

论 著

## 基于深度学习的多模态MRI辅助诊断新生儿急性胆红素脑病\*

董双君<sup>1</sup> 孙彬<sup>2</sup> 吴淼<sup>2</sup>  
贾文霄<sup>1,\*</sup>

1.新疆医科大学第一附属医院影像中心

(新疆乌鲁木齐 830011)

2.新疆医科大学医学工程技术学院

(新疆乌鲁木齐 830017)

**【摘要】目的** 基于多模态磁共振成像与深度学习的融合技术, 构建DenseNet121及InceptionV3两种卷积神经网络模型, 实现新生儿急性胆红素脑病的早期精准诊断。**方法** 选取覆盖苍白球区域的连续T1加权图像、T2加权图像、表观扩散系数图作为卷积神经网络输入, 在T1WI、T2WI、ADC三种单模态数据集上分别训练DenseNet121(SoftMax)、InceptionV3(SoftMax)、DenseNet121+SVM和InceptionV3+SVM, 比较不同分类器的性能。基于DenseNet121和InceptionV3提取深度特征, 采用支持向量机分类器, 对不同模态特征融合方法进行比较。运用五倍交叉验证方法来评价模型的泛化能力, 采用曲线下面积(AUC)、灵敏度、特异度、准确度、精确度、以及F1评分(F1-score)评估模型的性能。**结果** 在单模态特征中, InceptionV3+SVM和DenseNet121+SVM在T1WI上的AUC值最高, T2WI次之, ADC最低。InceptionV3+SVM和DenseNet121+SVM在双模态特征融合中的AUC值高于任何一个单模态特征的AUC值。在三模态特征融合中, T1WI+T2WI+ADC特征融合的AUC值高于单模态及双模态特征的AUC值, 其中DenseNet121+SVM表现最佳, AUC值为0.8730, 准确率为88.17%。**结论** 多模态MRI结合深度学习为新生儿急性胆红素脑病的早期诊断和及时治疗提供了客观的影像学依据。

**【关键词】** 急性胆红素脑病; 苍白球; 磁共振成像; 机器学习; 深度学习

【中图分类号】R445

【文献标识码】A

【基金项目】新疆维吾尔自治区

自然科学基金(2022D01C436);

新疆青年科技

英才项目(2023TSYCCX0067)

DOI:10.3969/j.issn.1672-5131.2025.12.001

# Deep Learning-based Multimodal MRI for Auxiliary Diagnosis of Neonatal Acute Bilirubin Encephalopathy\*

DONG Shuang-jun<sup>1</sup>, SUN Bin<sup>2</sup>, WU Miao<sup>2</sup>, JIA Wen-xiao<sup>1,\*</sup>.

1.Imaging Center, The First Affiliated Hospital of Xinjiang Medical University, Urumqi 830011, Xinjiang Uyghur Autonomous Region, China

2.College of Medical Engineering and Technology, Xinjiang Medical University, Urumqi 830017, Xinjiang Uyghur Autonomous Region, China

**ABSTRACT**

**Objective** Based on the fusion technology of multimodal magnetic resonance imaging and deep learning, two convolutional neural network models, DenseNet121 and InceptionV3, are constructed to achieve early and accurate diagnosis of neonatal acute bilirubin encephalopathy. **Methods** Continuous T1-weighted imaging (T1WI), T2-weighted imaging (T2WI), and apparent diffusion coefficient (ADC) maps covering the globus pallidus region were selected as inputs for the convolutional neural network (CNN). Four models—DenseNet121 (with SoftMax), InceptionV3 (with SoftMax), DenseNet121+SVM, and InceptionV3+SVM—were trained on the three single-modal datasets (T1WI, T2WI, and ADC) to compare the performance of different classifiers. Based on the deep features extracted by DenseNet121 and InceptionV3, a support vector machine (SVM) classifier was employed to evaluate different feature fusion strategies. A five-fold cross-validation approach was used to assess the models' generalization ability, while classification performance was evaluated using metrics including the area under the curve (AUC), sensitivity, specificity, accuracy, precision, and F1-score. **Results** Among single-modal features, InceptionV3+SVM and DenseNet121+SVM exhibited the highest AUC values on T1WI, followed by T2WI, with ADC performing the lowest. For dual-modal feature fusion, both InceptionV3+SVM and DenseNet121+SVM achieved higher AUC values than any single-modal feature. In multimodal feature fusion (T1WI+T2WI+ADC), the AUC value surpassed those of both single-modal and dual-modal features, with DenseNet121+SVM demonstrating the best performance—achieving an AUC of 0.8730 and an accuracy of 88.17%. **Conclusion** Multimodal MRI combined with deep learning provides objective imaging evidence for the early diagnosis and timely treatment of neonatal acute bilirubin encephalopathy.

**Keywords:** Acute Bilirubin Encephalopathy; Globus Pallidus; Magnetic Resonance Imaging; Machine Learning; Deep Learning

急性胆红素脑病(acute bilirubin encephalopathy, ABE)是新生儿高胆红素血症的严重并发症<sup>[1]</sup>。由于在早期阶段胆红素神经毒性造成新生儿大脑损伤是相对可控的, 因此, 及早诊断ABE并采取治疗是减少发生永久性脑损伤的关键<sup>[2]</sup>。目前, 临床上尚无客观公认的新生儿ABE的诊断方法, 现有的诊断方法主要依靠患儿的临床症状、实验室检查及影像学资料综合判断, 这些方法具有一定的局限性, 使得灵敏度和特异度不高<sup>[3]</sup>。计算机辅助诊断(computer aided diagnosis, CAD)技术近些年发展的非常迅速, 并且展现出了显著的效果, 机器学习被广泛应用于CAD中, 机器学习中最前沿的分支就是深度学习(deep learning, DL), 深度学习中常用的模型为卷积神经网络(convolutional neural network, CNN), 被用于医学影像学的研究中<sup>[4]</sup>。Wu等人<sup>[5]</sup>利用人工目测阅片法、半定量分析法以及深度学习方法研究了T1WI在ABE上的诊断价值, 准确率分别为53.58%、62.11%、72.15%。现有的研究局限于单一模态的磁共振影像数据<sup>[6]</sup>, 忽略了其他模态影像数据对新生儿ABE的诊断价值。本研究将多模态MRI与深度学习技术相结合, 运用两个CNN模型, 即DenseNet121和InceptionV3, 建立基于深度学习的多模态MRI特征融合分类方法, 旨在精准诊断新生儿ABE, 从而降低不可逆后遗症的风险。

**1 资料与方法**

**1.1 临床资料** 回顾性选取2019年1月至2023年8月新疆医科大学第一附属医院收治入院的临床诊断为急性胆红素脑病的新生儿54例, 其出生胎龄 $38.03 \pm 2.57$ 周。并选取正常新生儿47例, 其出生胎龄 $38.05 \pm 2.61$ 周。

**纳入标准:** 所有新生儿胎龄38-41周, 首次进行颅脑MRI检查时 $\leq 21$ 天; 正常新生儿血清总胆红素 $< 205 \mu\text{mol/L}$ (因有呼吸系统、消化系统、泌尿系统等其他系统疾病入院); ABE阳性病例的诊断基于临床诊断标准: 血清总胆红素 $\geq 342 \mu\text{mol/L}$ (20mg/dl); 有神经功能障碍相关的临床症状, 如激惹、肌张力异常、角弓反张、嗜睡、哭声尖锐、进食差等3项或3项以上; 影像学提示胆红素脑病可能; 患儿磁共振图像齐全, 且无明显的运动伪影。排除标准: 其它引起神经功能障碍的疾病, 包括新生儿窒息<sup>[7]</sup>、缺血缺氧性脑病、感染<sup>[8]</sup>、低血糖、遗传代谢性疾病等; 患有先天性脑发育异常。本研究通过医院伦理委员会的审查批准。

**1.2 检查方法** 所有磁共振图像采集均在Philips 3.0T扫描仪上进行。给予患儿口服10%

【第一作者】董双君, 女, 主治医师, 主要研究方向: 磁共振成像。E-mail: 384687003@qq.com

【通讯作者】贾文霄, 男, 主任医师, 主要研究方向: 磁共振成像。E-mail: jwxxj@sina.com

水合氯醛(0.5ml/kg)镇静, 头颅两侧垫以海绵垫隔音, 将新生儿的头部尽可能靠近线圈的中心, 受检新生儿取仰卧位并全程监测患儿状况。采取常规头颅扫描序列, 包括T1加权自旋回波(spinecho, SE)序列, T2加权自旋回波序列, T1加权液体衰减反转恢复序列(fluid attenuated inversion recovery, FLAIR), 扩散加权成像(diffusion weighted imaging, DWI)。具体参数为, T1WI: 重复时间(repetition time, TR)=583ms, 回波时间(echo time, TE)=18ms, 层厚=5mm, 矩阵432×432; T2WI: TR=2956ms, TE=117ms, 层厚=5mm, 矩阵512×512; DWI: TR=3427ms, TE=102ms, 层厚=5mm, 矩阵128×128, b值为0、800s/mm<sup>2</sup>。扫描包括新生儿的全脑范围, 所用时间为4min17s。

**1.3 MRI图像预处理** 为了提高计算效率和算法的鉴别精确度, 每个新生儿选取两张或三张覆盖苍白球区域的连续T1WI、T2WI、ADC切片作为CNN输入, 即从54名ABE患儿每个模态图像中各选取133张切片, 从47名正常新生儿的每个模态图像中各选取104张切片。将所有MRI图像的窗宽设置为870, 窗位设置为350, 调整后对颅骨周围黑色区域进行裁剪, 并将所有图像的像素值归一化至0~1范围内, 大小调整为224×224。

**1.4 建立深度学习框架** 选取复杂度低、有较少参数且易于训练的经典的CNN模型DenseNet121作为多模态图像分类任务的主干网络结构。为适应新生儿胆红素脑病的医学影像分析需求, 该模型在公共数据库ImageNet上进行了预训练, 并采用迁移学习的策略, 对在ImageNet数据集上经过预训练的DenseNet121模型进行微调。对T1WI、T2WI以及ADC三种模态的磁共振图像分别进行深度特征提取, 将提取到的多模态深度特征进行融合, 并构建一个支持向量机(support vector machine, SVM)分类器, 图1所示为基于多模态深度特征融合的分类方法流程。

为了验证不同模态图像深度特征融合的分类性能, 本研究主要采用以下策略: (1)单模态特征, 分别使用T1WI、T2WI和ADC图像深度特征作为SVM分类模型输入; (2)双模态特征, 分别使用T1WI+T2WI、T1WI+ADC和T2WI+ADC图像深度特征作为SVM分类模型输入; (3)三模态特征, 以T1WI+T2WI+ADC图像深度特征作为SVM分类模型输入。对于多模态特征融合分类, 模型首先从每个模态图像中分别提取深度特征, 然后进行特征串联融合, 最后使用SVM算法进行分类。为探索不同深度学习网络结构对分类性能的影响, 本研究还使用了图像表征丰富且参数量较少的InceptionV3模型作为核心网络进行多模态图像的深度特征提取。

**1.5 模型评价指标** 为确保模型评估的有效性并降低评估结果的随机误差, 在训练核心网络DenseNet121、InceptionV3和SVM

分类器的过程中采取了五倍交叉验证方法来评价模型的泛化能力。此外, 运用多种评估指标全面衡量模型的性能, 包括受试者操作特征曲线(receiver operating characteristics, ROC), 曲线下面积(area under the curve, AUC)、灵敏度、特异度、准确度、精确度、召回率以及F1评分。

**1.6 统计学分析** 采用IBM SPSS Statistics 21统计软件进行分析, 符合正态分布的计量资料采用均数±标准差表示。采用 $\chi^2$ 检验评估两组新生儿的性别分布差异, 对于通过Kolmogorov-Smirnov正态性检验的其它临床特征, 进行两独立样本t检验, 以 $P < 0.05$ 为差异有统计学意义。运用TensorFlow2.15构建DenseNet121和InceptionV3网络, Python程序绘制出两种CNN模型测试集的ROC曲线图, 得出测试集数据的曲线下面积(AUC)、灵敏度、特异度、准确度、精确度及F1评分, 评估两种CNN模型分类器的性能。

## 2 结果

**2.1 基本临床资料对比** 两组新生儿基本临床资料即性别( $\chi^2=0.065$ ,  $P=0.798$ )、日龄( $t=1.569$ ,  $P=0.122$ )及出生体重( $t=1.844$ ,  $P=0.068$ )组间差异无统计学意义( $P > 0.05$ ), 血清总胆红素值的组间差异具有统计学意义( $P < 0.05$ ), 相关临床资料组间比较见表1所示。

**2.2 不同分类器对单模态图像的分类性能对比** 如表2及图2所示, InceptionV3+SVM在T1WI和T2WI数据集上的AUC值高于InceptionV3(SoftMax)。DenseNet121+SVM在T1WI数据集上的AUC值比DenseNet121(SoftMax)高出3.51%, 在T2WI数据集上, DenseNet121+SVM的AUC值低于DenseNet121(SoftMax)。此外, DenseNet121+SVM在ADC数据集上的AUC值虽比DenseNet121(SoftMax)低1.15%, 但其灵敏度和特异度指标高于DenseNet121(SoftMax)。即在InceptionV3和DenseNet121从新生儿胆红素脑病的多个模态图像中提取深度特征的基础上, 使用SVM分类器的性能优于深度神经网络自带的SoftMax分类器。

表1 患儿临床资料特点组间比较

临床特点	ABE组(n=54)	正常对照组(n=47)	$\chi^2/t$ 值	P值
性别(男)	36(57.10%)	28(59.60%)	0.065	0.798
日龄(天)	7.30±3.27	9.45±8.94	1.569	0.122
出生体重(g)	3051.83±663.83	2803.83±741.13	1.844	0.068
血清总胆红素( $\mu\text{mol/L}$ )	359.49±125.31	125.28±96.30	8.456	<0.001

表2 不同分类器在T1WI、T2WI、ADC单模态数据集上的性能比较

Classification Methods	MRI Modality	Accuracy	AUC	Sensitivity	Specificity	Precision	F1 Score
InceptionV3(SoftMax)	T1	0.7562±0.0637	0.7578±0.0647	0.7666±0.1394	0.7491±0.1700	0.8112±0.0997	0.7747±0.0663
	T2	0.6750±0.0673	0.6566±0.0598	0.8193±0.1840	0.4940±0.1987	0.6949±0.0730	0.7342±0.0851
	ADC	0.6813±0.0538	0.6710±0.0579	0.7594±0.1296	0.5825±0.0921	0.6862±0.0601	0.7151±0.0686
InceptionV3+SVM	T1	0.7805±0.0528	0.7666±0.0721	0.8798±0.0939	0.6533±0.2367	0.7929±0.1177	0.8208±0.0219
	T2	0.7088±0.0492	0.6973±0.0608	0.7974±0.0887	0.5971±0.1830	0.7298±0.0750	0.7547±0.0321
	ADC	0.6619±0.0833	0.6495±0.0900	0.7510±0.1119	0.5481±0.1963	0.6934±0.0892	0.7129±0.0661
DenseNet121(SoftMax)	T1	0.8063±0.0538	0.8078±0.0580	0.8324±0.1253	0.7832±0.1879	0.8454±0.1082	0.8241±0.0439
	T2	0.7125±0.1090	0.7089±0.1071	0.7310±0.2129	0.6868±0.2153	0.7878±0.1194	0.7343±0.1185
	ADC	0.7562±0.0848	0.7411±0.0923	0.8228±0.1552	0.6593±0.2495	0.8035±0.1323	0.7913±0.0711
DenseNet121+SVM	T1	0.8481±0.0747	0.8429±0.0852	0.8877±0.0460	0.7981±0.1816	0.8663±0.1156	0.8715±0.0575
	T2	0.7131±0.0930	0.6981±0.1128	0.8205±0.1091	0.5757±0.2947	0.7504±0.1466	0.7672±0.0554
	ADC	0.7465±0.0821	0.7296±0.0945	0.8635±0.1203	0.5957±0.2537	0.7585±0.1144	0.7935±0.0572

**2.3 利用多模态深度特征融合方法的CNN模型DenseNet121及InceptionV3性能比较** 在单模态特征中, InceptionV3+SVM和DenseNet121+SVM在T1WI上的AUC值最高, T2WI次之, ADC最低。在双模态特征融合方法中, InceptionV3+SVM和DenseNet121+SVM的AUC值高于其中任何一个单模态特征的AUC值, 其中, T1WI+T2WI特征融合的AUC值最高, T1WI+ADC次之,

最低为T2WI+ADC。在三模态特征融合中, T1WI+T2WI+ADC特征融合的AUC值最高, 且高于任何单模态及双模态特征的AUC值。从表3和图3中可以发现随着模态特征的增加, InceptionV3+SVM和DenseNet121+SVM对新生儿胆红素脑病的识别性能提高。其中, DenseNet121+SVM方法在T1WI+T2WI+ADC特征融合中表现最佳, 其AUC值为0.8730, 准确度为88.17%。

**表3 基于DenseNet12+SVM和InceptionV3+SVM的多模态深度特征融合方法的性能对比**

Classification Methods	Deep	Accuracy	AUC	Sensitivity	Specificity	Precision	F1 Score
InceptionV3+SVM	Feature Fusion						
	T1	0.7805±0.0528	0.7666±0.0721	0.8798±0.0939	0.6533±0.2367	0.7929±0.1177	0.8208±0.0219
	T2	0.7088±0.0492	0.6973±0.0608	0.7974±0.0887	0.5971±0.1830	0.7298±0.0750	0.7547±0.0321
	ADC	0.6619±0.0833	0.6495±0.0900	0.7510±0.1119	0.5481±0.1963	0.6934±0.0982	0.7129±0.0661
	T1+T2	0.8187±0.0587	0.8108±0.0698	0.8806±0.0852	0.7410±0.1865	0.8311±0.0994	0.8467±0.0420
	T2+ADC	0.7299±0.1015	0.7131±0.1211	0.8575±0.0796	0.5686±0.2968	0.5686±0.2968	0.7868±0.0591
	T1+ADC	0.7681±0.0914	0.7602±0.1017	0.8285±0.1201	0.6919±0.2291	0.8001±0.1277	0.8019±0.0740
	T1+T2+ADC	0.8228±0.0540	0.8163±0.0674	0.8726±0.0602	0.7600±0.1852	0.8425±0.1079	0.8496±0.0340
DenseNet121+SVM	T1	0.8481±0.0747	0.8429±0.0852	0.8877±0.0460	0.7981±0.1816	0.8663±0.1156	0.8715±0.0575
	T2	0.7131±0.0930	0.6981±0.1128	0.8205±0.1091	0.5757±0.2947	0.7504±0.1466	0.7672±0.0554
	ADC	0.7465±0.0821	0.7296±0.0945	0.8635±0.1203	0.5957±0.2537	0.7585±0.1144	0.7935±0.0572
	T1+T2	0.8652±0.0637	0.8587±0.0749	0.9094±0.0793	0.8081±0.1853	0.8773±0.1029	0.8852±0.0467
	T2+ADC	0.7637±0.0488	0.7504±0.0672	0.8570±0.0942	0.6438±0.2252	0.7804±0.1081	0.8046±0.0190
	T1+ADC	0.8777±0.0641	0.8754±0.0712	0.8754±0.0712	0.8557±0.1565	0.9029±0.0952	0.8931±0.0518
	T1+T2+ADC	0.8817±0.0636	0.8730±0.0756	0.9470±0.0574	0.7990±0.1909	0.8757±0.1088	0.9029±0.0456


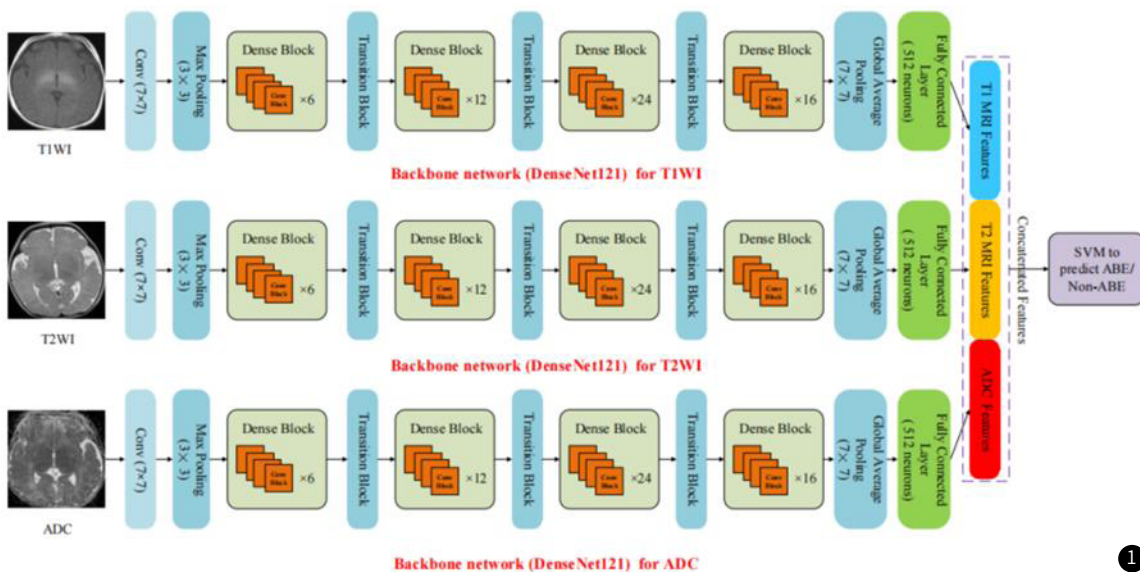


图1 基于多模态深度特征融合的分类方法流程图。

图2 2A-2D分别为InceptionV3(SoftMax)、DenseNet121(SoftMax)、InceptionV3+SVM、DenseNet121+SVM的ROC曲线。




图3 基于InceptionV3+SVM和DenseNet121+SVM的多模态深度特征融合方法的性能对比，图3A、3B分别为InceptionV3+SVM、DenseNet121+SVM的ROC曲线。

### 3 讨论

急性胆红素脑病的临床症状包括嗜睡、张力降低和吮吸力减弱等，在初期是可逆的，如果ABE进一步发展，可能会出现永久性核黄疸，表现为脑瘫、癫痫发作、感音神经性听力丧失等<sup>[9-10]</sup>。因此，为了降低永久性脑损伤的风险，及早地诊断ABE并实施有效的治疗措施是至关重要的。人工智能是包括机器学习和深度学习在内的技术，深度学习是机器学习的一个子集，相较于机器学习，深度学习提供了更灵活的架构来创建神经网络<sup>[11-13]</sup>。CNN是一种通过卷积、池化和全连接过程来压缩高维数据的方法，常用于处理结构化数据，如图像数据。该网络构建的理论依据是卷积理论，其中每一层都由多个二维平面组成，而这些二维平面内都包含了多个相互独立的神经元<sup>[14]</sup>。这个网络拥有一种与其他网络截然不同的权值共享架构，该架构不仅减少了所需权值的数量，还降低了网络模型的复杂性，使其更接近于人脑神经网络的特性<sup>[15-17]</sup>。

基于InceptionV3和DenseNet121模型从新生儿胆红素脑病多模态图像中抽取的深度特征，我们发现使用SVM分类器在性能上优于深度神经网络内置的SoftMax分类器。单模态图像结果表明，T1WI的分类性能最好，其次是T2WI和ADC，T1WI提供高分辨率解剖结构，对苍白球病变敏感<sup>[18]</sup>。在双模态特征融合方法中，T1WI和T2WI组合的灵敏度和特异性最好，InceptionV3+SVM和DenseNet121+SVM的双模态特征融合的AUC值高于单模态特征的AUC值，其中，T1WI+T2WI特征融合的AUC值最高，T1WI+ADC次之，最低为T2WI+ADC。在三模态特征融合中，采用T1WI+T2WI+ADC特征融合得到的AUC值最高，且高于其他任何单模态及双模态特征的AUC值。在InceptionV3+SVM和DenseNet121+SVM两种CNN模型中，随着输入图像中融合的MRI模态数量的增加，两种CNN模型的AUC值呈现出逐步提升的趋势，说明其对ABE的识别性能提高，其中，DenseNet121+SVM在T1WI+T2WI+ADC特征融合中表现最佳，其AUC值为0.8730。在DenseNet121和InceptionV3中，T1WI+T2WI+ADC特征融合的准确度分别为0.8817和0.8228，表现出较优的效果，与仅使用单一模态的情况相比，准确度有了明显的提升。这可能源于三种不同模式的图像所显示出的不同的ABE病理特征，并且这些特征之间相互支撑。T1WI和T2WI反映了组织的化学构成，而ADC与组织的微观结构密切相关，显示了水的扩散过程，能补充细胞毒性损伤信息。在分类的敏感性和特异性方面，不同的模态图像表现出一定程度的互补性。ADC单独使用时性能较低，但融合后能提升模型鲁棒性<sup>[19]</sup>。在两种CNN模型中，DenseNet121的分类准确率高于InceptionV3，这可能是因为在DenseNet201有更多的可学习层，这有利于特征提取和分类效果。DenseNet作为CNN的一种，结合了ResNet和Highway模型的优点，所有层都接收来自前一层的所有特征映射作为输入，这有助于网络减少参数的数量，也缓解了梯度消失<sup>[20]</sup>。

本研究对多模态MRI结合深度学习辅助诊断新生儿LBE进行了评估，通过运用两种CNN模型DenseNet121和InceptionV3，

使得新生儿LBE的诊断准确度显著提升，为临床提供了客观精准的诊断方法。研究中所收集的数据均来自一家医疗机构，因此，模型的可泛化性是未知的，今后的多中心研究需要验证模型的普遍性，由于成像采集的差异和重建算法的多样性，详尽的数据管理和协调过程对于获得多中心数据是必要的。

### 参考文献

- [1] Olusanya BO, Kaplan M. Neonatal hyperbilirubinaemia: a global perspective [J]. Lancet Child Adolesc Health, 2018, 8(2): 610-620.
- [2] 蔡艳华, 陈梅. 新生儿急性胆红素脑病颅脑MRI特征改变的临床意义 [J]. 中国实用医药, 2018, 13(18): 37-38.
- [3] 中华医学会儿科学会新生儿学组. 中国新生儿胆红素脑病的多中心流行病学调查研究 [J]. 中华儿科杂志, 2012, 50(5): 331-335.
- [4] Lakhani P, Gray DL, Pett CR, et al. Hello world deep learning in medical imaging [J]. J. Digit. Imaging, 2018, (3): 283-289.
- [5] Wu M, Shen X, Lai C. Detecting neonatal acute bilirubin encephalopathy based on T1-weighted MRI images and learning-based approaches [J]. Bmc Medical Imaging, 2021, 21(1): 103.
- [6] 庄毅, 蒋昊翔, 孙磊, 等. 磁共振T1WI及波谱成像在新生儿急性胆红素脑病的临床应用价值 [J]. 中国CT和MRI杂志, 2023, 21(5): 4-6.
- [7] 王书磊. 早期新生儿神经学评分对脑损伤新生儿治疗的影响研究 [J]. 罕少疾病杂志, 2024, 31(4): 19-20.
- [8] 左慧静, 栾晓飞, 徐荣荣. 病毒性脑炎患儿癫痫发作的风险预测列线图模型构建研究 [J]. 罕少疾病杂志, 2024, 31(3): 16-18.
- [9] 龚敏, 陈为官. 磁共振成像多序列扫描在早产儿胆红素脑病早期诊断中的应用价值探究 [J]. 现代医用影像学, 2023, 32(2): 288-291.
- [10] Karimzadeh P, Fallahi M, Kazemian M, et al. Bilirubin induced encephalopathy [J]. Iran J Child Neural, 2020, 14(1): 7-19.
- [11] 金诗晨, 孙晓鸣, 蒋皆忱, 等. 深度学习影像组学新技术及其在肿瘤诊断中的应用 [J]. 肿瘤影像学, 2021, 30(6): 439-444.
- [12] Lin A, Chen B, Xu J, et al. Ds-transunet: dual swin transformer u-net for medical image segmentation [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-15.
- [13] Dai Y, Gao Y, Liu F. Transmed: transformers advance multi-modal medical image classification [J]. Diagnostics, 2021, 11(8): 1384.
- [14] Han X. MR-based synthetic CT generation using a deep convolutional neural network method [J]. Med Phys, 2017, 44: 1408-1419.
- [15] Ibragimov B, Xing L. Segmentation of organs-at-risks in head and neck CT images using convolutional neural networks [J]. Med Phys, 2017, 44: 547-557.
- [16] Afat S, Wessling D, Afat C, et al. Analysis of a deep learning-based superresolution algorithm tailored to partial fourier gradient echo sequences of the abdomen at 1.5T: reduction of breath-hold time and improvement of image quality [J]. Invest Radiol, 2022, 57(3): 157-162.
- [17] Tanabe M, Higashi M, Yonezawa T, et al. Feasibility of high-resolution magnetic resonance imaging of the liver using deep learning reconstruction based on the deep learning denoising technique [J]. Magn Reson Imaging, 2021, 80: 121-126.
- [18] 汤文建, 黄裕斌, 李莉, 等. 基于高胆红素血症新生儿苍白球/壳核T1WI信号强度比值模型构建及其对胆红素脑病的预测价值 [J]. 中国CT和MRI杂志, 2024, 22(4): 23-25.
- [19] Zhang H, Zhuang Y, Xia S, et al. Deep learning network with spatial attention module for detecting acute bilirubin encephalopathy in newborns based on multimodal MRI [J]. Diagnostics (Basel, Switzerland), 2023, 13(9): 1577.
- [20] Liang H, Tsui BY, Ni H, et al. Evaluation and accurate diagnoses of pediatric diseases using artificial intelligence [J]. Nat Med, 2019, 25: 433-438.

(收稿日期: 2025-06-12)

(校对编辑: 韩敏求)