

DOI:10.3969/j.issn.1005-202X.2025.07.019

医学人工智能

基于自注意力生成式对抗网络的肺癌图像语义分析方法

胡志坚, 叶政春, 郑瀚森

福建医科大学附属协和医院数字协和发展研究办公室, 福建 福州 350001

【摘要】提出一种基于自注意力生成式对抗网络(SAGAN)的方法,旨在提升肺癌组织学分型的准确性。通过收集、预处理肺癌图像数据并进行数据增强,利用SAGAN模型进行训练。生成器通过自注意力机制加强特征提取,判别器则优化生成过程。实验结果表明SAGAN模型在训练集和测试集的准确率分别为0.852和0.845,召回率为0.833和0.829,均高于其他模型;且SAGAN的置信区间较窄,显示出模型在分类中的高稳定性。SAGAN方法提升了肺癌图像分析的效果,为临床提供更有力的决策支持。

【关键词】肺癌;自注意力机制;生成式对抗网络;语义分析

【中图分类号】R318;TP311

【文献标志码】A

【文章编号】1005-202X(2025)07-0969-05

Semantic analysis of lung cancer images based on self-attention generative adversarial network

HU Zhijian, YE Zhengchun, ZHENG Hansen

Office of Digital Coordination and Development Research, Fujian Medical University Union Hospital, Fuzhou 350001, China

Abstract: A self-attention generative adversarial network (SAGAN) is proposed to improve the accuracy of histological subtype prediction for lung cancer cases. After collecting and preprocessing the lung cancer image dataset and data augmentation, SAGAN model is trained, where the generator uses self-attention mechanism to strengthen feature extraction, while the discriminator optimizes the generation process. Experimental results show that SAGAN model achieves accuracies of 0.852 and 0.845 on the training and test sets, respectively, with recall rates of 0.833 and 0.829, outperforming the other models. Additionally, the narrow confidence intervals indicate the high stability of SAGAN model in classification. SAGAN is helpful for lung cancer image analysis, providing stronger support for clinical decision-making.

Keywords: lung cancer; self-attention mechanism; generative adversarial network; semantic analysis

前言

肺癌是全球致死率最高的恶性肿瘤之一,其早期检测和准确诊断对提高患者生存率至关重要^[1]。根据国际癌症研究机构的数据显示,每年肺癌导致的死亡人数已超过170万。肺癌主要分为两大类:非小细胞肺癌和小细胞肺癌,其中非小细胞肺癌又可以进一步细分为肺腺癌和鳞癌,这两种类型在生物学特性、治疗方案及预后方面存在显著差异,因此准确的组织学分型对于临床治疗非常重要^[2-3]。

随着医学影像学技术的发展,尤其是计算机断层扫描(Computed Tomography, CT)^[4-5]和磁共振成像^[6-7]的普及,医生能获取更高分辨率的影像数据。然而,传统的图像分析方法往往依赖于放射科医生

的经验,容易受到主观因素的影响,且难以处理复杂和高维度的数据,这些限制使得肺腺癌和鳞癌的准确分类变得具有挑战性。近年来,深度学习技术的迅猛发展为医学图像分析带来新的希望^[8-9],特别是卷积神经网络(Convolutional Neural Network, CNN)已广泛应用于肺癌图像分析中^[10-11]。传统CNN在处理长距离依赖关系和图像细微特征时存在不足之处,自注意力机制作为一种新兴技术,可以有效解决这一问题,通过对图像中特定区域的加权关注,自注意力机制使得模型能捕捉到重要特征,从而提升分类和分割的精度。生成式对抗网络(Generative Adversarial Network, GAN)是一种通过生成器和判别器的对抗训练实现高质量图像生成的框架,而自注意力生成式对抗网络(Self-Attention Generative Adversarial Network, SAGAN)进一步结合自注意力机制,能在图像生成和特征提取上实现更强的能力。本研究旨在提出一种基于SAGAN的肺癌组织学分型分析方法,聚焦于肺腺癌与鳞癌的准确分类,为临床提供更准确和有效的辅助决策支持。

【收稿日期】2025-01-05

【基金项目】福建省自然科学基金(2023J01647)

【作者简介】胡志坚,高级工程师,研究方向:医疗信息化应用、大数据与人工智能,E-mail: H12738jj@163.com

1 相关理论介绍

1.1 自注意力机制

自注意力机制是一种能在处理序列数据时关注输入中不同部分之间关系的方法,最初在自然语言处理领域得到广泛应用^[12]。自注意力机制允许模型在输入序列中动态地聚焦相关信息,增强特征表示能力^[13]。

自注意力的核心思想是通过计算输入序列中每个元素与其他元素之间的关系,从而为每个元素分配不同的权重^[14]。假设输入为一个矩阵 $X \in R^{n \times d}$,其中 n 是序列长度, d 是特征维度。接下来,生成查询 Q 、键 K 和值 V 的线性变换形式, $Q = XW_Q$, $K = XW_K$, $V = XW_V$,其中, $W_Q, W_K, W_V \in R^{d \times d}$ 是参数矩阵。通过查询和键的点积计算相似度,然后进行缩放和归一化:

$$\text{Attention}(Q, K, V) = \text{soft max} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (1)$$

其中, $\sqrt{d_k}$ 是对点积进行缩放的因子,确保在计算 softmax 时稳定性。最终的输出是对值 V 的加权和,每个值的权重由注意力权重决定。自注意力机制的优势在于其能有效捕捉输入序列中长距离依赖关系,适用于各种类型的输入数据,如图像和文本。

1.2 GAN

GAN 是一种深度学习模型,由生成器和判别器两个部分组成,通过对抗训练生成具有真实数据分布的合成数据^[15-16]。生成器接收随机噪声 z 作为输入,生成数据样本 $G(z)$,其目标是最大化判别器的误判概率;判别器接收真实数据样本 x 和生成器生成的样本 $G(z)$ 作为输入,输出一个概率值 $D(x)$ 和 $D(G(z))$,表示输入为真实样本的概率^[17]。

GAN 的损失函数由两个部分组成,分别对应生成器和判别器:

$$L_D = -E_{x \sim P_{\text{data}}(x)} [\ln D(x)] - E_{z \sim P_z(z)} [\ln(1 - D(G(z)))] \quad (2)$$

$$L_G = -E_{z \sim P_z(z)} [\ln D(G(z))] \quad (3)$$

其中, $P_{\text{data}}(x)$ 是真实数据的分布, $P_z(z)$ 是随机噪声的分布。整个训练过程为两者交替优化的对抗过程,判别器试图提高其对真实样本的识别能力,减少对生成样本的识别。生成器试图生成越来越真实的样本,以欺骗判别器。训练完成后,生成器能生成与真实样本分布相似的样本。

2 肺癌病例图像语义分析方法

2.1 数据预处理

在肺癌病例图像语义分析中,首先进行数据预处理,基于来自医院影像库的肺癌图像,通过医学专

家对这些图像进行标注,以区分肺腺癌与鳞癌。接着,所有图像都统一缩放到固定尺寸(512×512像素),以确保输入的一致性,缩放过程中可采用双线性插值等方法以最大限度保留图像细节。在数据增强方面,采用旋转、平移、随机剪裁、亮度和对比度调整等技术增加训练样本的多样性,进而提高模型的鲁棒性。图像转化与调整的公式为:

$$\begin{cases} R_{\text{Image}} = R(\text{Image}, \theta) \\ A_{\text{Image}} = \alpha \times \text{Image} + \beta \\ N_{\text{Image}} = \frac{\text{Image} - \mu}{\sigma} \end{cases} \quad (4)$$

其中, R 是旋转操作, θ 是旋转角度; α 是对比度因子, β 是亮度偏移量; μ 和 σ 分别为训练集的均值和标准差。

2.2 SAGAN

SAGAN 的构建主要包括生成器和判别器的设计,强调自注意力机制的应用^[18]。生成器以随机噪声 $z \in R^d$ 为输入,通过全连接层将其映射到更高维特征空间:

$$h_0 = \text{LeakyReLU}(W_1 z + b_1) \quad (5)$$

其中, W_1 和 b_1 分别是权重矩阵和偏置^[19]。随后,生成器使用转置卷积层逐步上采样生成图像,使用的转置卷积运算可以表示为:

$$h_{i+1} = \text{Deconv}(h_i, W_{\text{deconv}}, b_{\text{deconv}}) \quad (6)$$

在此过程中,生成器引入自注意力层,以增强对关键特征的关注。

最终,生成器输出生成的图像 $G(z)$,使用 Tanh 激活函数使得像素值范围在 $[-1, 1]$ 。判别器接收真实图像和生成图像作为输入,通过卷积层提取特征, $h_j = \text{LeakyReLU}(W_j * h_{j-1} + b_j)$,在特定层中引入自注意力机制,以提升对图像细节的敏感度,最终通过全连接层输出概率值 $D(x) = \sigma(W_D h_n + b_D)$ 。整个网络的训练采用对抗性学习的方式,生成器和判别器通过优化各自的损失函数交替更新,从而不断提升生成图像的质量和真实度^[20]。在训练过程中,为避免模式崩溃,加入梯度惩罚项:

$$L_{GP} = \lambda E_{\hat{x}} [(\|\nabla D(\hat{x})\|_2 - 1)^2] \quad (7)$$

其中, \hat{x} 是随机插值的样本, λ 是权重系数。SAGAN 能在图像生成中有效捕捉肺癌病例图像的复杂特征。

2.3 图像语义分析

在模型训练完成后,进行肺癌图像语义分析是最终目标^[21-22]。首先,通过已训练的生成器和判别器提取图像特征,特别关注自注意力层的输出,以获取更细致的上下文信息。这些提取的特征可以用于构建一个分类模型,实现对肺腺癌和鳞癌的有效分类。

分类模型的输出为 $\hat{y} = f(\mathbf{h})$,其中, f 是分类函数, \mathbf{h} 是从特征提取过程中获得的特征。在评估模型性能时,采用准确率、召回率和F1分数指标:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (8)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (9)$$

$$\text{F1分数} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (10)$$

其中,TP表示真正例,TN表示真负例,FP表示假正例,FN表示假负例^[23-24]。

在进行特征选择时,使用信息增益的公式来选择最具判别性的特征, $IG(Y|X) = H(Y) - H(Y|X)$,其中 $H(Y)$ 是目标变量的熵, $H(Y|X)$ 是在特征 X 条件下目标变量的熵。通过这一系列的分析步骤,基于SAGAN的肺癌病例图像语义分析方法能显著提升对肺癌图像的分析能力。

3 实验

3.1 实验数据

实验数据来源于某三甲医院的肺癌CT影像库,时间范围为2020年7月至2023年5月,共纳入137例患者的CT图像,包括肺腺癌88例和鳞癌49例。为确保数据的代表性和质量,所有影像数据由两名具有丰富经验的CT诊断医生进行评估和标注。医生通过评估图像提取7个关键的语义特征,包括肿瘤大小、形状、边界清晰度、密度、位置、空泡及影像学分型。

为确保肿瘤区域标注的准确性,CT图像的载入和处理使用ITK-SNAP软件,医生利用该软件进行手

动分割。此外,为评估标注结果的可重复性,每幅图像还由另一位经验丰富的医学专家进行复核和描述。在存在多人评估不一致的情况下,具体的病例取舍标准如下:如果两名医生的评估结果差异较大(如肿瘤边界不一致、大小存在较大差异等),则将该病例提交给第三位资深医学专家进行独立评审,如果最终评审无法达成一致,则该病例将被排除在数据集之外,以确保所使用数据的高质量。

3.2 实验过程

实验过程分为数据准备、模型训练和语义分析这3个阶段。首先,在数据准备阶段,将收集到的CT图像进行预处理,包括图像缩放、去噪声及归一化。接着,使用SAGAN对处理后的图像进行训练,训练在1块NVIDIA GeForce RTX 3070显卡上实现^[25-26]。通过对抗性学习使生成器和判别器相互优化,提取和分析肺癌的关键特征,并应用数据增强技术进一步训练样本。在训练过程中,数据集的划分为训练集和测试集,比例为9:1,重复50次。在语义分析的实验过程中,首先利用训练好的模型对测试集中的肺癌图像进行特征提取,通过自注意力机制有效识别肿瘤的形态和特征,接着,将提取的特征输入到分类模型中,对肺腺癌和鳞癌进行分类。

3.3 结果分析

为评估不同深度学习模型在肺癌病例图像语义分析中的表现,对多种常见模型进行实验比较,并统计它们在训练集和测试集上的性能指标。表1的数据展示了5种模型在训练集和测试集上的准确率和召回率的均值及其对应的95%置信区间。图1给出了不同模型的F1分数的箱线图。

表1 不同模型的评价指标

Table 1 Evaluation indicators of different models

模型	训练集		测试集	
	准确率(95%CI)	召回率(95%CI)	准确率(95%CI)	召回率(95%CI)
SAGAN	0.852(0.838, 0.866)	0.833(0.818, 0.848)	0.845(0.831, 0.859)	0.829(0.815, 0.843)
GAN	0.822(0.806, 0.838)	0.815(0.799, 0.831)	0.817(0.801, 0.833)	0.809(0.793, 0.825)
Attention-CNN	0.814(0.800, 0.828)	0.806(0.791, 0.821)	0.806(0.791, 0.821)	0.794(0.778, 0.810)
CNN	0.792(0.776, 0.808)	0.786(0.770, 0.802)	0.783(0.767, 0.799)	0.771(0.755, 0.787)
Visual Transformer	0.819(0.805, 0.833)	0.811(0.796, 0.826)	0.810(0.795, 0.825)	0.803(0.788, 0.818)

由表1可知SAGAN方法在肺癌图像语义分析的各项指标上均优于其他模型。在训练集和测试集中,SAGAN的准确率分别达到0.852和0.845,明显高于传统的CNN和GAN,这表明其在特征提取和分类任务中具有更强的泛化能力。SAGAN的召回率也在训练集和测试集中表现出最高值,表明该模型不

仅能有效区分肺腺癌和鳞癌,还能在分类过程中较好地兼顾召回率和准确率,确保模型在诊断中的鲁棒性和可靠性。相比之下,传统的CNN在召回率上表现较差,尤其是在测试集上的表现,说明其特征提取能力有限;Visual Transformer也表现出较好的效果,但在准确率上仍不及SAGAN,进一步印证了自

注意力机制与生成对抗网络结合在处理复杂医学图像任务中的优越性。综上,SAGAN模型在肺癌病例图像语义分析上表现出色。

根据图1可以得到,与其他模型相比,SAGAN在训练集和测试集中的均值F1分数都保持在最高水平,且其数据分布更集中,说明该模型在语义分析任务中的稳定性和准确性优于其他对比模型。GAN和Visual Transformer虽然也表现较好,但相较于SAGAN,其表现略逊一筹,可进一步确认自注意力机制的引入能有效提高对肺癌图像的特征提取能力,提升分类模型的性能,这一结果与表格数据的结论一致,表明SAGAN方法在肺癌图像语义分析中具有更高的适用性和鲁棒性。

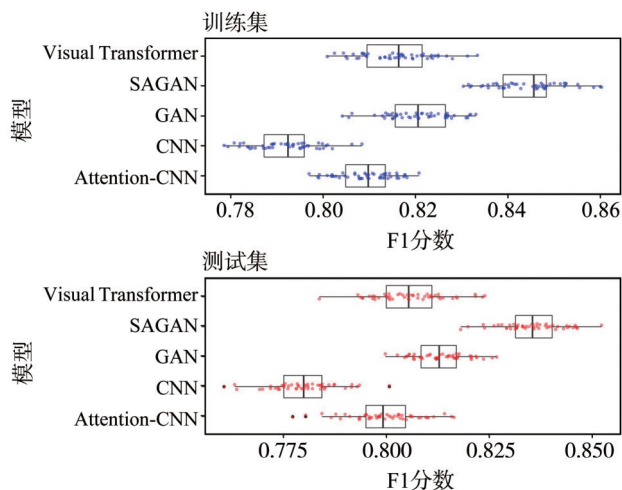


图1 不同模型的F1分数
Figure 1 F1 scores of different models

4 讨论

通过与传统的深度学习模型进行对比,本研究从多个角度分析SAGAN的优势和局限性。SAGAN的自注意力机制使其在大规模图像特征空间中能有效地捕捉长距离依赖关系,这在肺癌图像中尤为重要。肺癌图像包含许多细微且复杂的特征,如肿瘤的形状、边界、密度等,通过自注意力机制,SAGAN可以识别这些特征之间的相关性,从而增强模型的特征表达能力。从泛化能力的角度来看,SAGAN在测试集上的性能接近训练集,且其置信区间较窄,这反映了模型的稳定性和强泛化性。然而,SAGAN也有其局限性,由于模型结构较为复杂,其训练过程需要消耗更多的计算资源和时间,特别是需要较大规模的GPU支持,此外,在模型调参过程中,如何平衡

生成器和判别器的训练,是决定SAGAN模型性能的关键问题。

为进一步验证SAGAN模型的效果和可迁移性,未来的研究将扩展数据集,并针对未参与训练的新病例进行验证。通过将这些验证结果与医生标注的实际情况进行对比分析,可以更有效地评估模型的鲁棒性与迁移能力,并进一步证明该模型在临床应用中的潜力。

【参考文献】

- [1] Thandra KC, Barsouk A, Saginala K, et al. Epidemiology of lung cancer[J]. Contemp Oncol (Pozn), 2021, 25(1): 45-52.
- [2] Rudin CM, Brambilla E, Faivre-Finn C, et al. Small-cell lung cancer [J]. Nat Rev Dis Primers, 2021, 7(1): 3.
- [3] Travis WD. Lung cancer pathology: current concepts[J]. Clin Chest Med, 2020, 41(1): 67-85.
- [4] Hunger T, Wanka-Pail E, Brix G, et al. Lung cancer screening with low-dose CT in smokers: a systematic review and meta-analysis[J]. Diagnostics (Basel), 2021, 11(6): 1040.
- [5] Riquelme D, Akhloufi MA. Deep learning for lung cancer nodules detection and classification in CT scans[J]. AI, 2020, 1(1): 28-67.
- [6] Liu JJ, Shen B, Yang Y, et al. Survival benefit of prophylactic cranial irradiation in limited-stage small-cell lung cancer in modern magnetic resonance imaging staging: a systematic review and meta-analysis[J]. Acta Oncol, 2023, 62(3): 305-314.
- [7] Pezzi TA, Fang P, Gjyshi O, et al. Rates of overall survival and intracranial control in the magnetic resonance imaging era for patients with limited-stage small cell lung cancer with and without prophylactic cranial irradiation[J]. JAMA Netw Open, 2020, 3(4): e201929.
- [8] 张锐, 曾鑫. 结合注意力机制的CNN-LSTM心电信号识别[J]. 计算机应用与软件, 2023, 40(12): 209-216.
- [9] 杨炳乾, 冯秀芳, 董云云, 等. 结合CNN和Transformer病变信号引导的蜂窝肺CT图像识别[J]. 激光与光电子学进展, 2024, 61(14): 447-456.
- [10] 李雅迪, 韩佳芳, 马琳琳. 3D-CNN在肺癌图像识别中的应用研究[J]. 智能计算机与应用, 2022, 12(8): 161-164.
- [11] 岳晴, 尹健宇, 王生生. 基于改进CNN的低剂量CT图像肺结节自动检测[J]. 计算机科学, 2022, 49(S1): 54-59.
- [12] Chen LF, Tan XQ, Wang DY, et al. TransformerCPI: improving compound-protein interaction prediction by sequence-based deep learning with self-attention mechanism and label reversal experiments[J]. Bioinformatics, 2020, 36(16): 4406-4414.
- [13] Lin SG, Wang YJ, Zhang LF, et al. MDF-SA-DDI: predicting drug-drug interaction events based on multi-source drug fusion, multi-source feature fusion and transformer self-attention mechanism[J]. Brief Bioinform, 2022, 23(1): bbab421.
- [14] Kumar S, Solanki A. An abstractive text summarization technique using transformer model with self-attention mechanism[J]. Neural Comput Appl, 2023, 35(25): 18603-18622.
- [15] Aggarwal A, Mittal M, Battineni G. Generative adversarial network: an overview of theory and applications[J]. Int J Inf Manag Data Insights, 2021, 1(1): 100004.

- [16] Gui J, Sun ZN, Wen YG, et al. A review on generative adversarial networks: algorithms, theory, and applications[J]. IEEE Trans Knowl Data Eng, 2023, 35(4): 3313-3332.
- [17] Jabbar A, Li X, Omar B. A survey on generative adversarial networks: variants, applications, and training[J]. ACM Comput Surv, 2021, 54(8): 157.
- [18] Xue Y, Tong WN, Neri F, et al. PEGANs: phased evolutionary generative adversarial networks with self-attention module[J]. Mathematics, 2022, 10(15): 2792.
- [19] Zhang L, Wu JQ, Shen J, et al. SATP-GAN: self-attention based generative adversarial network for traffic flow prediction[J]. Transportmetrica B Transp Dyn, 2021, 9(1): 552-568.
- [20] Chen ZT, Tong L, Qian B, et al. Self-attention-based conditional variational auto-encoder generative adversarial networks for hyperspectral classification[J]. Remote Sens, 2021, 13(16): 3316.
- [21] Xie ZY, Yang Y, Niu ZF, et al. Preoperative computed tomography semantic features in predicting lymph node metastasis of part-solid nodules in non-small cell lung cancer: a multicenter retrospective study[J]. Quant Imaging Med Surg, 2024, 14(7): 5151-5163.
- [22] Huang BS, Tian JR, Zhang HY, et al. Deep semantic segmentation feature-based radiomics for the classification tasks in medical image analysis[J]. IEEE J Biomed Health Inform, 2021, 25(7): 2655-2664.
- [23] Mauricio J, Domingues I, Bernardino J. Comparing vision transformers and convolutional neural networks for image classification: a literature review[J]. Appl Sci, 2023, 13(9): 5521.
- [24] Huang SC, Pareek A, Jensen M, et al. Self-supervised learning for medical image classification: a systematic review and implementation guidelines[J]. NPJ Digit Med, 2023, 6(1): 74.
- [25] Liu J, Guan RX, Li ZH, et al. Adaptive multi-feature fusion graph convolutional network for hyperspectral image classification[J]. Remote Sens, 2023, 15(23): 5483.
- [26] Senokosov A, Sedykh A, Sagingalieva A, et al. Quantum machine learning for image classification[J]. Mach Learn Sci Technol, 2024, 5(1): 015040.

(编辑:谭斯允)