

基于特征增强金字塔网络的阿尔茨海默症早期诊断研究

石磊^{1,2}, 彭少康¹, 张亚萌³, 赵国桦⁴, 高宇飞^{1,2}

(1. 郑州大学网络空间安全学院, 郑州 450002; 2. 嵩山实验室, 郑州 450052; 3. 河南省人民医院病理科, 郑州 450003; 4. 郑州大学第一附属医院磁共振科, 郑州 450003)

摘要: 阿尔茨海默症(Alzheimer's disease, AD)作为一种不可逆转的神经退行性疾病,能在其发病初期进行干预治疗对病情的控制和改善具有重要意义。近年来,研究者广泛地使用深度学习方法对AD的核磁共振成像(Magnetic resonance imaging, MRI)进行分析并做出早期诊断。但AD早期的脑部结构变化与正常人差别较小,目前单一尺度的分析方法难以有效捕捉到这些细小差别的特征。针对以上问题,本文提出特征增强金字塔网络(Feature enhanced pyramid network, FEPN)进行AD的MRI早期诊断,通过设计的浅层特征重提取模型利用上下文信息补充高层特征,并计算融合权重指导高低层特征图的融合,增强了上下文信息交互和多尺度特征融合的匹配度。对比实验采用Kaggle公开的Alzheimer数据集对该方法进行验证,实验结果表明,相比于其他同类方法,FEPN有效提升了4种AD脑状态(非痴呆、非常轻度痴呆、轻度痴呆、中度痴呆)MRI的分类精度。

关键词: 阿尔茨海默症;核磁共振成像;深度学习;浅层特征重提取;融合权重

中图分类号: TP391 **文献标志码:** A

Early Diagnosis of Alzheimer's Disease Based on Feature Enhanced Pyramid Network

SHI Lei^{1,2}, PENG Shaokang¹, ZHANG Yameng³, ZHAO Guohua⁴, GAO Yufei^{1,2}

(1. School of Cyber Science and Engineering, Zhengzhou University, Zhengzhou 450002, China; 2. Songshan Laboratory, Zhengzhou 450052, China; 3. Department of Pathology, Henan Provincial People's Hospital, Zhengzhou 450003, China; 4. Department of Magnetic Resonance, The First Affiliated Hospital of Zhengzhou University, Zhengzhou 450003, China)

Abstract: Alzheimer's disease (AD) is an irreversible neurodegenerative disease, whose early medical intervention is of great significance to control and improve the condition. In recent years, deep learning methods have been widely used by researchers to analyze magnetic resonance imaging (MRI) of AD for early diagnosis. However, the changes of brain structure are less different from those of normal people in the early stage, and the existing single-scale analysis methods are difficult to capture these subtle differences. Aiming at the above problem, this paper proposes a feature enhanced pyramid network (FEPN) for early diagnosis of AD. The high-level features are supplemented by the contextual information extracted from the designed shallow feature re-extraction, and the fusion weights are calculated to guide the fusion of high-level and low-level feature maps, which enhance the interaction of contextual information

基金项目: 国家自然科学基金青年科学基金(62006210、62001284);2020年度河南省重大公益专项(201300210500);河南省高等学校重点科研项目(21B520018);郑州大学高层次人才科研启动基金(32340306)。

收稿日期: 2022-05-10; **修订日期:** 2022-06-23

and the matching degree of multi-scale feature fusion. The Alzheimer datasets published by Kaggle are employed to conduct comparison experiments to verify the performance of the proposed approach. The comparison experiment employs the Alzheimer dataset published by Kaggle to verify the performance. Compared with related methods, FEPN achieves the SOTA classification accuracy of MRI of four AD brain states (non-demented, very mild demented, mild demented, moderate demented).

Key words: Alzheimer's disease (AD); magnetic resonance imaging (MRI); deep learning; shallow feature re-extraction; fusion weight

引 言

阿尔茨海默症 (Alzheimer's disease, AD) 高发于 65 岁以上的老年人群中, 是一种慢性进行性疾病^[1]。研究表明, AD 患者最早在出现症状的 20 年以前脑部结构已开始产生变化^[2]。患病初期的脑部变化并不会被患者察觉到, 经过多年的大脑病变以后, 个体才会产生明显的症状, 比如记忆丧失和语言障碍。AD 会破坏患者大脑中与认知功能有关的部分神经元细胞, 从而影响患者的记忆力和思维能力, 导致患者逐渐丧失认知功能和行动能力^[3]。2020 年我国第七次全国人口普查结果显示, 全国 60 岁及以上人口为 264 018 766 人, 占全国人口的 18.70%, 其中 65 岁以上人群有 190 635 280 人, 占 13.50%^[4]。人口的老龄化程度进一步加重, AD 发病人数持续增加, 已经成为严重危害我国人群健康的重大疾病^[5]。轻度认知障碍 (Mild cognitive impairment, MCI) 是从正常认知发展为痴呆的中间阶段^[6], 是一个重要的可接受早期干预的时期。研究表明, MCI 患者每年约有 10%~15% 的概率转化为 AD^[7]。如果能够在 MCI 阶段中进行干预, 有可能减少或防止患者脑细胞的进一步损伤^[8], 避免 MCI 进一步发展为 AD, 从而降低 AD 的死亡率。

核磁共振成像 (Magnetic resonance imaging, MRI) 作为一种高空间分辨率的医学成像技术, 不会产生对人体有害的辐射, 目前被广泛地应用于 AD 的辅助诊断上^[9]。深度学习 (Deep learning) 方法最近在神经退行性疾病、骨科疾病和癌症等医学影像分析中得到了广泛的应用。它能够学习影像数据中复杂的特征表示, 自动提取有效的特征^[10], 与传统的机器学习技术相比减少了人工特征提取的操作, 提高了诊断效率。利用深度学习方法对 MRI 分析可以进行 AD 的早期检测, 可以提升医生的诊断效率和准确率^[11], 帮助医生及时制定早期干预方案, 从而抑制患者脑中疾病的蔓延^[12]。深度学习通过构建多层神经网络来自动学习从数据样本中提取出的不同层次的特征^[13], 与人工特征工程方法相比, 可以通过大量数据对模型进行迭代优化^[14]。当对图像进行特征提取时, 低级特征用来描述图像中的边缘和轮廓, 而高级特征蕴含图像的语义信息^[15]。

目前主流应用于 MRI 的深度学习方法多基于单一尺度, 很难捕捉到相邻病程阶段 MRI 的细微差别。本文重点关注多尺度 MRI 特征提取方法, 尝试解决不能有效捕捉 AD 早期脑部 MRI 变化的问题。因此, 本文提出特征增强金字塔网络 (Feature enhanced pyramid network, FEPN) 方法, 通过浅层特征重提取和计算融合权重来增强特征融合时的上下文信息匹配度, 从而提升模型分类的准确率。

1 相关工作

深度学习能够从大量的训练数据中自动学习特征, 所以越来越广泛地被用于 AD 的诊断^[16]。Ghazal 等^[17]提出了基于迁移学习的改进 AlexNet 模型, 将在 ImageNet 预训练后的模型迁移至 AD 分类数据集, 即非痴呆 (Non-demented, ND)、非常轻度痴呆 (Very mild demented, VMD)、轻度痴呆 (Mild demented, MD) 和中度痴呆 (Moderate demented, MOD) 数据集, 并且在四分类任务中获得了 91.7% 的

准确率;Islam 等^[18]设计了一个基于 Inception V4 的神经网络,并将 SoftMax 层重新编排为 4 个分类 (ND、VMD、MD、MOD),在 Oasis 数据集上取得了 73.75% 的准确率;Farooq 等^[19]采用 Resnet152 提取出 AD 各阶段分类的特征表示,在 ADNI 数据上采用 4 路二分类器对 AD、MCI、LMCI 和 CN 进行分类,达到了 98.1% 的预测精度;李彩等^[20]将脑部 sMRI 用于预测分类,并引入年龄、性别、受教育年限和 MMSE 量表评分来优化模型,提升了 0.89% 到 11.42% 的预测准确率;Zaabi 等^[21]利用基于 vgg16 训练的迁移网络,在 4 个阶段 (CN、AD、MCI、LMCI) 对 AD 进行多分类,取得的分类准确率为 95.31%;Odusami 等^[22]通过对 ResNet18 进行微调,设计出能够处理 7 个二分类任务的网络,并通过正则化微调,减少了过拟合并提高了分类精度。由此可见,深度学习算法在 AD 的病程分类和预测方面已经取得了良好的效果。以上研究均采用单一尺度的特征提取方法,在 AD 的多病程分类任务中仍存在难以捕捉不同病程 MRI 之间细小差距的问题。Ge 等^[23]提出一种三维多尺度卷积网络,提取出不同尺度的特征融合后进行特征增强,然后通过全连接层进行二分类 (AD、NC),在 ADNI 数据集上可获得较高的分类准确率。

特征金字塔网络 (Feature pyramid network, FPN)^[24]被广泛用于目标检测领域,可以提取多尺度的特征信息用于分类和检测任务。FPN 由自底向上的降采样、自顶向下的上采样和横向连接组成,如图 1 所示。自底向上的路径由主干 CNN 组成,从分辨率最高但语义最少的输入图像开始,逐步进行降采样 (Down sampling),在金字塔顶端产生语义最多但分辨率最低的特征图 C_5 。自顶向下的路径从 P_5 开始,将自顶向下的路径与自底向上的路径连接起来,逐步通过上采样 (Up sampling) 和横向连接将特征融合来丰富传递的信息,将语义信息从高层次传播到低层次来构建多尺度特征,使得低层特征也具有丰富的语义信息,进而提高特征提取器的性能^[25]。自顶向下路径生成的特征图同时具有丰富的语义信息和高分辨率,可以更好地用于目标检测和图像分类^[26]。

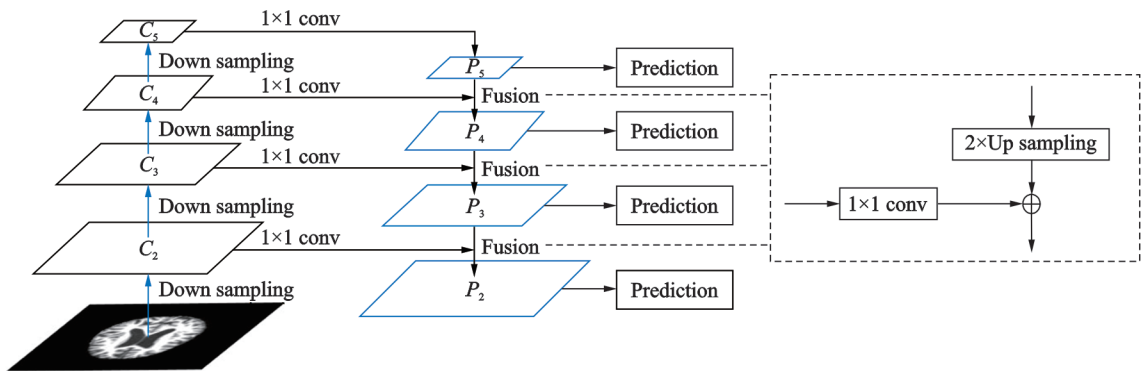


图 1 特征金字塔网络

Fig.1 Feature pyramid network

然而,由自底向上生成的最高层 C_5 生成自顶向下的最高层 P_5 时, C_5 仅通过 1×1 卷积进行通道数减少便得到 P_5 , 仅包含当前尺度的特征信息,缺乏了上下文信息。同时,在将自顶向下路径中上采样产生的特征图和自底向上降采样产生的特征图进行融合时,FPN 采用了简单的加法融合方法,对于来自不同层次的特征,两个层次上的特征存在一定程度的差异,且不同的输入特征对特征金字塔的贡献不同^[27],直接通过加法融合会破坏两个层次上的特征表示^[28]。

2 基于特征增强金字塔网络的 AD 早期诊断方法

目前在 FPN 中自顶向下的初始层 P_5 直接由自底向上生成的最高层 C_5 通过 1×1 卷积降低通道数

得到,只包含单尺度的上下文信息,使得高层特征的语义缺失,影响高层特征的特征表达,阻碍了FPN更全面地学习到多尺度的特征;而且在自顶向下阶段,来自高层的特征与来自底层的特征通过简单加法进行融合,破坏了高层和低层特征的细节表示和上下文信息。本文提出FEPN,通过浅层特征重提取(Shallow feature re-extraction, SFE)和计算融合权重(Fusion weight, FW)来增强上下文信息交互并提升特征融合的匹配度,如图2所示。

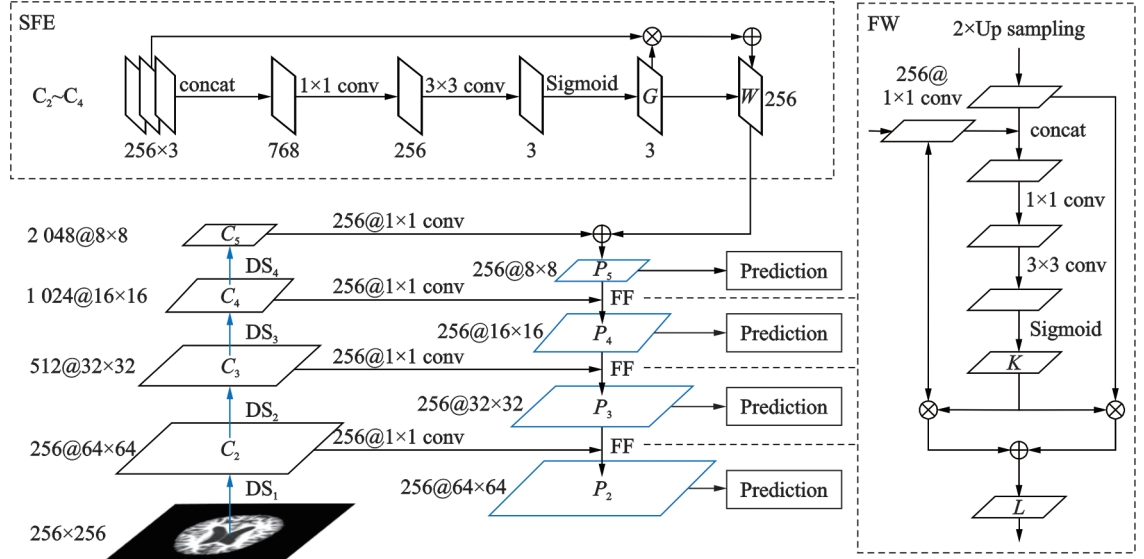


图2 特征增强金字塔网络

Fig.2 Feature enhanced pyramid network

针对 C_5 层到 P_5 层尺度单一、缺乏上下文信息的问题,引入 SFE 对 C_5 进行尺度扩充,使其包含多尺度的上下文信息,来解决该层尺度单一的问题。SFE 通过 C_2 、 C_3 、 C_4 层提取上下文信息用来丰富 P_5 层,得到没有信息损失的 P_5 层。

首先定义两种卷积块,ConvBlock1 为包含 1×1 、 3×3 和 1×1 卷积的模块,ConvBlock2 为通过 ConvBlock1 的卷积结构后与原特征进行残差连接的模块。输入的数据首先通过 DS_1 进行降采样处理得到 C_2 , DS_1 包含一个 7×7 卷积,ConvBlock2 和两层 ConvBlock1; C_2 通过 DS_2 得到 C_3 , DS_2 包含 ConvBlock2 和三层 ConvBlock1; C_3 通过 DS_3 得到 C_4 , DS_3 包含 ConvBlock2 和 5 层 ConvBlock1; C_4 通过 DS_4 得到 C_5 , DS_4 包含 ConvBlock2 和两层 ConvBlock1。SFE 流程为首先将 C_5 的通道数降至 256 得到 P_5 ,并将 C_2 、 C_3 、 C_4 降采样到 C_5 的特征图尺寸大小,通道降至与 P_5 相同的 256 维,然后将得到的 3 个特征图进行拼接,再通过卷积层提取特征后经过 Sigmoid 函数得到特征 G ,其计算公式为

$$G = \sigma \left(f^{3 \times 3} \left(f^{1 \times 1} \left(\text{concat} (C_i) \right) \right) \right) \quad (1)$$

式中: C_i 指 [C_2 , C_3 , C_4]; concat 为按通道拼接操作; $f^{1 \times 1}$ 为卷积核为 1×1 的卷积操作; $f^{3 \times 3}$ 为卷积核为 3×3 的卷积操作; σ 为 Sigmoid 函数。得到特征 G 后将 G 与原特征进行残差连接得到上下文信息 W 。 G 与原特征的残差连接可表示为

$$W = G'_0 \times C_2 + G'_1 \times C_3 + G'_2 \times C_4 \quad (2)$$

式中: G'_a ($a=0, 1, 2$) 通过将 G 的第 $a+1$ 个通道通过维度扩展后得到,可以作为权重与 C_i ($i=2, 3, 4$) 维度匹配后相乘,将得到的结果通过累加后得到上下文信息 W 。将得到的上下文信息 W 与 P_5 相加得到

没有上下文信息损失的 P_5 层。

FPN把高层特征通过上采样后与低层特征通过通道降维后进行简单相加,这样很难平衡不同层次之间的上下文信息,因为不同层次的特征对金字塔的贡献度不同^[29],高层特征包含更多的语义信息,低层特征包含更多的细节信息。本文引入FW指导高层特征和低层特征融合来解决两个层次特征表达差异的问题。FW可以从待融合的高层和低层特征中根据不同层次特征的贡献度来提取出对应的权重,依靠权重来指导两个层次上的特征融合。

FW将 P_i 通过上采样后的特征与 C_{i-1} 通过 1×1 卷积操作降维后的特征拼接起来,然后通过两层卷积层进行特征提取后通过Sigmoid函数得到特征 K ,其计算公式为

$$K = \sigma \left(f^{3 \times 3} \left(f^{1 \times 1} \left(\text{concat} (P_i, C_{i-1}) \right) \right) \right) \quad (3)$$

式中: i 的取值为5、4、3;concat指特征按通道进行拼接; $f^{1 \times 1}$ 为卷积核为 1×1 的卷积操作; $f^{3 \times 3}$ 为卷积核为 3×3 的卷积操作; σ 为Sigmoid函数。

得到特征 K 后,将 K 与原特征进行残差连接得到特征融合结果 L 。 K 与原特征的残差连接可表示为

$$L = K'_0 \times P_i + K'_1 \times C_{i-1} \quad (4)$$

式中: K'_0 和 K'_1 分别为 K 的第1个和第2个通道通过维度扩展后得到的权重,可以与 P_i 和 C_{i-1} 维度匹配后相乘,将得到的结果通过矩阵相加后得到按权重分配的高低层融合结果 L 。

3 实验与结果分析

实验运行系统为Ubuntu20.04,CPU为主频2.2 GHz的Intel(R) Xeon(R) Silver 4210,内存64 GB, GPU型号为Tesla T4*2,显存为16 GB,实验环境为python3.6和tensorflow2.3.0。

3.1 数据集与预处理

实验数据来源于Kaggle公开的Alzheimer's Dataset数据集(<https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images>)。数据包含ND、VMD、MD和MOD四类脑部MRI。针对数据集中存在的数据不平衡问题,本文对实验数据进行了预处理。由于MOD数据量较少,故对其进行数据增强并扩充至与MD近似的数量,处理过程包含概率为0.5的随机水平翻转,角度范围为 10° 的随机旋转、偏移范围为0.2的依概率修改亮度和对比度。为了消除MOD数据增强对实验造成的影响,对ND、VMD和MD进行数据量不变的相同数据处理操作,并将数据量较多的ND和VMD随机抽取至与MOD近似。预处理前后的数据量如表1所示。

表1 数据集参数

Table 1 Dataset parameters

数据分类	预处理前数据量	预处理后数据量
ND	3 200	1 496
VMD	2 240	1 240
MD	896	896
MOD	64	1 024

3.2 实验细节

(1)对比方法选择

本文选取3种主流的AD诊断方法开展对比实验,包括VGG19、MobileNet V2和ADDTLA。VGG19^[30]通过叠加较小的卷积核来加深网络,对于复杂高维的MRI数据,较小的卷积核可以关注到大卷积核关注不到的细节信息;MobileNet V2^[31]是一个轻量级网络,通过模型预训练以较小的参数量可以取得较高的AD分类准确率;ADDTLA^[17]是一种基于迁移学习的预训练模型,可以在MRI数据上取得较好的分类效果。

(2)实验设置

实验使用的 FEPN 模型以 ResNet 作为骨干网络, 训练过程中 batchsize 大小为 16, epoch 设置为 100, 学习率固定为 0.001, L2 正则化系数为 0.3。由于交叉熵损失函数在数据集各分类数据量均衡的条件下有良好的表现, 故实验采用交叉熵损失函数, 即

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^4 y_{ic} \ln p_{ic} \quad (5)$$

式中: N 表示 1 个 batchsize 的样本量; 4 表示该实验为四分类; y_{ic} 为符号函数, 如果样本 i 的真实类别为 c 则 y_{ic} 取 1, 否则取 0, p_{ic} 表示样本 i 预测为类别 c 的概率。

(3) 评价指标

实验采用精确率 (Precision, P)、召回率 (Recall, R)、平衡 F 分数 (F_1 -score, F_1) 和准确率 (Accuracy, A) 来评价模型性能。其中, 精确率、召回率和平衡 F 分数用来评价模型对每个分类的性能, 准确率用来衡量模型的整体性能。 P 、 R 、 F_1 和 A 分别表示为

$$P = \frac{X_{TP}}{X_{TP} + X_{FP}} \quad (6)$$

$$R = \frac{X_{TP}}{X_{TP} + X_{FN}} \quad (7)$$

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (8)$$

$$A = \frac{X_{TP} + X_{TN}}{X_{TP} + X_{TN} + X_{FN} + X_{FP}} \quad (9)$$

式中: X_{TP} 为真正类; X_{TN} 为真负类; X_{FP} 为假正类; X_{FN} 为假负类。

3.3 实验结果及分析

实验结果如表 2 所示, 其中 FPN 为特征金字塔网络模型; FPN+SFE 为引入 SFE 后的特征金字塔网络模型; FPN+FW 为引入 FW 后的特征金字塔网络模型; FEPN 为本文提出的特征增强金字塔网络模型。加入 SFE 后, 精确率、召回率和 F_1 分数都有所提升, 模型准确率提升了 2.7%, 说明 SFE 可以通过补充 FPN 中 P_5 层缺失的上下文信息来提升模型的多尺度特征提取能力; 加入 FW 后, 精确率、召回率和 F_1 分数都有所提升, 模型准确率提升了 1.4%, 说明加入 FW 后与 FPN 相比更能平衡不同层之间的上下文信息。加入 SFE 比加入 FW 的准确率和各项指标都要高, 说明 SFE 更有利于 FPN 能够充分提取 MRI 多尺度特征。FEPN 与 FPN 相比, 模型的准确率提升了 3.1%, 拥有更好的分类性能。图 3 为消融实验准确率随 epoch 的变化, 在 40 个 epoch 以前 4 种方法的准确率区分不明显, 在 40~60 个 epoch 中, FEPN 较其他方法的准确率有明显的提升, 并于 60 个 epoch 以后趋于稳定。

图 4 为模型预测每个分类的概率结果。图 4(a) 为正常人的脑部 MRI, 其脑组织结构特征明显, 并没有萎缩等现象, 因而模型的分类精度较高; 图 4(b) 为非常轻度痴呆病人

表 2 加入 SFE 和 FW 对特征金字塔网络性能影响的对比

Table 2 Comparison of FPN performance by adding SFE and FW

模型	P	R	F_1	A
FPN	0.918	0.887	0.897	0.948
FPN+SFE	0.928	0.913	0.910	0.975
FPN+FW	0.913	0.857	0.879	0.962
FEPN	0.928	0.895	0.905	0.979




图 3 消融实验结果

Fig.3 Ablation experimental results

的脑部MRI,此阶段病人的脑皮质已出现萎缩的前兆,分类精度较高;图4(c)为轻度痴呆病人的脑部MRI,该阶段的患者脑皮质处于萎缩的初级阶段,与非常轻度痴呆区分不明显,有18.6%的概率会误分类为非常轻度痴呆,分类精度较低;图4(d)为中度痴呆病人的脑部MRI,整个脑组织都会出现萎缩,其中颞叶、额叶和楔叶的萎缩相对明显,脑沟增宽,区分度较高,分类精度较高。




图4 本文方法预测结果示例

Fig.4 Example of prediction results of the proposed method

本文进一步对比了该模型与其他模型的性能,设置了4组对比试验,验证不同模型在相同数据集上的性能,结果如表3所示。FEPN的分类准确率与VGG19和MobileNet V2相比分别提升了41.1%和32%,但网络堆叠更深,参数量远多于MobileNet V2的 2.2×10^6 ;与ADDTLA相比提升了6.2%,但网络层数和参数量比ADDTLA更高,结构更复杂,对硬件和计算时间有更高的要求。

表3 与其他模型实验结果对比

Table 3 Comparison of experimental results with other models

模型	网络层数	参数量/ 10^6	精度/%
VGG19 ^[30]	19	139.6	56.8
MobileNet V2 ^[31]	24	2.2	65.9
ADDTLA ^[17]	7	15.0	91.7
FEPN	71	34.9	97.9

4 结束语

近年来AD的患者数量逐年增多且没有有效的治疗手段,通过早期诊断可以延缓病人脑组织病变。病人在患病早期脑部MRI与正常人相比差别很小,目前主流的单一尺度特征提取方法不能充分捕捉这些差异,导致早期的病程分类十分困难。本研究针对FPN中高层特征缺乏多尺度上下文信息的问题,通过SFE利用不同层次的上下文信息对高层特征进行补充;针对不同层次的特征表示在特征融合时的语义差距问题,计算FW指导高低层特征图的融合,增强了上下文信息交互和特征融合的匹配度,在Kaggle平台公开的Alzheimer数据集上的分类精度达到了97.9%,分类性能优于其他同类方法。由于原始的三维MRI在提取切片的过程中存在信息损失,在未来的工作中可以探究FEPN在三维MRI数据上

的表现,并对FEPN做进一步的改进,使其拥有良好的三维MRI处理能力。

参考文献:

- [1] REIMAN E M, QUIROZ Y T, FLEISHER A S, et al. Brain imaging and fluid biomarker analysis in young adults at genetic risk for autosomal dominant Alzheimer's disease in the presenilin 1 E280A kindred: A case-control study[J]. *Lancet Neurology*, 2012. DOI: 10.1016/S1474-4422(12)70228-4.
- [2] BARTHÉLEMY N R, LI Y, JOSEPH-MATHURIN N, et al. A soluble phosphorylated tau signature links tau, amyloid and the evolution of stages of dominantly inherited Alzheimer's disease[J]. *Nature Medicine*, 2020, 26(3): 398-417.
- [3] Association A S. 2021 Alzheimer's disease facts and figures[J]. *Alzheimers Dement*, 2021, 17(3): 327-406.
- [4] 国家统计局. 第七次全国人口普查公报(第五号)[EB/OL]. (2021-05-11). [Http://www.stats.gov.cn/tjsj/zxfb/202105/t20210510_1817181.html](http://www.stats.gov.cn/tjsj/zxfb/202105/t20210510_1817181.html).
- [5] 任汝静, 殷鹏, 王志会, 等. 中国阿尔茨海默病报告 2021[J]. *诊断学理论与实践*, 2021, 20(4): 317-337.
REN Rujing, YIN Peng, WANG Zhihui, et al. Chinese Alzheimer's disease report 2021[J]. *Journal of Diagnostics Concepts & Practice*, 2021, 20(4): 317-337.
- [6] ROBERTS R, KNOPMAN D S. Classification and epidemiology of MCI[J]. *Clinics in Geriatric Medicine*, 2021, 29(4): 753-772.
- [7] ZHANG T, LIAO Q, ZHANG D, et al. Predicting MCI to AD conversation using integrated sMRI and rs-fMRI: Machine learning and graph theory approach[J]. *Frontiers in Aging Neuroscience*, 2021, 13: 429.
- [8] ODUSAMI M, MASKELIUNAS R, DAMASEVICIUS R. An intelligent system for early recognition of Alzheimer's disease using neuroimaging[J]. *Sensors*, 2022. DOI: 10.3390/S22030740.
- [9] 陆小玲, 吴海锋, 曾玉, 等. 3D迁移网络的阿尔茨海默症分类研究[J]. *计算机工程与应用*, 2021, 57(16): 253-262.
LU Xiaoling, WU Haifeng, ZENG Yu, et al. 3D Transfer learning network for classification of Alzheimer's disease[J]. *Computer Engineering and Applications*, 2021, 57(16): 253-262.
- [10] ETMINANI K, SOLIMAN A, DAVIDSSON A, et al. A 3D deep learning model to predict the diagnosis of dementia with lewy bodies, Alzheimer's disease and mild cognitive impairment using brain 18F-FDG PET[J]. *European Journal of Nuclear Medicine and Molecular Imaging*, 2022, 49(3): 563-584.
- [11] 张进一, 万鹏, 孙亮, 等. 基于CT图像的双重注意力网络急性胰腺炎诊断方法[J]. *数据采集与处理*, 2022, 37(1): 147-154.
ZHANG Jingyi, WAN Peng, SUN Liang, et al. Dual-attention network for acute pancreatitis diagnosis with CT images[J]. *Journal of Data Acquisition and Processing*, 2022, 37(1): 147-154.
- [12] BRON E E, SMITS M, FLIER W, et al. Standardized evaluation of algorithms for computer-aided diagnosis of dementia based on structural MRI: The caddementia challenge[J]. *Neuroimage*, 2015, 111: 562-579.
- [13] SHEN D, WU G, SUK H I. Deep learning in medical image analysis[J]. *Annual Review of Biomedical Engineering*, 2017, 19(1): 221-248.
- [14] WANG S, CAO G, WANG Y, et al. Review and prospect: Artificial intelligence in advanced medical imaging[J]. *Frontiers in Radiology*, 2021. DOI: 10.3389/fradi.2021.781868.
- [15] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [16] BACKSTROM K, NAZARI M, GU Y H, et al. An efficient 3D deep convolutional network for Alzheimer's disease diagnosis using MR images[C]//*Proceedings of 2018 IEEE 15th International Symposium on Biomedical Imaging*. Washington D C, USA: IEEE, 2018: 149-153.
- [17] GHAZAL T M, ABBAS S, MUNIR S, et al. Alzheimer disease detection empowered with transfer learning[J]. *Computers, Materials & Continua*, 2022, 70(3): 5005-5019.
- [18] ISLAM J, ZHANG Y. A novel deep learning based multi-class classification method for Alzheimer's disease detection using brain MRI data[C]//*Proceedings of International Conference on Brain Informatics*. [S.l.]: Springer, 2017: 213-222.
- [19] FAROOQ A, ANWAR S M, AWAIS M, et al. A deep CNN based multi-class classification of Alzheimer's disease using MRI[C]//*Proceedings of 2017 IEEE International Conference on Imaging Systems and Techniques (IST)*. Beijing, China: IEEE, 2017.
- [20] 李彩, 范焯. 基于机器学习的阿尔兹海默症分类预测[J]. *中国医学物理学杂志*, 2020, 37(3): 379-384.

- LI Cai, FAN Zhao. Classification and prediction of Alzheimer's disease based on machine learning[J]. Chinese Journal of Medical Physics, 2020, 37(3): 379-384.
- [21] ZAABI M, SMAOUI N, DERBEL H, et al. Alzheimer's disease detection using convolutional neural networks and transfer learning based methods[C]//Proceedings of 2020 17th International Multi-Conference on Systems, Signals & Devices (SSD). Monastir, Tunisia: IEEE, 2020.
- [22] ODUSAMI M, MASKELIŪNAS R, DAMAŠEVIČIUS R, et al. Analysis of features of Alzheimer's disease: Detection of early stage from functional brain changes in magnetic resonance images using a finetuned resnet18 network[J]. Diagnostics, 2021, 11(6): 1071.
- [23] GE C J, QU Q X, GU I Y H, et al. Multiscale deep convolutional networks for characterization and detection of Alzheimer's disease using MR images[C]//Proceedings of 2019 IEEE International Conference on Image Processing. Taipei, China: IEEE, 2019.
- [24] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 936-944.
- [25] 史晨晨, 张长伦, 何强, 等. 基于改进特征金字塔的目标检测[J]. 电子测量技术, 2021, 44(20): 150-156.
SHI Chenchen, ZHANG Changlun, HE Qiang, et al. Object detection based on improved feature pyramid[J]. Electronic Measurement Technology, 2021, 44(20): 150-156.
- [26] HE L, JIANG M, OHBUCHI R, et al. Scale adaptive feature pyramid networks for 2D object detection[J]. Scientific Programming, 2020. DOI: 10.1155/2020/8839979.
- [27] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection[C]//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 10778-10787.
- [28] GUO C, FAN B, ZHANG Q, et al. AugFPN: Improving multi-scale feature learning for object detection[J]. Computer Vision and Pattern Recognition, 2019. DOI:10.48550/arXiv.1912.05384.
- [29] 赵义飞, 王勇. 基于注意力特征金字塔的轻量级目标检测算法[J]. 电子技术应用, 2021, 47(10): 33-37.
ZHAO Yifei, WANG Yong. Lightweight object detection algorithm based on attention feature pyramid network[J]. Application of Electronic Technique, 2021, 47(10): 33-37.
- [30] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Vision and Pattern Recognition, 2016. DOI:10.48550/arXiv.1409.1556.
- [31] SANDLER M, HOWARD A, ZHU M, et al. Inverted residuals and linear bottlenecks: Mobile networks for classification, detection and segmentation[J]. Computer Vision and Pattern Recognition, 2018. DOI: 10.48550/arXiv.1801.04381.

作者简介:



石磊(1967-),男,博士,教授,研究方向:云计算与大数据、网络与分布式计算、服务计算、人工智能、智慧城市, E-mail: shilei@zzu.edu.cn。



彭少康(1998-),男,硕士研究生,研究方向:医学影像分析。



张亚萌(1990-),女,博士,助理研究员,研究方向:病理图像识别、蛋白组学、生物标记物。



赵国桦(1992-),男,博士,助理研究员,研究方向:医学影像计算与分析、机器学习。



高宇飞(1990-),通信作者,男,博士,助理研究员,研究方向:人工智能、视觉计算、机器学习、医学影像分析、自然语言处理, E-mail: yfgao@zzu.edu.cn。

(编辑:王静)