

宽度学习系统的SAR影像海面强降雨智能检测研究

夏静^{1,2}, 汪胜^{1,3,4}, 杨晓峰^{1,2}, 张阳^{3,4}, 阮家荣^{3,4}, 杜延磊¹

1. 中国科学院空天信息创新研究院 遥感科学国家重点实验室, 北京 100101;

2. 中国科学院大学, 北京 100049;

3. 澳门大学, 澳门 999078;

4. 澳门大学 智慧城市物联网国家重点实验室, 澳门 999078

摘要: 海洋降雨对全球大气循环和局地气候均有重要影响, 从遥感影像中监测降雨团对于海洋天气预报具有重要意义。合成孔径雷达以高空间分辨率进行大范围观测的能力使其成为10—30 km尺度大小的强降雨团的有效观测手段之一。针对Sentinel-1波模式获取的9种海面现象的SAR影像组成的数据集, 本文使用融合特征的宽度学习系统BLS (Broad Learning System) 进行了海面强降雨团的智能检测研究。结果表明强降雨团的检测精度为98.51%, 召回率为95.24%, 该结果与ResNet50预训练模型的结果相当, 但是同等计算条件下后者的模型训练时间却是前者的20倍。此外, 与传统深度学习网络相比, BLS的结构是灵活的, 即可以通过增加节点或增加数据集来优化、更新模型。对于BLS的节点增量学习功能, 本文实验证实其可以在无需重训练整个模型的前提下更新模型。针对训练数据集增广导致的模型更新任务, 本文综合利用增量学习方案和重训练方案的优点提出了模型的混合更新方案, 新方案既能保证模型的高精度又能显著降低模型更新所需时间。

关键词: 人工智能检测, 海面强降雨检测, 宽度学习系统, 合成孔径雷达, 模型更新

中图分类号: P2

引用格式: 夏静, 汪胜, 杨晓峰, 张阳, 阮家荣, 杜延磊. 2023. 宽度学习系统的SAR影像海面强降雨智能检测研究. 遥感学报, 27(7): 1605–1614

Xia J, Wang S, Yang X F, Zhang Y, Yuen K V and Du Y L. 2023. Intelligent detection of rain cells with SAR imagery based on broad learning system. National Remote Sensing Bulletin, 27(7): 1605–1614 [DOI: 10.11834/jrs.20221800]

1 引言

海洋降雨对全球大气循环和局地气候均有重要影响。研究表明, 全球大气接收的热能中70—85%是降水释放的潜热, 其中海洋降雨约占全球总降雨量的79% (Liu等, 2016)。在热带和亚热带地区, 降雨主要以对流雨 (convective rain), 又称降雨团 (rain cells) 形式出现 (Houze, 1997)。一般来说, 降雨团的尺度是5—10 km, 持续时间10—30 min, 呈现独立或成团分布特点。自1978年获取第一张星载合成孔径雷达SAR (Synthetic Aperture Radar) 影像, SAR图像中经常可以观测到降雨现象 (Alpers等, 2007; Chan等, 2010; Melsheimer等, 2001; Xu等, 2015; Liu等, 2017;

甘锡林等, 2007)。海面降雨的SAR回波信号主要由两部分组成: 一是海表面的雷达后向散射, 二是雨滴对微波信号的体散射和衰减作用 (Alpers和Melsheimer, 2004; Contreras和Plant, 2006)。在降雨过程中, 雨滴不仅会使传感器信号衰减, 在雨滴落入海水时还会对海面产生扰动, 改变海面粗糙度从而影响回波信号的能量 (周旋等, 2012)。此外, 由于SAR具有全天时、全天候和高空间分辨率进行观测的能力, 有利于获取降雨团的结构信息。通常情况下, SAR图像上观测到的典型的对流雨团为圆形或椭圆形的明亮图案, 且边缘锋利 (Alpers和Melsheimer, 2004; Atlas, 1994)。对于大多数降雨团, 在其SAR回波信号的中心区域则有一个偏暗的斑块。这些降雨团在SAR影像上

收稿日期: 2021-12-06; 预印本: 2022-05-23

基金项目: 遥感科学国家重点实验室开放基金 (编号: OFSLRSS202009)

第一作者简介: 夏静, 研究方向为海洋微波遥感。E-mail: xiajing19@mails.ucas.ac.cn

通信作者简介: 汪胜, 研究方向为海洋微波遥感。E-mail: wangsheng@radi.ac.cn

的典型特征可用于对其的检测识别。

国内外学者针对降雨展开了大量研究。Davis等(2006)使用一种面向对象的降水检验方法获取中尺度雨区的位置,首先分割出连续降水区域然后过滤了孤立的、尺度较小的雨区。刘凑华和牛若芸(2013)总结了基于目标的降水检验方法,给出了确定降水位置、尺度和形态的算子参数。郭瑞芳和刘元波(2018)针对降水的大区域尺度和中小区域尺度检测归纳了一系列检验方法。马春野(2019)基于X波段船舶导航雷达回波图,利用混合高斯背景建模算法,实现了对降水云团的识别,并基于特征匹配的跟踪算法,实现了对降水云团的跟踪。吕博群(2020)基于航海雷达影像数据,提出了一种改进的基于回波差异性的降雨识别方法,并利用卷积神经网络中的LeNet-5模型,对降雨干扰进行了识别。陶润喆(2021)基于FY-4A静止卫星影像,建立了一种U-HRNet分割模型,进行多次多尺度特征融合,引入注意力机制模块,从而实现对小样本降水云团的检测。刘淑贤(2021)基于FY-3C微波湿度计数据,结合机器学习算法梯度提升决策树思想,提出了一种针对陆地的降水检测算法,并对检测结果进行了偏差订正等质量控制操作。以上研究说明,机器学习算法已经在降水检测中被广泛应用。

作为一种平面结构的神经网络模型,宽度学习系统BLS(Broad Learning System)与深度学习网络相比具有计算量小、训练时间短和能使用增量学习快速更新模型的优势(Chen和Liu, 2018)。BLS一经提出便在诸多领域得以应用。Kuok和Yuen(2020a)使用宽度学习系统对非结构化空间数据的复杂未知关系进行了建模研究,为了验证BLS的适用性和有效性,使用2008年汶川地震的记录数据进行了模拟和应用,结果表明BLS成功地描述了地震衰减剖面,并在估计地面峰值加速度方面实现了高精度。Kuok和Yuen(2020b)使用BLS成功对粘土参数进行了建模研究,并利用CLAY/10/7490全球数据库建立了13个非参数转换模型。Zhang和Yuen(2021)针对建筑物裂纹检测识别问题提出了基于融合特征的宽度学习系统FF-BLS(Fusion Features-based Broad Learning System),该系统使用固定权重的卷积模块来提取融合特征用作BLS的输入,实验结果表明FF-BLS能以20倍的速度得到与深度学习网络相当的预测精度。以

上所有研究均指出BLS具有增量学习能力,是可以根据任务需求对网络结构进行扩展或对数据集进行增广,确定新网络的权重时无需重新训练整个模型,能有效地提升模型更新效率。

在卫星遥感领域,当搭载各类传感器的遥感卫星成功发射后,其观测数据往往是随着时间的推移而逐渐积累的。这一特点与宽度学习的增量学习能力十分契合,使得基于遥感数据的智能算法具有不断更新和提升的潜力。相较于深度学习的复杂网络结构,基于宽度学习方法的模型的更新与改进的效率具有显著优势。

本文首次采用基于融合特征的宽度学习算法对SAR影像中的降雨团进行检测识别,并重点分析了增量学习方案和重训练方案在BLS模型更新中的表现,提出了“增量学习—重训练”混合训练方案,该方案既能保证模型的精度,又能最大限度地节约训练时间,提升模型更新效率。

2 基于融合特征的宽度学习检测算法

基于随机向量函数连接网络RVFLNN(Random Vector Functional-Link Neural Network)而构建的宽度学习系统是一种平面的神经网络结构。与深度学习网络相比,该网络的计算效率具有显著优势且对硬件设备的需求较低。如图1所示,宽度学习的网络结构的特征层主要由特征节点 F 和增强节点 E 组成,其中特征节点是输入数据 X 经过线性或非线性变换获取;然后将特征节点经过线性或非线性变换可获得增强节点;最后,利用训练数据的特征层和输出 Y 可以确定两层之间传递的权重 A 。然而,Zhang和Yuen(2021)的研究表明,宽度学习提取图像特征的能力较差,直接使用宽度学习对图像进行分类会导致较低的分类精度。因此,本文使用Zhang和Yuen(2021)提出的基于融合特征的宽度学习方法,首先使用卷积神经网络对样本图像进行特征提取;然后将这些特征向量 FV 作为BLS的输入数据来生成特征节点,进而使用特征节点生成增强节点;最后,使用这两类节点信息与训练数据计算网络结构的传播权重。从图1可知,生成节点所需的权重可随机确定,只有特征层和输出层之间的权重需要训练获取。此外,本文所使用的基于特征提取的宽度学习算法还具有增量学习能力,即当原始的BLS训练完成后可以通过增加节点数目或增加输入数据来更新

网络。本次实验所用数据集可通过（<https://doi.org/10.17882/56796> [2021-12-06]）下载。本文模

型的主要程序已经上传至 GitHub(https://github.com/HDFairy/RainCell_Detection.git [2021-12-06])。




图1 基于融合特征的宽度学习系统降雨团检测框架图

Fig. 1 Frame diagram of rain cells detection based on fusion features-based broad learning system

2.1 基于特征提取的数据集构建

卷积神经网络具有强大的图像特征提取能力，为选择最佳的深度学习预训练模型，本文对比了 ResNet50、InceptionV3、MoblieNetV2 和 VGG16 模型在表 2 数据集下的预测精度和训练时长，结果如表 1 所示。综合考虑实验精度和效率，ResNet50 模型表现最佳。因此本文最终选用 ResNet50（He 等，2016）作为预训练模型来提取训练集中 SAR 影像的特征，其权重信息由 ImageNet 数据集训练而来，其余参数设置如下：学习率为 10^{-3} ；batch size 为 16；epoch 取值为 30；图片输入大小为 224×224 。最后，将计算得到的最后一层均值池化层的特征向量作为 BLS 的输入 X 。图 2 中展示了 ResNet50 一个模块（building block）中的两种映射方式：自身映射（identity mapping）和残差映射（residual mapping），最后的输出为二者的叠加。其中 S 为输入的样本图像，权重层取值对于预训练的 ResNet 模型是已知的，ReLU（Rectified Linear Unit）为激活函数，残差输出为 $F(S)$ ，最终的输

出为 $F(S) + S$ 。

表 1 不同分类算法的实验结果		
Table 1 The results of each classification algorithm		
深度学习模型	模型精度/%	每个 epoch 训练所需时间/s
ResNet50	98.16	35
InceptionV3	97.79	48
MobileNetV2	94.85	17
VGG16	91.63	70




图2 ResNet50 的计算模块

Fig. 2 The computer block of ResNet50

2.2 宽度学习系统

在宽度学习系统中, 假设输入数据 $\mathbf{X} \in \mathbb{R}^{N_x}$ 由 N_x 个数据点 x 构成, 特征节点随机生成的权重和偏差值分别为 $\mathbf{W}_e$ 和 $\mathbf{b}_e$, 则特征节点集合 $\mathbf{F}$ 中任一节点可表示为

$$\mathbf{F}_i = \phi(\mathbf{X}\mathbf{W}_{e_i} + \mathbf{b}_{e_i}), i = 1, \dots, N_F \quad (1)$$

式中, $\mathbf{F}_i$ 表示第 i 个特征节点, 可视作 N_x 个数据点 x 的变换结果组成, 因此在图 1 中将每个特征节点表示为包含多个数据点的组。 $\mathbf{F}^{N_F} \equiv [\mathbf{F}_1, \mathbf{F}_2, \dots, \mathbf{F}_{N_F}]$ 表示由 N_F 个特征节点组成的集合。基于所有特征节点 $\mathbf{F}^{N_F}$ 可以计算增强节点 $\mathbf{E}$:

$$\mathbf{E}_j = \xi(\mathbf{F}^{N_F}\mathbf{W}_{h_j} + \mathbf{b}_{h_j}), j = 1, \dots, N_E \quad (2)$$

式中, $\mathbf{E}_j$ 表示第 j 个增强节点, $\mathbf{W}_{h_j}$ 和 $\mathbf{b}_{h_j}$ 分别表示随机生成的权重和偏置量。由于每个增强节点的运算需要所有特征节点作为输入, 可将其视为 N_F 个特征节点变换结果的组合, 因此图 1 中每个增强节点绘制为包含多个特征节点变换结果的组。 $\mathbf{E}^{N_E} \equiv [\mathbf{E}_1, \mathbf{E}_2, \dots, \mathbf{E}_{N_E}]$ 表示由 N_E 组增强节点组成的集合。最终由 N_F 个特征节点和 N_E 个增强节点组成了特征层 $\mathbf{A}$, 可表示为

$$\mathbf{A} = [\mathbf{F}_1, \dots, \mathbf{F}_{N_F} | \mathbf{E}_1, \dots, \mathbf{E}_{N_E}] = [\mathbf{F}^{N_F} | \mathbf{E}^{N_E}] \quad (3)$$

宽度学习中特征层 $\mathbf{A}$ 与输出 $\mathbf{Y}$ 之间通过权重 $\mathbf{W}$ 连接起来, 其关系可以用式 (4) 来简单表达:

$$\mathbf{Y} = \mathbf{A}\mathbf{W} \quad (4)$$

式中, $\mathbf{W} = \mathbf{A}^+\mathbf{Y}$ 为网络结构中连接节点层与输出层之间的权重, $\mathbf{A}^+$ 为矩阵 $\mathbf{A}$ 的伪逆矩阵 (pseudo-inverse)。在宽度网络中, 伪逆可以被认为是在求解神经网络输出层权值的一种非常方便的方法, 但是直接求解的成本太高, 尤其当训练样本和输入模式具有高容量、高速度以及高多样性的特点时。因此, 当直接计算伪逆的成本过高时, 可以通过岭回归来近似求解:

$$\mathbf{A}^+ = (\lambda \mathbf{I} + \mathbf{A}\mathbf{A}^T)^{-1} \mathbf{A}^T \quad (5)$$

式中, λ 是正则化参数。

2.3 增量学习

在深度学习中, 当网络表现不够好时往往可以通过增加卷积核或卷积层的数目来提升网络性能, 但是同时也会增加计算量和模型训练时长。对于宽度学习, 网络表现不佳通常是由于特征层节点数目过少或训练数据不足造成的, 因此可以

通过两种增量学习策略来改善网络性能: (1) 增加特征节点和增强节点; (2) 增加输入数据。

2.3.1 节点增量学习

假设原始的宽度学习系统中包含 N_F 个特征节点和 N_E 个增强节点, 则特征层全部节点可表示为 $\mathbf{A}$ 。如果需要在原有系统中增加增强节点, 则第 $N_E + 1$ 个增强节点可表示为

$$\mathbf{E}_{N_E+1} = \xi(\mathbf{F}^{N_F}\mathbf{W}_{h_{N_E+1}} + \mathbf{b}_{h_{N_E+1}}) \quad (6)$$

若增加特征节点, 第 $N_F + 1$ 个特征节点可以表示为

$$\mathbf{F}_{N_F+1} = \phi(\mathbf{X}\mathbf{W}_{e_{N_F+1}} + \mathbf{b}_{e_{N_F+1}}) \quad (7)$$

由于特征节点改变而相应生成的增强节点为

$$\mathbf{E}_{e_{N_E}} = \left(\xi(\mathbf{F}_{N_F+1}\mathbf{W}_{e_1} + \mathbf{b}_{e_1}), \dots, \xi(\mathbf{F}_{N_F+1}\mathbf{W}_{e_{N_E}} + \mathbf{b}_{e_{N_E}}) \right) \quad (8)$$

则通过增加特征节点和增强节点而得到新的节点层可表示为

$$\mathbf{A}' = [\mathbf{A} | \mathbf{E}_{N_E+1} | \mathbf{F}_{N_F+1} | \mathbf{E}_{e_{N_E}}] \quad (9)$$

其对应的 $\mathbf{A}'$ 矩阵的伪逆矩阵可表示为

$$(\mathbf{A}')^+ = \begin{bmatrix} \mathbf{A}^+ - \mathbf{D}\mathbf{B}^T \\ \mathbf{B}^T \end{bmatrix} \quad (10)$$

式中, 矩阵 $\mathbf{D}$ 和 $\mathbf{B}$ 分别为

$$\mathbf{D} = (\mathbf{A})^+ \begin{bmatrix} \mathbf{E}_{N_E+1} | \mathbf{F}_{N_F+1} | \mathbf{E}_{e_{N_E}} \end{bmatrix} \quad (11)$$

$$\mathbf{B}^T = \begin{cases} \mathbf{C}^*, & \mathbf{C} \neq 0 \\ (1 + \mathbf{D}^T\mathbf{D})^{-1} \mathbf{B}^T \mathbf{A}^+, & \mathbf{C} = 0 \end{cases} \quad (12)$$

$$\mathbf{C} = \begin{bmatrix} \mathbf{E}_{N_E+1} | \mathbf{F}_{N_F+1} | \mathbf{E}_{e_{N_E}} \end{bmatrix} - \mathbf{A}\mathbf{D} \quad (13)$$

计算可得到增加节点后更新的权重:

$$\mathbf{W}' = \begin{bmatrix} \mathbf{W} - \mathbf{D}\mathbf{B}^T\mathbf{Y} \\ \mathbf{B}^T\mathbf{Y} \end{bmatrix} \quad (14)$$

观察式 (14) 可知, 更新后的权重矩阵 $\mathbf{W}'$ 可视为原始权重矩阵 $\mathbf{W}$ 与新增部分的组合。因此, 更新权重矩阵时无需重新计算所有节点, 只需要计算新增节点并将其与原始计算结果进行叠加, 这样能有效减少权重矩阵更新的计算复杂度和耗费的时间。

2.3.2 数据增量学习

上述节点增量学习基于固定的数据集进行, 并不涉及数据集的增广。然而在大多数深度或宽度学习网络中, 输入数据集的大小是影响网络预测性能的主要因素之一。对于大多数深度学习模型, 如果要在训练数据集中增加数据, 则现有的

模型往往需要针对增广后的新数据集重新进行训练,从而确定新的模型参数,而且该重训练过程的计算量和耗费的时间将超过原始模型。然而,宽度学习网络却可以避免该缺陷,BLS 仅需计算新增数据的节点和权重,然后将其与原始网络计算结果相组合,从而达到更新网络的目的。

假设 X_a 是网络中新增的数据,则相应产生的特征节点和增强节点可分别表示为

$$F_x^{N_f} = \left(\phi(X_a W_{e_1} + b_{e_1}), \dots, \phi(X_a W_{e_{N_f}} + b_{e_{N_f}}) \right) \quad (15)$$

$$E_x^{N_e} = \left(\xi(F_x^{N_f} W_{h_1} + b_{h_1}), \dots, \xi(F_x^{N_f} W_{h_{N_e}} + b_{h_{N_e}}) \right) \quad (16)$$

式中, W_{e_1} 、 W_{h_1} 、 b_{e_1} 和 b_{h_1} 均为原始 BLS 中随机生成的权重或偏置。因此可以用 $A_x^T = [F_x^{N_f} | E_x^{N_e}]$ 表示由于新增数据生成的节点矩阵。因此,特征层节点矩阵可以更新为

$$A' = \begin{bmatrix} A \\ A_x^T \end{bmatrix} \quad (17)$$

最后,更新后的权重矩阵可以表示为

$$W_x = W + (Y_a - A_x^T W) B \quad (18)$$

式中, W 为原始系统得到的权重, W_x 为增加输入数据之后获得的权重。 Y_a 表示增加的数据 X_a 所对应的输出值。与节点增量学习策略类似,数据增量学习也只需要计算与新增数据相关的伪逆矩阵即可实现更新权重矩阵的目的,这样做同样大幅降低了运算量,提升了模型更新的速率。

3 数据介绍与实验分析

3.1 数据介绍

本文使用 SAR 图像样本均来自 Wang 等 (2019) 建立的已标注的 SAR 图像数据集 ([https://doi.org/10.17882/56796\[2021-12-06\]](https://doi.org/10.17882/56796[2021-12-06])) (Wang 等, 2019)。该数据集包含 37000 多幅 Sentinel-1 获取的波模式 (wave mode) SAR 影像,涵盖了 10 种海洋现象: 平静海面 (pure ocean waves)、风条纹 (wind streaks)、微对流团 (micro convective cells)、降雨团 (rain cells)、生物浮油 (biological slicks)、海冰 (sea ice)、冰山 (iceberg)、低风速区 (low wind areas)、大气锋面 (atmosphere front) 和海洋锋面 (oceanic front)。该数据集的样本均被处理成 PNG 和 TIFF 格式以便于在机器学习中应用,本文使用的数据均为 TIFF 格式。图 3 展示了 9 种海洋现象的 SAR 图像示例。




图 3 不同海洋现象 SAR 影像样本示例

Fig. 3 The examples of SAR image samples of different ocean phenomena

为构建正、负样本数量相当的数据集,本文选取 4740 幅降雨团影像作为正样本,标签值设置为 1; 在图 3 所示的平静海面、风条纹等另外 8 种海洋现象的 SAR 图像数据集中各自随机选取 691 幅共计 5528 幅组成负样本集,将其标签值设置为 0。然后将正、负样本集中 90% 作为训练集,其余 10% 组成测试集。最终数据集划分结果如表 2 所示。

表 2 训练集、测试集样本信息

Table 2 The sample information of training and testing dataset

数据集名称	正样本集 (降雨团)	负样本集 (非降雨团)	总数
训练集	4275	4989	9264
测试集	465	539	1004
总数	4740	5528	10268

3.2 宽度学习训练结果

在宽度学习系统中共包含 3 个超参数: 特征节点窗口数目 N_1 、每个特征节点窗口所包含的节点数 N_2 和增强节点数目 N_e , 其中 N_1 和 N_2 共同构成了特征节点 F , 因此特征节点数目 $N_f = N_1 \times N_2$ 。对于同一批数据,不同超参数组合的模型具有不同的预测精度。表 3 展示了对于本文数据集在不同超参数组合情况下模型的测试精度。

表3 不同超参数组合下的模型测试精度
Table 3 Model testing accuracy with different combination of hyperparameters

$(N_1 \times N_2)$	N_E	预测精度/%	召回率/%
(5×5)	100	96.81	79.96
(5×5)	300	97.61	85.53
(5×5)	500	97.81	87.16
(5×10)	100	97.41	83.61
(5×10)	300	97.91	88.35
(5×10)	500	97.81	90.14
(10×10)	100	97.51	83.67
(10×10)	300	97.71	89.76
(10×10)	500	98.21	90.85
(18×40)	806	98.51	95.24

表3结果表明节点数目的改变对模型精度产生一定影响,尤其是节点数目增加对召回率提升效果较为显著。因此,确定合适的模型超参数对于模型精度至关重要。贝叶斯最佳估计方法被广泛用于确定模型的最优超参数,在编程计算中可以很方便地调用 Hyperopt 库完成任务 (Bergstra 等, 2013)。根据实验经验,特征节点一般为几十到数百个,而增强节点最高可达数千个甚至上万个。由于本研究的数据量相对较少,因此相应的节点数目也较少,将3个超参数 N_1 、 N_2 和 N_E 的初始参考范围分别设置为 [1, 20]、[1, 50] 和 [1, 2000],经过最优化选择计算确定的超参数取值分别如下: $N_1 = 18$, $N_2 = 40$ 以及 $N_E = 806$,模型预测精度和召回率分别为 98.51% 和 95.24%,明显优于其他超参数组合结果。

3.3 模型对比验证

基于训练数据集确定了宽度学习系统超参数后,特征层与输出之间的权重矩阵可通过 2.2 节中式 (1)–(5) 计算得到。为了对比宽度学习系统的预测精度和训练时间成本,本文选用 ResNet50 预训练模型对同一数据集进行训练和验证。对于该 ResNet50 预训练模型,其主要参数设置如下:学习率为 10^{-3} , batch size 为 16, epoch 取值为 30。此外,为了公平地比较这两个网络的训练时间,训练任务均是基于同一计算机平台运行: Intel(R) Core(TM) i7–8700K CPU@3.70 GHz and 64 GB RAM。表4中列出了针对同一数据集两个网络的预测精度及训练时间成本。

表4 BLS和ResNet50的精度及训练时间
Table 4 The accuracies and training time of BLS and ResNet50

网络名称	预测精度/%	召回率/%	训练时间(CPU)
BLS	98.51	95.24	227.87
ResNet50	98.71	99.15	5312.584

表4结果表明, BLS 与 ResNet50 预训练模型的预测精度相当,召回率 BLS 略低,但是训练时间 ResNet50 比 BLS 高 22 倍左右。因此,在同等设备条件下, BLS 的效率明显高于卷积神经网络。

3.4 增量学习与模型更新方案

对于神经网络模型,当现有模型难以满足当前任务需求时,通常的模型优化有两种:一是增加窗口 (filter or window) 或者是网络层数 (layer),二是增加数据集中样本数量。对于深度学习,网络结构的复杂化或训练数据的更新需要重新训练整个模型。当数据集较大时,这一过程往往需要高算力的设备 (如 GPU) 的支持且会耗费大量的时间。与之不同的是,宽度学习系统是一个动态的网络结构,当增加新的节点或训练新增的样本数据时,只需要训练获取新增部分的权重矩阵就可以更新整个模型,其增量学习能力可以避免重新训练整个网络并有效降低因节点增加或新数据的加入带来的计算量和时间成本。

3.4.1 节点增量学习

为了验证宽度学习的节点增量学习能力可用于更新、优化模型,本文将 3.2 节中使用贝叶斯最佳估计确定的最优参数作为参考,计算了随着总节点数目的增加模型精度以及训练时间成本的变化 (表5)。结果表明,随着总节点数目接近于最佳超参数组合的节点总数时,模型的预测精度和召回率一般会随之提升;而当总节点数再次超过最佳超参数组合的节点总数时,其预测精度和召回率会出现下降的现象,这一趋势在召回率上体现的更为显著。此外,随着总节点数目的增加,模型训练时间虽然总体上呈微弱上升趋势,但在一个较小的范围内波动变化。事实上,本文模型的主要时间成本是读取数据和使用 ResNet50 提取图像特征向量产生的, BLS 计算所需要的时间占比很小。例如当节点超参数组合为 $N_1 = 18$, $N_2 = 40$, $N_E = 806$ 时,读取数据以及提取特征向量共

耗时 224.17 s，运算 BLS 耗时仅为 3.78 s，仅占总时间成本的 1.68%。当节点增加时，虽然会导致 BLS 运算时矩阵增大，但其运算量对于时间成本的增加影响有限。总体而言 BLS 运算的时间成本较低且节点改变对其影响并不大，因而使用贝叶斯最佳估计找到最佳超参数组合是很有必要的。使用最佳超参数组合确定的模型与其他随机超参数组合产生的模型相比能在几乎同等时间成本下获得更好的预测表现。

表 5 不同节点数目的 BLS 模型的精度及训练时间

Table 5 The model accuracy and training time with different combination of the number of nodes

$(N_1 \times N_2)$	N_E	预测精度/%	召回率/%	训练时间/s
(5×5)	100	96.81	79.96	220.83
(5×5)	400	98.00	86.67	218.79
(5×5)	806	97.91	87.84	225.71
(5×20)	806	98.30	93.67	224.85
(5×40)	806	98.11	93.47	226.42
(10×40)	806	98.31	95.03	224.14
(18×40)	806	98.51	95.24	227.87
(20×50)	1000	98.01	92.46	229.88

3.4.2 数据增量学习

对于宽度学习网络，当现有模型无法满足任务需求且需要通过增加数据集样本来改进模型时，模型优化方案可以分为两种：一是针对扩容后的数据集重新训练整个模型；二是利用数据增量学习功能更新模型。为了验证数据增量学习可以用于优化模型，本文设计以下实验步骤：

(1) 将现有所有数据构成的数据集成为全局数据集，数据增量学习过程最开始用到的数据集成为初始训练集，首先在全局数据集中各取 30% 的正、负样本组成初始训练集数据，测试集则与 3.1 节中划分结果一致。

(2) 初始模型训练：使用初始训练集确定模型最佳超参数组合，计算模型在各个节点的特征向量和特征层与输出层之间传播的权重并保存，统计模型训练的时间成本和测试集上的精度。

(3) 数据增量学习：分 7 次向初始训练集中增加样本数据，每次增加全局数据集中 10% 的正负样本，计算新增数据的节点特征向量，将其与步骤 (2) 中保存的特征向量进行组合，求解更新后

的权重，统计模型训练的时间成本和测试集上的精度。

表 6 中展示了模型增量学习结果。首先针对步骤 (1) 中的初始训练集确定 3 个超参数的取值。

表 6 数据增量学习的模型精度和训练时间

Table 6 The accuracies and training time of incremental learning

数据集规模	超参数组合 (N_1, N_2, N_E)	测试集精度/%	训练时间/s
2780	(16, 16, 1562)	80.78	92.76
2781—3707	(16, 16, 1562)	88.45	22.52
3708—4634	(16, 16, 1562)	87.95	22.52
4635—5561	(16, 16, 1562)	87.05	22.54
5562—6488	(16, 16, 1562)	89.64	22.53
6489—7415	(16, 16, 1562)	90.84	22.54
7416—8342	(16, 16, 1562)	91.43	22.55
8343—9264	(16, 16, 1562)	92.23	22.57

表 6 的结果显示，随着训练数据集中样本的增多，模型在测试集上的精度也从 80.78% 提升到了 92.23%。从训练时间来看，因为初始训练集训练时包含了超参数最优选择过程，因此时间较长。随着初始训练集中样本量的增加，训练时间几乎不变，因为每次新增的数据样本数目相同。此外，模型 3 个超参数以及节点间的随机权重使用初始训练集确定后，后续的增量学习过程中将不需要重新确定。

3.4.3 模型重训练

为了对比模型重训练方案与增量学习方案的优缺点，本文对上述实验步骤 (3) 每次更新后的训练数据集进行模型重训练，其结果如表 7 所示。随着训练数据集的增加，模型在测试集上的精度也从 80.78% 提升至最高 98.51%。需要注意的是，当精度达到 98.51% 后再次扩大训练集却下降为 98.21%，这说明数据集规模达到一定程度后模型精度稳定在 98% 左右，重新训练整个模型也无法显著提升其精度。此外，重新训练了整个模型意味着每次都需要最优化选择 3 个超参数，这会增加训练所需要的时长。

图 4 展示了两种模型训练方案的精度和训练时间的对比结果。从图 4 (a) 中可知，当训练样本数量低于 5561 (60% 总训练样本数目) 时，增

量学习方案的精度更高；当训练样本数量达到5561时，重训练方案的测试精度开始高于增量学习方案，并随着数据集的扩大二者差距逐渐扩大，最终在数据集大小为8342时差距达到最大值6.28%。但是当样本数量继续增加时，重训练方案的精度无法继续提升，而增量学习方案的精度则能继续提升。另一方面，从图4（b）可知，重训练方案的训练时间是增量学习方案的2.5倍左右；而且随着数据的不断增加，重训练的时间成本整体上呈现增长趋势，而增量学习方案则几乎保持不变。




表7 重训练的模型精度和训练时间成本
Table 7 The accuracies and training time of retraining model

数据集大小	超参数组合 (N_1, N_2, N_E)	测试集精度/%	训练时间/s
2780	(16, 16, 1562)	80.78	92.76
2781—3707	(19, 28, 398)	85.96	52.72
3708—4634	(19, 40, 1004)	85.46	55.03
4635—5561	(7, 30, 832)	88.55	52.13
5562—6488	(12, 10, 938)	91.64	62.75
6489—7415	(4, 48, 370)	95.22	56.87
7416—8342	(9, 46, 1346)	98.51	58.43
8343—9264	(14, 6, 1568)	98.21	65.25




图4 3种模型更新方案的精度和训练时间对比
Fig. 4 The Comparison of accuracies and training time between three updating schemes

基于以上分析，本文对这两种用于模型更新的方案的优缺点总结如下：（1）数据集较小时，增量学习方案具有精度优势；当数据集较大时，重训练方案具有精度优势，且能较快的达到最佳精度；（2）增量学习方案由于无需重新确定模型超参数和训练整个新数据集，显著降低了训练时间；（3）当数据集增加到一定大小后，重训练方案的精度达到了最佳精度后将不再随数据集的增大而提升；而随着样本数据不断增加增量学习方案精度不断提升的趋势未发生改变，具有逼近最佳精度的潜力。因此，当任务以效率优先时，增量学习训练方案是更好的选择；当任务以精度优先而不计较时间成本时，重训练方案可以较快的达到最优精度。

3.4.4 模型混合更新方案

为了同时利用这两种训练方案的优势，本文将二者结合提出了混合更新方案，即“增量学习—模型重训练”交替使用的模型更新方案。例如

数据积累初期，增加的数据较少时可以使用增量学习，既能保证较高的精度，还能大幅节约时间成本；当积累了足够多的增量样本数据时，采用重训练策略可以获得更好的精度；当该任务继续延续时，又可以继续增量学习策略。因此，两者模型更新策略的交替使用既保证了模型的高精度，又能最大程度节省训练时间。为验证混合更新策略的可行性，本文对3.4.2节和3.4.3节中的实验进行了以下修改：（1）初始数据集实验和前3次数据增量实验采用3.4.2节中的增量学习方案，其结果与表6中前4列相同；（2）第4次数据增加时采用重训练方案，这一步会改变模型的超参数的取值；（3）最后3次数据增量试验再次采用增量学习方案。以上试验的结果如表8和图4中所示，与增量学习方案相比，新方案的模型精度从92.23%提升至95.32%；与重训练方案相比，新方案的训练时间有了显著降低，大大提升了模型更新的速率。

表 8 模型混合训练方案的精度和训练时间
Table 8 The accuracies and training time of hybrid learning scheme

数据集规模	超参数组合 (N_1, N_2, N_E)	测试集精度/%	训练时间/s
2780	(16, 16, 1562)	80.78	92.76
2781—3707	(16, 16, 1562)	88.45	22.52
3708—4634	(16, 16, 1562)	87.95	22.52
4635—5561	(16, 16, 1562)	87.05	22.54
5562—6488	(12, 10, 938)	91.64	62.75
6489—7415	(12, 10, 938)	91.53	22.53
7416—8342	(12, 10, 938)	93.63	22.52
8343—9264	(12, 10, 938)	95.32	22.55

4 结 论

从遥感影像中检测海面强降雨团是研究其结构、分布、形成与作用机理的基础。本文使用基于融合特征的宽度学习方法对包含 9 种海洋现象的 SAR 波模式影像数据集进行了强降雨团的检测识别研究，结果表明 BLS 的检测精度为 98.51%，召回率为 95.24%，与典型的特征提取网络 ResNet50 实验结果近似，但后者的训练时间长达前者的 20 倍。与深度学习网络相比，BLS 具备增量学习能力，模型更新与优化可以通过增加网络节点或输入数据实现。本文通过对比增量学习和重训练两种模型更新方案的优缺点，提出了混合更新方案，该方案在保证模型高精度的同时又能明显减少训练时间。由于遥感领域的数据往往是随着时间推移逐渐积累的，因此宽度学习的增量学习能力和本文提出的模型更新方案可以实现遥感智能算法的持续更新和优化，这对于智能算法在遥感领域的业务化应用具有重要意义。未来将尝试将基于融合特征的宽度学习模型和混合更新方案应用于其他海洋现象的检测识别研究中。此外，将原始图像和深度学习模型提取的特征向量的集合作为 BLS 模型的输入，探索其对于模型计算效率和精度的影响也是未来的工作之一。

参考文献 (References)

Alpers W, Cheng C M, Shao Y and Yang L M. 2007. Study of rain events over the South China Sea by synergistic use of multi-sensor satellite and ground-based meteorological data. Photogrammetric Engineering and Remote Sensing, 73(3): 267-278 [DOI: 10.14358/pers.73.3.267]

Alpers W and Melsheimer C. 2004. Rainfall//Jackson C R and Apel J R, eds. Synthetic Aperture Radar Marine User's Manual. Washington: National Oceanic and Atmospheric Administration: 355-371

Atlas D. 1994. Footprints of storms on the sea: a view from space-borne synthetic aperture radar. Journal of Geophysical Research: Oceans, 99(C4): 7961-7969 [DOI: 10.1029/94jc00250]

Bergstra J, Yamini D and Cox D D. 2013. Making a science of model search: hyperparameter optimization in hundreds of dimensions for vision architectures//Proceedings of the 30th International Conference on International Conference on Machine Learning. Atlanta: JMLR.org: I-115-I-123

Chan P W, Cheng C M and Alpers W. 2010. Study of wind fields associated with subtropical squall lines using Envisat Synthetic Aperture Radar images and ground-based weather radar data. International Journal of Remote Sensing, 31(17/18): 4897-4914 [DOI: 10.1080/01431161.2010.485144]

Chen C L P and Liu Z L. 2018. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture. IEEE Transactions on Neural Networks and Learning Systems, 29(1): 10-24 [DOI: 10.1109/tnnls.2017.2716952]

Contreras R F and Plant W J. 2006. Surface effect of rain on microwave backscatter from the ocean: measurements and modeling. Journal of Geophysical Research: Oceans, 111(C8): C08019 [DOI: 10.1029/2005jc003356]

Davis C, Brown B and Bullock R. 2006. Object-based verification of precipitation forecasts. Part I: methodology and application to mesoscale rain areas. Monthly Weather Review, 134(7): 1772-1784 [DOI: 10.1175/mwr3145.1]

Gan X L, Hunag W G, Yang J S, Lou X L, Shi A Q, Zhang X L and Sun X M. 2007. The study of fine structure of a mesoscale thunderstorm from SAR image. Remote Sensing Technology and Application, 22(2): 246-250 (甘锡林, 黄韦良, 杨劲松, 楼琬林, 史爱琴, 张小丽, 孙向明. 2007. 利用合成孔径雷达研究中尺度雷暴的细结构. 遥感技术与应用, 22(2): 246-250) [DOI: 10.3969/j.issn.1004-0323.2007.02.025]

Guo R F and Liu Y B. 2018. Strategy and method for satellite precipitation data evaluation: an overview. Remote Sensing Technology and Application, 33(6): 983-993 (郭瑞芳, 刘元波. 2018. 遥感降水数据精度检验策略及检验方法综述. 遥感技术与应用, 33(6): 983-993) [DOI: 10.11873/j.issn.1004-0323.2018.6.0983]

He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]

Houze R A. 1997. Stratiform precipitation in regions of convection: a meteorological paradox?. Bulletin of the American Meteorological Society, 78(10): 2179-2196 [DOI: 10.1175/1520-0477(1997)078<2179:Spirc>2.0.Co;2]

Kuok S C and Yuen K V. 2020a. Broad learning for nonparametric spatial modeling with application to seismic attenuation. Computer-Aided Civil and Infrastructure Engineering, 35(3): 203-218 [DOI: 10.1111/mice.12494]

Kuok S C and Yuen K V. 2020b. Broad learning system for nonparametric modeling of clay parameters. ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering, 6(2): 04020024 [DOI: 10.1061/ajrua6.0001066]

- Liu C H and Niu R Y. 2013. Object-based precipitation verification method and its application. *Meteorological Monthly*, 39(6): 681-690 (刘凑华, 牛若芸. 2013. 基于目标的降水检验方法及应用. *气象*, 39(6): 681-90) [DOI: 10.7519/j.issn.1000-0526.2013.06.003]
- Liu S X. 2021. Precipitation Detection Algorithm over Land for FY3C MWHS-2 and its Application in LAPS-WRF Assimilation System. Nanjing: Nanjing University of Information Science and Technology (刘淑贤. 2021. FY3C MWHS-2 的陆地降水检测算法研究及其在 LAPS-WRF 同化系统中的应用. 南京: 南京信息工程大学) [DOI: 10.27248/d.cnki.gnjqc.2021.000012]
- Liu X N, Zheng Q A, Liu R, Sletten M A and Duncan J H. 2017. A model of radar backscatter of rain-generated stalks on the ocean surface. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2): 767-776 [DOI: 10.1109/tgrs.2016.2614897]
- Liu X N, Zheng Q A, Liu R, Wang D, Duncan J H and Huang S J. 2016. A study of radar backscattering from water surface in response to rainfall. *Journal of Geophysical Research: Oceans*, 121(3): 1546-1562 [DOI: 10.1002/2015jc010975]
- Lü B Q. 2020. Research on Rainfall Detection Technology Inversion Method based on Marine Radar Image. Harbin: Harbin Engineering University (吕博群. 2020. 基于航海雷达图像反演的降雨检测技术研究. 哈尔滨: 哈尔滨工程大学) [DOI: 10.27060/d.cnki.ghbcu.2020.001497]
- Ma C Y. 2019. Research on Dynamic Detection Algorithm of Precipitation Clouds. Dalian: Dalian Maritime University (马春野. 2019. 降水云团动态检测算法研究. 大连: 大连海事大学) [DOI: 10.26989/d.cnki.gdlhu.2019.000751]
- Melsheimer C, Alpers W and Gade M. 2001. Simultaneous observations of rain cells over the ocean by the synthetic aperture radar aboard the ERS satellites and by surface-based weather radars. *Journal of Geophysical Research: Oceans*, 106(C3): 4665-4677 [DOI: 10.1029/2000jc000263]
- Tao R Z. 2021. Research on Cloud Detection and Precipitation Extrapolating Forecast in Tibet based on FY-4A Satellite Images Nanjing: Nanjing University of Information Science and Technology (陶润喆. 2021. 基于风云4号卫星图像的西藏地区云检测和降水外推预报研究. 南京: 南京信息工程大学) [DOI: 10.27248/d.cnki.gnjqc.2021.000052]
- Wang C, Mouche A, Tandeo P, Stopa J E, Longépé N, Erhard G, Foster R C, Vandemark D and Chapron B. 2019. A labelled ocean SAR imagery dataset of ten geophysical phenomena from Sentinel-1 wave mode. *Geoscience Data Journal*, 6(2): 105-115 [DOI: 10.1002/gdj3.73]
- Xu F, Li X F, Wang P, Yang J S, Pichel W G and Jin Y Q. 2015. A back-scattering model of rainfall over rough sea surface for Synthetic Aperture Radar. *IEEE Transactions on Geoscience and Remote Sensing*, 53(6): 3042-3054 [DOI: 10.1109/tgrs.2014.2367654]
- Zhang Y and Yuen K V. 2021. Crack detection using fusion features-based broad learning system and image processing. *Computer-Aided Civil and Infrastructure Engineering*, 36(12): 1568-1584 [DOI: 10.1111/mice.12753]
- Zhou X, Yang X F, Li Z W, Yu Y and Ma S. 2012. Rain effect on C-band scatterometer wind measurement and its correction. *Acta Physica Sinica*, 61(14): 149202 (周旋, 杨晓峰, 李紫薇, 于旸, 马胜. 2012. 降雨对C波段散射计测风的影响及其校正. *物理学报*, 61(14): 149202) [DOI: 10.7498/aps.61.149202]

Intelligent detection of rain cells with SAR imagery based on broad learning system

XIA Jing^{1,2}, WANG Sheng^{1,3,4}, YANG Xiaofeng^{1,2}, ZHANG Yang^{3,4}, YUEN Kaveng^{3,4}, DU Yanlei¹

1. State Key Laboratory of Remote Sensing Science, Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100101, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China;

3. University of Macau, Macau 999078, China;

4. State Key Laboratory of Internet of Things for Smart City, University of Macau, Macau 999078, China

Abstract: Ocean rainfall has an important impact on the global atmospheric cycle and local climate. Monitoring rain cells from remote sensing images is vital for ocean weather prediction. The ability of Synthetic Aperture Radar (SAR) to probe with a wide swath and high spatial resolution makes it an effective observation approach for rain cells with a scale of 10—30 km. This study uses the fusion-feature-based Broad Learning System (BLS) to detect the rain cells. The SAR images dataset composed of nine sea surface phenomena obtained by Sentinel-1 wave mode is also used. Results show that the detection accuracy is 98.51%, and the recall rate is 95.24%. These values are equivalent to those of the ResNet50 pretrained model. However, the training time of ResNet50 is 20 times that of BLS under the same calculation conditions. Compared with the structure of a deep learning network, that of BLS is flexible. That is, the model can be optimized and updated by adding nodes or input data. The experiments show that the node incremental learning of BLS can update the model without retraining the whole model. Following the advantages of the incremental learning and retraining schemes, this study proposed a hybrid model-updating scheme for the model-updating task caused by the expansion of the training dataset. This new scheme can ensure the high accuracy of the model and significantly reduce the time cost for model updating.

Key words: artificial intelligence detection, rain cells detection, broad learning system, synthetic aperture radar, model updating
Supported by Open Fund of State Key Laboratory of Remote Sensing Science(No. OFSLRSS202009)