

# DenseNet-GRU: 直肠癌 CT 影像分类的 深度神经网络模型

贾欣齐, 李睿, 张志成, 王阳, 吕品  
(上海电机学院 电子信息学院, 上海 201306)

**摘要:** DenseNet 是一种广泛用于影像分类的卷积神经网络, 但它不具备记忆功能, 无法反映卷积操作后不同特征映射之间的关联关系。若将其直接应用于判断直肠癌是否发生淋巴结转移, 则无法比较直肠癌 CT 影像特征在深度神经网络映射过程中的变化。基于此, 提出了一种新颖的深度神经网络模型 DenseNet-GRU (gated recurrent unit), 其核心是利用 GRU 获取 DenseNet 提取的不同影像特征之间的关联关系, 进而获得不同图像之间相同像素区域的特征变化情况, 最终判断直肠癌患者的淋巴结是否存在转移。以包含 107 个患者 DCM 格式的腹部横断位动脉期和门脉期两种增强 CT 影像为实验数据集, 采用数据增强和阈值分割方法对数据进行预处理, DenseNet-GRU 模型在 F-score 上的分类精度达到了 65% 以上, 对临床辅助诊断具有重要的现实意义。

**关键词:** DenseNet; 门控循环单元; 深度神经网络; 影像特征; 影像分类

中图分类号: TP391.41

文献标识码: A

文章编号: 1673-629X(2021)03-0111-04

doi: 10.3969/j.issn.1673-629X.2021.03.019

## DenseNet-GRU: A Deep Neural Network Model for CT Image Classification of Rectal Cancer

JIA Xin-qi, LI Rui, ZHANG Zhi-cheng, WANG Yang, LYU Pin  
(School of Electronics and Information, Shanghai Dianji University, Shanghai 201306, China)

**Abstract:** DenseNet is a convolutional neural network widely used in image classification, but it has no memory function and cannot reflect the correlation between different feature maps after convolutions. If it is directly used to judge whether there is lymph node metastasis in rectal cancer, it is impossible to compare the changes of rectal cancer CT image features in the process of feature map of deep neural networks. To resolve this problem, a novel deep neural network model DenseNet-GRU (gated recurrent unit) is proposed. The core of DenseNet-GRU is to use GRU to obtain the correlation between different image features extracted by DenseNet. The feature changes of the same pixel area between different images can be captured by the correlation, and finally it is possible to judge whether there is lymph node metastasis in rectal cancer patients. The experimental dataset contains two kinds of arterial and portal phases of abdominal transection with DCM file format from 107 patients. The raw images are preprocessed by the methods of data enhancement and threshold segmentation. The classification accuracy of the proposed model on the F-score reaches beyond 65%, which indicates that Densenet-GRU is effective and feasible for judging whether rectal cancers have lymph node metastasis and important for clinical auxiliary diagnosis.

**Key words:** DenseNet; gated recurrent unit; deep neural network; image feature; image classification

### 0 引言

直肠癌是国内近年来发病率和死亡率均居前列的恶性肿瘤<sup>[1]</sup>。一般情况下, 直肠癌的临床判断主要依靠肉眼识别。这种方法虽简单可行, 但存在较强的主观性。随着信息技术的发展, 利用计算机实现医学图

像的辅导诊断逐渐普及。这种自动识别的最大优势在于它能帮助医生识别人眼无法观察到的信息, 为患者的个性化治疗方案提供更加丰富的临床依据<sup>[2-4]</sup>。

目前, 利用计算机实现医学图像处理的方法主要有两类: 浅层学习方法和深度神经网络。经典的浅层

收稿日期: 2020-01-21

修回日期: 2020-05-22

基金项目: 2019 年上海市大学生科创项目 (201911458042); 上海市教育科学研究项目 (C17014/17AR04)

作者简介: 贾欣齐 (1998-), 女, 研究方向为数据挖掘与机器学习; 吕品, 博士, 副教授, CCF 会员 (60050M), 研究方向为数据挖掘、机器学习与情感分析。

学习方法包括决策树<sup>[5]</sup>和聚类算法<sup>[6]</sup>。这类算法的主要优点是思想简单,但由于特征提取过程复杂,导致分类效率不高。深度神经网络中的卷积神经网络 CNN(convolutional neural network)<sup>[7]</sup>是一种广泛应用于医学图像处理的算法,且有许多变体,DenseNet 就是 CNN 其中之一。DenseNet 的主要特点是分类性能优,模型参数少,但由于不具备记忆功能,无法表示所提取的特征之间的关联关系<sup>[8]</sup>,因此,无法直接应用于直肠癌影像分类。为了解决这一问题,该文提出了一种直肠癌影像分类的深度神经网络模型 DenseNet-GRU。它利用了具有记忆功能的循环神经网络 GRU(gated recurrent unit)计算 DenseNet 所提取的特征之间的关联关系,进而获得不同图像之间相同像素区域的特征变化情况,最终判断直肠癌患者的淋巴结是否存在转移。

## 1 直肠癌影像分类模型 DenseNet-GRU

### 1.1 DenseNet 与 GRU

DenseNet 是一种具有密集连接特点的卷积神经网络,具有较强的图像特征提取能力。密集连接意味着网络中任意两层均直接相连,这就使得 DenseNet 中任意一层的输入均为该层之前所有层的输出之和。除此之外,DenseNet 还能通过密集连接的方式实现特征共享。这种技术不仅加强了网络中特征的传递,减少了网络参数,还能有效缓解梯度消失问题。GRU 是循环神经网络 LSTM(long short term memory)的一种变体<sup>[9-11]</sup>,它将忘记门和输入门合成了一个单一的更新门,可以解决循环神经网络中的长依赖问题。该文提出的直肠癌影像分类 DenseNet-GRU 模型正是利用了 GRU 的记忆特性来获取不同直肠癌影像特征映射之间的关联关系。

### 1.2 DenseNet-GRU 的网络结构

DenseNet-GRU 网络结构如图 1 所示。它是在去除原始 DenseNet 网络中的全连接层后,增加一个 GRU 神经网络,最后经全连接层输出分类结果。对于 DenseNet-GRU 网络中的 GRU,其输入层后依次是一个 TimeDistributed 包装层和一个双向的 GRU 网络层。此外,为了配合 SeLU 激活函数,增加了 Alpha Dropout 正则化层。

由于直肠癌影像数据本身的特点和功能限制的问题,该文没有使用激活函数 ReLU(rectified linear unit)<sup>[12]</sup>,而是将传统的 DenseBlock 中的激活函数 ReLU 优化为 SeLU(scaled exponential linear units)<sup>[13]</sup>。该文使用的 DenseBlock 结构如图 2 所示。它是一个五层的 dense block 结构,包括 4 个 Gn-SeLU-Con。在图 2 所示的 dense block 中,每一层的输入均为前面所

有层的输出,且层与层之间都进行了 Gn-SeLU-Con 操作。

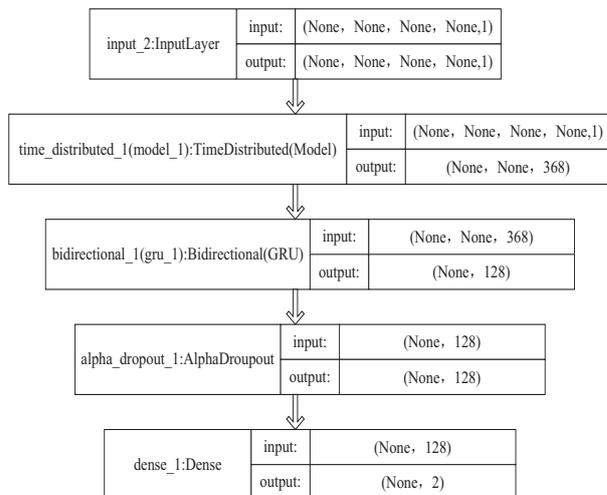


图 1 DenseNet-GRU 的网络结构

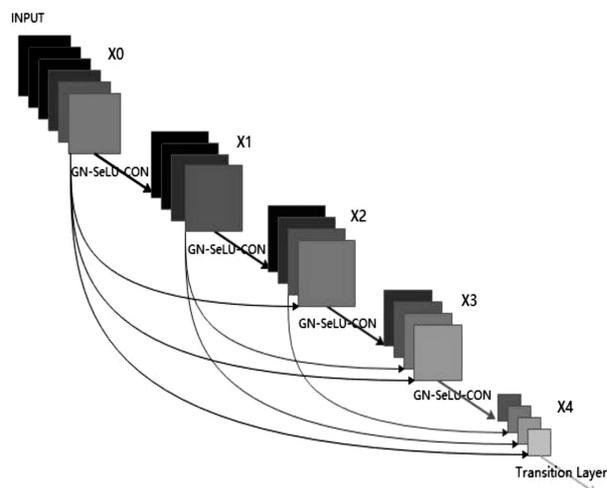


图 2 DenseBlock 结构

## 2 直肠癌影像预处理与模型参数的设定

### 2.1 基于 GU-Net 的直肠肿瘤分割预处理

为提高判断直肠癌患者是否出现淋巴结转移的分类精度,需要对直肠癌 CT 影像进行数据预处理,即分割出图像中的肿瘤区域。为此,设计了一个专用于直肠肿瘤分割的神经网络 GU-Net。GU-Net 是一种优化的 U-Net 图像分割模型,设有群组规一化层(group normalization, GN)。GU-Net 以群组的方式快速训练网络,不仅解决了深度学习中常用的批量归一化对硬件性能的严格要求,还能有效缓解梯度消失问题,提高分割准确度<sup>[14-16]</sup>。

GN 的原理是将通道分成组,在每组内计算归一化的均值和方差<sup>[17]</sup>。GN 层的数学表达式如式(1)所示:

$$S_i = \{K \mid K_N = i_N, \lfloor \frac{k_c}{C/G} \rfloor = \lfloor \frac{i_c}{C/G} \rfloor\} \quad (1)$$

其中,  $G$  表示组的大小,  $C/G$  表示组的个数,  $\lfloor \cdot \rfloor$  表示向下取整操作。由式(1)可知, GN 操作是对属于同一个  $C/G$  通道的特征值进行均值和方差计算。因此, GN 的计算与批量大小无关, 其准确度在各种批量大小下都很稳定。此外, 为快速寻找全局最优解或近似最优解, 在实验中还采用了模拟退火算法。该算法先以一定概率接受某个次要解, 并以此搜索全局最优解<sup>[18-19]</sup>。

由于原始数据集中直肠癌 CT 影像数量较少, 因此在构建 DenseNet-GRU 模型之前通过图像平移的方式, 对直肠癌 CT 影像数据集进行了扩充, 以提高模型的泛化能力。然后读入 CT 影像的灰度值矩阵, 按照一定阈值分割出淋巴结所在区域。最后通过优化窗宽和窗位对 CT 影像进行预分割, 对预分割后的图像做直方图均衡和归一化处理。

### 2.2 模型参数的设定

训练 DenseNet-GRU 模型时, 调整了 DenseNet 最后一个 DenseBlock 块的权重和 GRU 的权重, 优化器选用 Adam, 初始学习率设定为 0.000 1, 且每间隔 3 次迭代检查一次评估值, 以调整 DenseNet-GRU 模型的学习率。

## 3 实验

### 3.1 数据集

该文的实验数据集来自 107 个患者, 每个患者均

有 DCM 格式的腹部横断位动脉期和门脉期两种增强 CT 影像。数据集大小为 2.88 G。实验中随机抽取出 20 个直肠癌患者的 CT 影像作为验证集。

### 3.2 评价标准

实验中首先采用 Dice 系数评价 GU-Net 模型对直肠肿瘤的分割效果。Dice 系数的计算如式(2)所示, 它是一种集合相似度度量函数, 通常用于计算两个样本的相似度。Dice 系数的范围为  $[0, 1]$ ; 采用精确度 Accuracy 度量 DenseNet-GRU 模型的性能。

$$Dice = \frac{2|A \cap B|}{|A| + |B|} \tag{2}$$

其中,  $A$  表示 GU-Net 模型的分割结果,  $B$  表示专家手工分割结果。Dice 越接近 1, 则正确率越高, 分割效果越好。

### 3.3 结果分析

GU-Net 模型的准确率和损失如图 3 所示。观察图 3 可知, 随着迭代次数(一次 epoch 使用 250 个 batch)的增加, GU-Net 模型在验证集下的 Dice 系数呈平缓上升趋势, 且增长逐渐变得缓慢, 说明 GU-Net 模型已经开始逐渐收敛。GU-Net 模型的损失函数在验证集上总体呈平缓下降的趋势。图 4 展示了 GU-Net 分割直肠肿瘤的效果。由图 4 可知 GU-Net 网络分割区域与专家手工分割区域大致重合, 证明了 GU-Net 网络实现医学图像分割是具有可行性的。

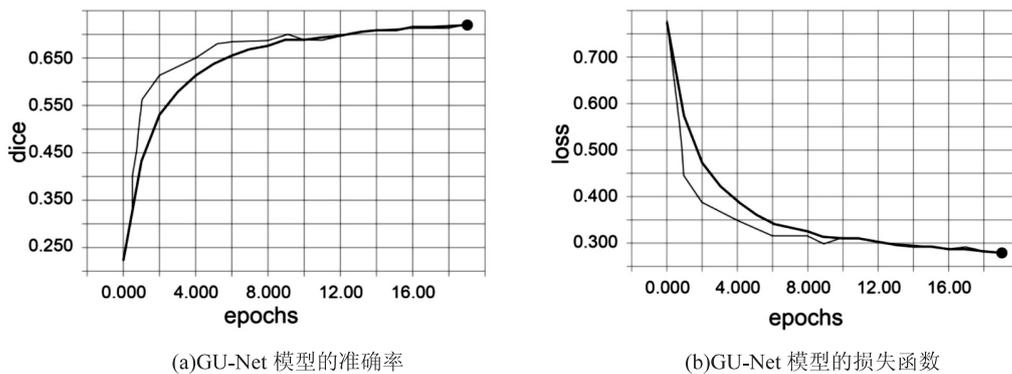


图 3 GU-Net 实验结果

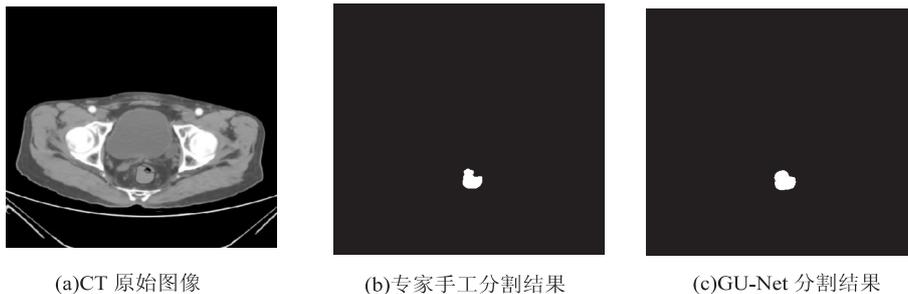


图 4 GU-Net 分割结果示例

图 5 给出了 DenseNet-GRU 模型的准确率和损失函数的变化趋势。观察图 5 可知, 随着迭代次数(一次

epoch 使用 250 个 batch) 的增加, DenseNet-GRU 模型在验证集上的精确度总体呈上升趋势, 最高可达到

65% 以上,模型的损失函数在训练集与验证集上呈现逐渐降低的趋势,这表明 DenseNet-GRU 模型具有较

好的泛化性能。

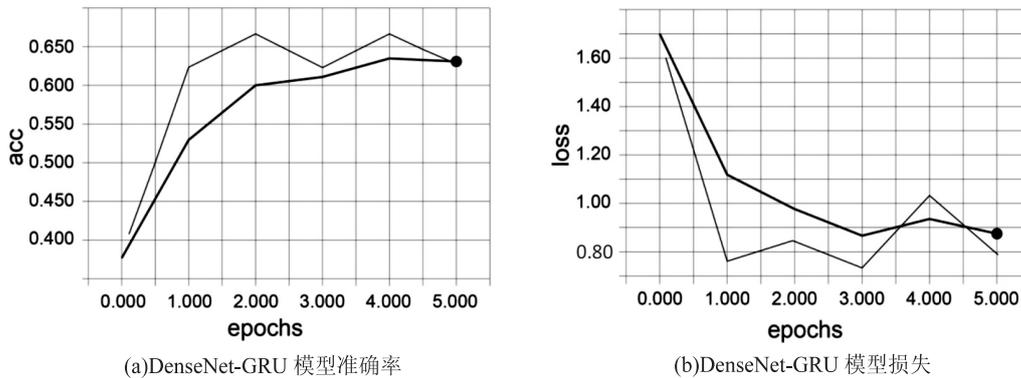


图 5 DenseNet-GRU 实验结果

#### 4 结束语

该文研究了如何利用深度神经网络模型 DenseNet-GRU 判断直肠癌患者是否发生淋巴结转移的问题。提出的 DenseNet-GRU 模型充分利用了 GRU 的记忆能力和 DenseNet 的良好分类性能。为了提高 DenseNet-GRU 的分类效果,实验中首先设计了一种直肠肿瘤分割模型 GU-Net,获取直肠肿瘤所在的淋巴结所在区域的影像特征;然后运用 DenseNet-GRU 模型判断直肠癌患者是否发生淋巴结转移,实验结果表明提出的模型具有较好的泛化能力。

#### 参考文献:

- [1] CHEN Wanqing. Cancer statistics: updated cancer burden in China[J]. Chinese Journal of Cancer Research, 2015, 27(1):1-1.
- [2] 赖苏何. CT 影像诊断对于直肠癌临床术前分期的价值评价[J]. 影像研究与医学应用, 2019, 3(16):57-58.
- [3] 郭钰,李明洋,刘祥春,等. CT 影像学对结直肠癌肝转移的诊断价值[J]. 中国临床医学影像杂志, 2018, 29(11):798-802.
- [4] DONOVAN M J, FERNANDEZ G, SCOTT R, et al. Development and validation of a novel automated Gleason grade and molecular profile that define a highly predictive prostate cancer progression algorithm-based test[J]. Prostate Cancer Prostatic, 2018, 21(4):594-603.
- [5] 任仪. 基于决策树的海量医学图像数据挖掘方法研究[J]. 电子设计工程, 2019, 27(6):33-36.
- [6] 张光华,潘婧,罗跃国. 聚类算法在医学图像分割中的应用[J]. 计算机产品与流通, 2019(3):101.
- [7] 李彦冬,郝宗波,雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9):2508-2515.
- [8] 杨婧,耿辰,王海林,等. 基于 DenseNet 的低分辨 CT 影像肺腺癌组织学亚型分类[J]. 浙江大学学报:工学版, 2019, 53(6):1164-1170.
- [9] KONG Jiangtao, HUANG Jian, YU Hongkai, et al. RNN-based default logic for route planning in urban environments[J]. Neurocomputing, 2019, 338:307-320.
- [10] 闫河,董莺艳,王鹏,等. 基于 CNN-LSTM 网络的声纹识别研究[J]. 计算机应用与软件, 2019, 36(4):166-170.
- [11] DIJK B, SANTOS B F, PITA J P. The recoverable robust stand allocation problem: a GRU airport case study[J]. OR Spectrum, 2019, 41(3):615-639.
- [12] 葛轶众,杨马英. 基于 ReLU 神经网络的移动目标视觉伺服研究[J]. 计算机测量与控制, 2018, 26(8):78-82.
- [13] KLAMBAUER G, UNTERTHINER T, MAYR A, et al. Self-normalizing neural networks[C]//Proceedings of the 31st international conference on neural information processing systems. Long Beach:MIT Press, 2017:972-981.
- [14] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4):640-651.
- [15] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//18th international conference of medical image computing and computer-assisted intervention. Munich:Springer, 2015:234-241.
- [17] NAKAMURA K, HONG B W. Adaptive weight decay for deep neural networks[J]. IEEE Access, 2019, 7:118857-118865.
- [18] WU Y, HE K. Group normalization[J]. International Journal of Computer Vision, 2020, 128(3):742-755.
- [19] 李元香,项正龙,张伟艳. 模拟退火算法的弛豫模型与时间复杂性分析[J]. 计算机学报, 2020, 43(5):796-811.