

覃月凤,董良森,刘国忠,等.广西区域性暴雨深度神经网络预测模型设计与应用[J].气象研究与应用,2024,45(3):29-36.
QIN Yuefeng, DONG Liangmiao, LIU Guozhong, et al. Design and application of deep neural network prediction model for regional rainstorm in Guangxi[J]. Journal of Meteorological Research and Application, 2024, 45(3): 29-36.

广西区域性暴雨深度神经网络预测模型设计与应用

覃月凤, 董良森*, 刘国忠, 梁存桂, 杨明鑫

(广西壮族自治区气象台, 南宁 530022)

摘要:遵循AI技术典型应用流程,从确定研究对象的数据表示开始,探讨从测试选用算法工具构建“区域性暴雨”深度学习预测模型,到调整优化模型超参数、对模型性能进行泛化增强,最终实现上线部署,成功对2023年广西“龙舟水”过程作出合理预测。结果表明,结合实际预报服务需求,在深入理解算法和模型架构特点基础上,选用能够模拟天气分析过程、合理解释预测机理的AI算法,可显著增强模型的实用性能。采用TimeDistributed层对样本时间层进行封装,先提取学习气象要素场空间特征和关联特征后再进一步学习时间变化知识,是一种符合天气分析思路且预测性能较好的气象AI模型构建方法。而针对“小概率”气象关注事件,在设定事件标签时适当降低气象评判指标、基于相似天气形势来增强样本数据,引导模型针对关注目标进行正向增强训练,是提升气象AI模型性能的有效技术手段,实现一个“有/无区域性暴雨发生”定性预报的基础分类模型。

关键词:气象对象表示;深度神经网络(DNN);模型性能基准;数据增强;TimeDistributed包装器

中图分类号:P457

文献标识码:A

doi: 10.19849/j.cnki.CN45-1356/P.2024.3.04

近年来,随着以深度学习(Deep Learning,简称DL)为代表的现代人工智能(Artificial Intelligence,简称AI)技术快速迭代演进,其展现出的在多维度时空建模、海量信息萃取、非线性特征映射等多方面能力优势,为科学研究领域带来前所未有的深刻变革。越来越多的AI应用开始融入到气象业务各个方面,这些基于机器学习(Machine Learning,简称ML)和DL技术的新思路新方法在各个天气预报细分领域均呈现出良好的应用前景^[1]。在该趋势影响下,一线业务单位也迫切期待能够借助AI技术提高常规天气预报、数值预报产品解释应用能力,以及社会普遍关注的极端天气预报服务水平。然而,相关气象应用文献多以传统“科研”视角,偏重于从基础理论和应用效果方面来论述某种特定AI方法,而对算法选择、模型训练和部署实施等具体应用细节

问题罕有专门提及,难以参考借鉴。

事实上,AI技术的核心就是“数据驱动”,即由计算机自主观察数据、自动学会规则,通过遍历、迭代一系列预先设定的数据变换操作,根据反馈信号来自行调整输入数据的中间表示方式,使之汇聚成符合预期结果的最优决策模型。在这个过程中,“规则”形成及其潜在机理往往以人类难以理解或描述的方式呈现,本不应该成为应用部门关注的重点;而若忽视输入数据选择、变换方式设定、模型训练反馈和超参数调整等能够人工干预的技术环节,AI应用落地将难以顺利实现。近期“盘古”、“风乌”等由非气象专业机构主导研发的气象大模型频创佳绩,在某种程度上也反衬出“调整AI技术应用思路、适应其在气象观测和预报服务中深度融合应用的需求”已成为部门当前新技术能力建设的重点。

收稿日期: 2023-12-18

基金项目: 中国气象局“揭榜挂帅”项目(CMAJBGS202217)、中国气象局气象能力提升联合研究专项(22NLTSY011)、广西气象科研计划项目(桂气科2024M03、桂气科2019M07)

第一作者: 覃月凤(1988-), 工程师, 主要从事天气预报技术研究。E-mail: qinyfjune@163.com

*通讯作者: 董良森(1973-), 正高级工程师, 主要从事天气预报技术研究。E-mail: nn172172@163.com

为此,本文以近期研发构建广西区域性暴雨深度神经网络预测模型的全过程为例,从确定研究对象的数据表示形式开始,到如何在种类繁杂的AI算法中作出适用性选择,继而合理构建出DL训练模型并增强其可信度和可用性,最终实现研究模型向业务模块转化(工程化),对这一系列应用环节所面临的挑战与应对进行探讨,以期促进相关技术在气象业务领域稳定应用发展。

1 资料与方法

1.1 数据集和资料预处理

质量可靠的大数据集对AI模型的训练和预测效果至关重要,它可提供更多的训练样本、更丰富的关键信息,支撑更全面的特征学习和更复杂的模型优化算法,从而更好地分析和理解数据,提高模型的准确性、泛化能力和综合性能。

本文以ECMWF第五代全球气候模式再分析资料(the 5th generation ECMWF atmospheric Reanalysis of the global climate,简称ERA5)作为基础数据集,包括温度、气压、湿度、风等基本物理量,资料序列从1961年1月1日—2022年8月1日,水平分辨率 $0.25^{\circ} \times 0.25^{\circ}$,时间分辨率为1 h。

原始样本数据在代入模型学习训练前,为消除不同特征值之间可能存在的量纲不同,以及属性值数量级差异可能导致的特征权重失衡问题,确保所有特征取值的“同质性”,需要根据不同应用场景进行“标准化(z-score normalization)”或“归一化(min-max scaling)”处理。此外,大多数DL框架为了让神经网络收敛得更快,信息萃取学习更容易,对输入数据一般有“①均值为0,②标准差为1,③取值范围在-1~1(或0~1)内”的最优化设定^[2](这三个限定条件很难同时满足,需根据不同应用场景权衡选择)。本文采用最常用的z-score标准化方案(满足前2个条件,但无法保证输入值保持在-1~1之间),其计算公式是:

$$x' = \frac{x - x_{\text{mean}}}{std} \quad (1)$$

其中, x' 为特征值 x 经过处理后得到的标准化特征值, x_{mean} 、 std 分别为该特征的平均值和标准差。

1.2 相关AI方法

AI方法是一个包含ML、DL以及其它不涉及学习(learning)方法的计算机任务自动化综合性概念^[2-4],其中“学习”意味着“从数据集中抽取有价值

的特征信息”。本文在描述分析测试和建模过程时使用到的ML方法有主成分分析(Principal Component Analysis, PCA)^[5-6]、支持向量机(Support Vector Machine, SVM)^[7-9];DL方法为长短期记忆神经网络(Long Short-term Memory, LSTM)^[10-11]、门控循环单元(Gate Recurrent Unit, GRU)^[12-13]、卷积神经网络(Convolutional Neural Networks, CNN)^[14-18]、ConvLSTM和ConvGRU(Convolutional Long Short-Term Memory, Convolutional GRU)^[19-20](考虑到现有平台算力存储局限,需要消耗更多资源的Transformer等更高级AI模型暂不考虑)。

在研究实践中使用Time-distributed技术,与典型神经网络层不同,它是一种时间步(timesteps)包装器(wrapper layer):一般情况DL模型各核心层按输入批次整体处理每个样本数据,不论该样本特征中是否包含有时间层次信息;当使用TimeDistributed层对核心层进行包装后,同一样本的不同时间层信息将按不同时间步分别处理,从而能够保留特定时间步骤的上下文信息,提高模型对序列数据的理解和预测能力。目前,尚未检索到TimeDistributed技术的气象应用案例。

2 广西区域性暴雨预测模型设计

2.1 研究对象的数据表示

用原始数据的某种组合将抽象的“研究对象”概念转换成机器学习算法能够理解和处理的形式,是确定对象“数据表示”的主要目的,这是深度学习模型设计中至关重要的第一步,完善的数据表示可以提供更丰富的信息,便于模型捕获研究对象的本质属性和关键特征,为后续数据预处理、问题简化和特征降维、模型性能改善,以及缩短研发训练时间等任务方面发挥重要作用。可以说,它在很大程度上决定模型的性能和潜力。

在本案例中,造成广西区域性暴雨(即:24 h内广西境内国家气象观测站累积雨量 ≥ 50 mm的台站数量 ≥ 10 个)的“天气形势”是关键研究对象。视“天气形势”为高、中、低层大气相互配合,大气静力、热力、动力条件相互影响的综合体,通过选取ERA5大数据集中的各种基本气象要素在多个空间层次的格点数据来表征刻画;此外,“天气形势”是“立体”的、“运动”的,其发展演变方向也是研究关注的焦点,需在样本特征中融合24 h内多个时次的综合信息;最后,尽可能使用各种原始气象要素信息而不

做人为分析设定,也是构建“天气形势”数据表示所应遵循的原则。

在研发环境允许的最大算力和存储资源限度内,按业务习惯,取前日 20 时至当日 20 时(UTC 12 时)24 h 内天气形势场的变化特征作为一个样本;将广西短期天气形势关注区域(经纬度 $35^{\circ} \sim 15^{\circ} \text{N}$ 、 $100^{\circ} \sim 120^{\circ} \text{E}$, 包含 81×81 个格点数据)范围内的 500 hPa、700 hPa、850 hPa 和地面 4 个层次的位势高度(地面层为海平面气压)、温度、比湿(地面层采用 2 m 露点温度)、经向风、纬向风、垂直速度共计 23 个格点场(地面层无垂直速度),每 3 h 取一个时间步共计 9 个时间层资料作为一个日期样本的特征数据集;最终合成一个形状为 (samples, timesteps, ny, nx, channels) 的 5D 样本数据集,实际数据维度为 (22 493, 9, 81, 81, 23),总数据量约 234 GB。

2.2 模型有效性评价基准

在构造、训练和评估 AI 模型前,须建立一个初始性能基准,效果优于该基准水平时才能证实模型具有合理性和实用价值。

在有确切雨量记录的 1961 年 1 月 1 日—2022 年 8 月 1 日 22 493 d 中,总计有 1 024 次广西区域性暴雨事件,过程发生概率仅为 4.55%,这意味着全部盲报为“无”也能达到 95.45% 的准确率。鉴于目前没有针对相应事件的其它预报产品供评估对比,这里简单以预测水平 $\geq 95.5\%$ 作为模型的有效性基准。

2.3 模型测试选型

判别一个天气形势场能否引发区域性暴雨,实质上是将该样本对象按“是否为区域性暴雨天气形

势”进行“二分类”的 AI 模型应用场景。对天气形势分析而言,首先应确定“影响系统”,把握其位置特征,这就需要从经-纬格点气象要素场中学习相关结构的空位置(几何分布)信息,涉及输入数据的 ny、nx 两个维度;其次,由于天气系统是多层次、多要素相互影响的综合体,挖掘结构信息在不同要素、层次中的表现形式及相互关联也非常关键,这需要对不同 channels 维度数据之间蕴含的特征信息进行学习;最后,天气形势在不断发展演变,影响系统处于发展、强盛阶段还是处于减弱、衰亡阶段,将对降水强弱造成截然不同的影响,掌握其运动变化特征需对不同时间数据(timesteps 维度)的结构变化信息进行提炼。构造能在输入数据中综合学习上述三方面关键特征的 AI 网络层组合,是满足模型预期性能要求的必要前提。

能够直接从 5D 样本数据集中综合学习“时-空”特征信息的 AI 神经网络层有 Conv3D、ConvLSTM2D、TimeDistributed 包装层+Conv2D 卷积 3 种主要构型。分别以三种神经网络层为主干构建 AI 模型,并与 SVM、LSTM 等普通 AI 模型共同训练,对比其分类效果(表 1)。按通常 AI 训练标准对样本数据集进行比例为 6:2:2 的训练-验证-测试集样本数划分,结合批训练参数调整需要,实际将 1961.01.01 ~ 1997.06.13 共 13 312 个样本(512×26 , 实际占比 59.18%)设定为“训练集”,后续 1997.06.14 ~ 2010.01.24 共 4 608 个样本(512×9 , 实际占比 20.49%)设定为“验证集”,剩下的 4 574 个样本留作“测试集”。

表 1 AI 模型测试评估细节对比

模型结构	输入数据形状	输入数据预处理	训练成本	模型预测 验证效果(%)
SVM 分类器	(samples, characters)	时-空特征展平 + PCA 降维	较低	< 95.5
LSTM 分类模型	(samples, timesteps, characters)	空间特征展平 + PCA 降维	中等	96.41
Conv3D 卷积分类模型	(samples, timesteps, ny, nx, channels)	保持原输入数据形状	中等	96.9
ConvLSTM2D 分类模型	(samples, timesteps, ny, nx, channels)	保持原输入数据形状	较高	96.35
TimeDistributed 多层分类模型	(samples, timesteps, ny, nx, channels)	保持原输入数据形状	中等	97.0

验证表明,经典 SVM 分类模型只接受 (samples, characters) 二维数据进行训练,在维度合并和 PCA 降维转换过程中原始数据蕴含的时-空信息大多遗失,模型预测(分类)准确率只有 95.2% 左右,甚至不及盲报的“基准”水平。LSTM 模型可接收 (samples,

timesteps, characters) 三维输入数据进行训练学习,在空间特征展平遗失的情况下,借助多层过滤萃取关键时间变化特征信息使得预测能力有所体现(图 1-a)。Conv3D 滤波器将输入数据中的(时间步长,高度、宽度)视为“深度 z、宽度 y 和高度 x”三维整体

先进行训练学习,然后才在 characters 维度滑动,学习气象要素及层次间的关联信息;虽未能像天气分析那样将各气象要素层次结构信息融合在一起作为系统整体特征考虑,但由于成功学习到输入数据中“时-空”交联特征,模型效果有明显提升(图 1b)。ConvLSTM2D 层首先学习 n_y 、 n_x 二维空间特征,然后用 LSTM 算法萃取这些特征在 timesteps 维度上的精细时序变化信息,最后才考虑这些“时-空”综合特征在不同 channels 维度上的关联,其分类成绩与单纯 LSTM 模型差别不大(图 1c),明显不如 Conv3D 层的学习效果,这也意味着在没有充分获取各气象要素及其不同层次的关联融合信息之前过早学习时间变化特征,结果将适得其反;另外,ConvLSTM2D 模型训练代价高昂,且批训练量设置稍大

(32 以上)易引发内存溢出(OOM)错误。

采用 TimeDistributed 包装层是高效学习样本数据集关键“时-空”特征的一种新方法。该机制能够先“固化”时间步以提取出时间层内的关键特征信息(此时模型训练被限制在特定时间步内较小数据范围内);解包后再使用 LSTM 层处理各时间层上下文,此时只需对各时次的高浓缩信息进行时序变化特征学习,训练成本显著降低;该算法过程与天气预报员“先在特定时次形势场中了解关键天气系统的空间分布位置,然后再从多个逐步演进的时次形势场中把握这些影响系统的强度变化状态,进而做出天气发展变化趋势预测结论”的预报思路完全吻合,其测试效果也最佳(图 1d)。

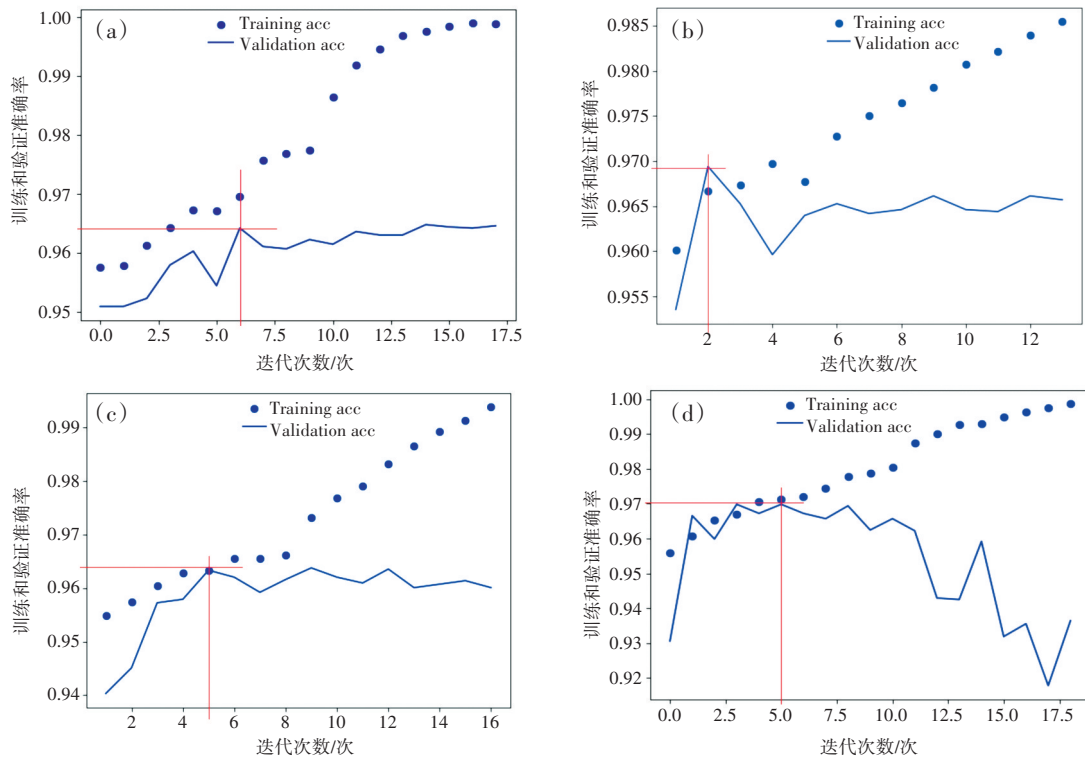


图1 筛选测试中几种广西区域性暴雨AI模型的训练和验证效果比较

(a)LSTM模型训练和验证效果图;(b)Conv3D模型训练和验证效果图;

(c)ConvLSTM2D模型训练和验证效果图;(d)TimeDistributed(Conv2D)层+LSTM模型训练和验证效果图

(各子图中的红线位置标识出验证损失率最低时的训练-验证准确率,此位置后的训练呈现过拟合。)

2.4 模型改进和超参数调优

选型测试时 TimeDistributed 层模型包装 3 个 Conv2D 膨胀卷积+相应的池化层,1 个展平(Flatten)层,3 个密集连接(Dense)层,实现对各时间层内的空间特征信息提取和浓缩,解包装后使用 1 个 LSTM

层学习时间变化特征,最后用 2 个 Dense 层汇聚和输出分类结果。由于网络层和隐藏参数较多,训练 5 轮后模型出现过拟合。为改进性能、延缓过拟合,在每个学习层后分别增加一个“批标准化层”(BatchNormalization),酌情增加 dropout 正则化层,

并将原先设置的批次训练 128 个样本逐步调整到每批只训练 32 个甚至 16 个样本; 另外, 改用 2 个 GRU 堆叠层来替代原先单一 LSTM 层, 既增强时序特征信息的萃取, 又能保证有足够运算资源支撑整个模型的训练学习; 最后, 采用以下超参数调整方法进一步提高模型训练效果: ①采用更小的初始学习率(0.001 左右); ②选择 Adam 优化器并显式指

定学习率调度策略; ③使用“早期停止”策略, 设置 EarlyStopping 回调函数的 restore_best_weights 参数, 确保在早期停止机制触发时恢复训练过程验证损失最低点时的最佳权重(best weights)。调整改进的准业务模型由 21 个神经网络层构成(图 2), 验证准确率和学习曲线稳定性有进一步提升(图 3)。




图 2 广西区域性暴雨预测深度神经网络模型结构

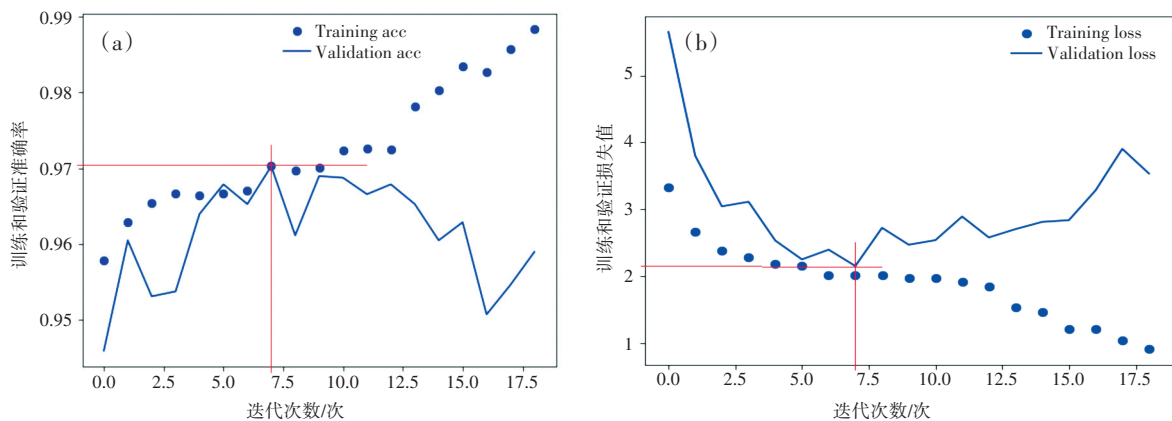


图 3 广西区域性暴雨深度神经网络预测模型训练和验证效果示意图

(a) 训练和验证准确率; (b) 训练和验证损失值

(各子图中的红线位置标识出验证损失率最低时的训练-验证准确率, 此位置后的训练呈现过拟合。)

3 模型增强训练和部署应用

3.1 模型增强训练

模型训练 7 轮后就开始出现过拟合, 其原因除

模型层次深、隐藏参数多(超过 240 余万个), 只需少数轮次训练就可以学习到关键特征信息外, 还有一个重要因素, 就是区域性暴雨是发生几率不足 5% 的小概率事件, 在训练过程中模型更多会从大量

“负现象”样本中学习不到现区域性暴雨的特征信息,这对暴雨形势关键特征提取和分析预测而言有显著负面影响,性能提升难度明显增大,相比之下,使用同样结构层次的模型对发生概率15%左右的区域性大雨以上事件进行训练学习,预测能力可在85%基准线水平上提高约10%,达到接近95%的验证准确率,升幅6倍。因此,必须对模型进行“正样本”增强训练,尽可能提升业务预测水平。

提高不平衡样本预测准确率的主要方法有:①欠采样或过采样:通过欠采样(随机删除多数类样本,对区域暴雨事件而言就是删除掉不可能出现该类事件的月份日期样本)或过采样(增加少数类样本)来平衡数据集中的类别分布,使模型更多地接触到小概率的样本。②类别权重调整:训练时给予小概率类别更高的权重,通过加大损失惩罚,模型会更关注该类别的预测准确性;③阈值调整:更改模型预测输出阈值,将一般情况下0.5概率阈值在预测输出小概率事件分类结果时调减到0.45甚至更低。上述几种方法可综合采用以增强模型对区域暴雨事件的学习和预测。

需注意,同一类致灾天气形势所造成的观测站实况降水多少会有差别,严格以某种量化指标来划分类别将导致模型特征学习无所适从。例如:严格按10站以上暴雨标准分类,若相似天气形势下的样本实况降水只有9个站达到暴雨量级,AI模型按分类标签“无(0)”来学习该天气形势下的综合特征,将导致事与愿违的结果,降低事件预测准确率。基于上述考虑,在设定事件标签时应适当降低“区域性暴雨”评判指标,例如将“24 h内广西境内国家气象观测站累计雨量 ≥ 50 mm的台站数量 ≥ 10 ”概念指标调整为“累计雨量 ≥ 25 mm的台站数量 ≥ 10 ”,并将“前日08时至当日08时”24 h累计降水量也包括在统计范围内,放大事件“1”样本数量后再输入模型增强训练学习。事实上,气象预报服务部门更关注重大过程的定性预报,即便在量级预报中出现些许偏差,只要大范围强降水趋势预报准确,效果都可肯定。这与AI准确率评分“非0即1、非对即错”的评判标准有显著区别。因此,再增强学习后,改以气象“准确率/空报率/漏报率”TS评分评估模型,针对区域性暴雨事件的业务效果更为合适。

表2 进行分类阈值、类别权重调整和大雨以上量级数据增强训练后模型分类效果对比

模型增强细节	区域性强降雨事件预测TS评分	空报率	漏报率
①暴雨标签训练的预测模型、分类阈值0.5	0.3509	0.4538	0.1953
②暴雨标签训练的预测模型、分类阈值下调为0.4	0.4097	0.4420	0.1482
③训练类别权重调整为20%、使用大雨以上数据增强学习,分类阈值0.5——预测区域暴雨	0.4144	0.4282	0.1574
④训练类别权重调整为20%、使用大雨以上数据增强学习,分类阈值0.5——预测区域大雨	0.6458	0.14-0	0.2112
⑤综合使用各种模型增强和数据增强学习,尽可能降低漏报率——预测区域暴雨	0.2949	0.6978	0.0073

使用2010年以后的“测试集”样本对增强模型进行评估(表2),结果表明,相比单纯调降分类阈值(表2①②),使用“大雨以上”数据样本进行增强训练对提升预测准确率,降低重大过程“空报率”(表2③)效果更好;此时的空报中有相当一部分满足“区域大雨以上”量级标准(表2④),综合服务效果可以接受。若希望尽可能降低“漏报率”,还可综合各种增强技术基本消除漏报可能(表2⑤),此时TS评分仅0.30左右,空报率明显增多,在“宁空勿漏”的气象服务要求背景下,若TS还有0.29以上的准确率,虽然以增加空报率为代价,但能大幅降低漏报率,此种方法(表2⑤)仍然有实际业务应用价值。

3.2 模型部署应用

确定模型结构及相关重要超参数后,合并训练和验证集,将80%样本代入模型进行训练,确定合并训练的最佳轮次;最后将全数据集合并,重新训练模型到最佳轮次,保存模型及参数权重,即可分发,部署到业务平台上线使用。

受高空槽、低涡系统和切变线共同影响,2023年6月22—25日广西全区出现“龙舟水”持续性大范围暴雨天气。广西壮族自治区气象台对该过程的预报服务早于一周前(6月16日)就已开始,根据当时数值预报模式研判,过程将于19日开始,持续至26日,决策服务部门为此编发2023年首份《重大

气象信息专报》。项目团队从6月17日开始每天提取当日20时ECWMF发布的未来24~48 h(每隔3 h)形势预报,作为“实况”样本数据输入模型进行分析预测,结果从6月20日起一直到26日止连续7 d均判定为“区域性暴雨”类别。与实况对比,22—25日预测结论正确,无漏报;20日、21日、26日3 d出现“空报”;但考虑到20日虽然只有4站暴雨(其中2站大暴雨),但有13站出现大雨,26日出现8站暴雨、11站大雨,实际预测效果不理想的只有21日,总体性能令人满意。

4 结论

本文按照AI典型技术流程,从确定研究对象的数据表示方式开始,探讨在环境算力及存储资源允许的条件下从众多算法中筛选合适工具构建模型,到调整优化超参数,对模型性能进行泛化增强,最终上线部署,实现对该小概率事件做出业务可用水平预测这一完整的工程实践过程。从中发现,AI技术应用于气象业务的一个关键是:大多数AI算法的最初应用场景为图像识别、视频内容分类等与天气分析有明显区别的场合,这些场景数据的不同颜色通道(即 channels 维度数据)间并无太多关联;而对天气系统而言,温度、气压、湿度、风在各高度层间的变化是相互约束的,模型必须学习到这些关键特征才能有足够的系统表达能力。对比测试表明,先采用TimeDistributed层时间层进行封装,待获取气象场空间特征及要素层次间关联特征后再进一步学习时间变化特征,是一种符合天气分析思路且预测性能较好的气象深度学习建模方法。

社会关注的重大致灾性天气过程往往是“小概率”事件,使用AI方法进行学习和预测的关键在于综合采用样本数据增强,类别权重倾斜以及输出阈值调整等多种方法,引导模型针对关注目标进行正向增强训练。其中,在设定事件标签时适当降低气象评判指标,基于相似天气形势放大关注事件的样本数量,是气象数据增强的重要方式,也是提升本案例AI模型性能最有效的技术手段。

本文模型目前仅是一个实现“有/无区域性暴雨发生”定性预报的基础分类模型,但相关概念方法在条件成熟的情况下可转化为适宜开展定点、定时、定量预报的单站降水回归模型;而将覆盖全区的单站降水回归模型组合在一起,就可实现区域范围内的AI精细化降水预报。另外,随着“盘古气象

大模型”^[21]的开源,在条件允许的情况下改用“盘古”模型的AI预测产品作为模型输入数据,就可真正实现全流程AI业务化,这也是本研究未来发展的方向。

参考文献:

- [1] 杨绚,代刊,朱跃建.深度学习技术在智能网格天气预报中的应用进展与挑战[J].气象学报,2022,80(5):649-667.
- [2] CHOLLET F.Deep learning with Python[M].Manning Publications,2022.
- [3] WU X D, KUMAR V.The top ten algorithms in data mining[M].Chapman and Hall/CRC,2009.
- [4] VASWANI A, SHAZEER N, PARMAR N, et al.Attention Is All You Need [J].Advances in Neural Information Processing Systems, Curran Associates, inc .2017,30:5998-6008.
- [5] 黄嘉佑.气象统计分析与预报方法[M].北京:气象出版社,2004.
- [6] 邓华,张颖超,顾荣,等.基于PCA-RBF的风电场短期风速订正方法研究[J].气象科技,2018,46(1):10-15.
- [7] 陈永义,俞小鼎,高学浩,等.处理非线性分类和回归问题的一种新方法(I)——支持向量机方法简介[J].应用气象学报,2004,15(3):345-354.
- [8] 冯汉中,陈永义.处理非线性分类和回归问题的一种新方法(II)——支持向量机方法在天气预报中的应用[J].应用气象学报,2004,15(3):355-365.
- [9] 熊秋芬,曾晓青.SVM方法在降水预报中的应用及改进[J].气象,2008,34(12):90-95.
- [10] 李晶,唐全莉.基于1DCNN和LSTM的单站逐时气温预报方法[J].热带气象学报,2022,38(6):800-811.
- [11] 周高进,杨智鹏,彭静.基于LSTM的地基微波辐射计湿度廓线反演[J].气象科技,2022,50(1):21-29.
- [12] 周满国,黄艳国,杨训根.基于GRU神经网络与灰色模型集成的气温预报[J].热带气象学报,2020,36(6):855-864.
- [13] 雷雷,徐邦琪,高庆九,等.基于卷积神经网络的长江流域夏季日最高温度延伸期预报方法研究[J].大气科学学报,2022,45(6):835-849.
- [14] 徐月飞,赵放,毛程燕,等.基于深度卷积神经网络的阵风锋识别算法[J].暴雨灾害,2020,39(1):81-88.
- [15] 陈锦鹏,冯业荣,蒙伟光,等.基于卷积神经网络的逐时降水预报订正方法研究[J].气象,2021,47(1):60-70.
- [16] 张烨方,冯真祯,刘冰.基于卷积神经网络的雷电临近预警模型[J].气象,2021,27(3):373-380.
- [17] 张延彪,宋林烨,陈明轩.基于卷积神经网络的京津冀地区高分辨率格点预报偏差订正试验[J].大气科学学

- 报, 2022, 45(6):850–862.
- [18] 周必高, 鲁小琴, 郑峰, 等. 基于改进的 VGG16 模型的副热带高压相似识别及应用评估[J]. 气象, 2022, 48(12):1608–1616.
- [19] 陈训来, 刘军, 郑群峰, 等. 基于卷积门控循环单元神经网络的临近预报方法研究[J]. 高原气象, 2021, 40(2): 411–423.
- [20] 谢文鸿, 徐广珺, 董昌明. 基于 ConvLSTM 机器学习的风暴潮漫滩预报研究[J]. 大气科学学报, 2022, 45(5): 674–687.
- [21] BI K F, XIE L X, ZHANG H H, et al. Pangu-Weather: A 3D high-resolution model for fast and accurate global weather forecast [J]. Atmospheric and Oceanic Physics, 2022.

Design and application of deep neural network prediction model for regional rainstorm in Guangxi

QIN Yuefeng, DONG Liangmiao*, LIU Guozhong, LIANG Cungui, YANG Mingxin
(Guangxi Meteorological Observatory, Nanning 530022, China)

Abstract: Following a typical application process of AI technology, and starting from determining the data representation of the research object, this article discusses the construction process of a deep learning prediction model for “regional rainstorm” from using testing and selecting algorithmic tools, to adjusting and optimizing the model hyperparameters, enhancing the generalization of the model’s performance, and ultimately achieving its deployment online, thus successfully making sensible predictions of the “Dragon-boat Rain” event in Guangxi in 2023. The results show that the practical performance of the model can be significantly enhanced by employing AI algorithms that can simulate the weather analysis process and provide reasonable explanations for prediction mechanisms based on an in-depth understanding of the characteristics of the algorithm and model architecture in combination with the actual demand for forecasting services. The application of TimeDistributed layers to encapsulate the temporal dimension of samples, which first extracts the spatial and related features of meteorological elements before further learning about temporal changes, is a meteorological AI model construction method that aligns with weather analysis approaches and shows better predictive performance. For “low probability” meteorological events of interest, it is an effective technical means to improve the performance of weather AI models by appropriately lowering meteorological evaluation indicators when setting event labels, enhancing sample data based on similar weather situations, and guiding the model to carry out the positive enhancement training for the focus of attention, so as to achieve a basic classification model for qualitative prediction of “with/without regional rainstorm occurrence”.

Key words: meteorological object representation; deep neural network(DNN); model performance baseline; data enhancement; TimeDistributed wrapper