al. Cancer Identification in Walker 256 Tumor Model Exploring Texture Properties Taken from Microphotograph of Rats Liver. Algorithms, Special Issue "Algorithms for Biomedical Image Analysis and Processing", 2022.

LECUN, Y. et al. Backpropagation Applied to Handwritten Zip Code Recognition. Neural Computation, vol. 1, 541-551, 1989.

OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 24, n. 7, p. 971-987, 2002.

TAN, M.; LE, Q. V. EfficientNetV2: Smaller Models and Faster Training. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 38., 2021, Virtual. Proceedings... Virtual: PMLR, 2021.

VAPNIK, V. N. (1998). Statistical Learning Theory. Wiley.