



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象图形学报

2021
05
VOL.26

ISSN1006-8961
CN11-3758/TB



参与介质渲染 P961



第26卷第5期 (总第301期)

2021年5月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿, 均视为同意在本刊网站及CNKI等全文数据库出版, 所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用, 所有内容, 未经许可, 不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院

主办单位 中国科学院空天信息创新研究院

中国图象图形学学会

北京应用物理与计算数学研究所

主 编 吴一戎

编辑出版 《中国图象图形学报》编辑部

通信地址 北京市海淀区北四环西路19号

邮 编 100190

电子信箱 jig@radi.ac.cn

电 话 010-58887035

网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号

总 发 行 北京报刊发行局

订 购 全国各地邮局

海外发行 中国国际图书贸易集团有限公司

(邮政信箱: 北京399信箱 邮编: 100048)

印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian

Monthly, Started in 1996

Superintended by Chinese Academy of Sciences

Sponsored by Aerospace Information Research Institute, CAS

China Society of Image and Graphics

Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Wu Yirong

Editor, Publisher Editorial Office of Journal of
Image and Graphics

Address No. 19, North 4th Ring Road West, Haidian District,
Beijing, P. R. China

Zip code 100190

E-mail jig@radi.ac.cn

Telephone 010-58887035

Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals

Domestic All Local Post Offices in China

Overseas China International Book Trading Corporation

(P.O.Box 399, Beijing 100048, P.R.China)

Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB

ISSN 1006-8961

CODEN ZTTXFZ

国外发行代号 M1406

国内邮发代号 82-831

国内定价 60.00元



均匀参与介质的渲染方法研究(第0961页)



循环生成对抗网络的线稿图像自动提取(第1117页)



伪点云修正增强激光雷达数据(第1157页)

学者观点

均匀参与介质的渲染方法研究

王贝贝, 樊家辉 0961

布料仿真建模研究进展

靳雁霞, 张晋瑞, 贾瑶, 马博 0970

综述

中国图像工程:2020

章毓晋 0978

图像处理和编码

双阶段信息蒸馏的轻量级图像超分辨率网络

李明鸿, 常侃, 李恒鑫, 谭宇飞, 覃团发 0991

具有纹理感知能力的超像素分割方法

吴江, 刘春晓 1006

图像分析和识别

深度聚类注意力机制下的显著对象检测

陈庆文, 谢宏文, 查浩, 奚瑜, 张雪 1017

特征增强策略驱动的车标识别

贺敏雪, 余烨, 程茹秋 1030

医学图像处理

融合上下文和注意力的视盘视杯分割

刘洪普, 赵一浩, 侯向丹, 郭鸿湧, 丁梦园 1041

遥感图像处理

复杂背景下SAR近岸舰船检测

阮晨, 郭浩, 安居白 1058

对抗型长短期记忆网络的雷达回波外推算法

方巍, 庞林, 张飞鸿, 盛胜利 1067

混沌系统和DNA编码的并行遥感图像加密算法

周辉, 谢红薇, 张昊, 张慧婷 1081

激光雷达大会2020

图匹配算法激光扫描点云树干分割

徐姗姗 1095

多特征融合与残差优化的点云语义分割方法

杜静, 蔡国榕 1105

NCIG 2020

循环生成对抗网络的线稿图像自动提取

王素琴, 张加其, 石敏, 赵银君 1117

面向COVID-19疫情预测的图卷积神经网络时空数据学习

杨成意, 刘峰, 齐佳音, 段妍, 吕润倩, 肖子龙 1128

结合汉明码和图像矫正的彩色图像盲水印

刘得成, 苏庆堂, 袁子涵, 张雪婷 1138

密文域高嵌入率图像全方位可逆数据隐藏

周旭, 吴福虎, 陈志立, 任帅 1147

伪点云修正增强激光雷达数据

宋绪杰, 戴孙浩, 林春雨, 詹书涛, 赵耀 1157

前沿进展

中国遥感软件研制进展与发展方向——以像素专家PIE为例

刘东升, 廖通逵, 孙焕英, 任芳 1169

CONTENTS

JOURNAL OF IMAGE AND GRAPHICS



Survey of rendering methods for homogeneous participating media(P0961)



Image extraction of cartoon line art based on cycle-consistent adversarial networks(P1117)



LiDAR data enhancement via pseudo-LiDAR point cloud correction(P1157)

Scholar View

Survey of rendering methods for homogeneous participating media

Wang Beibei, Fan Jiahui 0961

Progress of cloth simulation modeling

Jin Yanxia, Zhang Jinrui, Jia Yao, Ma Bo 0970

Review

Image engineering in China: 2020

Zhang Yujin 0978

Image Processing and Coding

Lightweight image super-resolution network via two-stage information distillation

Li Minghong, Chang Kan, Li Hengxin, Tan Yufei, Qin Tuanfa 0991

Superpixel segmentation with texture awareness

Wu Jiang, Liu Chunxiao 1006

Image Analysis and Recognition

Salient object detection based on deep clustering attention mechanism

Chen Qingwen, Xie Hongwen, Zha Hao, Xi Yu, Zhang Xue 1017

Vehicle logo recognition method based on feature enhancement

He Minxue, Yu Ye, Cheng Ruqiu 1030

Medical Image Processing

Optic disc and cup segmentation by combining context and attention

Liu Hongpu, Zhao Yihao, Hou Xiangdan, Guo Hongyong, Ding Mengyuan 1041

Remote Sensing Image Processing

SAR inshore ship detection algorithm in complex background

Ruan Chen, Guo Hao, An Jubai 1058

Radar echo extrapolation algorithm based on adversarial long short-term memory network

Fang Wei, Pang Lin, Zhang Feihong, Sheng Victor S 1067

Parallel remote sensing image encryption algorithm based on chaotic map and DNA encoding

Zhou Hui, Xie Hongwei, Zhang Hao, Zhang Huiting 1081

China LiDAR Conference 2020

Tree stem segmentation of laser scanning point clouds based on graph matching algorithm

Xu Shanshan 1095

Point cloud semantic segmentation method based on multi-feature fusion and residual optimization

Du Jing, Cai Guorong 1105

NCIG 2020

Image extraction of cartoon line art based on cycle-consistent adversarial networks

Wang Suqin, Zhang Jiaqi, Shi Min, Zhao Yinjun 1117

Spatiotemporal data learning of graph convolutional neural network for epidemic prediction of COVID-19

Yang Chengyi, Liu Feng, Qi Jiayin, Duan Yan, Lyu Runqian, Xiao Zilong 1128

Blind color image watermarking method combining Hamming code with image correction

Liu Decheng, Su Qingtang, Yuan Zihan, Zhang Xueting 1138

All bit planes reversible data hiding for images with high-embedding-rate in ciphertext field

Zhou Xu, Wu Fuhu, Chen Zhili, Ren Shuai 1147

LiDAR data enhancement via pseudo-LiDAR point cloud correction

Song Xujie, Dai Sunhao, Lin Chunyu, Zhan Shutao, Zhao Yao 1157

Frontier

Research progress and development direction of Chinese remote sensing software: taking PIE as an example

Liu Dongsheng, Liao Tongkui, Sun Huanying, Ren Fang 1169

中图法分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2021)05-1067-14

论文引用格式: Fang W, Pang L, Zhang F H and Sheng V S. 2021. Radar echo extrapolation algorithm based on adversarial long short-term memory network. Journal of Image and Graphics, 26(05):1067-1080(方巍, 庞林, 张飞鸿, 盛胜利. 2021. 对抗型长短期记忆网络的雷达回波外推算法. 中国图象图形学报, 26(05):1067-1080)[DOI:10.11834/jig.200316]

对抗型长短期记忆网络的雷达回波外推算法

方巍^{1,2,3}, 庞林¹, 张飞鸿¹, 盛胜利⁴

1. 南京信息工程大学计算机与软件学院, 南京 210044; 2. 浙江大学计算机辅助设计与图形学国家重点实验室, 杭州 310058;
3. 苏州大学江苏省计算机信息处理技术重点实验室, 苏州 215000; 4. 德克萨斯理工大学, 拉伯克 TX79409, 美国

摘要: 目的 雷达回波外推是进行短临降水预测的一种重要方法,相较于传统的数值天气预报方法能够实现更快、更准确的预测。基于卷积长短期记忆网络(convolutional long short-term memory network, ConvLSTM)的回波外推算法的效果优于其他的深度学习外推算法,但是忽略了普通卷积运算在面对局部变化特征时的局限性,并且在外推过程中将损失函数简单定义为均方误差(mean squared error, MSE),忽略了外推图像与原始图像的分布相似性,容易导致信息丢失。为解决以上不足,提出了一种基于对抗型光流长短期记忆网络(deep convolutional generative adversarial flow based long short-term memory network, DCF-LSTM)的回波外推算法。**方法** 首先,采用光流追踪局部特征的方式改进 ConvLSTM,突破了一般卷积核面对局部变化特征的限制。然后,以光流长短期记忆网络(flow based long short-term memory network, FLSTM)作为基本模块构建外推模型。最后,引入对抗网络,与外推模型组成端到端的博弈系统 DCF-LSTM,两者交替训练实现外推图像分布向原图像分布的拟合。**结果** 在4种不同的反射率强度下进行了消融研究,并与3种主流的气象业务算法进行了对比。实验结果表明,DCF-LSTM在所有评价指标中表现最优,尤其在反射率为35 dBZ的条件下。**结论** 由实验结果可知,引入光流法能够使模型具有更好的抗畸变性,引入深度卷积生成对抗网络(deep convolutional generative adversarial network, DCGAN)判别模块能进一步增加结果的准确性。本文提出的 DCF-LSTM 回波外推算法相比于其他算法,雷达外推准确率获得了进一步提升。

关键词: 雷达回波外推; 卷积长短期记忆网络(ConvLSTM); 深度卷积生成对抗网络(DCGAN); 光流法; 序列到序列结构

Radar echo extrapolation algorithm based on adversarial long short-term memory network

Fang Wei^{1, 2, 3}, Pang Lin¹, Zhang Feihong¹, Sheng Victor S⁴

1. School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China;
2. Key Laboratory of Computer Aided Design and Graphics, Zhejiang University, Hangzhou 310058, China;
3. Jiangsu Key Laboratory of Computer Information Processing Technology, Soochow University, Suzhou 215000, China;
4. Texas Tech University, Lubbock TX79409, United States

Abstract: Objective Radar echo extrapolation is an important method for short-term precipitation prediction. It can achieve

收稿日期:2020-06-21;修回日期:2020-08-24;预印本日期:2020-09-01

基金项目:国家自然科学基金项目(42075007);教育部天诚汇智创新促教科研创新基金项目(2018A03038);浙江大学计算机辅助设计与图形学国家重点实验室开放课题项目(A1916);苏州大学江苏省计算机信息处理技术重点实验室开放课题项目(KJS1935)

Supported by: National Natural Science Foundation of China (42075007); Ministry of Education Tiancheng Huizhi Innovation Promotion Education Research and Innovation Fund (2018A03038)

faster and more accurate predictions compared with traditional methods, such as numerical weather forecast and optical flow method. Among them, numerical weather forecasting requires complex and meticulous simulations of physical equations in the atmosphere and then uses observation data as input to predict future weather conditions. The optical flow method is currently the mainstream method used by the meteorological department, but it has two inherent flaws. On the one hand, only two adjacent frames can be used to estimate the optical flow; on the other hand, the radar echo sequence cannot be fully used for prediction. Nevertheless, the radar echo extrapolation method based on deep learning can take full advantage of spatiotemporal sequence data to achieve faster and more accurate prediction. In addition, the echo extrapolation algorithm based on convolutional long short-term memory network (ConvLSTM) has been proved to be effective in real applications, and the effect is superior to other deep learning extrapolation algorithms. However, it ignores the limitations of ordinary convolution operations in the face of locally changing features, and in the extrapolation process, the loss function is simply defined as mean square error (MSE), ignoring the distribution similarity between the extrapolated image and the original image, which is easy to cause information loss. To solve the above problems, an improved echo extrapolation algorithm based on adversarial long short-term memory network (LSTM) is proposed. **Method** First, in view of the local-invariance limitations of the traditional convolution kernel, we borrowed the idea of the dense optical flow method and constructed a two-dimensional instantaneous velocity field for all pixels to extract the motion information of each part of the object. Based on this idea, ConvLSTM is improved to form flow long short-term memory network (FLSTM), which is an optical flow optimization extrapolation algorithm. The algorithm uses optical flow to track local features, breaking through the limitation of local invariance of general convolution kernels. Then, according to the characteristics of radar sequence data (high-dimensional spatiotemporal data), the convolutional layer is used to extract effective spatial features to reduce spatial redundancy in the encoder, and then deconvolution is used in the decoder to amplify the generated decoded features to the size of the original image to form an output sequence. The convolutional layer and FLSTM are cross-stacked in depth to encode the input spatiotemporal sequence data into a fixed-length vector. The deconvolution and FLSTM are cross-stacked to decode the output sequence from the encoded vector. Finally, in order to obtain extrapolated images with higher accuracy, an adversarial generation network is introduced, and an extrapolation model forms an end-to-end game system deep convolutional generative adversarial flow-based long short-term memory network (DCF-LSTM). In this system, the generation network is the extrapolation model that tends to be stable after pre-training. Then, the pre-trained generation network continues to be alternately trained with the discriminator to further fit the extrapolated image distribution to the real image distribution, thereby improving the accuracy of the extrapolated image. **Result** Experiments were carried out under four different reflectance intensities. The DCF-LSTM model is compared with the flow based ConvLSTM (FLSTM) and DC-LSTM, which is an optimized convolutional LSTM by integrating deep convolutional generative adversarial network (DCGAN), and three mainstream meteorological business algorithms. The experimental results show that DCF-LSTM had the best performance under all intensity thresholds. Its probability of detection (POD) and critical success index (CSI) are higher than the other two methods, and it has the lowest false alarm rate (FAR) and mean square error (MSE), especially when the reflectivity is 35 dBZ. The higher the value of POD and CSI, the better the model performance; the lower the FAR value, the more accurate the model. Compared with FLSTM, DCF-LSTM has a 0.012 higher POD, 0.02 lower FAR, 0.015 higher CSI, and 0.115 lower MSE. Compared with DC-LSTM, DCF-LSTM has 0.035 higher POD, 0.03 lower FAR, 0.034 higher CSI, and 0.274 lower MSE. In addition, compared with TrajGRU, ConvLSTM, and Flow methods, DCF-LSTM has a 0.018, 0.047, and 0.099 higher POD; 0.015, 0.036, and 0.083 higher CSI; and 0.012, 0.034, and 0.087 lower FAR, respectively. **Conclusion** The experimental results show that the optical flow method can enable the model to learn the dynamic changes of local features in the radar sequence, breaking through the limitation of local invariance of the convolution operation and making the model more resistant to distortion. In addition, the introduction of DCGAN module for further game training prediction model can further increase the accuracy of the results. Compared with the three mainstream meteorological business algorithms, the DCF-LSTM echo extrapolation algorithm proposed in this study has further improved the accuracy of radar extrapolation.

Key words: radar echo extrapolation; convolutional long short-term memory network (ConvLSTM); deep convolutional generative adversarial network (DCGAN); optical flow; sequence-to-sequence structure

0 引言

雷达回波外推是进行短临降水预测的一种重要方法。由于雷达回波数据具有明显的时空特性,所以对时空序列进行建模成为解决回波外推问题的关键。时空序列预测需要在无监督条件下学习输入序列的内部表示,并在一定程度上理解其语义信息。近年来提出了各种方法来解决这个具有挑战性的任务。Srivastava 等人(2015)使用基于长短时记忆网络(long short-term memory, LSTM)的序列到序列(sequence to sequence, Seq2Seq)结构。Xu 等人(2019)提出了一种 LSTM 与 GAN(generative adversarial network)结合的网络。Shi 等人(2015)、Liang 等人(2017)、Elsayed 等人(2019)和 Wang 等人(2018,2019)通过对 LSTM 结构进行改进来优化任务表现。Finn 等人(2016)只进行运动预测,目标的外貌信息和背景通过前一帧获得。Villegas 等人(2017)将问题分解为运动和内容并分别进行预测。Shi 等人(2018)、吴昆等人(2018)和 Kim 等人(2017)使用深度学习的方法进行雷达外推,在短临降水预测中取得了良好效果。本文提出了一种改进

的基于 LSTM 的雷达回波外推方法进行短临降水预测,预测过程包括回波外推和降水预测两个步骤。首先,进行回波外推,根据当前多普勒雷达收集的实况数据,运用各种方法对未来缺失的雷达数据进行合理外推,实现对未来时段雷达数据的预测。其次,通过外推得到的雷达回波图像,应用 Z-R 关系式(Z-R relationship)(徐枝芳等,2006)进一步推导,得到降水预测值。

具体而言,回波外推是利用前若干时段内收集的雷达回波图像作为输入,输出指定时段后的外推图像。假设雷达回波图像序列间隔为 6 min,则 1 h 包含 10 幅图像,那么根据过去 J 小时雷达回波图像外推未来 K 小时回波图像时,输入数据可从 $10J + 1$ 长度序列中选取。于是可将上述问题转为在已知 t 时刻前 $10J + 1$ 帧数据的条件下,最大程度计算 t 时刻后 $10K$ 个时次长度的数据概率分布的条件概率事件。由此得出概率计算公式为

$$\begin{aligned} X_{t+1}, \dots, X_{t+10K} = \\ \operatorname{argmax}_{X_{t+1}, \dots, X_{t+10K}} p(\hat{X}_{t+1}, \dots, \hat{X}_{t+10K} | X_{t-(10J+1)}, \dots, X_t) \end{aligned} \quad (1)$$

式中, X 表示 3 维雷达图像数据。回波外推过程如图 1 所示。




图1 回波外推示意图

Fig. 1 Diagram of echo extrapolation

雷达回波图像的成像基于反射率转化而来,图1中的像素点数值与雷达回波强度相对应,反射率的值越大,雷达回波强度越强,对应像素点的数值越大,降水的可能性就越大。多普勒雷达产品制定的反射率范围一般为 $0 \sim 80$ dBZ,因此在衡量回波外推模型性能时,应采用具有代表性的不同量级的反射率进行综合评价,而不是仅依靠均方误差(mean squared error, MSE)这一个指标,这样更符合业务评价标准。观察式(1)可知,理论上可以通过堆叠条

件概率预测任意长度的图像序列,但是由于每幅图像的预测都会存在一定程度的误差,而随着预测长度的增加会出现误差暴增的情况,从而导致最终预测出的图像缺乏细节信息。此外,逐像素比较的损失函数 MSE 对较小的误差不敏感,进一步导致了图像视觉上表现模糊的情况。为了解决这个问题,本文提出了使用深度卷积对抗生成网络(deep convolutional generative adversarial network, DCGAN)(Radford 等,2015)优化外推结果,将整个编码器解

码器模型作为初始化生成器,使用损失函数和 MSE 结合训练生成器,同时将生成序列和真实序列作为判别器输入,使生成图像与真实图像无限接近,进一步减小散度差异。

1 算法提出

本文针对回波外推算法的优化主要包括整体时序建模、光流优化特征提取和对抗学习拟合分布。

1.1 基于 ConvLSTM 的时空序列建模

基于卷积长短时记忆网络 (convolutional long short-term memory network, ConvLSTM) (Shi 等,

2015) 的方法用卷积代替了 LSTM 中的全连接层,实现了对图像序列空间信息和时间信息的同步学习,在解决时空序列预测任务中表现出色。使用 Conv-LSTM 进行时空建模的主要流程如图 2 所示,图中特征提取和反向重构通过编码器解码器实现。在对时序图像进行完特征提取后,将得到的低维度信息输入到 ConvLSTM 网络中并利用随时间反向传播 (back propagation through time, BPTT) 算法 (Werbos, 1990) 学习网络模型。模型训练完成后,需利用验证集数据进行效果检测,质检合格的模型会保存起来用于回波外推,否则将继续迭代训练。




图 2 回波外推流程图

Fig. 2 Echo extrapolation flow chart

外推过程根据预测需求分为单步预测和多步预测。单步预测原理如图 3 所示,其中 H 为 C 均为 LSTM 的隐状态,网络的主要梯度来源可表示为 $(\{x_2, x_3, \dots, x_5\} - \{\hat{x}_2, \hat{x}_3, \dots, \hat{x}_5\})^2$ 。但现实情况中回波外推要求的时间往往跨度较长,仅依靠单步预测很难实现,于是引入多步预测概念。多步预测是在单步预测的基础上进行。单步预测中 t_1 时刻的图像经过 n 次更新后,才会输出 t_{n+1} 时刻的状态,这样的效率很低。而多步预测对较长时间跨度的学习可以一次更新多个时间步长,从而减少更新次数。假设每次更新的时间步长为 s ,则原数据 $\{X_1, X_2, \dots, X_t\}$ 只需经过 1 次状态更新即可得到新的预测序列 $\{\hat{X}_{s+1}, \hat{X}_{s+2}, \dots, \hat{X}_{s+t}\}$ 。对短时间内运动剧

烈的情况,多步预测需要缩短时间步长,反之则可以增大。多步预测的误差来源与单步预测相同。

鉴于时序序列的完整性约束,因此需要在时间维度上搭建序列到序列 (sequence to sequence, Seq2Seq) 网络架构 (Sutskever 等, 2014) 并返回完整的序列。由于神经网络具有深度特性,即线性嵌套运算,理论上越深的网络可以产生越大的假设空间,可以拟合更加复杂的函数。单层 ConvLSTM 是无法全面学习到复杂时空性的,需要在时间轴上扩展为多层。将单个隐含层单元表示为 σ ,那么在 t 时刻的输入表示为 X_t 和 H_{t-1} ,输出为 H_t ,即 $\sigma(X_t, H_{t-1}) = H_t$ 。当输入为 0 层,输出为 $L+1$ 层,可拓展为 $\sigma(X_t^{(L)}, H_{t-1}^{(L)}) = H_t^{(L)}$ 。具体拓展后的模型如图 4 所示。




图 3 单步预测原理图

Fig. 3 Single-step prediction schematic




图4 多层 ConvLSTM 原理图

Fig.4 Multi-layer ConvLSTM schematic




图5 多层 ConvLSTM 原理图

Fig.5 Schematic diagram of multi-layer ConvLSTM((a)normal convolution operation;(b)dynamic tracking operation)

ConvLSTM 隐含层采用的是普通卷积运算,在时序图像中信息传递是水平的,如图5(a)所示。现实中的运动大多具有非刚性动态变化的特性,内部质点在当前帧的位置与下一帧的位置很大可能不存在对应,所以需要建立一个动态的链接跟踪质点来突破一般卷积核的局限性,如图5(b)所示。光流法可以通过计算两帧间的运动矢量,完成对下一帧的回波结构的映射。

在光流图像中,所有像素点会构成一个2维瞬时速度场,可以理解为是物体中可见点的3维速度场的投影,所以利用光流可以准确反映观察的物体的各部分运动信息。虽然光流法在整个外推过程中有一定局限性,但其多项式拓展技术值得借鉴。求取光流的目的是为了计算每个像素点的运动矢量,而这些局部运动矢量可以用来辅助追踪质点。因此,可利用局部光流来量化云团内的局部特征运动状态。当输入数据在与隐含层权重进行卷积前,光流会优先作用于这些局部超参数。此时利用具有映射功能的 warp 函数将目标权重按照局部光流的指引,映射到下一帧的指定位置进行卷积,就能实现对质点的动态追踪。由于建立动态连接主要作用于隐

1.2 光流优化算法

本文在图像空间特征提取时采用了卷积操作。普通卷积具有位置不变的特性,但大多数事物都是局部特征变化的,例如旋转、放缩等特性,所以传统的卷积操作是有明显局限的。比如雷达回波在一段时间内可受风向、风速、局部压强以及强对流的影响,从而产生偏移、放缩、旋转或生消等复杂变化,因此在处理这样的序列图像时需要动态跟踪这些变化的质点。卷积运算从处理局部不变序列过渡到局部变化序列的过程,如图5所示。

含层,根据 ConvLSTM 可知当前时刻隐藏状态 H_t 与上一时刻隐含状态 H_{t-1} 有关,因此可以通过将 t 时刻特定位置 (i,j) 处隐含状态 $H_{t(i,j)}$ 重写为动态变化后的 $H'_{t(i,j)}$ 来实现动态跟踪。不妨设 $\Omega_{(i,j)}$ 为当前时刻的图像中位置 (i,j) 的邻域集合, $(p,q) \in \Omega_{(i,j)}$ 表示根据 (i,j) 的上一邻域与状态卷积权重计算出的位置 (i,j) 在当前邻域的特定位置点,即 $(p_{l(i,j)}, q_{l(i,j)})$ 是位置 (i,j) 在第 l 个邻域对应的位置, W_{hh}^l 是当前时刻状态卷积权重的矩阵表示。则 $H'_{t(i,j)}$ 可表示为

$$H'_{t(i,j)} = f\left(\sum_{l=1}^{\Omega_{(i,j)}} W_{hh}^l * \text{warp}(H_{t-1(p_{l(i,j)}, q_{l(i,j)})})\right) \quad (2)$$

式中, f 代表经过细胞状态 C_t 的复合函数变换过程。

由于大多数运动模式对不同位置有不同的邻域集,如旋转和放缩会产生指向不同方向不同大小的流场。因此,本文通过重新设计位置变量的计算结构实现使权重参数随 $(p_{l(i,j)}, q_{l(i,j)})$ 而动。为了实现当前输入和当前隐含状态在每个时间戳上对每个位置生成局部邻域集,需要使用光流引导轨迹的走向,至此获取光流成为首要任务。在对局部邻域进行光流提取时,由于像素点不可导,本文利用差商代

替求导计算局部光流,并使用双线性插值更新邻域集。利用当前输入 X_t 和隐含状态 H_{t-1} 计算局部光流,并用结构性字段 U_t 和 V_t 进行保存,此过程使用的算法是基于梯度 (Farneback, 2003) 的稠密光流法,这是一种基于前后两帧所有像素点的移动估算方法,效果比主要计算角点的稀疏光流更好。具体做法是,先利用多项式对相邻两帧图像中的每个像素点进行近似展开,然后在假设理想平移的条件下对平移量进行计算,得到基本关系公式。最终考虑实际运动状况,对多项式中系数进行近似替换,从而推导出真实位移场并进行光流提取。先将回波图像视为 2 维信号的函数,自变量信号可以利用两个坐标参数定义为 $X = (x \ y)^T$,接着利用二次多项式对图像进行近似建模,具体为

$$E(X) = X^T A X + B^T X + c \quad (3)$$

式中, A 是通过像素邻域信息的最小二乘加权拟合得到的维度为 2×2 的对称矩阵,其权重系数与邻域的像素大小及位置有关; B 是一个 2×1 的矩阵向量, c 为标量。据此,将 2 维信号空间转换为 6 维信号空间,具体为

$$(x \ y)^T = \begin{pmatrix} A_{11} & \frac{A_{12}}{2} \\ \frac{A_{12}}{2} & A_{22} \end{pmatrix} (x \ y) + \begin{pmatrix} B_1 \\ B_2 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} + c =$$

$$B_1 x + B_2 y + A_{11} x^2 + A_{22} y^2 + A_{12} xy + c \quad (4)$$

由于多项式展开的结果实质上是每个邻域的近似表示,因此先考虑在理想平移条件下的情况。设平移量为 d ,其中 $\hat{X} = X - d$,构建新的信号 $E_2(\hat{X}) = E_1(X - d)$,代入式(3),得

$$\begin{aligned} E_2(\hat{X}) &= (X - d)^T A_1 (X - d) + B_1^T (X - d) + c_1 = \\ &= X^T A_1 X + B_1^T X - 2A_1 d^T X + d^T A_1 d - B_1^T d + c_1 = \\ &= X^T A_2 X + B_2^T X + C_2 \end{aligned} \quad (5)$$

根据光流法的第一个假设微弱运动,令 $A_1 = A_2$,合并后得 $B_2^T = B_1^T - 2A_1 d^T$, $C_2 = d^T A_1 d - B_1^T d + c_1$,进一步得到 $-2A_1 d^T = B_2^T - B_1^T$,最终通过移项可以得到平移量 $d^T = -1/2A_1^{-1}(B_2^T - B_1^T)$ 。由于理想平移在实际中几乎不存在,将其设为单个多项式也存在不足,且 $A_1 = A_2$ 的假设过于理想,因此需要对其扩展系数进行近似处理,具体为

$$A(X) = \frac{A_1(X) + A_2(X)}{2} \quad (6)$$

$$\Delta B(X) = -\frac{B_2(X) - B_1(X)}{2} \quad (7)$$

此时,利用空间变化的位移 $d(X)$ 替代 d^T ,就能得到新的近似等式 $A(X)d(X) = \Delta B(X)$ 。但这仅是求出图像中每个像素点的光流,算法稳定性较差。

根据实际情况,本文假设位移是缓慢变化的,有利于整合邻域信息并找出合适的 $d(X)$ 。定义 $\omega(\Delta X)$ 为窗口权重函数,则利用最小二乘法可得

$$\sum_{\Delta X \in I} \omega(\Delta X) \|A(X + \Delta X)d(X) - \Delta B(X + \Delta X)\|^2 \quad (8)$$

式中, I 为输入帧中所有像素点集合。进一步近似,可得

$$d(X) = \omega(A^T A)^{-1} A^T \Delta B \quad (9)$$

此时,需要计算 $A^T A$ 和 $A^T \Delta B$,之后通过权重参数 ω 进行加权平均运算。

为了进一步近似建模,继续将位移场进行参数化,设新位移 $d(X)$ 为具有 6 个参数的运动模型,并在 x 和 y 方向上均有分量,具体表示为

$$d_x(X) = a_1 + a_2 x + a_3 y + a_4 x^2 + a_6 xy \quad (10)$$

$$d_y(X) = a_1 + a_2 x + a_3 y + a_5 y^2 + a_6 xy \quad (11)$$

令 $S = \begin{pmatrix} 1 & x & y & x^2 & 0 & xy \\ 1 & x & y & 0 & y^2 & xy \end{pmatrix}$, $P = (a_1 \ a_2 \ \dots \ a_6)^T$, $D = (d_x(X) \ d_y(X))^T$,则式(8)可改写为

$$\sum_{i \in I} \omega_i \|A_i S_i P - \Delta B_i\|^2 \quad (12)$$

式中, i 表示邻域内各个像素点的索引。利用最小二乘法解得

$$P = \left(\sum_i \omega_i S_i^T A_i^T A_i S_i \right)^{-1} \left(\sum_i \omega_i S_i^T A_i^T \Delta B_i \right), \text{代入式(12)即可得到 } d(X) \text{ 在 } x \text{ 和 } y \text{ 方向上的位移矢量。}$$

由于多项式展开适用于局部模型,对小的位移 $d^T = -1/2A_1^{-1}(B_2^T - B_1^T)$ 比较有利,但剧烈运动会引入较大误差,此时不应局限于同一个坐标系下比较两个多项式,应根据相邻帧的图像获得位移场的先验信息,将第 1 幅图像信号 X 处的多项式与第 2 幅图像信号 $X + \Delta d$ 处的多项式进行比较, Δd 是先验位移场得到的数值且近似于真实位移。重新替换后,式(6)和式(7)变为

$$A(X) = \frac{A_1(X) + A_2(X + \Delta d)}{2}$$

$$\Delta B(X) = -\frac{(B_2(X) + B_1(X))}{2} + A(X) \Delta d$$

首次计算 $\Delta \mathbf{B}(\mathbf{X})$ 时需要将 Δd 置为 0, 再利用式(9)计算新的位移, 并赋值到 Δd 进行多次迭代直至精确逼近真实位移。

为了能够尽量捕捉更大尺度的运动情况, 在实验中使用了分层金字塔技术。通过下采样逐层缩小图像, 会使得相邻两帧之间的大尺度运动也会缩小, 更加符合上述光流约束条件。设 $\mathbf{T}_1$ 和 $\mathbf{T}_2$ 为相邻两帧图像, $\mathbf{T}_1^k$ 和 $\mathbf{T}_2^k$ 分别为 $\mathbf{T}_1^{k-1}$ 和 $\mathbf{T}_2^{k-1}$ 通过采样得到的下层低分辨率图像。利用相邻的底层估计粗粒度光流场, 上层在此基础上进行精细化, 这样得到的残余光流向量会足够小, 进而获取较为精确的运动矢量。最终叠加所有层分段光流作为结果, 提高了估计较大运动幅度的准确性。

求出光流场后, 在隐藏层卷积核的尺寸 $n \times n$, 和图像尺寸 (W, H) 共同约束下, 利用双线性插值生成新的邻域位置 $\mathbf{H}_{(x,y,l)}$, 并与权重参数进行卷积运算。其中 Flow 代表光流算法 (x, y, l) 代表在第 l 邻域上的坐标位置, 插值过程为

$$\mathbf{U}_l, \mathbf{V}_l = \text{Flow}(\mathbf{X}_l, \mathbf{H}_{l-1}) \quad (13)$$

$$\mathbf{H}_{(x,y,l)} = \sum_{w=1}^W \sum_{h=1}^H \mathbf{H}_{(w,h,l)} \cdot \max(0, n - |y + \mathbf{V}_{i,j} - w|) \cdot \max(0, n - |x + \mathbf{U}_{i,j} - h|) \quad (14)$$

$\mathbf{U}_l$ 和 $\mathbf{V}_l$ 在一定意义上突破了传统卷积的局限, 理论上完成了对质点的追踪。有光流参与的

ConvLSTM 核心公式更新为

$$\mathbf{I}_t = \sigma(\mathbf{X}_t * \mathbf{W}_{xi} + \sum_{l=1}^L \mathbf{W}_{hi}^l * \mathbf{H}_{(x,y,l)} + \mathbf{b}_i) \quad (15)$$

$$\mathbf{F}_t = \sigma(\mathbf{X}_t * \mathbf{W}_{xf} + \sum_{l=1}^L \mathbf{W}_{hf}^l * \mathbf{H}_{(x,y,l)} + \mathbf{b}_f) \quad (16)$$

$$\mathbf{O}_t = \tanh(\mathbf{X}_t * \mathbf{W}_{xo} + \sum_{l=1}^L \mathbf{W}_{ho}^l * \mathbf{H}_{(x,y,l)} + \mathbf{b}_o) \quad (17)$$

$$\hat{\mathbf{C}}_t = \tanh(\mathbf{X}_t * \mathbf{W}_{xc} + \sum_{l=1}^L \mathbf{W}_{hc}^l * \mathbf{H}_{(x,y,l)} + \mathbf{b}_c) \quad (18)$$

$$\mathbf{C}_t = \mathbf{F}_t \circ \mathbf{C}_{t-1} + \mathbf{I}_t \circ \hat{\mathbf{C}}_t \quad (19)$$

$$\mathbf{H}_t = \mathbf{O}_t \circ \tanh(\mathbf{C}_t) \quad (20)$$

式中, $\mathbf{b}$ 为偏置矩阵, $\mathbf{W}$ 为权重矩阵, $\circ$ 表示 Hadamard 积运算。为表述方便, 本文将经过光流改进的 ConvLSTM 简称为 FLSTM(flow based LSTM)。

局部光流是在上一时刻的特征上提取的, 为了便于观察, 挑选一幅回波图像进行可视化, 显示在不同采用空间上的特征光流场, 从左至右, 层数递增, 如图 6 所示。图中带箭头的线段记录着每个特征邻域的运动方向和大小。通过观察发现, 在不同空间里会提取不同程度的运动信息。由于回波图像中没有反射率的区域没有运动趋势, 所以经过光流计算后空白区域的位移矢量为 0, 在光流场中表现为一个点。




图 6 可视化光流场(从左至右层数递增)

Fig. 6 Visualize the optical flow field(the number of layers increased from left to right)

1.3 DCGAN 对抗学习

从概率模型式(1)可以看出, 外推模型理论上可以生成任意时间长度的预测序列。但随着预测长度的增加, 条件概率会不断堆叠, 直接导致累计误差激增, 反映到输出结果上就是外推的图像缺乏细节

信息, 视觉上表现模糊。这样的外推图像多倾向于单峰分布, 与真实图像的多峰分布有较大差别, 因此需要进一步解决散度问题。此外, 基于深度学习的回波外推的损失函数常定义为逐像素比较的 MSE, 这是导致外推图像丢失细节的原因之一。

MSE 虽然能避免正值和负值相互抵消,但对较小误差敏感。更为关键的是 MSE 将噪声和图像局部特征独立开,这与人类视觉系统的感知相悖。因此仅利用 MSE 作为损失函数会使图像失真。当外推图像与真实样本的分布无限接近时,反向重构出的图像会更加清晰,于是提出 DCGAN 对抗学习的方法辅助纠正 MSE 损失函数的不足,进一步减小散度差异。

时序数据属于高维数据,内部包含很多无效信息,直接用于 FLSTM 学习效果并不好,需要先利用卷积层提取空间有效特征,配合步幅下采样进一步降低数据的冗余性。基于该思路,设计外推模型架构时,在每层 FLSTM 内核的前后的输入和输出端设置了编码模块和解码模块。编码模块的主要工作是卷积下采样,与其配合的解码模块则利用上采样分别提取不同尺度图像特征并反向重构。本文沿用了卷积自编码器的卷积层,配合提出的 FLSTM 实现对输入回波图像在每一时刻空间特征的提取,激活函数定义为 ReLU。解码过程需要利用反卷积 (deconvolution, DConv) 进行上采样,将学习到的特征反向重构成未来时段雷达回波图像的序列预测。外推模型的整体架构如图 7 所示,图中横向代表时间轴,纵向代表网络深度。结构中设计了 3 层 FLSTM,具体

层级参数如表 1 所示,表中返回序列为 True 表示 Seq2Seq 返回的是一个完整序列。为了使网络能够充分学习到不同尺度的时空特征,模型中各层 FLSTM 不仅学习下采样后的特征,对上采样也同样进行学习。

表 1 网络参数

Table 1 Parameters of network

网络层	卷积核尺寸	步幅	返回序列	神经元数量
特征提取	7×7	2×2	-	16
FLSTM1	3×3	1×1	True	64
下采样 1	5×5	2×2	-	64
FLSTM2	3×3	1×1	True	192
下采样 2	3×3	2×2	-	192
FLSTM3	3×3	1×1	True	192
FLSTM3	3×3	1×1	True	192
上采样 1	4×4	2×2	-	192
FLSTM2	3×3	1×1	True	192
上采样 2	5×5	2×2	-	192
FLSTM1	3×3	1×1	True	64
上采样 3	7×7	2×2	-	16
合并卷积	1×1	1×1	-	1

注:“-”代表 False。




图 7 外推模型架构图
Fig. 7 Diagram of extrapolation model architecture

接着,引入 DCGAN 对结果进行矫正。DCGAN 近年来在气象领域 (Gao 等,2018;Fang 等,2018) 得到广泛应用。将整个外推模型作为生成器,输入采

用真实数据而非随机噪声,损失函数依赖内部的编、解码器以及 FLSTM 单元。为了兼顾 FLSTM 反向传播的梯度同时保证与判别器的联动,将 MSE 也作为

生成器损失函数的一部分。同时,利用标准原数据与外推生成图像作为输入构造判别器。判别器共设置了4层卷积层,为防止梯度消失或爆炸,每层卷积之间加入局部归一化层(batch normalization, BN)。除全连接层使用 sigmoid 激活函数外,其余的激活函数统一使用 LeakyReLU。由于判别器的实质是 Logistic 回归,因此将这部分损失函数定义为 sigmoid 交叉熵较为合适。设 y_i 为标签值, $\hat{y}_i$ 为预测值,则经过激活函数的输出为 $p_i = \text{sigmoid}(\hat{y}_i)$, 批量样本总数为 N 。由此得到损失函数表达式为

$$Loss_i = -\frac{1}{N} [y_i \ln p_i + (1 - y_i) \ln(1 - p_i)] \quad (21)$$

式中,标识符 i 表示对抗学习的博弈性,不同的取值会引发不同的运算逻辑。对判别器而言,当 $i = 1$ 时,表示输入为真实数据,对应标签 $y_i = 1$ 为真,触发针对判别器的训练;当 $i = 2$ 时,表示输入为生成图像,对应 $y_i = 0$ 为假,触发判别器与生成器联动。对生成器而言, $i = 3$ 表示输入为生成图像,对应 $y_i = 1$ 为真,触发针对生成器的训练。判别器结构参数如图8和表2所示。




图8 判别器结构图

Fig. 8 Discriminator structure diagram

表2 判别器网络参数

Table 2 Discriminator network parameters

网络层	卷积核尺寸	步幅	填充类型	神经元数量
Conv1	5 × 5	2 × 2	same	64
Conv2	5 × 5	2 × 2	same	64
Conv3	3 × 3	2 × 2	same	128
Conv4	3 × 3	2 × 2	same	128
FC1	-	-	-	256
FC2	-	-	-	1

综上所述,将判别器 D 和生成器 G 的损失函数分别定义为

$$D_{\text{Loss}} = Loss_1 + Loss_2 \quad (22)$$

$$G_{\text{Loss}} = Loss_3 + MSE \quad (23)$$

训练过程中,需要先开启判别器的可训练模式,并为其分配损失函数和 Adam 优化策略进行预训练;之后将判别器设置为不可训练模式,作为生成模块训练的参考,同时也为生成器分配损失函数和

Adam 优化策略并进行训练。结束后,再将判别器训练模式开启,两个模块在训练过程中如此交替优化,可达到提升生成回波图像质量的目的。

需要注意的是, MSE 与交叉熵损失函数虽然都有各自的训练目的,但初始训练时二者的数量级相差太大,简单的加和无法实现优化整个生成器的目的。为解决这个问题,本文采用先对外推模型进行独立训练,之后在生成器中直接调用初步训练好的外推模型使其继续参与博弈训练的策略。

基于对抗型 LSTM 的整体模型框架如图9所示,该回波外推算法的具体步骤如下:

1) 对 ConvLSTM 的卷积操作按式(2)进行优化。利用梯度光流法提取局部区域的运动信息,进而按式(14)通过双线性插值更新出追踪目标区域并进行定向卷积。按照以上方法优化 ConvLSTM 中所有相关操作,得到抗畸变的 FLSTM。

2) 利用 FLSTM 根据图7结构进行时序建模。编码过程中, FLSTM 自上而下分为3层,对应卷积




图9 DCF-LSTM 整体模型架构
Fig.9 The overall model architecture of DCF-LSTM

核尺寸均为 3×3 , 下采样的步长均为 2。解码时上采样步长也为 2。在最后一次解码时, 采用数量为 1 的 1×1 的卷积核进行合并卷积。

3) 预训练 FLSTM 外推模型并将其封装成生成器, 同时构造如图 8 所示的判别器。利用对抗学习思想, 构建两者的损失函数, 交替训练这两个模型。训练完成后, 利用生成器在测试集上外推得到回波图像。

2 实验与分析

2.1 数据集

回波外推实验采用深圳市气象局与香港天文台共同建立的多普勒雷达数据集, 覆盖时间为 2010—2017 年每年的 3 月—7 月。其中每个雷达数据个案样本覆盖时长为 6 h, 时间间隔为 6 min, 共 61 个时段, 即每组样本由 61 幅雷达回波图像组成。垂直层次共 1 层, 海平面高度 3 km。雷达数据样本水平分辨率为 0.01 度, 约 1 km, 网格数量为 501×501 。实验利用 10 000 个序列作为训练, 1 000 个序列作为测试, 15 帧长度用于输入, 10 帧长度用于预测。雷达回波数据经过脱敏处理, 数据范围为 $0 \sim 80$ dBZ, 其值越高代表对应区域降水可能越大, 并以灰度图 PNG 格式存储。

2.2 评估方法

实验采用气象业务中的正确率 (probability of detection, POD)、空报率 (false alarm rate, FAR)、临界成功指数 (critical success index, CSI) 以及 MSE 作为回波外推模型的评估标准。

在气象业务中, 对不同的降水强度往往给予的

关注程度不同, 因此应该根据模型在不同降水程度下的综合表现作为评价算法好坏的重要依据。选取不同降水强度, 并找到对应的反射率进而定位到对应的灰度阈值上, 即可完成降水强度在回波图像上的表征。本文首先利用能够触发不同程度降水的反射率阈值来对外推图像和标准的对比图像进行二值化处理, 大于该阈值的数值设定为 255, 小于该阈值的数值一律设定为 0。然后统计命中数、空报数和误报数, 用来计算正确率 (POD)、空报率 (FAR) 和临界成功指数 (CSI)。同时, 将 MSE 作为直观反映外推图像相似程度的评价标准。

2.3 实验结果分析

实验结果包括多重反射率评估和可视化结果展示两个方面内容。

2.3.1 多重反射率评估

实验选取反射率为 35 dBZ、40 dBZ、45 dBZ 和 50 dBZ 的 4 个易导致强降水的等级作为对应灰度阈值进行二值化, 这些等级分别代表降水临界值、小雨级别、大雨级别和暴雨级别。通过自身对比和与其他主流方法对比对外推模型进行评估。自身对比使用本文提出基于对抗性 FLSTM 的回波外推算法 (DCF-LSTM) 与仅添加 DCGAN 的 ConvLSTM 算法 (DC-LSTM) 和仅添加光流的 ConvLSTM 算法 (FLSTM) 进行对比实验, 用于验证每个改进点的有效性。与其他主流方法对比包括与 ConvLSTM (Shi 等, 2015)、轨迹门控循环单元 (trajectory gated recurrent unit, TrajGRU) (Shi 等, 2017) 以及光流法 (Flow) (Farneback, 2003) 3 种主流算法对比, 用于验证所提算法的准确率。在 4 个阈值条件下, 进行

了外推时长为 1 h 的实验,实验结果如表 3—表 6 所示,其中评估指标为在这段时间内的均值。同时,为了更加直观地观察数据变化过程,对不同阈值条件下本文算法与 ConvLSTM、TrajGRU 和 Flow 算法在 10 个时序长度(1 h)中各项指标数据的变化过程进行统计,结果如图 10 所示。

表 3 不同算法在反射率大于等于 35 dBZ 时的实验结果对比

Table 3 Comparison of experimental results when reflectivity more than 35 dBZ among different algorithms

算法	POD	FAR	CSI	MSE/10 ⁴
FLSTM	0.642	0.450	0.421	1.944
DC-LSTM	0.619	0.465	0.402	2.174
ConvLSTM	0.612	0.473	0.395	2.244
TrajGRU	0.635	0.458	0.413	2.007
Flow	0.542	0.571	0.315	2.644
本文	0.654	0.433	0.436	1.854

注:加粗字体表示各列最优结果。

表 4 不同算法在反射率大于等于 40 dBZ 时的实验结果对比

Table 4 Comparison of experimental results when reflectivity more than 40 dBZ among different algorithms

算法	POD	FAR	CSI	MSE/10 ⁴
FLSTM	0.582	0.478	0.384	1.687
DC-LSTM	0.542	0.514	0.337	1.846
ConvLSTM	0.539	0.502	0.350	2.018
TrajGRU	0.571	0.483	0.372	1.644
Flow	0.483	0.542	0.307	2.271
本文	0.597	0.475	0.388	1.572

注:加粗字体表示各列最优结果。

从表 3—表 6 和图 10 可以看出,1)在自身对比实验方面,在不同反射率强度对应的统计结果中,本文提出的 DCF-LSTM 的 POD 和 CSI 在所有强度阈值下较另外两种方法均为最高,FAR 和 MSE 均为最低。在反射率大于等于 35 dBZ 条件下,相比较 FLSTM 和 DC-LSTM,POD 较另外两种方法分别高出 0.012 和 0.035;FAR 分别下降 0.02 和 0.03;CSI 分别高出 0.015 和 0.034;MSE 分别下降 0.115 和 0.274。这也是在所有阈值条件下的最好结果,原因是 35 dBZ 包含的信息最多。随着反射率取值增大,

表 5 不同算法在反射率大于等于 45 dBZ 时的实验结果对比

Table 5 Comparison of experimental results when reflectivity more than 45 dBZ among different algorithms

算法	POD	FAR	CSI	MSE/10 ⁴
FLSTM	0.539	0.502	0.350	1.455
DC-LSTM	0.518	0.519	0.332	1.722
ConvLSTM	0.507	0.524	0.325	1.794
TrajGRU	0.536	0.503	0.347	1.531
Flow	0.461	0.558	0.291	1.977
本文	0.548	0.499	0.354	1.328

注:加粗字体表示各列最优结果。

表 6 不同算法在反射率大于等于 50 dBZ 时的实验结果对比

Table 6 Comparison of experimental results when reflectivity more than 50 dBZ among different algorithms

算法	POD	FAR	CSI	MSE/10 ⁴
FLSTM	0.461	0.564	0.289	1.348
DC-LSTM	0.434	0.582	0.271	1.655
ConvLSTM	0.421	0.599	0.259	1.676
TrajGRU	0.453	0.567	0.284	1.362
Flow	0.385	0.637	0.230	1.802
本文	0.469	0.555	0.296	1.241

注:加粗字体表示各列最优结果。

过滤掉的信息也同步增多,效果自然会下降。在多重反射率评估条件下,通过 DCF-LSTM 和 FLSTM 的实验对比,证明了增加 DCGAN 对预测输出有矫正作用;与 DC-LSTM 的实验对比证明了引入光流法能够提升外推模型的预测准确性。实验结果符合本文对外推模型的设想。2)在与其他主流方法对比方面,本文提出的 DCF-LSTM 在所有评价标准中均为最优,相对于 ConvLSTM、TrajGRU 以及 Flow,获得的 MSE 和 FAR 最低,同时 POD 和 CSI 最高。虽然在某些特殊情境中,如大于 40 dBZ 的 CSI 和大于 45 dBZ 的 FAR 会有指标轻微反超现象,但考虑到时序序列是一个整体,利用积分面积和均值判断是比较科学的。在多重反射率评估过程中,DCF-LSTM 相比于 TrajGRU、ConvLSTM 和 Flow 方法,POD 平均增长 0.018、0.047 和 0.099;CSI 平均增长 0.015、0.036 和 0.083;FAR 平均下降 0.012、0.034 和 0.087。实验证




图 10 不同算法各指标变化对比

Fig. 10 Comparison of changes of every index among different algorithms

((a) frame-wise POD over test sets; (b) frame-wise FAR over test sets; (c) frame-wise CSI over test sets)

明,引入光流法能够使得模型具有更好的抗畸变性,引入 DCGAN 判别模块能进一步增加结果的准确性。实验结果表明,本文提出的基于对抗性 LSTM 回波外推算法相比于其他算法获得了更好的效果。

2.3.2 可视化展示

图 11 展示了两个样本利用不同外推方法进行 1 h 的外推可视化结果。前文提到雷达回波图像间隔为 6 min, 1 h 对应 10 幅图像。本文同样进行了间隔取样,每个样本对应 5 幅图像。可以看出,Flow 在后期的外推过程中出现了明显形变,其余 3 种基于深度学习方法外推的图像越往后越模糊,符合概率模型公式和多步预测累计误差原理。但相比较 DCF-LSTM 外推出的图像,ConvLSTM 和 TrajGRU 越

往后细节丢失越严重,都出现了较为明显的模糊、暗淡现象,与多重反射率评估的结论相符。

3 结 论

现有基于 ConvLSTM 的回波外推算法忽略了普通卷积运算在局部特征变化图像上的局限性以及外推图像与原始图像的分布相似性。为了解决上述问题,本文首先通过需求分析列出概率模型公式,将问题引入到 Seq2Seq 预测结构,为神经网络的搭建和评估标准提供技术支持。其次,提出利用光流建立局部特征动态连接方法,突破了传统卷积运算在处理局部变化特征问题上的局限性。接着根据对抗学




图 11 可视化回波外推结果

Fig. 11 Visualize echo extrapolation results ((a) extrapolating sequence 1; (b) extrapolating sequence 2)

习的原理,将 DCGAN 引入外推方法中,弥补了依赖 MSE 的不足。实验中利用真实雷达回波图像作为测试集,将本文提出的外推方法进行自身消融实验,并与现有主流方法进行多重反射率评估对比,实验结果表明,使用光流法进行改进的 ConvLSTM 可以较好地捕获像素点的局部运动矢量,从而实现运动轨迹的学习与预测;加入对抗学习可以外推出更多的细节信息;与其他方法对比,本文提出的 DCF-LSTM 在各类指标中表现最好,有效提高了外推的精准度。实验验证了本文方法的有效性。但是,本文方法也存在不足之处,主要表现在光流的提取和对抗模型的引入在一定程度上增加了模型复杂度。下一步将考虑从 FLSTM 内部改进训练一个端到端的模型,以消除 FLSTM 信息存储与向后传递的过程中重要信息的损失,解决外推结果越往后视觉表现越模糊的问题。

参考文献 (References)

- Elsayed N, Maida A S and Bayoumi M. 2019. Reduced-gate convolutional LSTM architecture for next-frame video prediction using predictive coding//Proceedings of the International Joint Conference on Neural Networks. Budapest, Hungary: IEEE: 1-9 [DOI: 10.1109/IJCNN.2019.8852480]
- Fang W, Zhang F H, Sheng V S and Ding Y W. 2018. A method for improving CNN-based image recognition using DCGAN. Computers, Materials and Continua, 57(1): 167-178 [DOI: 10.32604/cmc.2018.02356]
- Farneback G. 2003. Two-frame motion estimation based on polynomial expansion//Proceedings of the Scandinavian Conference on Image Analysis. Halmstad, Sweden: Springer: 363-370 [DOI: 10.1007/3-540-45103-X_50]
- Finn C, Goodfellow I and Levine S. 2016. Unsupervised learning for physical interaction through video prediction//Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona, Spain: Curran Associates: 64-72
- Gao F, Yang Y, Wang J, Sun J P, Yang E F and Zhou H Y. 2018. A deep convolutional generative adversarial networks (DCGANs) - based semi-supervised method for object recognition in synthetic aperture radar (SAR) images. Remote Sensing, 10(6): #846 [DOI: 10.3390/rs10060846]
- Kim S, Hong S, Joh M S and Song S. 2017. DeepRain: ConvLSTM network for precipitation prediction using multichannel dar data [EB/OL]. [2020-06-21]. <https://arxiv.org/pdf/1711.02316.pdf>
- Liang X D, Lin L, Shen X H, Feng J S, Yan S C and Xing E P. 2017. Interpretable structure-evolving LSTM//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 2175-2184 [DOI: 10.1109/cvpr.2017.234]
- Radford A, Metz L and Chintala S. 2015. Unsupervised representation learning with deep convolutional generative adversarial networks [EB/OL]. [2020-06-21]. <https://arxiv.org/pdf/1511.06434.pdf>
- Shi E, Li Q, Gu D Q and Zhao Z M. 2018. A method of weather radar echo extrapolation based on convolutional neural networks//Proceedings of the International Conference on Multimedia Modeling. Bangkok, Thailand: Springer: 16-28 [DOI: 10.1007/978-3-319-73603-7_2]
- Shi X J, Chen Z R, Wang H, Yeung D Y, Wong W K and Woo W C. 2015. Convolutional LSTM network: a machine learning approach for precipitation nowcasting//Proceedings of the 28th International Conference on Neural Information Processing Systems. Quebec, Canada: MIT Press: 802-810

- Shi X J, Gao Z H, Lausen L, Wang H, Yeung D Y, Wong W K and Woo W C. 2017. Deep learning for precipitation nowcasting: a benchmark and a new model//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates; 5617-5627
- Srivastava N, Mansimov E and Salakhutdinov R. 2015. Unsupervised learning of video representations using LSTMs//Proceedings of the 32nd International Conference on International Conference on Machine Learning. Lille, France: ACM; 843-852
- Sutskever I, Vinyals O and Le Q V. 2014. Sequence to sequence learning with neural networks//Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal, Canada: MIT Press; 3104-3112
- Villegas R, Yang J M, Hong S, Lin X Y and Lee H. 2017. Decomposing motion and content for natural video sequence prediction [EB/OL]. [2020-06-21]. <https://arxiv.org/pdf/1706.08033.pdf>
- Wang Y B, Gao Z F, Long M S, Wang J M and Yu P S. 2018. PredRNN++: towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning [EB/OL]. [2020-06-21]. <https://arxiv.org/pdf/1804.06300.pdf>
- Wang Y B, Zhang J J, Zhu H Y, Long M S, Wang J M and Yu P S. 2019. Memory in memory: a predictive neural network for learning higher-order non-stationarity from spatiotemporal dynamics//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE; 9154-9162 [DOI: 10.1109/CVPR.2019.00937]
- Werbos P J. 1990. Backpropagation through time: what it does and how to do it. Proceedings of the IEEE, 78(10): 1550-1560 [DOI: 10.1109/5.58337]
- Wu K, Liang W and Wang S Q. 2018. 3D convolutional neural network for regional precipitation nowcasting. Journal of Image and Signal Processing, 7(4): 200-212 (吴昆, 梁伟, 王书强. 2018. 基于3D卷积神经网络的区域降雨量预报. 图像与信号处理, 7(4): 200-212) [DOI: 10.12677/JISP.2018.74023]

- Xu Z, Du J, Wang J J, Jiang C X and Ren Y. 2019. Satellite image prediction relying on GAN and LSTM neural networks//Proceedings of 2019 IEEE International Conference on Communications. Shanghai, China: IEEE; 1-6 [DOI: 10.1109/ICC.2019.8761462]
- Xu Z F, Xiong J and Ge W Z. 2006. Application of genetic algorithm in optimizing the Z-R parameter to radar rainfall estimation. Plateau Meteorology, 25(4): 710-715 (徐枝芳, 熊军, 葛文忠. 2006. 使用遗传算法优化雷达测量降水 Z-R 关系. 高原气象, 25(4): 710-715) [DOI: 10.3321/j.issn:1000-0534.2006.04.020]

作者简介



方巍, 1975年生, 男, 副教授, 硕士生导师, 主要研究方向为人工智能、气象信息处理和大数据分析。

E-mail: hsfangwei@sina.com

庞林, 女, 硕士研究生, 主要研究方向为雷达外推的深度学习应用研究。E-mail: panglin0912@126.com

张飞鸿, 男, 硕士研究生, 主要研究方向为雷达图像处理及深度学习应用。E-mail: zhangfeihong_2017@163.com

盛胜利, 男, 教授, 博士生导师, 主要研究方向为数据挖掘与机器学习、人工智能、数据安全和决策支持。

E-mail: ssheng@uca.edu