

Dados de mentira, ciência de verdade: Uso de Dados Hiperespectrais Sintéticos para melhorar a Classificação de Melanoma

Ana Caznok Silveira
a231745@dac.unicamp.com

Krithian Aguilar
k298976@dac.unicamp.com

Aline Machado
a265731@dac.unicamp.com

Paula Dornhofer P. Costa
paulad@unicamp.br

Letícia Rittner
lrittner@unicamp.br

Departamento de Engenharia de Computação e Automação (DCA)
Faculdade de Engenharia Elétrica e de Computação (FEEC)
Universidade Estadual de Campinas (UNICAMP)

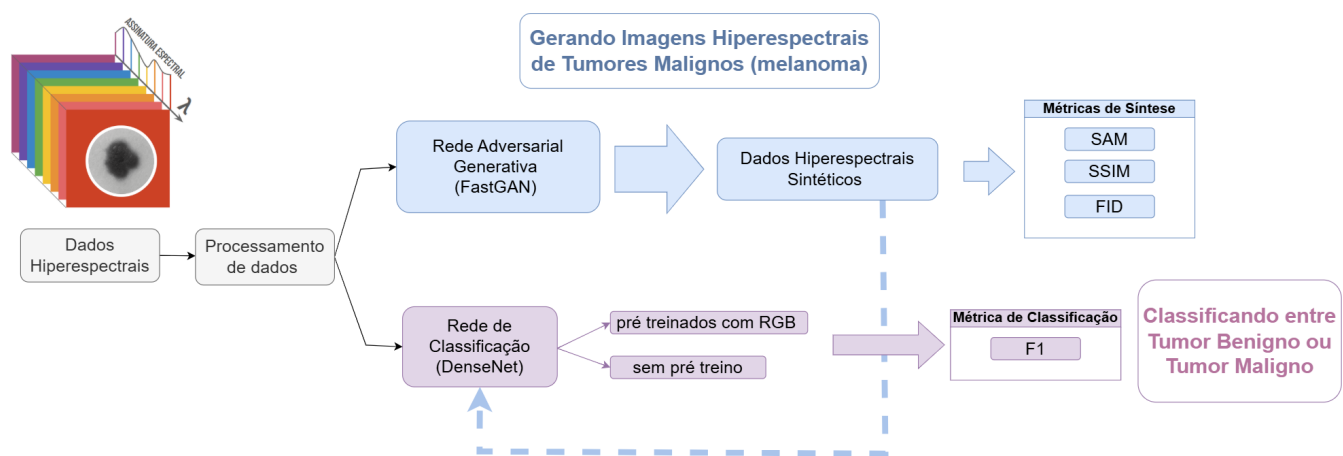


Figura 1: Metodologia: testando se as métricas de classificação melhoram com o uso de dados sintéticos

Resumo

Este trabalho investiga o uso de Redes Adversárias Generativas (GANs) para criar imagens hiperespectrais sintéticas de melanoma, com o objetivo de aprimorar a detecção automática de tumores. Utilizando o conjunto de dados Hyperspectral Dermoscopy, o modelo FastGAN foi treinado para gerar amostras artificiais visual e espectralmente semelhantes às reais, avaliadas por meio das métricas FID, SAM e SSIM. Dois classificadores DenseNet201 foram comparados: um treinado apenas com dados reais e outro combinando dados reais e sintéticos. O modelo combinado apresentou desempenho superior ($F1\text{-score} = 0,892$) e maior sensibilidade na detecção de melanomas. Os resultados indicam que o uso de dados sintéticos pode reduzir o desbalanceamento entre classes e melhorar a capacidade de generalização dos modelos, demonstrando o potencial da síntese hiperespectral baseada em GANs para aplicações diagnósticas mais precisas e não invasivas.

Palavras-Chave — GANS, Imagens Hiperespectrais

1. Introdução

Imageamento hiperespectral (HSI) é uma técnica que permite analisar a composição de materiais e tecidos a partir da luz que eles refletem, analisando faixas do espectro que vão do ultravioleta ao infravermelho [1]. Essa tecnologia já é aplicada em diferentes áreas, como agricultura [2], medicina [3] e sensoriamento remoto [4]. Com ela, é possível identificar substâncias químicas, medir a umidade de alimentos e até detectar tumores de forma não invasiva. No entanto, ainda é difícil obter grandes quantidades de dados hiperespectrais devido à complexidade dos equipamentos utilizados. Essa limitação restringe o aprendizado das redes neurais, que dependem de grandes volumes de dados variados para alcançar bom desempenho e generalizar seus resultados para situações reais. Quanto mais amplo e diverso for o conjunto de dados disponível, mais confiáveis e úteis serão os modelos, o que é fundamental para auxiliar,

por exemplo, médicos em diagnósticos mais seguros e precisos.

Mas se é tão difícil obter mais dados hiperespectrais, como os modelos diagnósticos que usam HSI podem se tornar mais precisos? A resposta pode estar na síntese de imagens por inteligência artificial. As Redes Adversárias Generativas (GANs) [5] têm se destacado como uma solução promissora para a escassez de dados, pois conseguem aprender as características de uma imagem e, a partir disso, gerar centenas de novos exemplos sintéticos [6]. Esses dados artificiais podem ser usados para treinar classificadores, ajudando-os a reconhecer melhor as variações possíveis de uma imagem tumoral [7]. Neste trabalho, utilizamos a arquitetura FastGAN [8], projetada para funcionar bem em cenários com poucos dados, com o objetivo de sintetizar imagens hiperespectrais de melanoma e aprimorar o desempenho de um classificador na distinção entre tumores malignos (melanoma) e benignos (displasia).

2. Métodos

A metodologia deste estudo (Fig. 1) foi elaborada para avaliar se a inclusão de imagens hiperespectrais sintéticas pode aprimorar a classificação de tumores em comparação ao treinamento realizado apenas com dados reais. O workflow consistiu em treinar um modelo FastGAN para gerar imagens hiperespectrais de melanoma e em paralelo, treinar um classificador DenseNet com imagens reais para distinguir melanomas benignos e malignos. Após a etapa de geração, as imagens sintéticas foram adicionadas ao conjunto real para um novo treinamento do classificador, e o desempenho do modelo foi comparado antes e depois da inclusão das imagens sintéticas. Para isso, utilizamos o conjunto de dados Hyperspectral Dermoscopy [9]. Este conjunto de dados possui 348 imagens hiperespectrais, das quais 85 são de melanoma, 185 de tumores benignos e 78 de outras lesões pigmentadas. As imagens possuem 482x512 pixels e 16 canais. A menor quantidade de amostras de melanoma, em comparação às demais classes, resulta em um desbalanceamento que pode comprometer o desempenho dos classificadores.

Os dados originais foram processados para extrair apenas a lesão, e em seguida, foram utilizados para o treinamento do modelo generativo FastGAN [8], responsável por criar novas imagens hiperespectrais sintéticas apenas da classe de melanoma, a fim de balancear o conjunto de dados. Durante esse processo, o modelo aprendeu as características espectrais e es-

paciais dos tumores malignos, gerando amostras sintéticas de melanoma o mais semelhantes possível às reais. A qualidade dessas imagens é avaliada por meio de métricas consolidadas de geração, incluindo o Spectral Angle Mapper (SAM), o Structural Similarity Index (SSIM) e o Fréchet Inception Distance (FID), que medem a similaridade espectral e perceptual entre as imagens sintéticas e reais.

Em seguida, dois modelos classificadores baseados em DenseNet [10] são treinados para distinguir tumores malignos de benignos. Optamos por utilizar o DenseNet201 porque sua estrutura de conexões internas densas torna o modelo mais eficiente e estável mesmo com um número limitado e desbalanceado de imagens, como é o caso do nosso conjunto de dados.

O primeiro classificador utiliza exclusivamente imagens reais, enquanto o segundo combina imagens reais e sintéticas em seu conjunto de treinamento. O número de imagens sintéticas acrescentado é suficiente para igualar o número de imagens das duas classes. Cada classificador é avaliado em duas condições: (i) utilizando pesos pré-treinados em imagens RGB e (ii) treinado do zero diretamente sobre os dados hiperespectrais. O desempenho final é quantificado por meio das métricas de classificação F1-score que avalia a precisão e a sensibilidade dos modelos.

3. Impactos da Pesquisa

A geração de imagens sintéticas hiperespectrais, aplicadas à classificação de melanoma, contribui diretamente para o aprimoramento de modelos de classificação que podem ser utilizados em diagnósticos precoces e não invasivos, possibilitando a detecção mais precisa e confiável de lesões malignas e, consequentemente, a redução da taxa de mortalidade associada a essa doença.

Do ponto de vista econômico e social, os diagnósticos tardios de melanoma resultam em custos substancialmente mais elevados, uma vez que o tratamento de casos avançados ou metastáticos é mais complexo e custoso. Ao favorecer diagnósticos precoces, a pesquisa contribui para reduzir gastos hospitalares e de saúde pública, além de diminuir a carga sobre o sistema de saúde.

Sob o aspecto tecnológico, a criação de dados sintéticos hiperespectrais amplia a diversidade dos conjuntos de dados disponíveis para treinamento e validação de modelos. Esses dados sintéticos incorporam assinaturas espectrais mais ricas e discriminativas, capa-




Figura 2: Comparação entre dados reais e sintéticos gerados com FastGAN. (a) Amostras reais e sintéticas de melanoma, cada imagem representa a média de todos os canais hiperespectrais; (b) Comparação entre as assinaturas espectrais médias do melanoma em imagens hiperespectrais reais e sintéticas.

zes de capturar variações ópticas sutis entre tecidos da pele, frequentemente imperceptíveis em imagens RGB convencionais.

4. Resultados e Discussão

4.1. FastGAN

O modelo generativo FastGAN foi avaliado por meio de métricas objetivas (Tab 1), alcançando um FID de 114,7, indicando uma diferença moderada entre as distribuições das imagens reais e geradas. O valor obtido de SAM de 0,17 mostra que as características espectrais das imagens sintéticas estavam razoavelmente alinhadas com as das amostras reais. O valor SSIM de 0,67 sugere que as lesões geradas compartilhavam estruturas espaciais gerais semelhantes às reais, embora detalhes finos como bordas de contornos não tenham sido bem capturados.

Quando comparamos as imagens reais e as amostras sintéticas de melanoma geradas com FastGAN (Fig. 2 (a)), notamos que as lesões sintéticas reproduziram as formas arredondadas e irregulares do melanoma, além de manter um contraste global adequado entre os núcleos das lesões e a pele ao redor.

A análise espectral apoia esses achados visuais (Fig. 2 (b)), uma vez que o espectro médio mostra que os dados sintéticos e reais seguiram praticamente as mesmas tendências. Os espectros das lesões de me-

lanoma exibiram formas semelhantes, mas com magnitudes ligeiramente deslocadas. Isso está de acordo com as métricas espectrais e sugere que o FastGAN foi capaz de reproduzir padrões espectrais fisicamente plausíveis.

Tabela 1: Métricas de avaliação do modelo FastGAN, obtidas ao comparar o conjunto de dados reais com um número equivalente de sintéticos. As setas ao lado de cada métrica indicam a direção de melhoria da medida ($\uparrow$ indica que valores maiores são melhores; $\downarrow$ indica que valores menores são melhores).

FID $\downarrow$	SAM $\downarrow$	SSIM $\uparrow$
114,7	0,17	0,7

4.2. Classificador DenseNet201

Os resultados quantitativos de classificação (F1 score) mostram o impacto do uso de dados sintéticos e do pré-treinamento sobre o desempenho do classificador DenseNet201 (Tab. 2).

Para o modelo sem pré-treinamento, observa-se que o treinamento exclusivamente com dados reais resultou em um desempenho bastante limitado, com F1-score de 0,40. No entanto, ao incorporar as amostras sintéticas no conjunto de treino, o desempenho aumentou significativamente, alcançando F1-score de 0,819.

Por outro lado, o modelo pré-treinado apresentou

desempenho superior em ambos os cenários. Quando treinado apenas com dados reais, o F1-score foi de 0,847, sugerindo que o conhecimento prévio adquirido no pré-treinamento favorece a extração de características relevantes mesmo com um número limitado de imagens. Com a adição das amostras sintéticas, o desempenho foi novamente aprimorado, atingindo F1-score de 0,892, o melhor resultado entre todos os experimentos.

De modo geral, observa-se que tanto os modelos não pré-treinados quanto pré-treinados se beneficiam da inserção de dados sintéticos durante o treino. Em particular, o modelo pré-treinado com dados sintéticos obteve o melhor desempenho, demonstrando que mesmo modelos com um alto desempenho podem se beneficiar do uso de dados sintéticos.

Tabela 2: Avaliação de classificadores DenseNet201 com e sem dados sintéticos inseridos no conjunto de treino. Métricas calculadas a partir do conjunto de validação.

Pré-treino	Dados	F1 Score ↑
✗	Reais	0,400
✗	Reais + Sintéticos	0,819
✓	Reais	0,847
✓	Reais + Sintéticos	0,892

5. Conclusão

Os resultados indicam que os classificadores que usaram dados hiperespectrais sintéticos tiveram um desempenho melhor do que aqueles treinados apenas com dados reais. As imagens de melanoma geradas pela GAN contribuíram para que os modelos aprendessem melhor os padrões relevantes, resultando em maior sensibilidade, especialmente nas classes com menor representatividade. Também observamos que redes projetadas para gerar imagens de alta resolução, como a Fast-GAN, funcionam muito bem mesmo sem terem sido criadas especificamente para imagens hiperespectrais. Isso provavelmente acontece porque nosso conjunto de dados tem resolução espacial mais alta (256×256) e menos canais espectrais do que o comum em estudos de HSI.

Agradecimentos

Os autores expressam profunda gratidão ao Instituto de Pesquisas ELDORADO, e ao Google DeepMind

pelo apoio financeiro. Além disso, os autores agradecem a Faculdade de Engenharia Elétrica e de Computação, em específico ao Laboratório de Computação e Automação Industrial, que forneceram apoio técnico e infraestrutura essenciais para o desenvolvimento do projeto.

Referências

- [1] A. et. al, “Configuration of hyperspectral and multispectral imaging systems,” in *Data handling in science and technology*. Elsevier, 2019, vol. 32, pp. 17–34.
- [2] Z. et. al, “Application of hyperspectral technology in detection of agricultural products and food: A review,” *Food science & nutrition*, vol. 8, no. 10, pp. 5206–5214, 2020.
- [3] Guolan and F. et. al, “Medical hyperspectral imaging: a review,” *Journal of biomedical optics*, vol. 19, no. 1, pp. 010 901–010 901, 2014.
- [4] J. Jia and Y. Wang, “Status and application of advanced airborne hyperspectral imaging technology: A review,” *Infrared Physics & Technology*, vol. 104, p. 103115, 2020.
- [5] I. J. Goodfellow and J. P. Abadie, “Generative adversarial networks,” 2014. [Online]. Available: <https://arxiv.org/abs/1406.2661>
- [6] M. Frid-Adar and E. Klang, “Synthetic data augmentation using gan for improved liver lesion classification,” in *ISBI*. IEEE, 2018, pp. 289–293.
- [7] S. e. Dhivya, “Gan based data augmentation for enhanced tumor classification,” in *ICCCSP*. IEEE, 2020, pp. 1–5.
- [8] B. Liu and Y. Zhu, “Towards faster and stabilized gan training for high-fidelity few-shot image synthesis,” in *ICLR*, 2021.
- [9] Y. e. a. Gu, “A hyperspectral dermoscopy dataset for melanoma detection,” in *International Workshop on Computer-Assisted and Robotic Endoscopy*. Springer, 2018, pp. 268–276.
- [10] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, “Densely connected convolutional networks,” 2018. [Online]. Available: <https://arxiv.org/abs/1608.06993>