

6-23-2021

Creating Synthetic Satellite Cloud Data Based on GAN Method

Wencong Cheng

Air-Force Research Academy, Beijing 100085, China;

Xiaokang Shi

Air-Force Research Academy, Beijing 100085, China;

Zhigang Wang

Air-Force Research Academy, Beijing 100085, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Creating Synthetic Satellite Cloud Data Based on GAN Method

Abstract

Abstract: To create the synthetic satellite cloud data in the domain of Meteorology, *a method based on Generative Adversarial Networks (GAN) is proposed*. Depending on ability of the nonlinear mapping and the information extraction of raster data with the deep learning network, *a deep generative adversarial network model is proposed to extract the corresponding information between the numerical weather prediction(NWP) products and the satellite cloud data, and then the appropriate elements of the NWP product are chosen as the input to synthesize the corresponding satellite cloud data*. The experiments are conducted on the re-analysis products of the European Centre for Medium-Range Weather Forecasts (ECMWF) and FY-4A satellite cloud data. The results show that the proposed method is effective to create synthetic satellite cloud data by using the NWP products.

Keywords

deep learning, generative adversarial networks, numerical weather prediction products, satellite cloud data, simulation

Recommended Citation

Cheng Wencong, Shi Xiaokang, Wang Zhigang. Creating Synthetic Satellite Cloud Data Based on GAN Method[J]. Journal of System Simulation, 2021, 33(6): 1297-1306.

基于生成对抗网络的仿真卫星云图生成方法

程文聪, 史小康, 王志刚

(空军研究院, 北京 100085)

摘要: 针对气象领域中仿真云图生成问题, 提出一种基于深度生成对抗网络的仿真卫星云图生成方法。利用深度学习的非线性映射能力和对栅格数据的信息提取能力, 选取合适的数值模式产品要素作为输入, 建立深度生成对抗模型提取同时次、同区域数值模式产品和卫星云图产品的对应有效信息, 再利用提取的信息将数值模式产品重构为卫星云图产品。基于欧洲中期天气预报中心数值模式再分析场产品和风云 4A 气象卫星产品的实验表明, 所提方法可以有效的将数值模式产品重构为卫星云图仿真产品。

关键词: 深度学习; 生成对抗网络; 数值模式产品; 卫星云图; 仿真

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X (2021) 06-1297-10

DOI: 10.16182/j.issn1004731x.joss.20-0055

Creating Synthetic Satellite Cloud Data Based on GAN Method

Cheng Wencong, Shi Xiaokang, Wang Zhigang

(Air-Force Research Academy, Beijing 100085, China)

Abstract: To create the synthetic satellite cloud data in the domain of Meteorology, a method based on Generative Adversarial Networks (GAN) is proposed. Depending on ability of the nonlinear mapping and the information extraction of raster data with the deep learning network, a deep generative adversarial network model is proposed to extract the corresponding information between the numerical weather prediction(NWP) products and the satellite cloud data, and then the appropriate elements of the NWP product are chosen as the input to synthesize the corresponding satellite cloud data. The experiments are conducted on the re-analysis products of the European Centre for Medium-Range Weather Forecasts (ECMWF) and FY-4A satellite cloud data. The results show that the proposed method is effective to create synthetic satellite cloud data by using the NWP products.

Keywords: deep learning; generative adversarial networks; numerical weather prediction products; satellite cloud data; simulation

引言

随着卫星遥感技术的快速发展, 卫星云图在天气分析和预报中的作用日益增大。利用卫星云图可以分析不同尺度云系结构及其活动规律, 云的分布、形态、数量及其变化体现了大气运动的变化趋势和状态, 是天气变化的重要征兆, 也是灾害性天气预警和预报的有效手段之一, 具有先导性价值^[1-2],

而且云图数据直观性强, 易于理解, 是气象预报员实时分析天气现象的重要资料。由于卫星云图是一种实时监测数据, 实际业务过程中只能获取过去临近时次的卫星云图, 而获取未来数小时或数十小时的卫星云图对于预报员判明未来天气演变具有重要的指导意义。

天气的数值预报模式是能够定量表述未来天

收稿日期: 2020-01-19 修回日期: 2020-04-21

基金项目: 高分对地观测专项(GFZX0402180102)

第一作者: 程文聪(1981-), 男, 博士, 高工, 研究方向为数据挖掘与气象信息处理。E-mail: emailtocheng@sina.com

气变化的一种技术手段,通过在数值模式产品基础上生成仿真卫星云图,可获取未来数小时或数十小时的卫星云图仿真产品,对于预报员直观的掌握未来天气形势发展有很大的帮助,具有重要的实际使用价值。在现有技术方法中,可以通过 RTTOV (Radiative Transfer for TOVS)^[3]和 CRTM (Community Radiative Transfer Model)^[4]等辐射传输模式根据大气温、压、湿廓线及地表、卫星参数计算辐射亮温,从而生成红外通道的仿真云图。国内外在此基础上开展了一系列的工作,丁伟钰等^[5]根据 WRF 模式输出的气象场,利用 RTTOV 模式模拟了台风“珍珠”的 HIRS/3 红外辐射亮温,马刚等^[6]利用 RTTOV7 模式对风云二号红外和水汽通道进行了模拟,Chevallier 等^[7]利用欧洲中长期气象中心资料和 RTTOV 模式模拟了有云条件下静止卫星 11 μm 通道的辐射亮温,张兴海等^[8]利用飓风天气预报模式(HWRF)输出的大气状态参数结合 CRTM 模式实现了 FY-2F 红外通道的亮温仿真,史小康等^[9]利用 WRF 模式输出产品及 RTTOV 模式实现了 FY-2D 红外模拟亮温图的制作。这些基于辐射传输模式的云图仿真方法在实际使用过程中存在一定的限制条件,具体表现为:①针对可见光通道的仿真产品研究较少,效果一般。常规的辐射传输模式仅计算辐射亮温,一般不计算可见光通道的反照率数据,因而仅能模拟云图的红外通道;②起始预报时次仿真效果不佳。基于辐射传输模式的方法需要经历一个启动过程后才能获取稳定的输出,在实际中通常使用模式起报时刻 3~6 时次后的产品;③辐射传输模式需要的基础输入数据的类别和相应高度层较多,对输入数据条件有较高的要求;④辐射传输模式的计算过程需要大量计算资源,在基层气象台站的实际业务工作中难以满足。

当前,深度学习在图像分类、图像识别和语音识别等领域的应用取得了较好的结果,基于卷积神经网络(CNN)的深度学习^[10]在计算机视觉等领域有了广泛的应用,但在图像生成领域中使用欧式距离作为相似性度量的常规深度学习^[11]方法通常

会倾向于产生模糊的图像^[11-13]。生成对抗网络模型^[14]是近年来人工智能领域有较多研究的一个方向,通过生成器和判别器的对抗,实现生成器参数和判别器参数的训练优化,从而建模从特定领域 A 向特定领域 B 的数据映射关系,实现从领域 A 向领域 B 的转换,生成对抗网络模型目前在图像生成领域有较广泛的应用。

本文提出一种基于生成对抗网络技术和数值模式再分析场产品仿真生成卫星云图的方法。利用深度学习网络的非线性映射能力,使用生成对抗的网络架构建立仿真卫星云图生成模型,从而实现将数值模式再分析场产品重构为卫星云图产品的目标。由于数值模式再分析场产品与数值模式预报场产品具有相同的要素和格式,而利用数值模式预报通常可以获取未来数小时至数十小时的预报场产品,因而使用本文所提方法可以生成未来对应时次的预报仿真云图产品,对于气象保障具有重要的实用价值。

1 资料和方法

1.1 所用资料

本文选用欧洲中期天气预报中心提供的 0.25°×0.25°分辨率的 ERA5 再分析场产品和 FY-4A 气象卫星 4 km 分辨率产品进行实验分析,选取产品的覆盖范围均为北纬 10°~北纬 50°、东经 90°~东经 130°。目前 FY-4A 气象卫星数据在国家气象卫星中心网站上的数据获取起始时间为 2018 年 3 月 18 日,因而训练数据选取了 2018 年 4 月 1 日~7 月 20 日逐小时数据,共计 2 500 余个时次的数据,测试数据为 2018 年 7 月 21 日~25 日逐小时数据。

(1) FY-4A 卫星资料。

FY-4A 地球静止气象卫星是我国第二代静止轨道气象卫星的首发星,搭载了多通道扫描成像仪、干涉式大气垂直探测仪、闪电成像仪、空间环境监测仪器包等多种载荷,本文的工作中选择 FY-4A 搭载的多通道扫描成像仪产品作为仿真云

图模拟的对象。多通道扫描成像仪的主要任务是对地球表面和云物理状态参数的高频次、高精度、多光谱定量遥感, 直接为天气分析和预报、短期气候预测以及环境和灾害监测服务。观测波段覆盖可见光、近红外、短波红外、中波红外和长波红外, 既可观测到大尺度天气系统的全貌, 又可观测到中、小尺度天气系统的迅速演变过程。多通道扫描成像仪共配备 14 个通道, 包括 7 个可见光-近红外通道和 7 个红外通道。14 个通道中 500 m 地面分辨率通道 1 个, 1 km 通道 2 个, 2 km 通道 4 个, 4 km 通道 7 个, 全圆盘观测时间间隔为 15 min。

本文工作中选择红外 12 通道(波段: 10.3~11.3 μm)和可见光 1、2、3 通道合成图作为目标产品; 为统一各通道产品分辨率, 且不影响工作的一般性, 均选取 4 km 分辨率的产品, 则在所考察范围(N 10°~N 50°, E 90°~E 130°)内单一通道产品分辨率为 1 000×1 000; 为配合数值模式产品的时效, 云图产品也选择逐小时的整点产品。

(2) 欧洲中期天气预报中心第五代再分析场产品 ERA5。

欧洲中期天气预报中心发布的数值模式产品是实际业务中使用较为广泛的产品之一, 是各个气象业务部门进行天气分析和预报的重要资料来源。ERA5 再分析数据是其发展的第 5 代全球大气再分析数据, 通过欧洲中期天气预报中心网站可下载该中心制作的 1979 年至今的历史 ERA5 再分析场产品, 本文中采用 0.25°×0.25° 空间分辨率的逐小时 ERA5 再分析场产品, 则在所考察范围(N 10°~N 50°, E 90°~E 130°)内单一要素产品分辨率为 160×160。

选取的产品类别和高度层如表 1 所示。其中云量产品直接与云图云量相关, 地表温度是计算红外通道产品的基础数据之一, 云液水含量和固水含量与云状相关^[9], 风场数据以及涡度场数据与云的流向和外形相关。

表 1 作为模型输入的数值模式再分析场产品要素
Tab. 1 Elements of the NWP re-analysis products as the model input

要素	英文名	单位	层次
云量	Fraction of cloud cover	(0-1)	
U 风场	U-component of wind	m/s	100/200/300/400/500/600/
V 风场	V-component of wind	m/s	700/800/850/900/950/1000
涡度	Vorticity	S ⁻¹	
温度	Temperature	K	
湿度	Relative humidity	%	
地表温度	Skin temperature	K	单层
云液水含量	Total column cloud liquid water	Kg·m ⁻²	单层
云冰水含量	Total column cloud ice water	kg·m ⁻²	单层

不同时段仿真云图产品的生成依赖于输入的对应时段数值天气预报模式产品。由于欧洲中期天气预报中心的 ERA5 产品为小时间间隔数据, 即提供每小时整点时刻的要素产品, 而本文的研究目标为使用数值天气预报模式产品作为输入, 建立模型生成同时次、同区域的仿真云图产品, 因而生成的结果产品是与输入的数值模式产品时段对应的逐小时整点时刻的仿真云图产品。

1.2 基于生成对抗网络的仿真云图生成方法

本文采用基于生成对抗网络的模型用于生成仿真卫星云图产品。仿真云图产品生成过程示意图 1 所示, 该问题可形式化为如下表述:

定义 1: 仿真云图产品 给定 S 为卫星云图的特定通道产品, $\tilde{S}$ 为由数值模式产品生成的与 S 同属性仿真云图产品, $N_1, N_2, \dots, N_n$ 为数值预报模式产品要素集合, 则重构出的仿真云图产品为条件期望值:

$$\tilde{S} = E[S|N_1, N_2, \dots, N_n] \quad (1)$$

为了生成仿真云图产品, 首先收集同一时段、同一区域历史数值模式产品和云图产品构建训练数据集, 继而构建深度生成对抗模型提取数值模式产品与云图产品间的对应信息, 最后将待重构时段

的数值模式产品作为模型的输入, 获取对应时次的仿真云图产品作为输出结果。




图 1 仿真云图产品生成过程示意图

Fig. 1 Process of creating the synthetic satellite cloud data

如图 2 所示, 生成对抗网络需要训练 2 个不同的网络, 分别为生成网络 G 和判别网络 D 。选用 SEBlock 模块^[15]、U-Net 结构^[16]再结合一个上采样层(Upsample)构成生成网络 G 。由于参与计算的数值模式产品类别及层次总数多达 75 种(如表 1 所示), 这些产品类别及层次对于仿真云图生成的贡献权重不同, 如无区别的作为模型输入将会影响模型的收敛。因而在输入层之后引入压缩-激活模块(SEBlock)来显式的将各输入要素类别及层次的重要性参数化。该模块首先进行压缩(Squeeze)操作, 顺着空间维度进行特征压缩, 将每个输入的二维气象要素通过全局平均池化层变成一个实数, 该实数表征着在特定要素上响应的全局分布, 使得靠近输入的层也可以获得全局的感受野, 该步骤后共生成 75 个与输入要素相对应的实数。其次是激活(Excitation)操作, 通过引入全连接神经网络层(FCNLayer)在 Squeeze 步骤操作获取的实数数组基础上为每个要素特征通道生成权重, 该权重被用来显式的建模要素特征通道间的相关性。最后将 Excitation 步骤输出的权重看做为各个输入产品类别及层次的重要性权重, 通过点积操作逐要素通道加权到输入数据上, 完成输入产品的重标定。U-Net 结构是一种增加了跳跃连接的编码-解码器网络,

在图像分割领域有较广泛的使用, 由于数值模式产品与云图产品具有不同的分辨率, 因此在 U-Net 结构后增加上采样层。判别网络 D 为一个多层卷积分类网络, 通过计算输入其中的图像为真实云图的概率, 判别输入其中的图像是真实云图还是仿真生成云图。在训练过程中, 判别器 D 尝试正确的判别真实云图与仿真云图, 生成器 G 则尝试生成尽可能真实的云图使判别器 D 无法辨别真伪。令 x 表示数值模式产品, y 表示对应的真实云图产品, 为了提取输入数值模式产品 x 与云图产品 y 的映射关系, 使用条件 GAN 模型^[17]作为判别器的基本架构, 即将 x 和 y 一起作为判别器 D 的输入(常规 GAN 模型的判别器仅使用 y 作为输入)。

令 $D(x, y)$ 为判别器准确识别真伪云图的概率, $G(x, z)$ 为由数值模式产品 x 生成仿真云图的函数(z 为随机噪声), 则对于判别器 D , 目标函数为找到如下使 D 最大化的模型参数:

$$\operatorname{argmax}_D \ln(D(x, y)) + \ln(1 - D(x, G(x, z))) \quad (2)$$

对于生成器 G , 目标函数为找到如下最优优化参数:

$$\operatorname{argmax}_G \ln(D(x, G(x, z))) \quad (3)$$

具体实现中, 使用二元交叉熵作为损失度量。

即对于判别器 D 而言, 损失函数如下:

$$L_D = L_{bce}(D(x, y), 1) + L_{bce}(D(x, G(x, z)), 0) \quad (4)$$

其中:

$$L_{bce}(\hat{a}, a) = -\frac{1}{N} \sum_{i=1}^N (a_i \ln \hat{a}_i + (1 - a_i) \ln (1 - \hat{a}_i)) \quad (5)$$

式中: N 为模型输入的一个批样本数量; $a \in \{0, 1\}$ 表示输入数据的标签(0: 仿真云图; 1: 真实云图); $\hat{a} \in [0, 1]$ 为判别器 D 输出的判别值, 该值靠近 0 则判别器认为输入是仿真云图的概率高, 靠近 1 则认为输入是真实云图的概率高。

对于生成器 G 而言, 文献[11]的研究表明将生成对抗损失与传统的损失函数结合将得到更好的结果。因此令 G 的损失函数为生成对抗损失与 L_1 损失的按比例合成, 具体损失函数如下:

$$L_G = \lambda_1 L_{bce}(D(x, G(x, z)), 1) + \lambda_2 |y - G(x, z)| \quad (6)$$




图 2 仿真云图产品生成对抗网络架构

Fig. 2 GAN architecture for creating the synthetic satellite cloud data

训练过程以迭代方式执行。首先对判别器 D 进行训练, 对 D 批量输入真实云图和生成器 G 生成的仿真云图, 利用损失 L_D 通过反向传播的方式更新 D 的参数; 继而冻结判别器 D 的参数, 对生成器 G 批量输入数值模式产品 x 和对应的真实云图 y , 计算生成器损失 L_G , 通过反向传播的方式更新 G 的参数。重复上述过程直至生成器和判别器的能力达到平衡。

在训练过程中, 优化方法为使用 minibatch SGD 的 ADAM 方法^[18], 学习率为 0.000 2, 优化器动量参数 $\beta_1=0.5$, $\beta_2=0.999$, Upsample 上采样层采用 Phase-Shift 方法^[19]提高输出结果的分辨率。在推理过程中, 使用生成器网络用于生成仿真云图, 生成器网络架构与训练阶段的生成器网络模型相同, 参数为训练后的生成器模型参数。

2 结果验证

为便于观察和量化重构效果, 生成的仿真云图质量判别方法为平均绝对误差 MAE 和均方误差根 $RMSE$, 在实验中 MAE 和 $RMSE$ 仅计算真实云图产品和仿真云图产品中不同时为 0 的格点。出于对云图产品进行可视化的考虑, 使用图像重构领域中常用的峰值信噪比 $PSNR$ (该值越大说明重构效果越好)度量云图可视化重构质量。对于尺寸为 $m \times n$ 的仿真云图产品数据 I 以及真实云图产品数据 K , 本文涉及的相关计算公式如式(7)~(9)所示:

$$MAE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} |I(i, j) - K(i, j)| \quad (7)$$

$$PSNR = 20 \lg \left(\frac{MAX_I}{\sqrt{MSE}} \right) \quad (8)$$

$$RMSE = \sqrt{\frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i, j) - K(i, j)]^2} \quad (9)$$

式中: MAX_i 为图像点颜色的最大数值, 本文中取 255。

实验环境配置如下, CPU: Intel Xeon 4116×2, 内存: 64 GB, GPU: NVIDIA GTX 1080ti 11GB×2, 硬盘: 512GB SSD, 操作系统: Ubuntu 18.04, 深度学习平台: Pytorch 1.0.1。训练数据选取 2018 年 4 月 1 日—7 月 20 日逐小时数据, 其中红外通道产品共计 2 523 个时次的数据, 可见光通道产品共计 1 057 个时次(仅取每日白天北京时 08 时—17 时)的数据。模型输入的数值模式产品的水平分辨率为 160×160 , 模型输出的仿真云图产品水平分辨率为 $1\,000 \times 1\,000$ 。模型经历 300 个训练周期(epoch)的训练, 红外通道产品的训练时长为 34 h 05 min, 可见光通道产品的训练时长为 25 h 08 min。

2.1 结果统计分析

参与统计分析的测试数据为 2018 年 7 月 21 日—25 日逐小时数据, 红外通道共 116 个时次, 由于夜晚可见光通道无数据, 因而可见光通道仅取每天白天 10 个时次(北京时 08 时—17 时)共 50 个时次的数据。表 2 为可见光组合产品和红外 12 通道产品的 MAE 误差(小值更优)、RMSE 误差(小值更优)和 PSNR 评价值(大值更优)统计, 从统计结果中可以发现, 红外 12 通道产品的所有样本均方根均值为 17.4 K (热力学温度单位), 误差变化范围为 10.7 ~21.6 K, 与文献[9]中提到的 FY-2D 的红外 1 通道预报场仿真云图个例产品的 20 ~27 K 误差范围, 文献[5]中提到的 20 ~40 K 误差范围, 文献[6]中提到的 25 ~45 K 误差范围相比有了一定的提高, 说明基于深度生成对抗网络的仿真云图生成方法具有较好的重构效果。另外现有基于辐射传输模式的方法一般较少计算云图可见光通道的反照率, 因而难

以模拟可见光通道的云图产品, 而本文所提方法也能对可见光通道的云图产品进行仿真模拟, 可见光通道仿真云图产品的均方根均值为 0.19, 误差变化范围为 0.15~0.22。

2.2 红外通道云图仿真个例分析

图 3 为使用本文所提基于深度学习方法模拟 FY-4A 红外 12 通道产品的效果图, 图 3(a)~(c)为 2018 年 7 月 21 日北京时 8 时的仿真云图效果对比图, 其中(a)为欧洲细网格 0.25 格距分析场图(为进行可视化, 仅使用 RGB 颜色显示数值模式产品的高、中、低云量数据), (b)为基于本文方法的 FY-4A 红外 12 通道仿真云图, (c)为 FY-4A 红外 12 通道实际数据。其平均绝对误差 MAE 为 6.9 K, 均方根误差 RMSE 为 10.7 K, 峰值信噪比 PSNR 为 27.4。图 3(d)~(f)为 2018 年 7 月 21 日北京时 19 时的仿真云图效果对比图, 其中(d)为欧洲细网格 0.25 格距分析场图(同样仅使用 RGB 颜色显示产品的高、中、低云量数据), (e)为基于本文方法的 FY-4A 红外 12 通道仿真云图, (f)为 FY-4A 红外 12 通道实际数据。其平均绝对误差 MAE 为 13.3 K, 均方根误差 RMSE 为 19.0 K, 峰值信噪比 PSNR 为 22.4。从上述仿真云图红外通道产品的误差数据及直观感受均表明本文所提方法能够较好的仿真云图的红外通道产品。通过从训练后的推理模型中提取压缩-激活模块(SEBlock)中每个特征通道权重参数, 可大致了解生成仿真红外云图的数值模式产品要素对最终仿真产品的贡献度。2018 年 7 月 21 日 8 时的数据经模型运算后提取后的权重如表 3 所示。从表中可以看出在各个多层要素中云量产品对于红外云图仿真产品的生成具有最大的贡献, 其次是湿度和温度要素, 而风场对仿真云图生成的贡献较低。需要注意

表 2 数值模式产品生成仿真云图产品的结果统计
Tab. 2 Results statistics of the synthetic satellite cloud data

测试通道	取值范围	Mean MAE	Min MAE	Max MAE	Mean RMSE	Min RMSE	Max RMSE	PSNR
红外 12 通道亮温/K		11.9	6.9	15.3	17.4	10.7	21.6	23.2
可见光通道反照率	0~1.65	0.15	0.09	0.17	0.19	0.15	0.22	17.5

的是由于生成对抗模型中的卷积操作本身具备一定的通道权重调整能力, 因而 SEBlock 模块的通道权重仅能大致定性的反映该时次各要素对生成产品的贡献度, 并不是要素重要性的绝对定量度量指标。

2.3 可见光通道云图仿真个例分析

图 4 为使用本文所提基于深度生成对抗网络方法模拟 FY-4A 可见光 3 个通道合成产品的效果

图, 仿真产品的时间区间为 2018 年 7 月 21 日 8 时—11 时(北京时)共 4 个时次。图 4(a)~(d)为 8 时—11 时(北京时)根据本文所提算法生成的仿真可见光云图产品, 图 4(e)~(f)为 8 时—11 时(北京时)对应的实际可见光云图产品, 仿真云图产品与实际云图产品的误差数据如表 4 所示。从仿真可见光云图产品的误差数据及直观感受均表明本文所提方法能够较好的仿真云图的可见光产品。




图 3 2018 年 7 月 21 日 8 时、19 时(北京时)红外 12 通道云图仿真效果对比

Fig. 3 Comparison between the hourly synthetic satellite 12 infrared data and the ground truth at 08:00, 19:00 (Beijing time) on July 21, 2018

表 3 2018 年 7 月 21 日 8 时生成红外 12 通道产品的 SEBlock 模块中对应要素的权重
Tab. 3 Elements weights of SEBlock module of the infrared channel 12 at 8:00 on July 21, 2018

要素	通道权重	层次	要素累计权重
云量	0.10/0.08/0.08/0.10/0.11/0.07/0.04/0.03/0.03/0.03/0.04/0.20		0.91
U 风场	0.04/0.09/0.02/0.01/0.03/0.04/0.05/0.03/0.02/0.01/0.02/0.04		0.40
V 风场	0.02/0.07/0.06/0.03/0.03/0.02/0.03/0.02/0.01/0.01/0.03/0.06	100/200/300/400/	0.39
涡度	0.01/0.10/0.03/0.06/0.04/0.02/0.03/0.05/0.02/0.05/0.07/0.03	500/600/700/800/	0.51
温度	0.12/0.06/0.09/0.07/0.02/0.03/0.04/0.03/0.07/0.03/0.04/0.10	850/900/950/1000	0.70
湿度	0.06/0.06/0.12/0.10/0.10/0.10/0.08/0.07/0.03/0.03/0.03/0.09		0.87
地表温度	1.00	单层	1.00
云液水含量	0.31	单层	0.31
云冰水含量	1.00	单层	1.00

表4 2018年7月21日4个时次误差

Tab. 4 Result error on July 21, 2018 for 4 hours

误差	8时	9时	10时	11时
MAE/K	0.11	0.12	0.16	0.15
RMSE/K	0.16	0.18	0.22	0.21
PSNR	19.9	18.9	17.2	17.4

与红外通道产品的实验类似,通过从推理模型中提取压缩-激活模块(SEBlock)中每个特征通

道权重参数,可大致了解用于生成可见光仿真云图的数值模式产品要素对最终仿真产品的贡献度。2018年7月21日8时的数据经模型运算后提取的权重如表5所示,对比同时次红外通道仿真产品,在多层要素中涡度的贡献度上升,而风场的贡献依然较低,在单层要素中液水含量的贡献度也有一定的上升。




图4 2018年7月21日08时~11时(北京时间)可见光仿真云图与实际云图产品的效果对比

Fig. 4 Comparison between the hourly synthetic satellite visible channel data and the ground truth at 08:00-11:00 (Beijing time) on July 21, 2018

表5 2018年7月21日8时生成可见光通道产品的SEBlock模块中对应要素的权重

Tab. 5 Elements Weights of SEBlock module of the visible channel at 8:00 on July 21, 2018

要素	通道权重	层次	要素累计权重
云量	0.06/0.07/0.11/0.16/0.27/0.19/0.18/0.20/0.15/0.16/0.22/0.69		2.46
U 风场	0.16/0.08/0.04/0.03/0.14/0.09/0.15/0.18/0.12/0.10/0.05/0.45		1.59
V 风场	0.13/0.13/0.14/0.15/0.11/0.14/0.18/0.17/0.08/0.12/0.17/0.50		2.02
涡度	0.36/0.28/0.26/0.18/0.21/0.26/0.22/0.11/0.18/0.27/0.58/0.63	100/200/300/400/ 500/600/700/800/ 850/900/950/1000	3.54
温度	0.56/0.31/0.13/0.23/0.17/0.25/0.21/0.33/0.18/0.03/0.31/0.77		3.48
湿度	0.09/0.05/0.13/0.12/0.20/0.23/0.23/0.22/0.26/0.34/0.22/0.64		2.73
地表温度	0.96	单层	0.96
云液水含量	0.99	单层	0.99
云冰水含量	1.00	单层	1.00

由于实际云图的可见光通道仅白天有数据, 而北京时间 2018 年 7 月 21 日 19 时处于昼夜相交时分, 实际可见光云图产品东南部分已经无数据, 其后数小时实际云图可见光产品已完全无数据, 而仿真云图产品仍能模拟出上述时刻整个区域的仿真可见光云图产品, 这对于预报员连续掌握天气状况有一定帮助。夜间可

见光云图仿真效果如图 5 所示, 图 5(a)~(d)为 19 时~22 时(北京时间)本文所提算法生成的仿真可见光云图产品, 图 5(e)~(f)为 19 时~22 时(北京时间)对应的实际可见光云图产品, 由于实际产品的可见光通道在这些时次已经不可用, 因而不计算相关误差, 仅进行直观的视觉对比。




图 5 2018 年 7 月 21 日 19 时~22 时(北京时间)可见光仿真云图与实际云图产品的效果对比

Fig. 5 Comparison between the hourly synthetic satellite visible channel data and the ground truth at 19:00-22:00 (Beijing time) on July 21, 2018

3 结论

人工智能技术, 特别是深度学习技术是当前研究的热点领域, 在很多研究点上已经取得了相对于传统方法的突破性进展。本文通过引入深度生成对抗网络方法探索了一种从气象数值模式产品生成仿真卫星云图产品的新途径, 提出了仿真云图生成对抗网络模型和相应的损失函数。本文所提基于深度学习的方法可以通过训练提取历史数值模式产品数据和卫星云图产品数据的相关性, 从而有效地从数值模式产品生成仿真云图产品, 实验表明该方法在统计指标及直观视觉效果上均有较好的表现。

在此研究的基础上, 未来的研究工作包括:

(1) 产品分级模型。本文的工作中所有数值模式产品要素均采用统一的输入方式, 后续将尝试区分模式产品要素类型进行合适的数据前处理和特征工程;

(2) 区域分割模型。本文工作中将模式产品和云图产品作为整体输入模型, 后续工作中将尝试将根据不同云量或云状对各个区域进行区别处理;

(3) 卫星同化应用。未来工作中将尝试使用本文所提方法替换卫星资料同化过程中的辐射传输模式。

(4) 保障及业务应用。未来将探索研制基于本文工作的业务系统平台,用于实际气象业务保障工作。

参考文献:

- [1] 盛裴轩, 毛节泰, 李建国, 等. 大气物理学[M]. 北京: 北京大学出版社, 2009: 290-307.
Sheng Peixuan, Mao Jietai, Li Jianguo, et al. Atmospheric Physics[M]. Beijing: Peking University Press, 2009: 290-307.
- [2] 杨军, 陈宝君, 银燕. 云降水物理学[M]. 北京: 气象出版社, 2011: 1-15.
Yang Jun, Chen Baojun, Yin Yan. Physics of Clouds and Precipitation[M]. Beijing: China Meteorological Press, 2011: 1-15.
- [3] Hocking J, Rayer P, Rundle D, et al. RTTOV v11 Users Guide[R]. Exeter, Devon, UK: NWP-SAF report, Met Office, 2013.
- [4] Han Y, Delst P V, Liu Q, et al. User's Guide to the JCSDA Community Radiative Transfer Model(Beta Version)[R]. Camp Springs, Maryland, USA: Joint Center for Satellite Data Assimilation, 2005.
- [5] 丁伟钰, 万齐林. “珍珠”台风卫星红外通道亮温的数值模拟[J]. 大气科学, 2008, 32(3): 572-580.
Ding Weiyu, Wan Qilin. The Simulation of Typhoon Chanchu Infrared Channels Brightness Temperature[J]. Chinese Journal of Atmospheric Sciences, 2008, 32(3): 572-580.
- [6] 马刚, 邱崇践, 黎光清, 等. 利用 RTTOV7 快速辐射传输模式模拟风云二号红外和水汽成像通道辐射率的研究[J]. 红外与毫米波学报, 2006, 25(1): 37-40.
Ma Gang, Qiu Chongjian, Li Guangqing, et al. Study of Simulation on Radiance from Infrared and Water Vapor Channel of FY2B by a Fast Forward Model-RTTOV7[J]. Journal of Infrared and Millimeter Waves, 2006, 25(1): 37-40.
- [7] Chevallier F, Kelly G. Model Clouds as Seen from Space: Comparison with Geostationary Imagery in the 11- μ m Window Channel[J]. Mon Weather Rev (S0027-0644), 2002, 130(3): 712-722.
- [8] 张兴海, 端义宏. FY-2F 红外亮温资料模拟与偏差分析[J]. 气象, 2014, 40(9): 1066-1075.
Zhang Xinghai, Duan Yihong. Simulation of Brightness Temperature in Infrared Channel of FY-2F and Bias Analysis[J]. Meteorological Monthly, 2014, 40(9): 1066-1075.
- [9] 史小康, 李耀东, 刘健文, 等. FY-2D 红外亮温模拟及对 WRF 模式云预报误差的响应[J]. 中国科学: 地球科学, 2018, 48(8): 1096-1109.
Shi Xiaokang, Li Yaodong, Liu Jianwen, et al. Simulation of FY-2D Infrared Brightness Temperature and Sensitivity Analysis to the Errors of WRF Simulated Cloud Variables[J]. Science China Earth Sciences, 2018, 48(8): 957-972.
- [10] Lecun Y, Bengio Y, Hinton G. Deep Learning[J]. Nature (S0028-0836), 2015, 521(7553): 436-444.
- [11] Pathak D, Krahenbuhl P, Donahue J, et al. Context Encoders: Feature Learning by Inpainting[C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 2536-2544.
- [12] Zhang R, Isola P, Efros A A. Colorful Image Colorization [C]// European Conference on Computer Vision (ECCV). Berlin, German: Springer, 2016: 649-666.
- [13] Mathieu M, Couprie C, Lecun Y. Deep Multi-scale Video Prediction beyond Mean Square Error[C]// International Conference on Learning Representations (ICLR). Caribe Hilton, San Juan, Puerto Rico: arXiv, 2016: 1-14.
- [14] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative Adversarial Nets [C]// Advances in Neural Information Processing Systems (NIPS). Cambridge, MA, USA: MIT Press, 2014: 2672-2680.
- [15] Hu J, Shen L, Albanie S, et al. Squeeze-and-Excitation Networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S0162-8828), 2017, 42(8): 2011-2023.
- [16] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation [C]// International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI). Berlin, German: Springer, 2015: 2-3.
- [17] Isola P, Zhu J Y, Zhou T, et al. Image-to-image Translation with Conditional Adversarial Networks [C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 5967-5976.
- [18] Kingma D, Ba J. Adam: A Method for Stochastic Optimization[C]// International Conference on Learning Representations (ICLR). San Diego, CA, USA: arXiv, 2015: 1-13.
- [19] Shi W, Caballero J, Huszar F, et al. Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network[C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 1874-1883.