

激光与光电子学进展

利用生成对抗网络从地球静止卫星图像中反演
大气运动矢量李孝涌^{1,2}, 陈科艺^{1*}¹成都信息工程大学大气科学学院, 四川 成都 610225;²台州市气象局网络与装备保障中心, 浙江 台州 318000

摘要 深度学习技术中的生成对抗网络(GAN)方法由于能够从输入的大量数据中抽取变量特征,生成更为真实的气象图像预测,在遥感领域有较为广泛的应用。但目前该算法在大气运动矢量(AMVs)的反演中应用较少,而AMVs是数值天气预报资料同化系统所需的重要产品资料。基于此,本文提出了利用生成对抗网络pix2pix从静止气象卫星图像反演AMVs的方法,由pix2pix模型将遥感影像转换为200 hPa和850 hPa的矢量风场。在最佳的资料和模型架构条件下,该方法反演得到的AMVs与传统算法所得产品资料质量相当,且克服了传统算法高度订正困难、无法获得某一层面完整风场和低层样本数偏低等缺点。个例分析亦表明,该方法针对具体的天气系统也有良好的表现。

关键词 大气光学; 气象学; 大气运动矢量; 深度学习; 生成对抗网络

中图分类号 P412.27

文献标志码 A

DOI: 10.3788/LOP221036

Retrieving Atmospheric Motion Vectors from Geostationary Satellite
Images Using Generative Adversarial NetworksLi Xiaoyong^{1,2}, Chen Keyi^{1*}¹*School of Atmospheric Sciences, Chengdu University of Information Technology,
Chengdu 610225, Sichuan, China;*²*Network and Equipment Support Center, Taizhou Meteorological Bureau, Taizhou 318000, Zhejiang, China*

Abstract Generative adversarial network (GAN), a deep learning technique, is widely applied in the field of remote sensing because of its ability to extract features from large input data and generate more realistic forecasts of meteorological images. At present, however, the application of GANs in atmospheric motion vector (AMV) retrieval is rare, although AMVs are important data source for numerical weather prediction (NWP), especially in data assimilation. Based on this, a method for retrieving AMVs from geostationary satellite images using pix2pix, a type of GAN, is proposed. The pix2pix model is used to convert remote sensing images into wind vector fields at 850 hPa and 200 hPa. With the best data and model architecture, the AMVs obtained by this method are comparable to the AMVs retrieved using traditional algorithms. This method avoids the drawbacks of traditional algorithms, such as the inability to obtain complete wind fields at a certain level, difficulty of height assignment, and sparse AMVs at lower atmospheric levels. Case analysis shows that this method also performs well for specific weather systems.

Key words atmospheric optics; meteorology; atmospheric motion vectors; deep learning; generative adversarial networks

1 引言

大气运动矢量(AMVs),也被称为云导风,是通过追踪静止卫星图像中云或水汽的连续运动而得出的大气的风矢量^[1-2]。Tetsuya Fujita^[3]在20世纪60~70年

代提出了从静止卫星图像中获取AMVs的技术,AMVs在被提出后不久就被应用到业务中。AMVs提供了不同位置高度上包括风速和风向在内的大气运动的信息,在常规观测(如自动站、探空)资料稀缺的区域(如海洋、高纬地区),AMVs是数值天气预报(NWP)

收稿日期: 2022-03-17; 修回日期: 2022-03-28; 录用日期: 2022-06-13; 网络首发日期: 2022-06-23

基金项目: 国家自然科学基金面上项目(41875039)

通信作者: *ckydlt@aliyun.com

重要的数据来源。前人研究指出,即使在全球气象观测网日臻完善的今天,AMVs 仍可带给 NWP 相当的正面影响^[4]。

AMVs 可通过匹配相关法(也称交叉相关法或互相关法)获得,这种方法的思路是先从某时刻的卫星图像上选取合适的目标追踪云,再在相邻时刻的图像上匹配寻找相似的目标,从而确定目标的位移,最后通过时间和位移计算即可得到 AMVs。得到 AMVs 之后,还需对其进行高度订正和质量控制。高度订正即确定 AMVs 所处的高度;质量控制则负责剔除得到的 AMVs 中结果不可靠的一部分,从而提升数据质量。

尽管 AMVs 对 NWP 的准确率有积极的作用,但是由于算法本身的特性,AMVs 同样存在相应问题^[5-6]。例如直接用匹配相关法在整幅卫星图像上计算 AMVs,计算开销将十分巨大。因此,在实际业务中还需引入其他策略如逐步搜索、快速傅里叶变换或利用数值预报风场缩小搜索范围等。另外,目前对 AMVs 的高度订正存在困难,这在急流区等垂直风切变大的区域会带来严重的问题。由于在急流处风速的垂直变化巨大,因此高度的误差会带来巨大的风速误差。同时,即使准确地获得了 AMVs 的高度,但依然无法得到某一高度层的完整风场,这是因为获得的 AMVs 分布在不同高度,这同样给使用数据时带来不便。最后,AMVs 的垂直分布不均匀,观测样本数在中高层最多^[7],而低层存在样本数偏低甚至不可用的问题^[8]。

近些年,随着计算机硬件和算法水平的提升,深度学习技术在遥感领域也得到了越来越多的关注。农元君等^[9]使用神经网络目标检测算法,在嵌入式设备上实现了对遥感图像目标的实时检测。李潇凡等^[10]基于 U-net 从卫星资料中提取海洋藻类的分布信息,结果表明基于深度学习的方法比常用的数值阈值法更为适用。刘金香等^[11]基于卷积神经网络,在高光谱遥感图像分类问题上取得了较好的分类精度和计算速度。但目前深度学习在静止卫星图像风场反演方面的应用较少,仍有待进一步研究。He^[12]利用深度神经网络(DNN)从天气研究和预报模式输出的连续水汽场资料获得风场,和传统方法相比,DNN 有更好的表现,例如有更小的均方根误差和没有出现缺失的数据点。He 的研究显示了利用神经网络算法来获得 AMVs 的可能性。由于神经网络算法的多样性,本文将利用生成对抗网络(GAN)探讨反演 AMVs 的可行性,为丰富 AMVs 的反演算法提供更多的参考。

2 研究资料介绍

2.1 卫星数据

卫星数据由日本高知大学的气象信息页面(<http://weather.is.kochi-u.ac.jp/>)提供下载^[13],包括 GMS、GOES-9、MTSAT 系列地球静止卫星提供的遥

感数据及影像,网站已预先对资料进行了插值和投影等处理。本文使用的卫星图像的覆盖范围为 70°N~70°S、70°E~150°W,图像大小为 560 pixel×560 pixel,空间分辨率为 0.25°×0.25°,时间范围为 2000 年~2019 年,时间分辨率为 1 h,时次分别为 00z(世界时,下同)、06z、12z、18z。本文选用的卫星观测通道包括长波红外通道(波长 10.3~11.3 μm)、水汽通道(6.5~7.0 μm)和可见光通道(0.55~0.90 μm)。

由于权重函数反映了通道对不同高度的敏感性,权重函数在某高度的值越大,说明该高度大气的辐射贡献越大^[14],因此本文利用威斯康星大学麦迪逊分校气象卫星研究合作研究所(University of Wisconsin-Madison Cooperative Institute for Meteorological Satellite Studies, UW/CIMSS)提供的计算工具(<http://cimss.ssec.wisc.edu/goes/wf/examples/AHI/>),分别计算了在标准大气、天顶角为 45°的条件下,长波红外通道和水汽通道的权重函数,如图 1 所示。由图 1 可见,水汽通道权重函数的峰值出现在对流层高层,而长波红外通道出现在低层。因此,水汽通道更多地表征了对流层中高层的水汽信息,而长波红外通道则可以反映中低层的信息,这两个通道分别与本文选择反演的风矢量的层面(高层 200 hPa 和低层 850 hPa)对应。

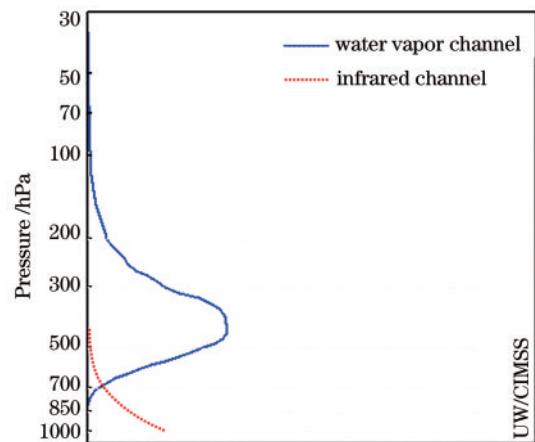


图 1 GOES 卫星水汽通道和红外通道的权重函数,引自 <http://cimss.ssec.wisc.edu>

Fig. 1 Weighting functions of water vapor channel and infrared channel of GOES satellite, quoted from <http://cimss.ssec.wisc.edu>

另外,许多深度学习架构常采用 2 的整数次幂作为使用数据的尺寸,这是因为算法常涉及到将数据尺寸减半或翻倍的操作,如此处理可方便计算^[15]。因此,这里使用双线性插值算法^[16]将卫星图像插值到 512 pixel×512 pixel 的新格点上,插值后的分辨率为 0.27°×0.27°。

2.2 再分析资料

再分析资料利用物理定律将数值模式数据和观测

资料结合,从而得到对过往大气状态的一个最优估计,在一定程度上可以认为再分析资料十分接近大气的真实状态。本文使用的风矢量数据来自再分析资料,包括 NCEP/NCAR 和 ERA5 两种再分析资料。其中, NCEP/NCAR 再分析资料的空间分辨率为 $2.5^\circ \times 2.5^\circ$, 时间分辨率为 6 h ^[17]; ERA5 再分析资料的空间分辨率为 $0.25^\circ \times 0.25^\circ$, 时间分辨率为 1 h ^[18]。相应地, 两种再分析资料选取的时次均与上文卫星资料的时次一致, 均为每日 00z、06z、12z、18z。

与卫星图像的覆盖范围一致, 截取的资料范围也为 $70^\circ\text{N} \sim 70^\circ\text{S}$ 、 $70^\circ\text{E} \sim 150^\circ\text{W}$ 。由于水汽通道和红外通道可反映对流层中高层和中低层的信息, 与之相应, 在选择再分析资料时, 选择的是 200 hPa(高层)和 850 hPa(低层)的经向风和纬向风。

同样把再分析资料用双线性插值算法插值到的新格点上, 经过插值后的 ERA5 再分析资料的格点大小为 $512\text{ pixel} \times 512\text{ pixel}$, 空间分辨率为 $0.27^\circ \times 0.27^\circ$; 经过插值后的 NCEP/NCAR 再分析资料的格点大小为 $64\text{ pixel} \times 64\text{ pixel}$, 空间分辨率为 $2.17^\circ \times 2.17^\circ$ 。不同分辨率的两种再分析资料, 用于研究模型输出分辨率高低对反演效果的影响。

2.3 数据集的分类

上述两种资料的时间范围选取为 2000 年~2019 年, 共 20 a。排除因格式错误无法读取的文件以及缺失的时次之后, 总共可用的时次数量为 28252 个。上述数据按照 8:1:1 的比例分别划分为训练集(2000 年~2015 年, 共 22455 个时次, 占 79.6%)、验证集(2016 年~2017 年, 共 2920 个时次, 占 10.3%)和测试集(2018 年~2019 年, 共 2877 个时次, 占 10.1%)。其中, 训练集专门用于训练神经网络; 验证集则用于在训练过程中实时检验训练效果, 以此判断是否需终止训练, 同时也作为调整优化模型超参数的依据; 测试集作为独立的数据, 用于避免在评估模型效果时使用训练时的数据, 可以真实地评价及检验模型在之前未使用的数据上的效果。本文实验效果的分析均在测试集上进行。

3 算法与硬件

3.1 GAN

一般的神经网络求解问题时, 在面临可能存在多个解的情况下, 神经网络为了使误差最小化, 倾向于输出多种可能性的一个平均。但在有的情况下, 平均值并不是想要的结果, 因为它会忽略许多细节。在这种情况下, GAN 有助于获得更加真实的一个解, 而不是平均值。例如, Leinonen 等^[19]利用条件 GAN 从成像光谱仪的测量数据中, 推断出合理的云的二维垂直结构, 这展现了用 GAN 用于研究大气遥感问题的可行性。

GAN 由 Goodfellow 等^[20]在 2014 年提出。GAN 由生成器和判别器组成。其中, 生成器负责接受输入,

并将输入转化为结果输出; 判别器负责判断生成器输出的结果是否合理。在训练 GAN 时, 轮流训练生成器和判别器, 直到两者达到平衡, 即最终生成器无法生成更合理的数据, 而判别器也无法判断生成器生成的数据是否合理。由于 GAN 能够生成更加清晰真实的图像, 它被应用在短临预报^[21-23]、统计降尺度等气象领域中^[24]。

本文所使用的 GAN 的架构为 2017 年提出的 pix2pix^[25]。pix2pix 与传统 GAN 的区别在于它的生成器为由卷积神经网络构成的 U-net。U-net 具有自上而下的收缩路径和自下而上的扩张路径(图 2), 与字母 U 形状相似, 因此而得名。U-net 最开始提出时是用作生物学图像分割^[26], 但它也可推广到用于一般性的图像到图像的像素级回归问题。Han 等^[27]基于 U-net 结构设计了一个用于 NWP 偏差订正的神经网络, 将 NWP 偏差订正视为图像到图像的翻译问题, 取得了优于传统订正方法的效果。针对本文研究的内容, 要解决的便是从连续多帧多通道卫星图像到风场的回归问题。这里, 神经网络的输入为临近 3 个时刻($t-\Delta t$ 、 t 、 $t+\Delta t$)的多通道卫星图像; 输出为中间时刻(t)的 850 hPa 和 200 hPa 的经向风和纬向风(同时输出), 共 4 个通道。

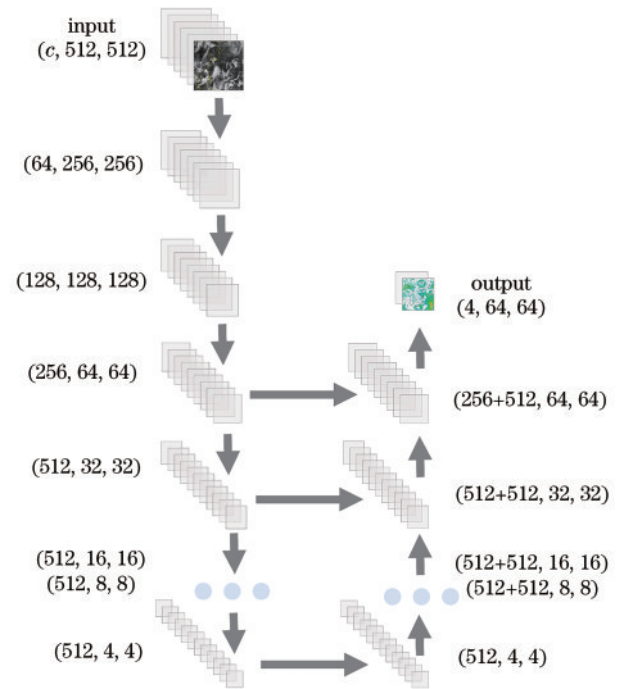


图 2 pix2pix 的生成器使用的 U-net 结构。括号中为数据的尺寸, 依次为通道数、宽度、高度

Fig. 2 U-net architecture used by generator of pix2pix. Dimensions of data are shown as (channels, width, height)

图 2 展示了本文使用的 U-net 的结构。括号中标注了数据的尺寸, 依次为: 通道数、宽度和高度。输入到 U-net 的卫星图像经过多次卷积运算, 分辨率不断

降低,而后又经多次反卷积运算,分辨率重新提高,最终组合成为所需的场数据。U-net的一个特点是它采用了跳层结构(skip connections,图2中横向箭头所示),这样可以使神经网络充分利用不同分辨率下图像的特征。对卫星图像而言,就是充分了利用不同尺度(小尺度、中尺度到天气尺度)下的云系特征。

图2中,输入数据的通道数 c 随实验条件(见4.1节)而变化,当仅使用红外和水汽通道时, c 取6;当使用红外、水汽和可见光通道时, c 取9。

当使用NCEP/NCAR再分析资料时,输出风场的格点大小为 $64 \text{ pixel} \times 64 \text{ pixel}$,这与图2所示一致。当使用ERA5再分析资料时,风场的格点大小为 $512 \text{ pixel} \times 512 \text{ pixel}$,需继续延长图2中U-net的向上扩张路径,直到输出数据的格点大小同样为 $512 \text{ pixel} \times 512 \text{ pixel}$ 。

关于激活函数,在U-net的向下路径中每层卷积层后接 α 参数取0.2的LeakyReLU函数;在向上路径中,除最后一层外使用的都是ReLU函数;最后一层为保证输出范围有限,使用的激活函数是Sigmoid函数。

U-net使用的优化方法为Adam,其学习率为0.0002, β_1 参数为0.5。

另外,在U-net的每个卷积层后都添加了批归一化(batch normalization)层,在U-net向上路径中则使用了失活率为0.5的随机失活(dropout)层。

鉴别器为卷积神经网络,其结构、参数和优化器等与U-net的向下路径部分完全一致。

3.2 软硬件依赖

神经网络使用是基于Tensorflow后端的Python

深度学习库Keras搭建的,Keras包含了模块化的神经网络层、损失函数和优化器等,易于构建神经网络。神经网络在单张NVIDIA Quadro P4000显卡上训练,在使用计算统一设备体系结构加速的情况下,根据输出分辨率的不同,完成一次完整训练所需时间为3~7 d。

4 神经网络风场反演实验

4.1 不同资料和神经网络架构对反演效果的影响

为了比较输入的连续卫星图像的间隔、卫星图像的通道(红外、水汽和可见光)和神经网络架构(U-net和pix2pix)对结果的影响。本文做了一系列对比实验,这些实验采用插值后的低分辨率的NCEP/NCAR风场数据训练模型,并训练迭代了较少的次数(15500次)。

一般情况下,在模型训练时损失函数曲线会先快速下降,之后下降缓慢趋于收敛。在迭代15500次之后,观察损失曲线图可见此时各个模型的损失曲线都已进入缓慢下降的阶段,而且趋向于收敛到不同的值。因而此时各个模型的表现也大致反映了不同方法的最终效果。以卫星图像间隔1 h、不使用可见光通道、采用pix2pix模型、输出高分辨风场的实验结果为例,从误差曲线看出模型在训练的早期已经收敛[图3(a)],继续训练提升的效果十分细微,在迭代50万次的补充实验中[图3(b)]甚至出现了训练不稳定、效果反而下降的现象。因此迭代15500次之后的效果具有代表性,能较好地反映不同条件下模型的最终效果。

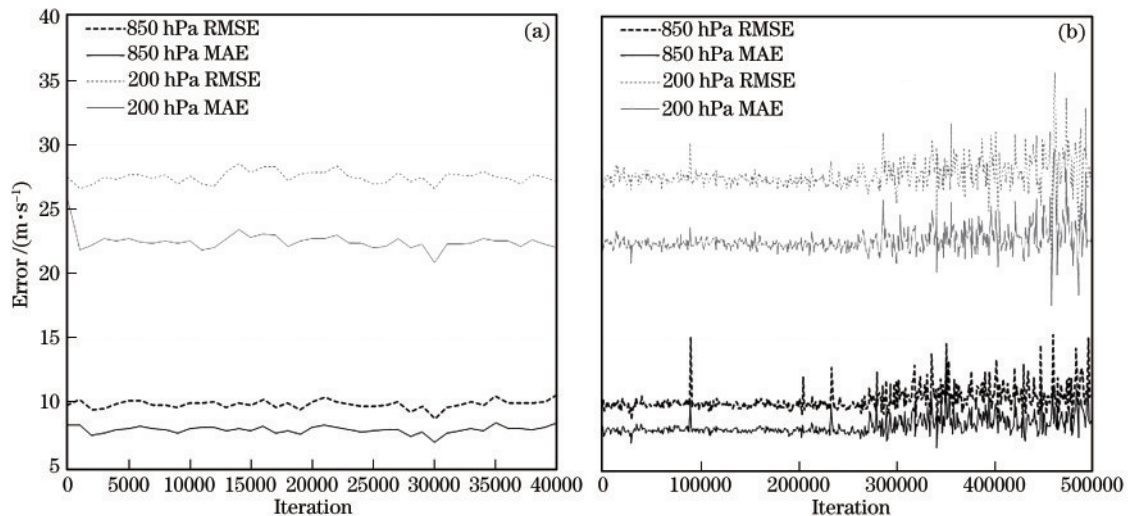


图3 采用1 h卫星图像间隔、pix2pix架构、高分辨率数据,及不使用可见光通道的实验测试误差。(a) 40000次迭代; (b) 500000次迭代

Fig. 3 Test error for experiments using 1 h satellite image intervals, pix2pix architecture, high resolution data, and without visible channels. (a) 40000 iterations; (b) 500000 iterations

将200 hPa和850 hPa两个层面风速的均方根误差(RMSE)、平均绝对误差(MAE)和相关系数

(Corr.)作为评价标准,比较利用神经网络从卫星图像中获得的场和再分析资料中的场场的差异。这些指

标的计算方法可参考式(1)~(5)。式(1)为矢量差(V_D);式(2)为偏差(B_{IAS});式(3)为平均矢量差(M_{VD});式(4)为标准矢量差(S_D);式(5)为均方根矢量差(R_{MSVD})。其中, u_i 和 v_i 为算法得出的大气运动矢量, u_r 和 v_r 为再分析资料中的风矢量。

$$V_D = \sqrt{(u_i - u_r)^2 + (v_i - v_r)^2}, \quad (1)$$

$$B_{IAS} = \frac{1}{n} \sum_{i=1}^n [(u_i - u_r)^2 + (v_i - v_r)^2], \quad (2)$$

$$M_{VD} = \frac{1}{n} \sum_{i=1}^n V_{Di}, \quad (3)$$

$$S_D = \sqrt{\frac{1}{n} \sum_{i=1}^n (V_{Di} - M_{VD})^2}, \quad (4)$$

$$R_{MSVD} = \sqrt{S_D^2 + M_{VD}^2}. \quad (5)$$

表 1 不同的输入卫星图像间隔、通道和神经网络架构的风场反演结果

Table 1 Results of wind field retrieve with different input satellite image intervals, channels, and neural network types

| Image interval | Visible channel | Network type | 850 hPa RMSE | 850 hPa MAE | 850 hPa Corr. | 200 hPa RMSE | 200 hPa MAE | 200 hPa Corr. |
|----------------|-------------------------|--------------|-----------------|----------------|------------------|-----------------|----------------|------------------|
| 6 h | Without visible channel | pix2pix | 3.2811 | 2.5179 | 0.8391 | 6.0010 | 4.5630 | 0.9311 |
| 6 h | Without visible channel | U-net | 3.3376 | 2.5418 | 0.8315 | 5.9632 | 4.5557 | 0.9323 |
| 1 h | Without visible channel | pix2pix | 3.2087 | 2.4267 | 0.8380 | 5.8723 | 4.4369 | 0.9343 |
| 1 h | With visible channel | pix2pix | 3.2933 | 2.5044 | 0.8311 | 6.1142 | 4.6513 | 0.9272 |

除了低分辨率NCEP/NCAR再分析资料之外,本文还同时使用经插值的高分辨率ERA5再分析资料训练了另一个神经网络,不过与低分辨率资料相比,误差明显增大(表2第1、2行)。为了排除分辨率对指标计

算的影响,将网络输出的数据插值到与NCEP/NCAR再分析资料相同的低分辨率格点上后再次进行比较,但结果(表2第3行)没有大的变化。

如表1所示,当使用卫星图像的间隔为1h、不加入可见光通道、神经网络架构采用pix2pix这一组合时,模型的总体表现最佳。此处简要探讨采用此组合时有最佳效果的可能原因。对于输入图像间隔 Δt ,传统的云导风算法要求示踪云的生命史必须大于 Δt ,否则便无法成功追踪云的移动^[28]。因此一般要求 Δt 足够小,一般取30min或更短。如果本文使用比1h更高时间分辨率的数据,可能还将得到更好的效果。对于可见光通道,有文献显示传统算法中经过质量控制后,可利用的可见光通道AMVs数量极少^[29]。说明在风场反演过程中,可见光通道提供的信息十分有限,这可能是加入该通道后效果没有改善的原因。对于模型架构的选择,前文在GAN一节中已做讨论,即GAN能避免一般神经网络存在的偏好输出平均值这一问题。

表 2 不同分辨率的数据风场反演结果

Table 2 Results of wind field retrieve with different resolutions of data

| Data (resolution) | 850 hPa RMSE | 850 hPa MAE | 850 hPa Corr. | 200 hPa RMSE | 200 hPa MAE | 200 hPa Corr. |
|------------------------------|-----------------|----------------|------------------|-----------------|----------------|------------------|
| NCEP/NCAR reanalysis (64×64) | 3.2087 | 2.4267 | 0.8380 | 5.8723 | 4.4369 | 0.9343 |
| ERA5 (512×512) | 10.7033 | 8.5650 | 0.4416 | 27.1458 | 22.0882 | 0.7435 |
| ERA5 (64×64) | 10.6600 | 8.5344 | 0.4426 | 27.1926 | 22.1428 | 0.7433 |

由此可见,相较于低分辨率数据,神经网络对于高分辨率数据的表现不佳,研究认为这是由于高分辨率数据包含了更多的信息,神经网络要学会完成从卫星图像到风场的转换也更加困难。高分辨率数据包含了各种低分辨率数据没有的中小尺度信息,比如局部的大气运动或中小尺度天气系统,这些信息在低分辨率数据中由于被平均化而消失,神经网络无需去描述各种细微的结构,因而任务也更加容易完成。

4.2 不同资料和神经网络架构对反演效果的影响

通过以上实验,确定了反演效果最佳的资料和神经网络架构。在此基础上,为了进一步提高效果,增加

了训练迭代的次数,共迭代了50万次,尽管在约20万次迭代之后效果就不再有大的提高。训练完成后,将神经网络的输出结果和传统AMVs算法的结果进行比较。

为了考察神经网络算法和传统AMVs算法的差异,把神经网络的结果和葵花8号卫星AMV产品(以下称H8 AMV)的结果^[30]做了比较,如表3所示,在平均矢量差(MVD)、均方根矢量差(RMSVD)的表现上,神经网络与H8 AMV较为接近。在偏差(Bias)的表现上,H8 AMV的高层偏差比神经网络小,而两者的低层偏差同样较为接近。

表 3 神经网络模型和 H8 AMV 产品的结果比较

| | AMV product | | |
|--------------------------|---|---|--|
| | MVD / ($\text{m}\cdot\text{s}^{-1}$) | RMSVD / ($\text{m}\cdot\text{s}^{-1}$) | Bias / ($\text{m}\cdot\text{s}^{-1}$) |
| H8 AMV (100~400 hPa) | 4.86 | 5.77 | -0.20 |
| Neural network (200 hPa) | 4.86 | 5.77 | -1.11 |
| H8 AMV (700~1100 hPa) | 3.14 | 3.86 | 0.68 |
| Neural network (850 hPa) | 3.20 | 3.81 | -0.42 |

值得注意的是,在计算表 3 中的指标时,本文所用算法和 H8 AMV 存在着一些差异,此处做简要说明:首先,计算指标时,本文是将再分析资料作为真值,将其与神经网络的输出结果进行比较。而 H8 AMV 是将探空仪的测量数据作为真值与反演产品相比较;其次,由于神经网络能够通过学习而建立卫星图像和指定高度层上风场的联系,因此得出的风场是单独确定完整的高低两层(200 hPa 和 850 hPa),且高低两层风矢量的数量相同;而 H8 AMV 产品的 AMVs 不均匀地分布在各个高度,其高层(100~400 hPa)和低层(700~1100 hPa)是一个高度范围,因而在进一步使用

AMVs 产品时需要高度订正。

由于存在着这些差异,所以比较的时候,指标有微小差别并不能说明两者孰优孰劣,只能认为两者在性能上是接近的。也就是说,此处所做的更多的是定性的比较,可以认为从指标上看,本文所用神经网络反演出的风场与传统算法相比,结果相当。

4.3 神经网络反演风场的误差分析

本文研究了神经网络模型在测试集上的效果,图 4 为神经网络反演的风速与 NCEP/NCAR 再分析资料中风速差异的分布。如果神经网络的结果与再分析资料完全一致,那么所有数据点将分布在对角线上;如果神经网络高估了风速,那么数据点将位于对角线上方;如果神经网络出现低估,那么数据点将位于对角线下方。从图 4 可以看到,数据点基本沿着对角线分布,且对角线两侧的数据点数量基本相同,表明没有出现明显的系统性偏差,这与表 3 中的结果一致,即神经网络没有明显的偏差。但也要注意,存在极少数的情况,神经网络给出的风速与再分析资料中的风速有较大的区别(图中边缘的数据点),这种大的误差在什么情况下会出现,以及如何能够减少或避免这种误差,值得进一步深入研究。

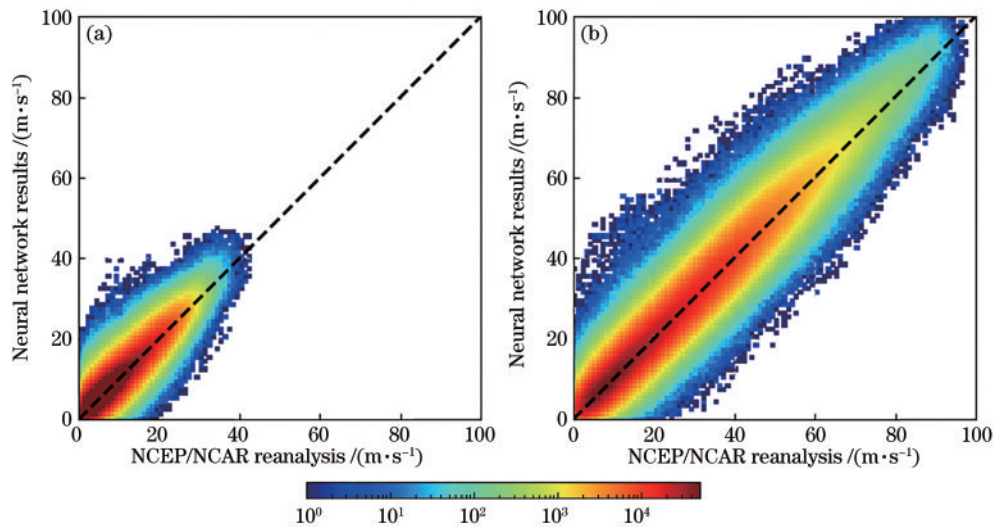


图 4 神经网络反演的风速与 NCEP/NCAR 再分析资料风速的比较。(a) 850 hPa; (b) 200 hPa

Fig. 4 Comparison of wind speed retrieved by neural network and wind speed of NCEP/NCAR reanalysis. (a) 850 hPa; (b) 200 hPa

图 5 展示了验证时间段内的 MVD 的空间分布情况,可以看出 MVD 较大的区域主要有两个:一个是图像边缘地区,另一个是高空的南北纬 30°附近。对于第一个误差大的区域,考虑到其出现的位置,误差可能是由以下原因导致的:首先,边缘区域离卫星下点较远,实际分辨率也低,卫星的仰角小,接收到的辐射与实际情况偏差大,存在失真的情况^[31]。其次,出现在边缘的云层有可能在前一时刻还未移入视野,这样就无法获得它的位移,给确定其速度带来困难。而高空的南北纬 30°附近的误差则可能是由高空急流引起的。

4.4 反演个例分析

选取了 2019 年 10 月 9 日 12:00 UTC [图 6(a)~6(d)] 和 2018 年 1 月 26 日 18:00 UTC [图 6(e)~6(h)] 作为两个个例,研究神经网络对于具体天气系统的反演情况。

4.4.1 热带系统的反演对比

如图 6(b) 所示,此时西北太平洋上存在一个热带气旋,850 hPa 高度其中心附近最大风速出现在其东侧,达到 55 m/s 以上,图 6(d) 可见该热带气旋在高空(200 hPa)存在反气旋式气流辐散。从神经网络算法的反演结果 [图 6(a)、6(c)] 来看,其能够较好地重现热带气旋低空的气旋式环流和高空的反气旋式辐散。同




图 5 神经网络反演风的 MVD 的空间分布。(a) 850 hPa; (b) 200 hPa

Fig. 5 Spatial distribution of MVD of wind retrieved by neural network. (a) 850 hPa; (b) 200 hPa

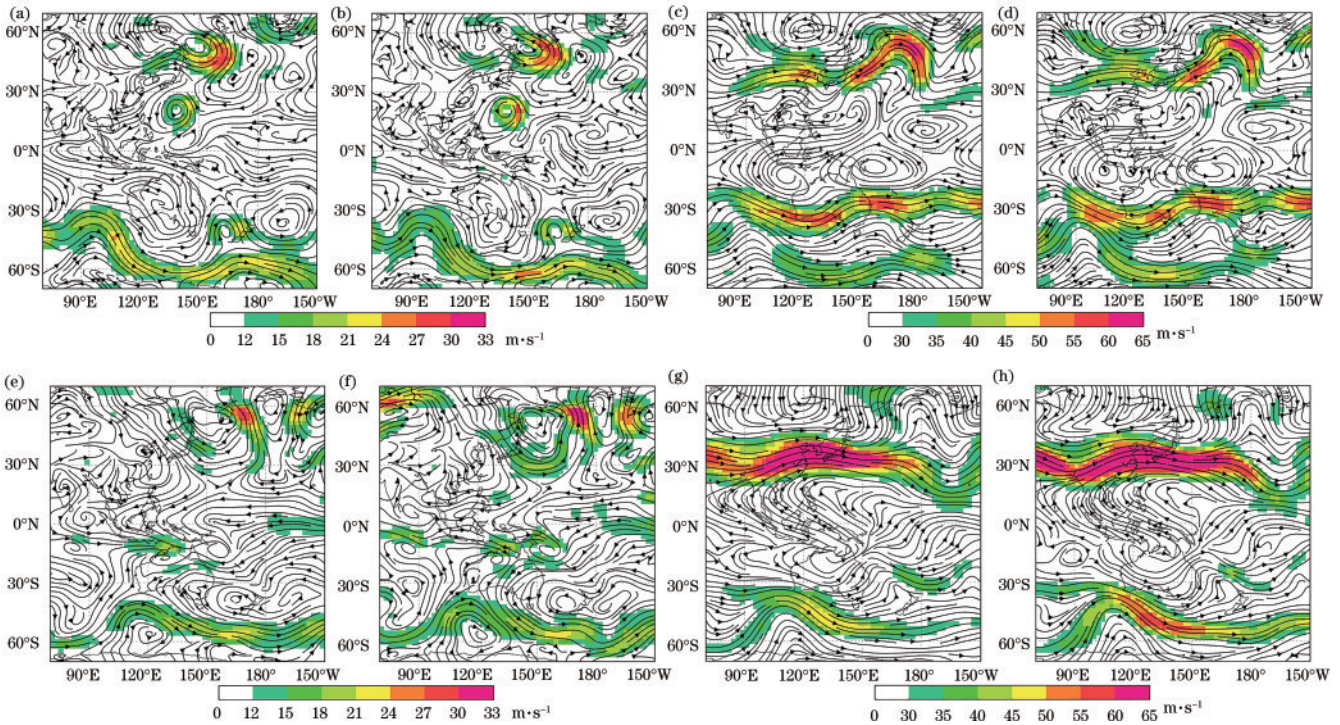


图 6 神经网络反演的风场与 NCEP/NCAR 再分析资料风场的比较。(a) 2019 年 10 月 9 日 12:00 UTC 神经网络反演的 850 hPa 风向(流线)和风速(深色);(b) 同(a),但为再分析资料;(c) 2019 年 10 月 9 日 12:00 UTC 神经网络反演的 200 hPa 风向(流线)和风速(深色);(d) 同(c),但为再分析资料;(e)~(h)同(a)~(d),但为 2018 年 1 月 26 日 18:00 UTC

Fig. 6 Comparison of wind field retrieved by neural network and wind field of NCEP/NCAR reanalysis. (a) 850 hPa wind direction (streamline) and speed (shaded) retrieved by neural network at October 9, 2019 12:00 UTC; (b) same as (a), but with NCEP/NCAR reanalysis data; (c) 200 hPa wind direction (streamline) and speed (shaded) retrieved by neural network at October 9, 2019 12:00 UTC; (d) same as (c), but with NCEP/NCAR reanalysis data; (e)~(h) same as (a)~(d), but at January 26, 2018 18:00 UTC

时,神经网络还能反演出该热带气旋的风速分布特征,即最大风速出现在中心东侧。

神经网络的不足之处在于对热带气旋的最大风速存在低估,反演的最大风速在 50 m/s 以下。本文所做的另外几个个例同样表明神经网络对较强热带气旋的

风速存在低估,这可能是训练数据不平衡导致的。数据不平衡是指数据集中各个样本的数目差异巨大,它会给神经网络的训练带来负面影响^[32]。西北太平洋热带气旋的强度分布特征同样存在数据不平衡的问题,据统计,达到超强台风强度的热带气旋占有所有热带气

旋的 17.8%^[33],虽然所占比例较大,但当仅考虑其风速真正处于超强台风等级的时间段时,这一比例会明显下降。因而,神经网络在估计出现较少的处于超强台风强度的热带气旋的风速时,会出现比较大的误差。

从图 6(f)可见,此时澳大利亚北部存在活跃的季风槽,季风槽中有东西两个明显的环流中心。同时在赤道附近 180°经线以东有较强的偏东信风。神经网络能够反演出季风槽和信风,但对于季风槽中的东环流中心的风速存在低估的情况。

4.4.2 温带气旋的反演对比

从图 6(b)可见,鄂霍茨克海和塔斯曼海上各存在一个温带气旋,神经网络的反演结果[图 6(a)]能够较好地重现这两个系统的气旋性环流,对二者的中心和强度也有较好的反映。但是对于鄂霍茨克海温带气旋最大风速区域的估计,神经网络依然存在偏差,再分析资料中最大风速区出现在东侧,而神经网络反演的最大风速区出现在东南侧,说明神经网络对温带气旋东部暖输送带的反演存在不确定性。

对于图 6(f)中鄂霍茨克海的温带气旋,神经网络反演低估了其南侧的偏西大风。

4.4.3 急流的反演对比

图 6(b)、6(d)时间为北半球夏季,由图可见,研究区域内存在若干条西风急流,包括:850 hPa 高度上 30°S 到 60°S 之间的急流、200 hPa 上位于北半球的西风急流、30°S 的副热带急流和 60°S 的极锋急流。图 6(f)、6(h)时间为北半球冬季,此时,最明显的急流位于东亚上空对流层高层。从反演结果[图 6(a)、6(c)]来看,神经网络同样能反演出高低空急流的位置以及急流轴的形态,比如南半球高空急流的汇合与分支。中纬度高层大气是准地转平衡的,急流弯曲的形状与槽脊的位置密切相关,说明神经网络能从卫星图像中推断出槽脊的分布情况。但对于急流轴的位置,神经网络的结果与再分析资料中的不完全一致,例如,在个例中估计的东亚急流的位置比实际略偏北[图 6(g)、6(h)],这种不一致是导致 4.3 节中误差出现的一个原因。

5 结 论

提出了一种通过 GAN 算法利用连续的静止卫星图像反演 AMVs 的方法。通过一系列实验,确定了效果最佳的资料 and 模型架构,即当卫星图像间隔为 1 h、使用红外和水汽通道以及 pix2pix 模型时,反演的 AMVs 误差最小。与 H8 卫星 AMVs 产品的对比分析表明,本文所用方法的误差与传统算法接近,反演 AMVs 误差较大的区域主要出现在图像边缘和高空的南北纬 30°附近。对典型个例的研究分析显示,该方法能较为准确地捕捉各种天气系统的环流特征,且可提供较低层次(如 850 hPa)上的完整环流信息。

本文方法弥补了传统 AMVs 算法存在的高度订

正困难、无法获得某一层面完整环流和低层样本数低等缺点,但也有需要进一步改进和完善的地方,比如无法准确输出高分辨率环流,并存在因训练数据不平衡而低估热带气旋风速,以及对急流轴位置反演误差而导致在高空急流处误差较大等问题。之后,将利用该算法反演的 AMVs 产品资料进行同化和预报实验,分析该方法所反演的 AMVs 数据对数值预报效果的同化及预报影响,为丰富 AMVs 反演算法和数值天气预报研究提供更为可靠的参考。

参 考 文 献

- [1] Lean P, Migliorini S, Kelly G. Understanding atmospheric motion vector vertical representativity using a simulation study and first-guess departure statistics[J]. *Journal of Applied Meteorology and Climatology*, 2015, 54(12): 2479-2500.
- [2] Hubert L F, Whitney L F, Jr. Wind estimation from geostationary-satellite pictures[J]. *Monthly Weather Review*, 1971, 99(9): 665-672.
- [3] Menzel W P. Cloud tracking with satellite imagery: from the pioneering work of Ted Fujita to the present[J]. *Bulletin of the American Meteorological Society*, 2001, 82(1): 33-48.
- [4] Bormann N, Thépaut J N. Impact of MODIS polar winds in ECMWF's 4DVAR data assimilation system[J]. *Monthly Weather Review*, 2004, 132(4): 929-940.
- [5] 许健民, 张其松. 卫星风推导和应用综述[J]. *应用气象学报*, 2006, 17(5): 574-582.
Xu J M, Zhang Q S. Status review on atmospheric motion vectors-derivation and application[J]. *Journal of Applied Meteorological Science*, 2006, 17(5): 574-582.
- [6] 李艳兵, 黄思训, 翟景秋. 卫星反演风场进展概述[J]. *气象科学*, 2009, 29(2): 2277-2284.
Li Y B, Huang S X, Zhai J Q. A review of satellite wind retrieval technologies[J]. *Scientia Meteorologica Sinica*, 2009, 29(2): 2277-2284.
- [7] 万晓敏, 龚建东, 韩威, 等. FY-4A 云导风在 GRAPES_RAFS 中的同化应用评估[J]. *气象*, 2019, 45(4): 458-468.
Wan X M, Gong J D, Han W, et al. The evaluation of FY-4A AMVs in GRAPES_RAFS[J]. *Meteorological Monthly*, 2019, 45(4): 458-468.
- [8] 万晓敏, 田伟红, 韩威, 等. FY-2E 云导风的算法改进及其在 GRAPES 中的同化应用研究[J]. *气象*, 2017, 43(1): 1-10.
Wan X M, Tian W H, Han W, et al. The evaluation of FY-2E reprocessed IR AMVs in GRAPES[J]. *Meteorological Monthly*, 2017, 43(1): 1-10.
- [9] 农元君, 王俊杰. 基于嵌入式的遥感目标实时检测方法[J]. *光学学报*, 2021, 41(10): 1028001.
Nong Y J, Wang J J. Real-time object detection in remote sensing images based on embedded system[J]. *Acta Optica Sinica*, 2021, 41(10): 1028001.
- [10] 李潇凡, 王胜强, 翁轩, 等. 基于 UNet 深度学习算法的东海大型漂浮藻类遥感监测[J]. *光学学报*, 2021, 41(2):

0201002.
Li X F, Wang S Q, Weng X, et al. Remote sensing of floating macroalgae blooms in the East China Sea based on UNet deep learning model[J]. *Acta Optica Sinica*, 2021, 41(2): 0201002.
- [11] 刘金香, 班伟, 陈宇, 等. 融合多维度 CNN 的高光谱遥感图像分类算法[J]. *中国激光*, 2021, 48(16): 1610003.
Liu J X, Ban W, Chen Y, et al. Multi-dimensional CNN fused algorithm for hyperspectral remote sensing image classification[J]. *Chinese Journal of Lasers*, 2021, 48(16): 1610003.
- [12] He F. Deep Neural Network (DNN) perspective on atmospheric motion vectors[EB/OL]. (2019-04-24) [2021-06-01]. https://www.star.nesdis.noaa.gov/star/documents/meetings/2019AI/Wednesday/S2_2-5_NOAAai2019_He.pdf.
- [13] Tokio K, Masaru K. Kochi university weather home: a satellite image distribution system utilizing the Internet [J]. *IEICE Technical Report*, 2000, 100(227): 79-83.
- [14] 马原, 邹晓蕾. 气象卫星微波湿度计资料简介[J]. *气象科技进展*, 2013, 3(6): 45-51.
Ma Y, Zou X L. Serial of applications of satellite observations an introduction to satellite-based microwave humidity sounding data[J]. *Advances in Meteorological Science and Technology*, 2013, 3(6): 45-51.
- [15] Rasp S, Düben P D, Scher S, et al. WeatherBench: a benchmark data set for data-driven weather forecasting [J]. *Journal of Advances in Modeling Earth Systems*, 2020, 12(11): e2020MS002203.
- [16] Kirkland E J. Bilinear interpolation[M]//Advanced computing in electron microscopy. Boston: Springer, 2010: 261-263.
- [17] Kalnay E. The NCEP/NCAR 40-year reanalysis project [J]. *Bulletin of the American Meteorological Society*, 1996, 77(3): 437-471.
- [18] Hersbach H, Bell B, Berrisford P, et al. The ERA5 global reanalysis[J]. *Quarterly Journal of the Royal Meteorological Society*, 2020, 146(730): 1999-2049.
- [19] Leinonen J, Guillaume A, Yuan T L. Reconstruction of cloud vertical structure with a generative adversarial network[J]. *Geophysical Research Letters*, 2019, 46(12): 7035-7044.
- [20] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [21] 陈元昭, 林良勋, 王蕊, 等. 基于生成对抗网络 GAN 的人工智能临近预报方法研究[J]. *大气科学学报*, 2019, 42(2): 311-320.
Chen Y Z, Lin L X, Wang R, et al. A study on the artificial intelligence nowcasting based on generative adversarial networks[J]. *Transactions of Atmospheric Sciences*, 2019, 42(2): 311-320.
- [22] Ravuri S, Lenc K, Willson M, et al. Skilful precipitation nowcasting using deep generative models of radar[J]. *Nature*, 2021, 597(7878): 672-677.
- [23] Liu H B, Lee I. MPL-GAN: toward realistic meteorological predictive learning using conditional GAN [J]. *IEEE Access*, 2020, 8: 93179-93186.
- [24] Leinonen J, Nerini D, Berne A. Stochastic super-resolution for downscaling time-evolving atmospheric fields with a generative adversarial network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(9): 7211-7223.
- [25] Isola P, Zhu J Y, Zhou T H, et al. Image-to-image translation with conditional adversarial networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5967-5976.
- [26] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.
- [27] Han L, Chen M X, Chen K K, et al. A deep learning method for bias correction of ECMWF 24-240 h forecasts[J]. *Advances in Atmospheric Sciences*, 2021, 38(9): 1444-1459.
- [28] 王振会, 杨艳蓉, 肖稳安, 等. TCFM 技术的卫星导风数据在台风模拟中的应用初探[J]. *遥感学报*, 2009, 13(3): 515-521.
Wang Z H, Yang Y R, Xiao W A, et al. Preliminary study on the application of satellite wind guidance data of TCFM technology in typhoon simulation[J]. *Journal of Remote Sensing*, 2009, 13(3): 515-521.
- [29] 薛志彬, 龚建东, 何财福, 等. 静止卫星云导风的质量控制及在同化中的应用[J]. *应用气象学报*, 2013, 24(3): 356-364.
Xue C B, Gong J D, He C F, et al. Quality control of cloud derived wind vectors from geostationary meteorological satellites with its application to data assimilation system[J]. *Journal of Applied Meteorological Science*, 2013, 24(3): 356-364.
- [30] Shimoji K. Introduction to the Himawari-8 atmospheric motion vector algorithm[EB/OL]. (2017-03) [2020-06-01], <http://www.data.jma.go.jp/mscweb/technotes/msctechrep62-4.pdf>.
- [31] 陈渭民. 卫星气象学[M]. 北京: 气象出版社, 2003.
Chen W M. *Satellite meteorology*[M]. Beijing: China Meteorological Press, 2003.
- [32] Mazurowski M A, Habas P A, Zurada J M, et al. Training neural network classifiers for medical decision making: the effects of imbalanced datasets on classification performance[J]. *Neural Networks*, 2008, 21(2/3): 427-436.
- [33] 赵珊珊, 高歌, 孙旭光, 等. 西北太平洋热带气旋频数和强度变化趋势初探[J]. *应用气象学报*, 2009, 20(5): 555-563.
Zhao S S, Gao G, Sun X G, et al. Climatological characteristics of tropical cyclones in the northwestern Pacific[J]. *Journal of Applied Meteorological Science*, 2009, 20(5): 555-563.