

APRENDIZADO DE MÁQUINA PARA SAÚDE

Visão Computacional Médica: além do olhar humano

CNNs, arquiteturas clássicas, transfer learning e validação em imagens médicas

APOSTILA TÉCNICA · ENCONTRO 07

Prof. Flávio Luiz Seixas
Pós-graduação em Computação

Sumário

Sumário	2
Introdução	3
1. Da imagem ao tensor	3
2. Convolução e hierarquia de características	3
3. Arquiteturas e transferência	4
4. Aumento de dados e validade.....	4
Síntese do encontro.....	4
Referências	4

Introdução

Imagens médicas combinam grande dimensionalidade, estrutura espacial e metadados de aquisição. Modelos de visão precisam aprender padrões relevantes sem confundir anatomia e doença com marcas de equipamento, instituição ou protocolo. [1]

O encontro apresenta o funcionamento de redes convolucionais, distingue tarefas de classificação, detecção e segmentação e discute transferência de aprendizado, aumento de dados e validação por paciente e instituição. [1]



Figura 1 — Blocos de uma rede convolucional. Fonte: elaboração própria a partir do material da disciplina, com base em [1].

1. Da imagem ao tensor

Uma imagem digital representa intensidades em uma grade e pode conter canais ou volumes. Modalidades médicas diferem em mecanismo de aquisição, resolução, contraste e artefatos. DICOM apoia o intercâmbio e associa pixel a informações necessárias para interpretar e gerenciar o estudo [1].

CONCEITO-CHAVE

Uma imagem digital representa intensidades em uma grade e pode conter canais ou volumes.

2. Convolução e hierarquia de características

Uma camada convolucional aplica filtros locais ao tensor de entrada e produz mapas de características. Camadas sucessivas podem combinar padrões simples em representações mais abstratas; pooling reduz resolução e agrega respostas. O aprendizado ajusta pesos a partir dos exemplos e da função de perda [1].

Classificação produz um rótulo ou probabilidade para a imagem; detecção localiza objetos por regiões; segmentação atribui classe a pixels ou voxels. Essas saídas exigem referências e métricas diferentes [1].

3. Arquiteturas e transferência

Arquiteturas profundas variam em organização das camadas e caminhos de informação. Redes residuais facilitam o treinamento de redes mais profundas por conexões de atalho. A U-Net combina um caminho de codificação com um caminho de decodificação e conexões entre escalas, sendo adequada a segmentação [2].

Na transferência de aprendizado, pesos obtidos em outro conjunto iniciam a rede e são ajustados para a tarefa atual. Essa estratégia pode ajudar diante de poucos exemplos, mas diferenças entre imagens de origem e domínio médico devem ser avaliadas [1].

4. Aumento de dados e validade

Aumento de dados gera variações dos exemplos durante o treinamento. Transformações só são válidas quando preservam o significado clínico. Além disso, divisões devem ocorrer por paciente e, quando necessário, por instituição, para impedir repetição e medir dependência de proveniência [3].

O desempenho deve ser interpretado junto com qualidade do rótulo, composição populacional, equipamento e protocolo. Atalhos podem sustentar alta acurácia local e falhar quando o contexto muda [3].

Síntese do encontro

Da imagem ao tensor: uma imagem digital representa intensidades em uma grade e pode conter canais ou volumes.

Convolução e hierarquia de características: uma camada convolucional aplica filtros locais ao tensor de entrada e produz mapas de características.

Arquiteturas e transferência: arquiteturas profundas variam em organização das camadas e caminhos de informação.

Aumento de dados e validade: aumento de dados gera variações dos exemplos durante o treinamento.

Referências

- [1] Rubin, D. L.; Greenspan, H.; Hoogi, A. Biomedical Imaging Informatics. In: Biomedical Informatics. Springer, 2021.
- [2] Kahn, C. E. et al. Interpreting Medical Images. In: Intelligent Systems in Medicine and Health. Springer, 2022.
- [3] Subramanian, D.; Cohen, T. A. Machine Learning Systems. In: Intelligent Systems in Medicine and Health. Springer, 2022.