



中国科学院大学
University of Chinese Academy of Sciences

博士学位论文

静止气象卫星大气探测的反演与短临预报应用研究

作者姓名: 马 铮

指导教师: 孙建华 研究员 中国科学院大气物理研究所

李 俊 研究员 国家卫星气象中心

学位类别: 理学博士

学科专业: 气象学

培养单位: 中国科学院大气物理研究所

2022 年 6 月

Studies of the Retrieval and Nowcasting Applications of
Hyperspectral Infrared Sounders onboard the Geostationary
Meteorological Satellites

A dissertation submitted to
University of Chinese Academy of Sciences
in partial fulfillment of the requirement
for the degree of
Doctor of Philosophy
in Meteorology

By

Ma Zheng


Supervisor :
Professor Sun Jianhua
Professor Li Jun

Institute of Atmospheric Physics, Chinese Academy of Sciences

June 2022

中国科学院大学
研究生学位论文原创性声明

本人郑重声明：所提交的学位论文是本人在导师的指导下独立进行研究工作所取得的成果。尽我所知，除文中已经注明引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的研究成果。对论文所涉及的研究工作做出贡献的其他个人和集体，均已在文中以明确方式标明或致谢。


作者签名： 


日期： 2022 年 5 月 24 日

中国科学院大学
学位论文授权使用声明

本人完全了解并同意遵守中国科学院有关保存和使用学位论文的规定，即中国科学院有权保留送交学位论文的副本，允许该论文被查阅，可以按照学术研究公开原则和保护知识产权的原则公布该论文的全部或部分內容，可以采用影印、缩印或其他复制手段保存、汇编本学位论文。

涉密及延迟公开的学位论文在解密或延迟期后适用本声明。

作者签名： 

导师签名： 

日期： 2022 年 5 月 24 日 日期： 2022 年 5 月 24 日

摘要

气象卫星上的高光谱红外探测数据能够提供垂直方向上高分辨率的大气结构信息，对于灾害性天气监测和数值预报模式的同化应用具有重要作用。但是目前在轨运行的高光谱红外探测仪多数搭载于极轨气象卫星上，每日仅能获得两次全球观测数据，无法实现对局地大气变化特征的连续观测。与此同时，搭载于静止轨道卫星的高分辨率成像观测能够实现对同一区域大气的连续观测，但是由于光谱分辨率的限制，缺乏对大气垂直结构特征的观测信息。将两种观测模式所具优势的联合应用将有助于获得高精度的三维大气状态和演变信息，对于数值天气预报和强天气的短临预警具有重要意义。本研究围绕高光谱大气探测的定量反演和预报应用问题，首先利用国际领先的极轨卫星高光谱大气反演产品 NUCAPS (NOAA Unique Combined Atmospheric Processing System)，与静止卫星成像观测 ABI (Advanced Baseline Imager) 进行了数据融合，开发了能够改进低层大气反演精度的联合反演算法。并且利用国际上首个静止卫星高光谱成像仪 GIIRS (Geostationary Interferometric Infrared Sounder) 在台风“玛利亚”期间的加密观测数据，探索了其在大气热力学和动力学信息的定量反演算法中的应用，同时对 GIIRS 所特有的时间变化观测信息在反演中所起的作用进行了分析。最后利用 ERA5 (ECMWF Reanalysis version 5) 作为静止轨道高光谱大气探测的模拟数据，与基于静止卫星成像观测 ABI 的对流初生预警模型相结合，讨论了其在对流初生短临预报中的潜在效用。主要的研究内容和结论如下：

(1) 利用基于极轨卫星高光谱探测的 NUCAPS 反演产品与美国 CONUS (continental U.S.) 区域的 ABI 快速成像晴空观测，以及地面实时中尺度分析场 RTMA (Real-Time Mesoscale Analysis) 在 2018 年 4~6 月的资料进行了多源数据融合，以 ERA5 再分析数据的大气温湿廓线作为训练真值通过多隐层神经网络开发了一个能够在晴空及部分有云条件下改进卫星在低层大气温湿廓线反演精度的联合反演改进模型。独立检验发现，该模型对于 700 hPa 以下的各等压面上的温度和湿度反演均减小了超过 30 % 的误差标准差 (standard deviation of error, STDE)。其中在晴空条件下，700 hPa 至地面温度和相对湿度平均方差分别减少

了 68.1 %和 65.9 %，而在部分有云条件下则分别减小了 58.1 %和 65.5 %。对不同数据源的相对贡献分析表明，ABI 和 RTMA 都能对低层大气的反演精度产生改进效果，其中 ABI 观测能够在整个对流层区域对 NUCAPS 的反演精度进行改进，而 RTMA 只对低层大气的反演产生影响。研究通过 2017 年的数据检验和 2017 和 2018 年时空匹配的无线电探空数据对比验证了模型的泛化能力。该模型在两个探空观测个例和美国东部一次对流天气事件中的应用中体现出其相比 NUCAPS 数据更为准确地描述低层大气温湿结构的能力，及其在高影响天气预报中的应用前景。

(2) 利用国际上首个静止卫星高光谱红外探测仪 GIIRS 在台风“玛利亚”登陆期间的 15 分钟分辨率加密观测资料，选择能够代表不同层次大气温湿信息及其变化的长波和中波红外通道，以其观测亮温作为自变量，ERA5 的大气温湿廓线作为训练真值，通过神经网络训练了一个适应于加密观测区域和时段的晴空大气温湿廓线定量反演模型，并分析了 GIIRS 观测的时间变化信息对反演精度的影响。独立检验结果发现，温度反演结果在 100 至 1000 hPa 的总体 RMSE 为 0.639 K，平均偏差为 0.092 K；而相对湿度在 300 hPa 及以下层次的平均 RMSE 为 5.089 %，平均偏差为 0.004 %，但在 300 hPa 以上的对流层高层误差显著增大。利用独立分析数据 GDAS (Global Data Assimilation System) 对反演模型的检验结果表明，模型相对 GDAS 的反演误差大于其相对 ERA5 的误差，而分析表明误差主要来源于 GDAS 与 ERA5 之间的差异，说明了反演结果与训练真值的选择有关。与此同时，反演模型相对 GDAS 的反演误差仍在合理范围，表现出反演模型算法具备一定的稳定性。将 GIIRS 观测的时间变化信息加入训练的模型，相比于仅使用单一时刻观测的反演结果在温度和相对湿度的反演精度都有不同程度的提升。其中温度反演的改进比相对湿度更为显著，温度和湿度都在低层大气的改进幅度较大。

(3) 利用 GIIRS 在 2018 年 7 月台风“玛利亚”期间的 15 分钟分辨率区域加密观测资料，通过将观测信息的时间变化与空间分布信息相结合，用 ERA5 的 U、V 风场廓线作为训练真值通过神经网络训练建立了一个基于 GIIRS 高频观测的四维风场（不同气压层和不同时间的水平风场）反演模型。通过与 ERA5 的独立检验数据集、GDAS 分析场以及下投探空观测进行验证，发现高频次的静止轨

道高光谱探测数据可以在晴空和非高云厚云覆盖的视场条件下反演得到高时间分辨率的三维水平风场。其中，反演得到的风场 U 和 V 分量在对流层内各等压面上相对于 ERA5 的均方根误差小于 2 m/s，且能够表现出与 ERA5 相一致的时间变化特征。反演风场与 GFS (Global Forecast System) 数值预报的风场产品的对比说明了 GIIRS 风场反演结果对数值预报潜在的同化改进作用。敏感性试验的结果表明，相比于低时间分辨率，利用更高时间分辨率观测数据训练的风场反演模型能够获得更高的风场反演精度。通过与来自葵花 8 号卫星成像仪 AHI (Advanced Himawari Imager) 的大气运动矢量 AMV (Atmosphere Motion Vector) 产品进行对比分析，发现 GIIRS 反演的三维风场在数据密度和准确性上都部分体现出了其相对传统的 AMV 算法的优势。

(4) 在国家卫星气象中心开发的基于静止卫星成像观测与大气数值预报场相结合的对流初生短临预报模型 SWIPE (Storm Warning In Pre-convection Environment) 的基础上，通过在目标追踪与数据匹配过程中引入光流法和持续追踪对模型框架进行了优化，并利用 ABI 在美国 CONUS 区域的高频次观测结合 GFS 数值预报场以及 CMORPH (The Climate Prediction Center Morphing technique) 降水分析数据，通过随机森林算法开发了针对美国 CONUS 区域的 SWIPE V2 模型。并在此基础上，基于 ERA5 的大气动力学与热力学廓线资料模拟静止卫星高光谱探测资料并加入到模型中，分析了其在对流初生短临预报中的改进作用。研究表明，SWIPE V2 统计对于面积在 5000 km² 及以上的强对流目标具有较高的预测准确度，而对于面积在 1000 km² 以内的对流目标预测精度显著降低。将 ERA5 作为代用的静止卫星高光谱探测数据加入 SWIPE 模型之后，其对强对流样本的预报能力得到了提高。模型当中 ERA5 廓线的重要性评分超过 GFS 预报数据，展示了静止卫星高光谱探测数据在对流初生短临预报模型的潜力。相比于面积较大的对流样本，静止卫星高光谱探测对于面积在 1000 km² 以内的对流目标改进效果不够显著，这可能与作为代用资料的 ERA5 的时空分辨率不足有关。当具有更高时空分辨率的静止卫星高光谱大气探测仪投入使用之后，将通过与静止卫星高分成像观测的联合应用对于中小尺度对流初生预报产生更大的效益。

关键词：静止气象卫星，高光谱红外探测仪，反演，四维风场，短临预报

Abstract

Hyperspectral infrared radiance measurements from meteorological satellites provide information on atmospheric structures with high vertical resolution, which is helpful for the monitoring of potential hazardous severe weather events and data assimilation applications. However, the majority of on-orbit hyperspectral infrared sounders are based on polar-orbiting satellites which only measure the atmosphere twice a day without continuous observations on regional atmospheric variations. Meanwhile, advanced imagers onboard geostationary satellites with high temporal resolution can provide continuous observations of the atmosphere for specific regions, but information on the vertical structure of the atmosphere is lacking due to the limitation of spectral resolution. The fusion use of the benefits from both measurements would provide accurate information on three-dimensional state of the atmosphere as well as its temporal variations, which are crucial for numerical weather forecasts and nowcasting of high impact weather events. Focusing on the quantitative retrievals and forecasting applications using hyperspectral infrared sounding observations, this thesis first utilizes the state-of-art hyperspectral sounding products NUCAPS (NOAA Unique Combined Atmospheric Processing System) from polar-orbiting satellites, along with geostationary imager observations from ABI (Advanced Baseline Imager) to develop a profile retrieval enhancement algorithm through data fusion. The thesis then develops and presents the quantitative dynamic and thermodynamic retrieval models from the world's first hyperspectral infrared sounder onboard a geostationary meteorological satellite GIIRS (Geostationary Interferometric Infrared Sounder) using the regional intensified observations during Typhoon Maria with high temporal resolutions, with analysis of the impact of temporal variations of GIIRS observations on the retrieval accuracies. Finally, the potential impact of geostationary hyperspectral sounding observations on local storm nowcasting is evaluated in a nowcasting framework based on geostationary imager observations with profiles from ERA5 used as proxy. The major findings are summarized as follows:

- (1) Three continuous months of NUCAPS sounding products, along with clear sky

ABI radiance observations and Real-Time Mesoscale Analysis (RTMA) in the CONUS region from April to June 2018 are used to develop a profile retrieval enhancement algorithm, or a data fusion model. The model is capable of enhancing the accuracy of temperature and moisture profiles in the lower atmosphere through a deep neural network, using the aforementioned fused dataset as inputs, and collocated profiles from ERA5 as the benchmark for training. Independent validation results show that the model is able to reduce the standard deviation of error (STDE) of both temperature and moisture by more than 30 % on different pressure levels below 700 hPa. The improvement, in the mean variance reductions of lower levels from 700 hPa to surface, is 68.1 % for temperature and 65.9 % for relative humidity in clear skies, and 58.1 % for temperature and 65.5 % for relative humidity in partly cloudy conditions. Evaluations on relative impacts of different data sources show that both ABI and RTMA have substantial impacts on reducing the uncertainties in the lower levels, with ABI contributes to most levels from the lower to upper troposphere, while RTMA only provides contributions to the lower levels. The generalization performance of the model has been validated with independent dataset from 2017 and spatiotemporally collocated radiosonde observations (RAOBs) from 2017 and 2018. The applications on two RAOB cases and a convective event in eastern U.S. are presented to illustrate the ability of the model over NUCAPS on capturing the structures of the lower atmosphere and the potential benefits on the nowcasting and forecasting of high impact weather events.

(2) The intensified observations from GIIRS with 15-minute temporal resolution during Typhoon Maria in 2018 are used to develop atmospheric profile retrieval models for both temperature and moisture under clear sky through neural network trainings, based on which the impacts from temporal variations observed by GIIRS on the retrievals are analyzed. The models are trained with brightness temperature (BT) observations from selected GIIRS channels that are capable of capturing the atmospheric information and its temporal variation on different levels as inputs, and thermodynamic profiles from ERA5 used as benchmarks of the training. Independent validation results show that the overall root mean squared error (RMSE) of temperature from 100 to 1000 hPa is 0.639 K, and the mean bias is 0.092 K. For relative humidity,

the overall RMSE and mean bias from 300 to 1000 hPa are 5.089 % and 0.004 %, respectively. However, the uncertainty of relative humidity increases drastically above 300 hPa. Validation results using independent Global Data Assimilation System (GDAS) analysis show that the errors of retrievals against GDAS are larger than those against ERA5, and further analysis proves that the major source is from differences between GDAS and ERA5. This indicates that the retrieval performance is likely to be affected by the benchmarks selected in the training process. Meanwhile, the retrievals' validation results against GDAS remain reasonable, indicating the stability of the retrieval models. Comparing to the model trained from GIIRS observations from single time step that corresponds to the ERA5 profile time, the model with GIIRS temporal variations added to the predictors show enhanced retrieval accuracy on both temperature and moisture. Results show more significant enhancements on temperature than relative humidity, while in the lower troposphere both temperature and relative humidity are more substantially improved than upper troposphere.

(3) Four-dimensional wind fields are derived from GIIRS observations onboard the FengYun-4A satellite with 15-minute temporal resolution during Typhoon Maria in 2018. The retrieval model is trained through a deep neural network with selected GIIRS longwave and midwave observations along with temporal and spatial variations combined as the inputs, and U and V wind components from ERA5 used as the benchmark. Results are evaluated with independent ERA5 reanalysis, independent GDAS analysis and dropsonde wind profiles, and confirm the potential of the model on retrieving three-dimensional wind fields with high accuracy from GIIRS high temporal resolution observations under clear and non-thick cloudy skies. Validation results show a statistical root mean squared error less than 2 m/s for U and V components in troposphere against ERA5 and GDAS, and good consistency from the temporal variations of wind fields from GIIRS with that of the hourly ERA5. Further experiments show that higher temporal resolution from geostationary infrared (IR) sounder measurements could provide better dynamic information. Comparing with the Atmosphere Motion Vector (AMV) products derived from Advanced Himawari Imager (AHI) onboard Himawari-8, the wind retrievals from GIIRS show advantages in both

accuracy and information density.

(4) Based on the local severe storm (LSS) nowcasting model named SWIPE (Storm Warning in Pre-convection Environment) previously developed by National Satellite Meteorological Center (NSMC) using the combination of geostationary satellite imager observations and numerical weather prediction (NWP) products, an enhanced SWIPE is developed for the Continental United States (CONUS) region with random forest using high temporal observations from ABI, combined with NWP products from GFS and precipitation analysis from CMORPH (The Climate Prediction Center Morphing technique). The SWIPE framework is enhanced by introducing the classical optical flow and continuous tracking into the collocation of datasets, based on which the potential impact of geostationary hyperspectral infrared sounding (GeoHIS) information on storm nowcasting is partially evaluated with ERA5 profiles used as proxy. Analysis shows that the enhanced model has higher accuracy on severe storms with areas equal or larger than 5000 km² over smaller storms, and less accuracy on storms smaller than 1000 km². The accuracy of SWIPE model on severe storm nowcasting shows enhancement when GeoHIS information with ERA5 as proxy is added to the predictors. The accumulated importance score of ERA5 profiles is higher than that of GFS NWP predictors, indicating the sounding information from GeoHIS would provide more added value on atmospheric pre-convection environment associated with LSS on top of current coarse resolution NWP forecasts. The impact of GeoHIS on small storms within 1000 km² is not as significant compared with that on larger storms, possibly due to the lack of temporal and spatial resolution from ERA5 as a proxy. Future geostationary hyperspectral infrared sounders with finer resolution would bring better benefits to the nowcasting of convective initiations with meso-to-micro scales when used in combination of high resolution geostationary imagers.

Key Words: Geostationary Meteorological Satellite, Hyperspectral Infrared Sounder, Retrieval, Four-dimensional Wind Fields, Nowcasting

目 录	
第 1 章 引言	1
1.1 研究背景和意义.....	1
1.2 国内外研究进展.....	3
1.2.1 气象卫星与大气探测技术的发展.....	3
1.2.2 卫星反演大气温湿廓线的研究.....	7
1.2.3 卫星反演大气水平风场的研究.....	10
1.2.4 静止卫星高光谱大气探测的预报应用研究.....	13
1.2.5 静止卫星高光谱探测的发展与应用前景.....	15
1.3 研究目的与研究内容.....	17
1.3.1 拟解决的科学问题.....	17
1.3.2 研究内容.....	17
1.4 研究的创新点.....	18
1.5 章节安排.....	19
第 2 章 极轨卫星探测与静止卫星成像的联合大气廓线反演	21
2.1 引言.....	21
2.2 研究数据.....	24
2.2.1 基于 CrIS/ATMS 的 NUCAPS 反演数据.....	24
2.2.2 静止卫星成像观测 ABI.....	27
2.2.3 实时中尺度地面分析产品 RTMA.....	29
2.2.4 ERA5 再分析数据.....	29
2.2.5 无线电探空观测.....	30
2.3 数据预处理.....	30
2.3.1 质量控制.....	32
2.3.2 时空匹配.....	33
2.3.3 云区处理.....	33
2.4 神经网络设置与训练.....	35
2.5 统计检验.....	38

2.5.1 晴空条件下的检验.....	38
2.5.2 部分有云条件下的检验.....	40
2.6 敏感性试验.....	43
2.6.1 多源数据的相对贡献.....	43
2.6.2 ABI 不同通道信息在反演改进中的作用.....	46
2.7 泛化能力检验.....	48
2.8 基于探空数据的独立检验.....	51
2.8.1 统计检验.....	51
2.8.2 个例分析.....	53
2.9 数据融合反演在对流天气环境的预报应用.....	55
2.10 本章小结.....	57
第 3 章 基于静止卫星高光谱探测的大气廓线反演.....	60
3.1 引言.....	60
3.2 研究数据.....	62
3.2.1 GIIRS L1 数据.....	62
3.2.2 2018 年第 8 号台风“玛利亚”.....	63
3.2.3 GIIRS 加密观测.....	65
3.2.4 ERA5 再分析数据.....	66
3.2.5 GDAS 分析场.....	66
3.2.6 机载下投探空.....	67
3.3 通道选择.....	67
3.4 数据预处理.....	69
3.5 神经网络设置与训练.....	69
3.6 反演结果与检验.....	71
3.7 探空分析.....	77
3.8 时间变化信息的影响.....	79
3.9 本章小结.....	81
第 4 章 基于静止卫星高光谱探测的四维风场反演.....	84
4.1 引言.....	84
4.2 资料和方法.....	85
4.2.1 数据资料.....	85

4.2.2 反演方法.....	87
4.3 反演结果与检验.....	90
4.3.1 样本分类.....	90
4.3.2 统计检验.....	91
4.3.3 GDAS 检验.....	97
4.3.4 探空检验.....	99
4.4 时空变化敏感性试验.....	99
4.5 与 AMV 产品的对比.....	103
4.6 本章小结.....	108
第 5 章 静止卫星高光谱探测与成像观测相结合的短临预报应用 ..	110
5.1 引言.....	110
5.2 研究数据.....	111
5.3 对流初生模型及改进.....	112
5.3.1 SWIPE 模型框架与不足.....	112
5.3.2 模型框架的改进.....	114
5.4 数据集构建与模型训练.....	119
5.5 预测结果与评估.....	124
5.6 对流个例预报应用.....	129
5.7 预报因子的重要性评分.....	133
5.8 GeoHIS 观测在 SWIPE 模型中的敏感性试验.....	135
5.9 GeoHIS 观测在 SWIPE 对流预警中的潜在贡献.....	137
5.10 本章小结.....	141
第 6 章 总结与展望 ..	144
6.1 全文总结.....	144
6.2 未来展望.....	149
参考文献.....	152
附录.....	171
致谢.....	175

作者简历及攻读学位期间发表的学术论文与研究成果179

图表目录

图 1.1 静止卫星红外高光谱探测仪 GIIRS 与几个极轨卫星红外高光谱探测仪光谱范围对比.....	6
图 1.2 利用 GIFTS 模拟得到的风场，用于阐述未来静止卫星高光谱探测仪可得到的风场密度和垂直分布.....	13
图 2.1 CrIS 一次上升轨道对应的地面视场 FOV（实线圆圈或椭圆）与视野像元 FOR（虚线圆圈或椭圆）以及几何属性示意图。.....	24
图 2.2 针对一个特定 NUCAPS FOR 中 ATMS 和 CrIS 匹配视场示意图，.....	25
图 2.3 NUCAPS 算法流程图.....	27
图 2.4 ABI 红外通道（通道 7-16）在 1976 年美国标准大气条件下(U.S. Standard Atmosphere, 1976)的星下点权重函数及模拟亮温.....	28
图 2.5 在有云状况下 ABI 和 NUCAPS 的匹配个例示意图.....	34
图 2.6 本章应用的四层全连接神经网络模型示意图。.....	36
图 2.7 NUCAPS（红线）与 DNN 模型输出（蓝线）在检验数据集上统计得到的的温度和相对湿度相对 ERA5 的 STDE 与平均偏差, 在晴空条件下和部分有云条件下的垂直廓线。.....	42
图 2.8 各个试验的输出以及 NUCAPS 相对 ERA5 的温度与相对湿度 STDE 垂直廓线。.....	45
图 2.9 各个 ABI 通道试验的输出相对 ERA5 的温度与相对湿度 STDE 垂直廓线。.....	47
图 2.10 在美国标准大气的条件下利用 CRTM 计算出的 ABI 各红外通道的水汽混合比（对数形式）Jacobian。.....	48
图 2.11 NUCAPS（红线）与 DNN 模型输出（蓝线）在 2017 年数据集上统计得到的的温度和相对湿度相对 ERA5 的 STDE 与平均偏差, 在晴空条件下和部分有云条件下的垂直廓线。.....	50
图 2.12 NUCAPS 与 DNN 模型的输出结果相对于 2017 和 2018 年匹配到的探空观测数据集上统计得到的的温度和相对湿度的 STDE 与平均偏差的垂直廓线。.....	52
图 2.13 两个探空个例中大气廓线中温度与露点在 Skew-T 图上的体现。.....	55
图 2.14 2017 年 6 月 18 日来自 1800 UTC 的 ERA5 再分析数据；以及在 1827 至 1839 UTC 的 NUCAPS 观测区域的 NUCAPS 以及神经网络模型预测结果计算出的	

计算的抬升 CAPE (SBCAPE) 分布。	56
图 2.15 2017 年 6 月 18 日来自 1800 UTC 的 ERA5 再分析数据; 以及在 1827 至 1839 UTC 的 NUCAPS 观测区域的 NUCAPS 以及神经网络模型预测结果计算出的计算的抬升指数 LI (Lifted Index)。	57
图 3.1 GIIRS 常规观测区域示意图, 背景为 FY4A 的多通道静止轨道辐射成像仪 AGRI 的真彩色图像。	63
图 3.2 来自于中国台风网(http://typhoon.weather.com.cn)的以北京时(世界时+8)表示的台风“玛利亚”最佳路径。	64
图 3.3 台风“玛利亚”期间 GIIRS 加密观测区域范围.	65
图 3.4 本研究中选择的分别用于大气温湿廓线反演的长波红外通道的温度 Jacobian, 和中波红外通道的对数形式水汽混合比 Jacobian, 以及以红色实心圆表示的所选通道叠加于用 1976 年美国标准大气模拟的 GIIRS 全部红外通道的亮温光谱。	68
图 3.5 神经网络训练的 GIIRS 温度反演模型在独立检验数据集上的反演结果相对于 ERA5 的统计检验结果。	72
图 3.6 GIIRS 温度反演结果与 ERA5 的对比。	73
图 3.7 神经网络训练的 GIIRS 比湿反演模型在独立检验数据集上的反演结果相对于 ERA5 的统计检验结果。	74
图 3.8 神经网络训练的 GIIRS 的相对湿度反演模型在独立检验数据集上的反演结果相对于 ERA5 的统计检验结果。	75
图 3.9 GIIRS 反演的温度和相对湿度结果相对于 GDAS 和 ERA5, 以及 GDAS 相对 ERA5 的 STDE 和 Bias 在不同等压面的分布廓线。	77
图 3.10 来自探空观测与模型反演的大气廓线中温度与露点在 Skew-T 图上的体现。	79
图 3.11 使用单一时次作为自变量训练的模型, 与自变量中包含时间变化的模型的温度与相对湿度反演结果相对 ERA5 的 STDE 和 Bias 在不同等压面的分布廓线。	81
图 4.1 选择的用于风场反演的通道(红点表示)叠加在美国标准大气模拟的亮温光谱; 所选长波通道的温度 Jacobian; 所选中波通道的水汽混合比 (lnq) Jacobian。	88

图 4.2 利用独立的测试数据集计算的的 GIIRS 反演和 GFS 预报场的风场 U、V 分量各自与 ERA5 之间的均方根误差。	92
图 4.3 2018 年 7 月 10 日 1200 UTC 开始的 GIIRS 区域观测范围内来自晴空和薄云覆盖视场的 200 hPa 和 850 hPa 的 GIIRS 反演风场和 GFS 数值预报风场与 ERA5 风场之间的对比。	93
图 4.4 2018 年 7 月 10 日 2200 UTC 开始的 GIIRS 区域观测范围内来自晴空和薄云覆盖视场的 500 hPa 和 850 hPa 的 GIIRS 反演风场和 GFS 数值预报风场与 ERA5 风场之间的对比。	95
图 4.5 GIIRS 反演风场与 ERA5 风场分别在位于(113.1°E, 27.0°N), 和 (132.1°E, 31.9°N) 的 GIIRS 视场的 U、V 风场分量在 200、500 和 850 hPa 的时间变化特征。	96
图 4.6 利用 2018 年 7 月 10 日 0600 和 1200 UTC 的晴空和薄云覆盖条件的视场对于 GIIRS, ERA5 以及全球数据同化系统分析场 (GDAS) 的风场 U、V 分量之间的均方根误差 (RMSE) 对比分析。	98
图 4.7 2018 年 7 月 10 日的机载下投探空风场观测与对应的 GIIRS 反演结果、ERA5 以及 GDAS 的风场 U、V 分量廓线对比。	100
图 4.8 利用 2018 年 7 月 10 日的 GIIRS 观测数据通过不同训练方式获得的风场 U、V 分量反演结果与 ERA5 之间的均方根误差分布廓线对比。	102
图 4.9 2018 年 7 月 10 日 1200 UTC 的来自于 AHI 基于直接追踪算法的 AMV 产品, 与 GIIRS 使用本章的机器学习算法的风场反演结果的三维空间分布图。	106
图 4.10 2018 年 7 月 10 日 1200 UTC 的 AHI 基于直接追踪算法的 AMV 产品与来自 GIIRS 使用本章的机器学习算法的风场反演结果在 200 hPa 和 300 hPa 的对比。	107
图 5.1 SWIPE 在 2018 年 7 月 1 日 1940 UTC 在 CONUS 追踪到的对流初生目标云分布。	115
图 5.2 应用光流法结合面积重合法对快速移动的目标云进行降水匹配的示意图, 以及 SWIPE V1 模型与改进后的 SWIPE 模型针对不同类型目标云的匹配结果对比。	117
图 5.3 改进后模型的追踪与数据匹配流程示意图。	119
图 5.4 强对流样本与非强对流样本在小目标云类别 (面积小于 1000 km ²)、中等目标	

云类别（面积在 1000 到 5000 km ² 之间）以及大目标云类别（面积在 5000 km ² 及以上）内的样本量；以及各训练场景得到的模型对不同大小的强对流样本的 POD、FAR 和 CSI 评分。	129
图 5.5 SWIPE 模型于 2019 年 8 月 1 日在北卡罗莱纳州追踪到的一次强风暴个例，以及对应的 ABI 10.3 μm 通道亮温观测和对应的 CMORPH 降水分布。	131
图 5.6 SWIPE 模型于 2019 年 8 月 7 日在威斯康星州追踪到两个对流云合并成一个强对流云的过程，以及对应的 ABI 10.3 μm 通道亮温观测和对应的 CMORPH 降水分布。	133
图 5.7 各试验得到的模型对于独立检验测试集当中不同大小的强对流目标云样本预报中统计得到的 POD、FAR 和 CSI。	140
表 2.1 在训练和检验中使用到的数据集与具体变量	32
表 2.2 本章研究中使用的神经网络设置	38
表 2.3 在晴空条件下训练集和检验集当中各个等压面上的有效样本量	39
表 2.4 在部分有云条件下训练集和检验集当中各个等压面上的有效样本量	41
表 2.5 2017 年 4-6 月数据中晴空和部分有云条件下各个等压面上的有效样本量 ..	49
表 2.6 与 NUCAPS 相匹配的探空观测在不同高度层的有效样本量	51
表 3.1 风云 4A GIIRS 在台风“玛利亚”期间加密观测的相关参数	66
表 3.2 本章研究中使用的神经网络设置	70
表 4.1 本章研究中使用的神经网络设置情况	90
表 4.2 数据分类依据与各类别样本量	91
表 4.3 对 AHI 的 AMV 产品和 GIIRS 的机器学习反演结果以 ERA5 为基准的的误差统计对比	105
表 5.1 经过匹配用于随机森林训练与短临预测模型的预报变量。对于每个变量使用其在目标云范围内的最大、最小以及平均值（除了最大降温率与云覆盖面积这两个可以直接作为输入的变量）来作为随机森林模型的输入。	120
表 5.2 SWIPE 模型在 2018 年 3 到 10 月之间在 CONUS 区域追踪到的对流预报目标样本量	122
表 5.3 不同训练场景所对应的分类框架与采样信息，以及各自场景下通过不同超参	

数组合训练得到的模型的袋外评分以及在测试集上的分类准确性的统计平均值 以及标准差（在括号中表示）	124
表 5.4 本研究中在分类问题中针对某一特定类别以预测值和对应的真实标签表示的 混淆矩阵.....	124
表 5.5 研究中用于评估随机森林分类模型对某一特定类别的预报能力的指标.....	125
表 5.6 不同训练情景下训练和优化得到的短临预报分类模型的统计评估结果.....	126
表 5.7 随机森林训练得到的模型 3CBA 和 2CBA 的预报因子重要性评分排名情况。	134
表 5.8 由 ERA5 作为代用数据的静止卫星高光谱大气探测产品预测因子.....	136
表 5.9 通过机器学习框架评估卫星观测在对流预警中影响的试验设置.....	137
表 5.10 不同试验模型在强对流样本中的评估结果以及各自模型中来自 ABI、GFS 和 GeoHIS 变量的重要性评分总和。	138

第1章 引言

1.1 研究背景和意义

客观而准确的大气观测资料对于天气预报业务和气象科学研究都具有重要的意义。对于数值天气预报,随着计算能力、预报模式和资料同化系统在近年来的不断发展和完善,来自于大气观测资料的模式初值的准确性已愈发成为影响数值模式预报精度的关键因素(Bauer 等., 2015; 曾庆存, 2013; 薛纪善, 2009; 董佩明 等, 2008)。特别是在对于常伴随有暴雨、大风、冰雹等气象灾害的强对流天气的短临预报方面,由于其时空尺度小,发展迅速,通过常规地面和探空观测资料很难及时而准确地识别和预报其初生和发展,使得具有高时间分辨率和高空间覆盖率的非常规观测资料显得尤为重要(孟智勇 等, 2019)。在这样的需求背景下,具有较好的时空分辨率,且覆盖范围不受下垫面环境影响的卫星遥感观测资料在数值天气预报和强对流天气的短临预警方面具有很好的应用前景(Zhang X 等., 2020; 俞小鼎 和 郑永光, 2020)。

近年来,通过气象卫星观测资料的发展和应用,弥补了传统地面测站和雷达观测存在的空间分布不足的问题,特别是在山地、沙漠、高原等复杂地形地区,能够提供持续有效的观测资料。通常被搭载于极轨卫星上的高光谱红外探测仪能够反演得到高精度高垂直分辨率的大气温湿廓线(Menzel 等., 2018)。这些经由反演得到的大气廓线能够很大程度上弥补地面探空观测在时间和空间分布上的不足,为数值天气预报提供所需的初始场(Cardinali, 2009; McNally 等., 2006; Le Marshall 等., 2006, 2005)。与此同时,通过温度与湿度的垂直分布情况,能够反映出大气实时的稳定性特征,并且经由计算可以得到例如对流有效位能(convective available potential energy, CAPE) 以及对流抑制能量(convective inhibition, CIN) 等可用于判定对流环境特征的物理量,对于对流系统的短时临近预报有很好的指示作用(Weisz 等., 2015; Li J 等., 2011)。而搭载于静止卫星上的高分辨率成像仪能够提供较高时间和空间分辨率的连续观测,一方面在空间上弥补了山地、高原等地区地面测站分布密度不足的缺陷,另一方面相较于雷达能够在相对更早的时间在相对更大的范围内对于发展中的目标云进行监测。通过静止

卫星高分成像仪观测到的目标面积轮廓, 纹理特征和边缘特征等的连续演变, 能够一定程度上反映出对流系统的发展和变化特征, 对于对流天气系统的监测和预警起着重要的作用(黄亦鹏 等, 2019; Rao 等., 1990; Purdom, 1976; Anderson, 1974)。

与此同时, 不同类型的卫星观测也各自存在着不足之处, 例如搭载于极轨卫星上的红外高光谱大气探测通常存在着时间分辨率不足, 视场易受云的影响, 反演得到的温湿廓线在大气边界层准确度降低等问题(Nalli 等., 2018, 2013; Sun B 等., 2017)。而高时空分辨率的宽谱成像仪资料受制于光谱覆盖范围, 其反映的大气动力学和热力学状态在垂直方向的分辨率上有所欠缺, 想要提高对于对流系统的短临预警能力也需要更多的大气环境信息加以补充(Schmit 等., 2009)。因而如何能够将来自高光谱探测仪的观测与高分辨率成像信息有效地联合起来, 将高精度、高垂直分辨率的大气温度、湿度以及风场垂直廓线信息, 与不同通道的高时空分辨率观测信息科学而有效地联合起来, 进而提高对流系统短临预报的预报时效和准确率, 建立先于雷达探测的识别预报模型, 对于解释局地对流系统初生和发展因素的科学问题和实际的对流天气短临预报和数值天气预报业务应用都具有重要意义。

近年来, 我国已成功发射了多颗极地轨道与地球静止轨道气象卫星, 其中于 2016 年 12 月 11 日成功发射的第二代地球静止轨道风云 4 号卫星 A 星(FY-4A), 其上搭载有多通道扫描成像辐射计(Advanced Geosynchronous Radiation Imager, AGRI)、干涉式红外高光谱大气探测仪(Geostationary Interferometric Infrared Sounder, GIIRS)以及闪电探测仪(Lightning Mapping Imager, LMI)等多个先进的观测仪器(Yang J 等., 2017; 董瑶海, 2016; 张鹏 等, 2016)。其中, 风云四号 A 星搭载的红外干涉式红外高光谱大气探测仪(GIIRS)成为了世界上首个搭载于地球静止轨道卫星上的高光谱大气探测仪(Yang J 等., 2017), 其所观测的具有高时间分辨率和高垂直分辨率的大气三维动力学和热力学信息, 对于中小尺度天气系统的监测和预报, 以及数值预报模式的同化应用都能起到非常大的促进作用。因此, 在这个气象卫星事业快速发展的新阶段, 如何充分利用世界上首个静止轨道高光谱大气探测仪 GIIRS 的观测数据, 反演得到高质量的大气热力学和动力学廓线, 并能够与不同类型的观测数据(如高分辨率成像仪观测)实现科学

的联合应用，对于获得高分辨率高精度的三维大气观测数据及其时间变化信息，进而在数值天气预报和对流天气的短临预警中发挥其独特价值，具有十分重要的意义。

1.2 国内外研究进展

1.2.1 气象卫星与大气探测技术的发展

世界上第一颗气象卫星于1960年4月1日发射于美国的泰罗斯-1号(TIROS-1)，首次获得了能够显示大尺度天气系统特征的卫星云图，自此拉开了世界各国的气象卫星和卫星气象学发展的序幕(李俊和方宗义, 2012)。气象卫星按照其运行轨道分为极轨卫星(太阳同步轨道卫星)和静止卫星(地球同步轨道卫星)。其中极轨卫星可以实现全球观测，轨道高度低，适合观测中高纬度以及较大尺度的天气系统，但是对于低纬度不一定能完全覆盖，且由于时间分辨率低难以捕捉短生命史的中小尺度天气系统；静止轨道卫星可以实现高时间分辨率的连续观测，适合观测中小尺度系统并追踪云和水汽的移动，但是仅能覆盖地球表面约三分之一的固定区域，其适合于观测中低纬度而对高纬度由于倾斜角的影响而畸变严重(蒋尚城, 2006)。在气象卫星所搭载的观测仪器方面，包括了红外大气探测仪、宽谱成像仪、微波探测仪等。气象工作者们利用多种类型的卫星观测资料，合理地选择相应的通道，通过科学的反演算法能够得到大气温度、湿度以及大气中气体成分的三维空间分布等信息(曾庆存, 1974)。

世界上最早的卫星大气探测仪是发射于1969年4月的美国雨云-3号卫星(Nimbus-3)所搭载的卫星红外分光辐射仪SIRS(Satellite Infrared Spectrophotometer)-A(董超华等, 2013)。该仪器首次利用CO₂吸收带的8个谱段实现了对大气温度廓线的探测，尽管由于光谱分辨率低，且250 km的星下点视场过大，导致其资料可用性受限，该仪器依然对当时的天气预报业务有了显著的改进(Smith W等., 1970)。随着大气探测技术的发展，极轨气象卫星的大气探测实现了从星下点观测到跨轨道宽幅扫描的技术进步，并且在光谱分辨率、空间分辨率和辐射定标准确性上获得了全面的进步(Menzel等., 2018)。自20世纪90年代以来，已发展的极轨卫星大气探测仪器包括了搭载于美国NOAA-15至NOAA-19上的ATOVS(Advanced TIROS Operational Vertical Sounder)系统，包括了一个

高分辨率红外辐射探测器(HIRS, High Resolution Infrared Radiation Sounder)以及两台微波探测器 AMSU(Advanced Microwave Sounding Units), 能够在不同气象条件下提供大气垂直探测信息(Li J 等., 2000)。

对于精细的大气垂直结构的观测需求促进了高光谱大气探测仪的发展(Eyre, 1989), 如搭载于美国 NASA EOS(Earth Observing System) Aqua 卫星的 AIRS(Atmospheric Infrared Sounder), 在 3.7~15.4 μm 范围内的三个不同吸收带共有 2378 个通道, 其对晴空条件下温度和湿度反演的垂直分辨率分别达到 1 km 和 2 km (Chahine 等., 2006)。搭载于欧洲气象卫星组织的 MetOp 系列卫星上的高光谱红外探测器 IASI (Infrared Atmospheric Sounder Interferometer)共有 8641 个通道, 首次实现了在 3.62~15.5 μm 红外光谱范围内对地球大气的连续光谱观测 (Blumstein 等., 2004), 光谱分辨率达到 0.25 cm^{-1} , 其在晴空条件下对 200 hPa 以下温度和湿度反演的准确性分别达到了 1 K 和 10 %, 而垂直分辨率分别达到了 1 km 和 1.5~2 km (Lerner 等., 2002)。最新一代的美国极轨卫星系列 JPSS (Joint Polar Satellite System)搭载的跨轨道高光谱红外探测器 CrIS (Cross-track Infrared Sounder)具有三段式光谱覆盖的 2211 个通道, 其在短波、中波、长波红外谱段的光谱分辨率为 0.625 cm^{-1} (Strow 等., 2013; Han 等., 2013)。CrIS 与同平台上的微波探测仪 ATMS (Advanced Technology Microwave Sounder)协同观测, 能够在晴空和有云条件下对大气温湿廓线的 1~2 km 垂直高分辨率探测(Goldberg 等., 2013)。

静止卫星大气探测的概念最早是由威斯康星大学麦迪逊分校的 Suomi 教授提出的, 并于 1980 年在美国静止卫星 GOES-4 上搭载的探测仪 VAS (Visible and Infrared Spin Scan Radiometer (VISSR) Atmospheric Sounder)上首次实现了在地球静止轨道上的高时间分辨率大气探测(Hayden, 1988; Smith W 等., 1981), 而在此之前的静止卫星上携带的主要是成像类仪器。然而由于 VAS 的信噪比不够高且垂直分辨率较低, 限制了其在预报业务中的应用。自 1994 年发射的 GOES-8 卫星之后, 美国的静止卫星携带新的 GOES 探测仪, 将红外通道数从 12 个增加到了 18 个, 提供北美大陆和周边海域逐小时的温湿度廓线反演产品, 相比于 VAS 提高了光谱分辨率和时间分辨率(Menzel 等., 1998; Menzel 和 Purdom, 1994)。然而, GOES 探测器对大气的垂直探测能力仍然有限, 主要是由于其光谱分辨率仍

然较低。在美国新一代的 GOES-R 系列静止卫星上已不再搭载该仪器(Schmit 等., 2017), 其探测产品在静止轨道高光谱探测器投入运行之前, 由具有 10 个红外通道的, 且时空分辨率更高的先进基线成像仪 ABI (Advanced Baseline Imager) 与短期数值模式的预报产品相结合而代为产生(Schmit 等., 2008)。尽管来自世界各地的许多学者已经通过模拟研究, 证实了搭载于静止卫星的高光谱大气探测器在对流天气预报和短临预警中潜在的重要价值(Okamoto 等., 2020; Li Z 等., 2018; Li J 等., 2011; Schmit 等., 2009; Sieglaff 等., 2009), 美国也先后设计了 GHIS (GOES High Resolution Interferometer Sounder)和 GIFTS (Geostationary Imaging Fourier Transform Spectrometer)两种静止卫星高光谱大气探测器(Smith W 等., 2002, 1990), 但是到目前为止, 世界上除我国以外的其他国家仍没有搭载于静止轨道卫星的高光谱探测器投入使用。

我国的气象卫星发展始于 1969 年, 周恩来总理在该年 1 月我国华东、中南地区发生的雨雪冰冻灾害之后, 提出了自主发展我国的气象卫星的最初设想(李俊和方宗义, 2012; 许健民等, 2010; 方宗义等, 2004)。自从 1988 年我国的风云一号第一颗卫星 (FY-1A) 成功发射以来, 我国已先后发展了风云一号和风云三号系列极轨卫星, 以及风云二号和风云四号系列静止卫星(王新等, 2021; 卢乃锰和谷松岩, 2016; 许健民等, 2010)。我国新一代极轨卫星风云三号系列的 FY-3A/B/C 三颗卫星上搭载了包括了自主研发的通道式红外探测器——红外分光计 IRAS、中分辨率光谱成像仪 MERSI、微波温度计 MWTS、微波湿度计 MWHS、以及微波成像仪 MWRI 等多种探测仪器, 实现了全球范围、全天候、多光谱三维大气定量遥感(杨军等, 2009)。从 2017 年 11 月 15 日发射成功的 FY-3D 卫星开始, 搭载了红外高光谱大气探测器 HIRAS 取代 IRAS, 通道数目由 26 个增加到了 1370 个, 首次实现了我国自主的卫星高光谱红外高精度大气垂直观测(漆成莉等, 2016)。近期于 2021 年 7 月 5 日成功发射的 FY-3E 作为世界上首颗晨昏轨道气象卫星, 其上搭载了改进的高光谱大气探测器 HIRAS-II, 与同时运行的 FY-3C 和 FY-3D 组网联用, 将能够提供 6 小时间隔的三维大气观测信息(Zhang P 等., 2022)。

成功发射于 2016 年 12 月 11 日的风云四号 A 星 (FY-4A) 是我国新一代静止轨道卫星系列的首颗卫星, 其上搭载了全球首个静止轨道高光谱红外探测器

GIIRS, 第一次实现了高时间分辨率与高垂直分辨率的三维大气连续观测(Yang J 等., 2017)。GIIRS 采用的是迈克尔逊干涉分光方式对大气红外辐射进行观测, 分别以 0.625 cm^{-1} 的光谱分辨率覆盖 $700\sim 1130 \text{ cm}^{-1}$ 的长波红外谱段和 $1650\sim 2250 \text{ cm}^{-1}$ 的中波红外谱段, 具有和计划中的欧洲第三代静止卫星上高光谱红外探测仪相类似的光谱覆盖范围和光谱分辨率(如图 1.1 所示), 而其具备的对于大气温湿度廓线高频次连续观测的能力是极轨卫星探测仪所不具备的。模拟数据的研究表明, 相比于以 GOES 探测仪为代表的静止卫星传统大气探测仪, GIIRS 能够在更高的垂直分辨率上反演得到更为准确度温度和湿度廓线(Yang J 等., 2017)。除 GIIRS 之外, FY-4A 还搭载了先进的静止轨道辐射成像仪 AGRI(Advanced Geosynchronous Radiation Imager), 该成像仪相比于风云二号系列卫星所搭载的成像仪在通道数目和时空分辨率上都有提高。搭载于同平台上的静止卫星高光谱探测与高分辨率成像仪的联合应用, 将有助于实现在三维空间上对大气热力学和动力学信息的高频次观测。




图 1.1 静止卫星红外高光谱探测仪 GIIRS 与几个极轨卫星红外高光谱探测仪光谱范围对比 (引用自 Menzel 等., 2018)

Figure 1.1 Comparison of geostationary hyperspectral sounder GIIRS and several polar-orbiting hyperspectral sounders on detection spectral range (cited from Menzel et al., 2018).

1.2.2 卫星反演大气温湿廓线的研究

利用卫星观测到的红外辐射来反演大气温度的想法最早是由美国科学家 King 于上世纪 50 年代提出的(King, 1956)。Kaplan (1959)发现了卫星在不同谱段观测到的辐射来自于大气的不同高度层,因而可以用来反演大气的温度廓线,并提出了采用大气中 CO_2 和水汽的吸收和发射特征来分别反演温度和湿度的垂直分布。此后随着卫星探测仪器的发展和数值预报应用需求的提高,国内外的许多科学家发展了不同类型的定量反演算法,传统的处理方法可分为物理反演法和统计反演法两个大类。其中物理反演法的基本思想是根据大气辐射传输的物理规律,结合数学求解方法实现对于辐射传输方程的求逆解,而统计反演法则是不涉及大气辐射传输的具体计算,通过建立到达卫星探测仪器的辐射量与大气廓线之间的统计关系来实现大气廓线的定量反演(董超华 等, 2013)。

通过物理反演方法反演大气廓线需要对辐射传输方程求逆解,但是由于辐射传输方程是一个积分方程,该方程的解具有不适定性,必须在求解过程中加入一定的约束条件才有可能得到稳定的解(曾庆存, 1974)。比较经典的做法是通过给定初始猜想值代入辐射传输模式得到辐亮度,再通过对大气廓线不断修正使其无限逼近观测值,从而得到方程的一个解,例如 Chahine 松弛法(Chahine, 1970)和 Smith 迭代法(Smith W, 1970)等。曾庆存 (1974) 对红外遥感的理论问题作了系统的论述并提出了温度和水汽反演中不同的“最佳信息层”概念,并提出用最速下降法来求解温度和水汽廓线。Lorenz (1986)从贝叶斯理论出发提出了代价函数的概念,将辐射传输方程的求解问题转化成一个非线性最优化问题,进而发展出很多最优化求解方法。李俊和曾庆存 (1997)在此基础上利用牛顿非线性迭代法实现了对大气和云参数的反演。Li 和 Huang (1999)在 GOES-8 资料的反演中使用偏差原则定义平滑系数,使得迭代过程能够稳定和有效地获得收敛解。Li J 等 (2000)将类似的方法应用在 International Advanced Television and Infrared Observation Satellite Operational Vertical Sounder (ATOVS)的反演中,获得了在 1 km 垂直分辨率上平均 RMSE 约为 2 K 的温度反演准确率。Atmospheric Infrared

Sounder (AIRS) 基于一维变分算法 (1D-Var) 的大气廓线反演算法在晴空条件下能够在 850 hPa 以上达到 RMSE 平均 1 K 和 10 % 的温度和相对湿度准确度(Wu 等., 2005), 且可以通过清云处理应用于部分有云的视场条件下的反演(Susskind 等., 2003)。针对风云四号 A 星所搭载的 GIIRS 观测信息, Xue 等 (2022)应用了基于一维变分的物理反演算法在晴空和部分有云条件下实现了大气温度和湿度廓线的反演, 获得了对流层平均 RMSE 在 2 K 和 $2 \text{ g}\cdot\text{kg}^{-1}$ 以内的温度和湿度反演精度。

与物理反演方法相比, 统计反演方法的主要思路是使用大气廓线数据集和与之匹配的卫星辐射观测, 通过建立二者之间的回归方程进行定量反演, 由于不涉及辐射传输方程的计算而具备比物理反演算法更高的计算效率。Smith 和 Woolf (1976)最先使用特征向量法建立了从观测辐射值反演大气温湿廓线的统计反演模型。官莉 (2006)利用基于主成分分析的特征向量统计算法实现了针对 AIRS 观测数据的大气温湿廓线反演。Smith W 等 (2012)基于 CrIS (Cross-track Infrared Sounder)观测数据开发了基于经验正交函数 (EOF) 的双回归反演算法, 使得温湿度廓线反演拓展到有云情况。伴随着机器学习理论和算法的发展, 传统的统计回归算法逐步地被能够更好解决非线性问题的机器学习算法所取代。例如谭永强和 费建芳 (2010)使用支撑向量机针对 AMSU (Advanced Microwave Sounding Unit) 的模拟亮温资料实现了温湿廓线的反演, 并表现出了较强的抗噪声能力。Di Paola 等 (2018)使用随机森林算法训练了基于 ATMS (Advanced Technology Microwave Sounder)的温湿廓线反演算法。神经网络算法凭借其对于非线性关系强大的拟合能力而被越来越多地应用到大气廓线的反演工作中(Boukabara 等., 2019)。Aires 等 (2002)将神经网络应用在 IASI 模拟资料的温湿廓线反演中并取得了快速而准确的反演结果。姚志刚 和 陈洪滨 (2006)的研究发现, 神经网络的反演结果相比线性统计反演算法表现出更高的准确度, 对于存在较厚逆温结构的大气温度廓线具有更高的复现能力。张雪慧 等 (2009)利用神经网络对 AIRS 晴空模拟数据进行大气廓线反演, 得到了比特征向量统计法更高的反演精度。蒋德明 等 (2010)使用三层前馈型神经网络针对 AIRS 高光谱观测数据进行了温度廓线反演, 获得了 $1 \text{ K}\cdot\text{km}^{-1}$ 的对流层温度反演精度。Blackwell 和 Milstein (2014)基于神经网络算法实现了对来自 AIRS 的高光谱红外观测和 AMSU 的微波观测

数据相融合的大气温湿廓线反演,并通过多源数据的检验证实了其相对业务算法的效果改进以及该算法在 CrIS/ATMS 数据反演的适用性(Milstein 和 Blackwell, 2016)。

对于国际上首个静止轨道高光谱大气探测仪 GIIRS,一些学者也通过神经网络进行了大气廓线反演的尝试。鲍艳松 等 (2017)利用来自美国威斯康星大学卫星气象合作研究所(CIMSS, Cooperative Institute for Meteorological Satellite Studies)提供的全球大气晴空样本训练数据,通过辐射传输模式得到 GIIRS 的模拟亮温,经由单隐层 BP (Back Propagation)神经网络分别训练了中国区域和全球范围的大气温度反演模型,发现中国区域的反演精度高于全球范围的精度,在中国区域对流层和平流层温度反演的 RMSE 分别为 0.846 和 2.020 K。利用 GIIRS 的实际观测资料,Cai 等 (2020)通过以 ERA-Interim 再分析数据为真值建立 BP 神经网络,训练得到了一个针对我国华北平原陆地地区晴空条件下的 ANN 反演算法,其对流层温度相对于真值(ERA-Interim)的 RMSE 小于 1 K,而相对湿度 RMSE 小于 10%,超过了 AIRS 廓线产品相对于同样真值的准确度。Huang 等 (2021a)利用 GIIRS 在印度地区的观测数据,分别使用一维变分的物理反演算法和神经网络算法进行温度反演,并根据两种算法在不同层次上反演精度提出了 ANN 与 1D-Var 相结合的温度廓线反演算法,得到了比 GIIRS 业务温度产品更高的反演精度。在湿度反演方面,Huang 等 (2021b)提出了使用卷积神经网络(CNN)对 GIIRS 的观测亮温中波红外通道观测亮温以 ERA5 大气廓线的模拟亮温光谱作为真值进行训练订正,并以订正后的亮温光谱作为一维变分物理反演算法的输入数据,在印度地区获得了比传统的物理反演算法更高的湿度反演精度。通过这些对 GIIRS 的反演研究中可以发现,神经网络已经成为了卫星高光谱反演应用的重要手段之一,且反演精度具有较强的局地性特征。与此同时,GIIRS 相比于传统的极轨卫星高光谱探测仪器的一个重要优势是对同一区域的连续观测,尽管在(Huang 等., 2021b)的研究中引入了中波红外通道的时间观测序列作为 CNN 的输入,但是其仅作用在对于观测亮温的订正方面,并没有直接参与反演过程。GIIRS 在同一区域连续观测所包含的时间变化信息对于大气廓线反演效果的影响也是一个值得研究的问题。

1.2.3 卫星反演大气水平风场的研究

准确的四维风场信息对于大气系统的观测和数值天气预报应用都具有重要的意义和价值。世界上最早通过卫星观测来反演大气运动矢量(AMV, Atmospheric Motion Vectors)的研究工作可以追溯到上个世纪 70 年代早期(Menzel, 2001; Hubert 和 Whitney, 1971; Leese 等., 1971)。随着卫星遥感观测技术的不断发展,利用气象卫星对于同一地区的连续观测来反演 AMV 的算法也得到了广泛的发展和使用(Velden 等., 2005)。在业务上反演风场的惯常方法是通过连续的三幅静止卫星成像进行特征提取和追踪(Daniels 等., 2000; Velden 等., 2000)。其中对于云覆盖的区域,通常采用可见光和长波红外通道来追踪云的移动,得到“云导风”(Velden 等., 1998);而对于晴空区域,则采用对于水汽敏感的通道来追踪水汽的移动变化,从而得到“水汽导风”(Velden 等., 1997)。在夜间无法使用可见光通道的时段,也有研究采用 $3.9\mu\text{m}$ 的短波红外通道来反演低层云导风(Dunion 和 Velden, 2002; Daniels 等., 2002)。对于静止卫星难以有效覆盖的极地地区,可以通过大约 100 分钟观测间隔,且具有较大重复观测面积的极轨气象卫星利用类似的算法得到高纬度的 AMV 产品。例如 Key 等 (2003)通过利用搭载于 NASA 的 Terra 和 Aqua 极轨卫星上的 MODIS 在极地地区的 1 km 分辨率红外窗区和水汽通道观测,在 30 天的研究时段内每日每极地获得了约 25000 个经过质量控制的风矢量。

在追踪确定目标的位移矢量之后,将对捕捉到的每个运动矢量进行一个定高过程来得到最终的 AMV 产品。对于 AMV 的定高通常依据的是对于所追踪对象(云或者水汽)所处于的气压层的估计(Velden 等., 2005)。对于不透明云的云导风定高,传统方法是利用数值模式预报的温度廓线与卫星红外通道观测的窗区亮温信息进行匹配,找到云顶亮温与温度廓线最为匹配的高度层作为 AMV 的高度层(Le Marshall 等., 1994; Schmetz 等., 1993)。对于半透明卷云有关的风场定高,由于红外窗区通道观测到的一部分辐射来自云下的背景,因而需要采用多通道结合的方法来确定云导风的高度(许健民 和 张其松, 2006),其中比较经典的方法有 Szejwach (1982)提出的结合水汽和窗区通道的“水汽截距法”和 Menzel 等 (1983)利用长波红外窗区通道与 CO_2 通道相结合的 CO_2 切片法等。对于晴空水汽导风则一方面通过计算示踪目标的有效亮温进而在数值预报的温度廓线上找到最佳层次(Velden 等., 1997),也可利用局地大气廓线的计算得到的相应水汽通道

辐射贡献函数（或权重函数）的峰值高度信息来确定(Daniels 和 Bresky, 2001)。然而，尽管伴随着卫星成像仪观测通道的不断增加带来了定高算法的持续发展，由于卫星观测到的辐射是来自于对流层内某个具有厚度的气层而非特定的某个等压面，研究表明 AMV 的定高仍然是卫星风场反演误差的主要来源(Velden 和 Bedka, 2009)。伴随着卫星高光谱红外大气探测的发展，风场定高的问题可以通过追踪高分辨率的湿度垂直廓线中的特征变化来得以改善(Menzel 等., 2018)。例如，Santek 等 (2019)通过高光谱红外探测仪 AIRS 在极地地区观测的高分辨率水汽和臭氧廓线信息，并利用极轨卫星在高纬度地区的连续覆盖观测，成功地反演得到该地区的三维大气运动矢量，该产品的不确定性主要是来自湿度廓线反演的误差。然而，由于极轨卫星在中低纬度没有对于同一地点的连续观测，所以该方法的应用目前仅局限于高纬度极地地区。

基于卫星反演得到的 AMV 产品已在天气分析诊断以及数值天气预报的资料同化方面体现出了其重要的价值(Velden 等., 2017, 2005, 1998; 许健民 和 张其松, 2006)。通过将来自 GOES-8 的 AMV 同化进入美国地球流体力学实验室 (GFDL, Geophysical Fluid Dynamics Laboratory) 飓风预测模式，使该模式存在的偏西路径预报偏差在超过 100 个个例中得到了修正(Soden 等., 2001)。Pu 等 (2008) 利用中尺度预报模式 WRF 同化 GOES-11 快速扫描的 AMV 产品，发现其对飓风强度和降水的预报都有改进作用。伴随着观测仪器的发展和风场反演算法的改进，具有更高时间和空间分辨率的 AMV 产品能够更好地捕捉中尺度流场特征，从而为热带气旋尺度 (TC-scale) 的流场预报提供更多有用的信息(Velden 等., 2017)。许多学者将高分辨率的风暴尺度 AMV 信息加入到飓风中尺度预报模式 HWRF 进行了相关的同化试验，得到了许多有益的结论(Li J 等., 2020; Zhang S 等., 2018)。除了静止卫星的 AMV 之外，极轨卫星对于风场的反演对于测站分布稀疏的极地地区也具有非常重要的价值(Francis, 2002)。通过在 ECMWF 的四维变分同化系统中同化来自于 MODIS 反演的风场，发现模式对于北半球位势高度场的预报有显著的提升，并对全球的中期天气预报具有改进作用(Bormann 和 Thépaut, 2004; Key 等., 2003)。

我国的科学家从 20 世纪 80 年代开始利用卫星数据从事大气风场的反演和应用工作，并通过大量的个例研究，于 1997 年提出了用红外和水汽两个通道为云

导风定高的算法(许健民 等, 1997)。国家卫星气象中心(NSMC)又在此之上开发出了针对我国静止气象卫星业务化反演 AMV 的逐步质量控制方案(Xu 等., 2002)。王振会 等 (2004)将傅里叶相位分析技术应用于高时间分辨率的卫星导风, 解决了卫星快速扫描导风的“亚像素尺度位移”问题。朱平等 (2007)在此基础上发展了傅里叶相位分析与最大相关法相结合的 TCFM(Technique based on combination of Fourier phase analysis and maximum correlation)方法, 并在中尺度数值模式中进行了同化应用(王振会 等, 2009)。自从 2005 年 6 月风云二号 C 星的卫星反演风产品正式投入业务应用以来, 我国的风云系列卫星风矢量产品也被广泛应用到数值天气预报和天气分析之中(许健民 和 张其松, 2006)。周兵 等 (2002)在针对 1998 年夏季长江流域大暴雨的研究中, 将卫星气象中心的高空风产品加入同化, 发现其能有效地改善高空急流强度的描述进而改进降水模拟的结果。国内很多从事台风数值预报研究的学者也针对台风过程开展了一系列卫星风同化试验, 发现卫星风资料对客观分析风场的订正可以有效地改进台风路径和强度的预报质量(刘瑞 等, 2012; 王栋梁 等, 2005; 庄照荣 和 薛纪善, 2004; 张守峰 和 王诗文, 1999a, b)。除了在数值模式中的同化应用之外, 卫星风资料自身的特征也被广泛用于台风中心定位、中小尺度系统研究、以及对流层上部环流特征的描述等多个研究领域(侯青 和 许健民, 2006; 王萍 等, 2005; 刘启汉 和 陈受钧, 2004; 刘正光 等, 2003; 方翔 等, 2000)。

利用静止轨道高光谱大气探测反演风场的算法最初是由美国 CMISS 的科学家 Velden 等 (2004)基于静止轨道高光谱探测仪 GIFTS (Smith W 等., 2002)的模拟数据提出的。该方法首先利用静止轨道高光谱探测数据反演得到垂直方向处于固定层次上的三维湿度分析场, 再将连续时刻的三维水汽分布以类似于分布在不同的定常层次上的水汽分析场的形式作为风场追踪的“图像”, 进而得到三维的水平风场(如图 1.2 所示)。由于 GIFTS 的水汽反演结果处于若干固定的等压面上, 追踪得到的风场也在同样的层次上, 这在极大程度上减小了传统 AMV 产品在定高过程中带来的误差, 同时也能够获得 AMV 所不具备的垂直风廓线。然而, GIFTS 由于种种原因并没有被发射和应用, 这一算法也没有在真正的观测数据中得到实现。如今随着我国新一代静止卫星风云四号所搭载的静止轨道红外高光谱探测仪 GIIRS 投入业务使用, 从卫星观测反演高频次、高垂直分辨率的三维大气

风场再次成为了可能。如何充分利用高分辨率的 GIRS 高光谱观测数据实现高精度三维大气风场的反演，也是本研究的重点内容之一。




图 1.2 利用 GIFS 模拟得到的风场，用于阐述未来静止卫星高光谱探测仪可得到的风场密度和垂直分布（引用自 Velden 等., 2004）

Figure 1.2 Simulated GIFS winds illustrating the data density and vertical distribution that could be achievable from geostationary hyperspectral sounders of the future. (Cited from Velden et al., 2004).

1.2.4 静止卫星高光谱大气探测的预报应用研究

卫星红外高光谱大气探测在天气预报业务上被广泛应用于天气预报业务和强天气的短临预警(Menzel 等., 2018)。卫星红外探测器在红外窗区的多个水汽和二氧化碳的弱吸收带观测可以提供大气对流层低层热力学性质及其演变信息(Sieglaff 等., 2009)。高光谱红外探测器能够提供高垂直分辨率的大气热力学廓线，

能够为中尺度天气系统的短时预报和强风暴的预警提供例如大气稳定性、大气边界层结构和风暴相关指数等关键信息(Li J 等., 2012)。例如, Sieglaff 等 (2009)指出基于高光谱红外探测反演得到的 800 和 600 hPa 之间的相当位温差异能够指示雷暴发生的趋势, Li J 等 (2012)的研究发现 AIRS 在晴空区域反演的高垂直分辨率大气廓线, 能够准确计算出如 CAPE 和 LI 等大气稳定性指数, 而这些指数能够有效地在对流发生前的环境中给出对流预警并降低虚警率。Weisz 等 (2015)指出将业务运行的多个极轨卫星高光谱大气探测, 包括 AIRS、IASI 以及 CrIS 等进行联合应用, 可以得到大气温湿廓线的时间序列, 进而获得可用于局地强风暴预警的关键大气环境变化信息。然而, 由于极轨卫星的观测频次较低, 多仪器联用后的时间分辨率仍然较粗, 不利于反映与快速发展的中小尺度系统相关的环境变化特征。

与极轨卫星相比, 能够对同一区域实现连续观测的地球静止轨道卫星能够对地面同一区域进行连续观测, 其所搭载的多通道高分辨率成像仪, 例如搭载于日本葵花 8 号卫星上的 AHI (Advanced Himawari Imager, Bessho 等., 2016)、美国 GOES-R 系列卫星搭载的 ABI (Advanced Baseline Imager, Schmit 等., 2017)、以及我国风云四号卫星的 AGRI (Advanced Geosynchronous Radiation Imager, Yang J 等., 2017), 其观测数据和产品被广泛用于中小尺度天气系统的短临预报。Roberts 和 Rutledge (2003)利用红外窗区通道观测的云顶亮温降温率可以早于地面雷达的观测实现对初生强对流系统的预报。Mecikalski 和 Bedka (2006)提出使用云顶亮温最大降温率结合不同通道观测亮温差来识别对流初生的 SATCAST (Satellite Convection Analysis and Tracking)短临预报模型。Sieglaff 等 (2011)利用 GOES 成像仪高频次观测提出了基于“盒状平均”的红外云顶降温率和云顶相态产品相结合的 UWCI (University of Wisconsin Convective Initiation)对流初生预报模型。伴随着机器学习算法的发展和大量观测数据的获得, 许多学者针对不同地区发展了基于静止卫星观测和机器学习相结合的短临预报模型, 有效地提升了对流初生、热带气旋以及短时强降水的短临预报水平(Boukabara 等., 2019)。Mecikalski 等 (2015)应用逻辑回归与随机森林方法将 RAP (Rapid Refresh)数值预报场与 GOES-R 静止卫星观测的云顶亮温变化信息相结合, 构建了能够提前 0-1 小时预报对流初生的概率模型。Liu Z 等 (2019)利用随机森林训练了基于葵花 8 号的 AHI 高

分辨率观测与 GFS (Global Forecast System)数值预报场相结合的东亚地区对流初生预报模型 SWIPE (Storm Warning In Pre-convective Environment)。尽管高水平分辨率、高时间分辨率的静止卫星成像观测能够反映云顶变化特征,但是受到光谱分辨率的限制而缺乏足够的大气垂直环境信息。Mecikalski 等 (2015)的研究发现,在预测模型中引入 NWP 数据能够提供与对流环境有关的大气背景信息,从而降低单独由静止卫星观测的 SATCAST 模型的虚警率。Liu Z 等 (2019)通过比较 SWIPE 模型中不同的预报因子的重要性评分,也发现来自 NWP 的 K 指数、CAPE 等大气环境变量有较高的重要性排名。依此看来,能够以高时间分辨率提供三维大气信息的静止卫星高光谱大气探测将能够为现有的对流监测和短临预警提供重要的大气热力学和动力学环境信息。

搭载于风云四号静止卫星上的 GIIRS 高光谱大气探测仪,兼具高时间分辨率和高光谱分辨率的双重优势,既能弥补极轨高光谱探测在时间分辨率上的不足,又能提供高垂直分辨率三维大气信息(董瑶海, 2016)。已有的研究通过模拟的静止卫星高光谱观测数据在天气过程的应用发现,相比于来自 ABI 成像仪的大气稳定度产品,静止轨道高光谱探测能够更为准确地描述大气温度和湿度廓线的变化,进而更好地反映大气稳定度的变化,从而更早地表现出能够指示对流发生的中尺度大气环境特征(Li J 等., 2011; Schmit 等., 2009)。Li Z 等 (2018)通过快速区域观测系统模拟试验(OSSE, Observing System Simulation Experiment)发现静止轨道的高光谱红外探测能够在现有的极轨高光谱探测基础上对局地强风暴的预报产生更大的正贡献。Wang 等 (2021)利用混合观测系统模拟试验(Hybrid OSSE)发现静止轨道高光谱探测在两个局地强风暴个例中对大气温度、湿度以及降水的预报都体现了改进作用。随着来自 FY-4A GIIRS 的实际观测资料的获取,以及 FY-4B GIIRS 在时间和空间分辨率上的提高,将会对我国的对流短临预警和中尺度天气系统研究工作贡献更大的价值。

1.2.5 静止卫星高光谱探测的发展与应用前景

以 W. Smith 为代表的美国科学家于上世纪 90 年代提出了一个静止卫星高光谱大气探测仪 GHIS (GOES High Resolution Interferometer Sounder)的理论设计,并提出了反演高垂直分辨率的大气热力学廓线和三维风场的设想(Smith W 等.,

1990)。在本世纪初,美国的 NASA 等多家机构合作设计了一个静止轨道高光谱傅里叶分光成像仪 GIFTS (Geostationary Imaging Fourier Transform Spectrometer),最初计划于 2005 年发射使用。Smith W 等 (2002)提出了其在三维风场反演、高时空分辨率大气廓线反演以及观测对流层大气污染物传输方面的潜在效用。围绕着 GIFTS 的一系列理论研究和地面试验也证实了静止轨道高光谱探测在三维大气监测,以及对局地强风暴和热带气旋预报的应用前景(Smith W 等., 2009; Zhou D K 等., 2007; Smith W 等., 2006), 然而该仪器并没有被搭载和使用。

我国的 FY-4A 卫星成功搭载的 GIIRS 是世界上首个搭载于静止轨道气象卫星的红外高光谱大气探测仪,能够提供高时间分辨率的三维大气探测信息,开启了静止气象卫星的新纪元。Yin 等 (2021)通过将台风“玛利亚”期间的 GIIRS 加密观测在数值模式中进行同化,发现同化更高时间分辨率的 GIIRS 观测能够对台风的路径和强度预报精度进一步提升。Di 等 (2021)的研究也提出了更高的空间分辨率对于高光谱红外探测仪在捕捉中小尺度大气湿度变化的重要作用。随着风云四号 B 星的成功发射,其所搭载 GIIRS 的空间分辨率由 16 km 提高到 12 km,时间分辨率也将通过双星联用和更多的适应性探测而获得进一步的提高。

世界气象组织 WMO 在对全球观测系统的展望中指出,到 2040 年全球应有至少 6 个同时搭载先进成像仪和高光谱探测仪的静止轨道气象卫星。除了我国的风云系列卫星以外,EUMETSAT 计划在静止轨道 MTG(Meteosat Third Generation)卫星上的红外高光谱探测仪将在 2024 年投入使用(Holmlund 等, 2021),日本也计划在葵花 8 号和 9 号的后续卫星上搭载静止轨道红外高光谱探测仪(Okamoto 等., 2020),美国的 GeoXO (Geostationary and Extended Observations)探测器也在计划之中(Adkins 等., 2021)。随着未来的静止卫星红外高光谱大气探测仪在时间和空间分辨率上不断提高,以及对不同经度范围的更完整覆盖,将对全球大气三维观测和数值天气预报的发展起到重要的推动作用。

综合上述的研究进展不难发现,高光谱分辨率的卫星红外大气探测能够获得高垂直分辨率的大气热力学廓线,进而反映与强天气发生相关的大气稳定度信息;高时间分辨率的静止卫星成像仪通过对区域内大气活动进行连续观测,能够实现中小尺度天气系统的短临预警。搭载于静止气象卫星上的红外高光谱探测仪能

能够在一定程度上兼具二者的优势,在提供高垂直分辨率的三维大气信息的同时又能提供高时间分辨率的连续观测。以 GIIRS 为代表的静止卫星高光谱大气探测在大气热力学反演、三维风场反演、数值天气预报和强天气短临预警等多个领域具有非常重要的应用前景,并已是全球气象机构在卫星遥感探测上的重要发展方向。

1.3 研究目的与研究内容

1.3.1 拟解决的科学问题

通过对前人已有研究工作的总结和学习,本研究拟解决以下几个科学问题:

(1) 如何基于传统的极轨红外高光谱探测仪和静止卫星成像仪各自在大气观测和预报应用方面的优势和缺陷,建立能够融合二者优势的联合反演算法,增强现有极轨卫星高光谱大气探测对低层大气廓线的反演能力。

(2) 如何基于国际上首个静止卫星高光谱探测仪 GIIRS 的实际观测数据,以及其相对于极轨卫星探测具有高时间分辨率和连续观测的特点,建立充分利用时间变化信息的大气温湿廓线反演模型。

(3) 如何基于 GIIRS 观测对大气中的水汽垂直分布特征与时间变化的探测能力,通过高时间分辨率 GIIRS 观测建立四维风场反演模型,并研究风场反演精度与 GIIRS 探测的时间分辨率之间的联系。

(4) 如何利用静止卫星高光谱大气探测所特有的兼具高时间分辨率和高光谱分辨率的优势,与高水平分辨率的成像观测进行联用,建立能够早于雷达观测识别对流初生的短临预警模型。

1.3.2 研究内容

针对上述的研究目的,本论文的研究内容包括以下四个方面:

(1) 极轨卫星探测与静止卫星成像的联合反演。

将现有的极轨卫星高光谱反演数据,与同区域的高分辨率静止卫星成像观测进行时空匹配。通过选取高分辨率成像仪在极轨卫星探测视场内的晴空像元以及包含大气廓线信息的特征通道,建立联合反演改进模型,并在实际的对流天气预报中进行应用。

(2) 基于 GIIRS 观测的温湿廓线反演以及时间变化信息的影响。

在 GIIRS 长波及中波通道中选取能够代表不同层次大气热力学信息的特征通道,利用这些通道的观测资料结合 ERA5 再分析数据的大气廓线,通过机器学习方法建立具有高准确性和高效率的大气廓线反演算法,并通过 GIIRS 在台风“玛利亚”期间的 15 分钟分辨率加密观测资料,研究高光谱红外探测的时间变化信息在大气温湿廓线反演中的作用和影响。

(3) 基于 GIIRS 观测的四维风场反演以及时间分辨率的影响

利用 GIIRS 在台风“玛利亚”期间的 15 分钟分辨率加密观测资料,通过高光谱红外观测以及时间变化信息,结合 ERA5 再分析数据的四维风场资料,建立高精度的四维风场反演模型。通过建立不同时间分辨率的反演模型并对精度进行对比评估,讨论不同的时间分辨率对风场反演的影响。

(4) 静止卫星高光谱探测与成像观测相结合的短临预报应用

对现有的基于高分辨率卫星成像观测的对流初生预报模型 SWIPE 进行优化,通过机器学习训练改进现有模型对于对流初生和发展的预报预警能力,在实际的对流天气预报中实现定量应用。在预报因子中加入以 ERA5 作为代用资料的高时间分辨率静止卫星高光谱大气探测数据,以 OSSE 方式评估其在对流初生预警模型中的改进贡献。

1.4 研究的创新点

本文的研究围绕极轨红外高光谱大气探测与静止卫星观测的联合应用,结合国际上首个静止轨道高光谱大气探测仪 GIIRS,开展了包括大气温湿廓线和三维风场的反演,以及短临预报应用等方面的研究,主要有以下几点创新:

(1) 利用多源数据融合以及神经网络训练框架,实现了极轨卫星大气探测与静止卫星成像观测的联合反演应用,并在晴空和部分有云的条件下实现了对极轨卫星高光谱反演大气廓线的改进,尤其是低层大气,并定量分析了静止卫星成像观测对改进大气廓线反演准确度的影响。低层大气温湿廓线反演精度偏低一直是卫星反演的弱点,该研究一定程度上缓解了该弱点,提高了卫星反演的适用性。

(2) 利用静止卫星红外高光谱探测仪 GIIRS 在一次台风个例的加密观测建

立了温湿廓线反演模型，定量讨论了 GIIRS 高光谱观测亮温的时间变化信息对于大气廓线反演精度的影响。相比较于极轨卫星的大气廓线反演，基于静止卫星高光谱探测器的大气廓线反演能够给出大气随时间的演变特征。

(3) 利用加密观测期间 GIIRS 的高时间分辨率观测信息，结合神经网络训练，建立了高精度的四维风场反演模型，并通过不同类型的分析场和探空数据对模型准确度进行了验证。利用不同时间分辨率的数据讨论了不同时间分辨率观测对风场反演精度的影响。该研究相比较于传统的基于成像仪的风场反演，具有更高的垂直分辨率，也不会因为气压高度指定带来误差。目前国际上没有类似研究。

(4) 对基于高分辨率静止卫星成像观测的对流初生预警模型 SWIPE 进行了优化。通过 ERA5 的大气温湿廓线模拟静止卫星高光谱大气探测的反演产品并加入改进的 SWIPE 模型中，分析了其在不同的训练框架之下对不同面积大小的强对流样本的短临预警能力。

1.5 章节安排

本文的章节安排如下：

第一章：引言。介绍了选题的背景和意义，以及国内外相关领域的研究进展和存在的不足，给出了论文的研究目的、研究内容以及创新点。

第二章：极轨卫星探测与静止卫星成像的联合大气廓线反演。本章利用来自极轨卫星 Suomi-NPP 的大气廓线反演数据 NUCAPS，与来自 GOES-16 的 ABI 的高频次静止卫星观测，以及地面中尺度分析数据 RTMA 相融合，利用神经网络建立了能够在晴空和部分有云条件下改进对流层低层大气温湿廓线反演精度的联合反演改进模型，讨论了多源数据以及 ABI 不同通道在改进大气反演中的相对贡献。在实际的探空观测和对流天气个例中进行了应用，并分析了模型的改进效果。

第三章：基于静止卫星高光谱探测的大气温湿廓线反演。利用国际上首个静止卫星红外高光谱大气探测器 GIIRS 的观测资料，选取对于不同层次大气温度和湿度具有敏感性的长波和中波红外通道，以 ERA5 再分析数据的大气温湿廓线作为训练真值，建立基于多层神经网络的大气温湿廓线反演模型。并利用 GIIRS 在台风“玛利亚”期间的 15 分钟加密观测资料，通过将所选通道观测的时间变化信息加入模型，讨论时间变化信息对于大气温湿廓线反演精度的影响。

第四章：基于静止卫星高光谱探测的四维风场反演。利用静止卫星红外高光谱探测仪 GIIRS 在台风“玛利亚”期间的加密观测资料，选取对不同层次温湿度特征有代表性的通道，通过高光谱观测资料以及对应的时间变化特征，结合 ERA5 再分析数据的风场廓线作为训练真值，建立基于神经网络的三维风场反演模型。通过使用不同时间分辨率的模型进行训练，讨论时间分辨率对于风场反演精度的影响。

第五章：静止卫星高光谱大气探测与高分成像观测的联合预报应用。将已有的基于高分辨率静止卫星成像仪观测的 SWIPE 模型框架进行优化，并利用再分析数据 ERA5 的温湿廓线产品模拟静止卫星高光谱大气探测数据加入到模型的训练因子中，讨论了高分辨率静止卫星高光谱探测在对流初生和短临预警中的作用。

第六章：结论与讨论。对全文的研究结果进行总结讨论，并针对现有研究存在的不足对进一步的研究方向提出展望。

第2章 极轨卫星探测与静止卫星成像的联合大气廓线反演

2.1 引言

大气温度和湿度的垂直廓线包含并反映了重要的大气环境信息,特别是包括但不限于边界层的低层大气温湿廓线,因为与人类生产生活关系密切,且是充满能量、动量和物质交换的地方,其特征与演变规律对天气预报和气象研究至关重要。在对低层大气的观测方面,相比于业务上常规使用的地面常规观测与雷达观测,基于卫星大气探测得到的反演数据具有更好的空间覆盖范围,特别是在复杂下垫面以及人迹罕至的地区等。由于受到地表发射率和地面温度的复杂作用以及较粗的空间分辨率的限制,现有的卫星大气探测反演产品通常存在低层廓线反演准确度降低的情况。美国大气与海洋管理局(NOAA)的官方大气联合处理算法(NUCAPS)能够提供在非降水云条件下的大气垂直廓线反演数据。该数据通过处理搭载于联合极轨卫星系统(JPSS)的Suomi-NPP和NOAA-20两颗卫星上的跨轨道红外大气探测器(CrIS)和先进微波探测器(ATMS)的观测数据(Goldberg等.,2013),能够给出垂直方向上在马里兰大学(UMBC)辐射传输模式确定的100个标准气压层上的温度和湿度产品(Gambacorta和others,2013),为世界各地的预报员和气象研究者提供了非常重要的观测信息。近年来,相关领域的专家学者们对于NUCAPS大气温湿廓线产品的精确度和可用性开展了一系列的检验和应用试验(Nalli等.,2018,2013;Feltz等.,2017;Sun B等.,2017;Smith A等.,2015)。特别是在重点关注局地强对流系统(LSS)的灾害性天气试验台(HWT)春季实验中,预报员发现NUCAPS反演产品有助于填补现有大气探测系统中的空间和时间空白,但也报告说反演廓线准确度在近地面存在较大的不确定性。这种不确定性可能会导致大气热力学结构的错误判断,并限制NUCAPS探测和其衍生产品的进一步应用(Michael和Kristin,2017)。例如对流有效能量(CAPE)和抬升指数(LI)等在风暴预报和预警过程中有重要意义的物理量都会由于不准确的低层大气廓线而带来明显的误差。因此,预报员经常不得不根据其他信息和他们的经验对于NUCAPS在低层大气的反演结果进行手动修改订正,这在业务工作中既费时又不客观。

卫星反演的低层大气廓线,其精度可通过与包含低层大气信息的其他观测数据进行融合来加以改进。传统的 GOES 大气探测仪反演算法即采用了这样的方法,通过使用地面温度和露点的分析场来实现低层大气廓线的处理(Hayden, 1988)。Smith W 等 (2020)的研究发现,通过融合极轨卫星高光谱探测和静止卫星多光谱探测产品,可以提高数值预报产品在灾害性天气预报中的准确性。对于 NUCAPS 数据, Bloch 等 (2019) 的研究证明,通过融合 NUCAPS 廓线和地面观测,可以改善 NUCAPS 产品对地基对流有效位能 (SBCAPE) 的低估。NUCAPS 团队也提出了一种自适应的校正方案,通过采用实时中尺度分析数据 (RTMA, De Pondecia 等., 2011)实时对地面温度和露点的观测,创建一个充分混合的边界层用以替换 NUCAPS 的低层廓线结果(Michael 和 Kristin, 2017)。这个修改后的 NUCAPS 版本受到了预报员的好评,因为它比原来的 NUCAPS 探测有更好的精度,并且节省了预报员手动订正廓线的时间。然而,由于该校正方案是基于边界层充分混合的假设,因此有两个重要问题有待解决: 1) 边界层并不总是充分而且完全混合的状态,尤其是在早上和晚上,因此很难以确定在垂直方向上应校正到多高的层次; 2) 卫星反演精度在低层的降低的并不仅局限于实际的边界层内,这一点将会在后面的讨论中具体证明和阐述。在这样的情况下,需要一种更客观的方法来改进低层大气的反演精度,从而提高 NUCAPS 产品在天气预报,特别是对流过程预报中的应用质量。

发射于 2016 年 11 月的 GOES-16 静止卫星是美国新一代地球同步运行环境卫星 (GOES-R 系列) 的第一颗卫星。尽管 GOES-R 系列卫星没有像 CrIS 那样的高光谱红外探测仪来提供具有高垂直分辨率的大气廓线,但 ABI 能够提供关于低层大气特征的有用信息。ABI 各通道的权重函数表明,四个长波窗口光谱通道 (11/13/14/15) 和 CO₂ 通道 (16) 对低层大气敏感,因为它们的权重函数在地表附近达到峰值(Schmit 等., 2017)。此外,由于 ABI 提供了具有高时间分辨率的连续观测,它能够识别低层大气热力学特征的时间变化。此外,ABI 的高空间分辨率使得对于 NUCAPS 视场 (FOR, Field-of-Regard) 内部空间特征的观测成为可能。虽然光谱分辨率的限制使得单独使用 ABI 很难提供具有高垂直分辨率的大气剖面(Schmit 等., 2019, 2018)。但来自 ABI 的信息可以帮助改进低层大气的 NUCAPS 反演产品。与此同时,同化了来自常规观测、中尺度观测以及

飞机、船舶等多种观测信息的逐小时、2.5 公里水平分辨率的实时中尺度分析场 RTMA 能够提供高精度的地面温度与湿度观测信息。如果能将这些数据与 NUCAPS 的反演廓线进行科学而有效的融合, 对于获得高精度的低层大气温湿廓线具有重要的科学意义和应用价值。

深度神经网络(DNN)是在人工神经网络(ANN)的基础上发展起来的, 在输入和输出层之间有多个隐藏层的一系列多层神经网络的总称(Bengio, 2009; Hinton, 2006)。DNN 在计算机视觉、生物信息处理和语音识别等领域取得了许多的成功(Tao 等., 2018, 2016; Liu Y 等., 2017; Liu J 等., 2014; Seltzer 等., 2013; Dahl 等., 2011)。在大气科学领域中, Boukabara 等(2019)指出 DNN 可以应用于数据融合、反演、数据同化, 甚至对流临近预报等多个方面, 在处理大量数据时, DNN 算法是一种强大且极其高效的工具。近年来, 基于 DNN 的算法在卫星观测产品的偏差校正方面取得了许多成果, 如 Tao 等(2016)成功应用 DNN 减少卫星降水产品的偏差和误报, 以及 Zhou 和 Grassotti(2020)的工作利用 DNN 实现了针对 MiRS 系统中辐射偏差校正的新方法。在这些工作中, DNN 在处理非线性关系方面表现出良好的能力, 并且在生成具有良好准确性的预测模型方面表现出了很高的效率。这些特性使其非常适合被用来融合多源数据集以改善 NUCAPS 对于低层大气廓线的反演精度, 使其更加适用于高影响天气过程的临近预报和预警。

本章的研究主要致力于解决两个问题:

1. 如何通过使用 DNN 融合多源数据来改进低层大气 NUCAPS 反演精度?
2. 高分辨率静止卫星观测资料和地面温湿观测资料分别对 NUCAPS 反演精度的改进有什么影响?

在本章的研究中, 低层大气的定义是 σ 坐标中 0.7 至地面之间的层次, 即大约是平原地区 700 hPa 气压层与地面之间的层次。本章的研究内容主要使用 ERA5 再分析数据作为机器学习算法的真值数据, 通过神经网络的应用得到精度改进的、更适用于临近预报的低层大气反演产品, 从而更好地应用于对于局地强对流事件的短临预报和预警。除此之外, 静止卫星成像观测与极轨卫星探测数据在大气定量反演中的联合应用以及各自的相对贡献, 对于新一代静止气象卫星潜在的同平台多仪器的观测数据联用具有重要的意义。

2.2 研究数据

2.2.1 基于 CrIS/ATMS 的 NUCAPS 反演数据

本章使用的大气反演数据是来自搭载于美国极轨卫星 Suomi NPP (The U.S. Suomi National Polar-Orbiting Partner-ship)上的高光谱红外探测仪 CrIS (Cross-track Infrared Sounder) 和微波探测仪 ATMS (Advanced Technology Microwave Sounder) 的观测信息, 经由美国大气与海洋局(NOAA)官方的 NUCAPS (NOAA Unique Combined Atmospheric Processing System) 算法联合反演得到的 EDR (Environmental Data Records)数据。该数据包含了反演得到的云信息(如云量与云顶气压)、地面信息(如地面温度与地面气压), 以及温度、水汽以及其他示踪物气体(如甲烷、二氧化碳等)在大气中的垂直分布廓线。

该反演数据的观测来源之一是红外高光谱探测仪 CrIS, 作为拥有 2211 个探测通道的傅里叶变换光谱仪, 其标称光谱分辨率对应三个红外光谱区间, 分别对应于长波红外 ($650\text{-}1095\text{ cm}^{-1}$), 中波红外 ($1210\text{-}1750\text{ cm}^{-1}$), 以及短波红外 ($2155\text{-}2550\text{ cm}^{-1}$)。在空间分辨率上, 视场大小随卫星天顶角的变化而变化, 在星下点的视场(Field-of-View, 即 FOV)直径为 14 km。图 2.1 所示的是 CrIS 上升轨道的一次跨轨扫描示意图, 其中以 3×3 形式排列的 9 个 FOV 构成一个视野像元(Field-of-Regard, 即 FOR), 星下点 FOR 的大小约为 50 km (Han 等., 2013)。每个 FOR 即对应着 NUCAPS 反演产品的基本空间像元。




图 2.1 CrIS 一次上升轨道对应的地面视场 FOV (实线圆圈或椭圆) 与视野像元 FOR (虚线圆圈或椭圆) 以及几何属性示意图。引用自(Han 等., 2013)。

Figure 2.1 Schematic of A ground cross-track of FOVs (solid circles or ellipses) and FORs (dashed circles or ellipses) and their related geometric characteristics viewed from the satellite on an ascending orbit. Cited from (Han et al., 2013).

同样搭载于 Suomi-NPP 极轨卫星上的微波探测器 ATMS (The Advanced Technology Microwave Sounder)拥有覆盖 23 GHz 至 183 GHz 谱段的 22 个通道 (Weng 等., 2012)。ATMS 的第 1-16 通道被设计用来反演从地面到大约 1 hPa 高度层的大气温度廓线, 而第 17-22 通道用于反演地面至约 200 hPa 高度层的大气湿度廓线(Weng 等., 2013)。在 NUCAPS EDR 产品的处理中, 对于 ATMS 在和 CrIS 的重叠视场中按照 CrIS 的 3×3 FOV 的排列形式, 以其中心 FOV 为匹配标准进行了重采样(Gambacorta 等., 2013), 如图 2.2 所示, 从而得到了用于 NUCAPS 反演算法的结合了红外与微波波段信息的原始观测数据。

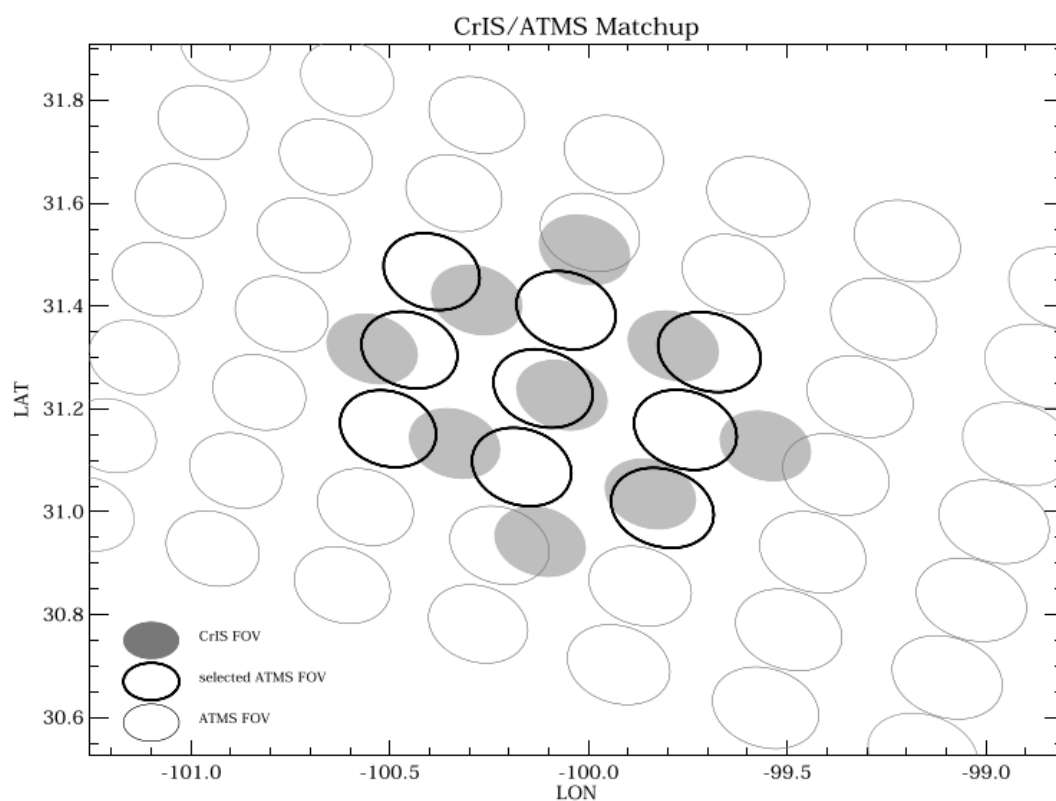


图 2.2 针对一个特定 NUCAPS FOR 中 ATMS 和 CrIS 匹配视场示意图, 其中灰色阴影椭圆代表作为匹配对象组成该 NUCAPS FOR 的 CrIS 视场, 白色加粗黑边框的椭圆代表被选中用于匹配 CrIS 视场的 ATMS 视场, 白色没有加粗边框的椭圆代表扫描中没有被用于匹配当前 NUCAPS FOR 的视场(Nalli 等., 2018)。

Figure 2.2 Schematic of ATMS/CrIS collocation for a specific NUCAPS FOR. The grey shaded ellipses represent the 3×3 CrIS FOVs that composites the NUCAPS FOR. The white ellipses with bold black borders represent the ATMS FOVs that are selected to match-up

with the 3×3 CrIS FOVs, while the white ellipses without bold black borders represent those ATMS FOVs that are not chosen to match-up with the CrIS FOVs (Nalli et al., 2018).

本研究使用了从 2018 年 4 月至 2018 年 6 月在美国 CONUS 区域 ($20^{\circ} \sim 55^{\circ} \text{ N}$, $60^{\circ} \sim 140^{\circ} \text{ W}$) 的 S-NPP 连续三个月的 NUCAPS V1.0 业务化 EDR 数据(Liu Q 等., 2014)。该数据将空间上 3×3 排列的视场内 CrIS 和 ATMS 匹配的观测相结合, 提供在晴空和非降水云覆盖条件下的大气廓线反演。该算法的主要流程如图 2.3 所示, 包括质量控制模块、微波反演模块、两次特征向量回归反演模块、清云模块以及红外物理反演模块等, 其具体算法介绍请参见 Gambacorta 等 (2013)。在垂直方向上, NUCAPS 反演的大气廓线固定于在 0.016 hPa 至 1100 hPa 的 100 个气压层, 分别对应于独立辐射传输模式算法 (Stand-Alone Radiative Transfer Algorithm) 的 100 个标准气压层和 101 个等压面 (Strow 等., 2003; Hannon 等., 1996)。在本章的研究中, NUCAPS 大气廓线作为需要改进的对象, 被用作神经网络的主要预报因子。尽管这项研究关注在低层大气, 700 hPa 至 200 hPa 之间的层次也被包含在研究对象之中, 且在后文的研究中同样得到了一定程度的改进。除此之外, 在训练中我们也引入了地面气压的信息, 用于判断相应的等压面是否处于地面以上。对于实际位于地面以下的层次, 在训练中我们假设其为等温和等湿的, 且这些层次上的反演结果不被包含在统计分析之中。由于 NUCAPS FOR 的分辨率很粗 (在星下点约为 50 km), 完全晴空的 FOR 在实际情况下仅占很小的比例, 而 NUCAPS 像元中的很大一部分处于部分有云的状态。本研究的重点是在晴天和部分有云的 NUCAPS 视场条件下改进低层大气的反演准确度。

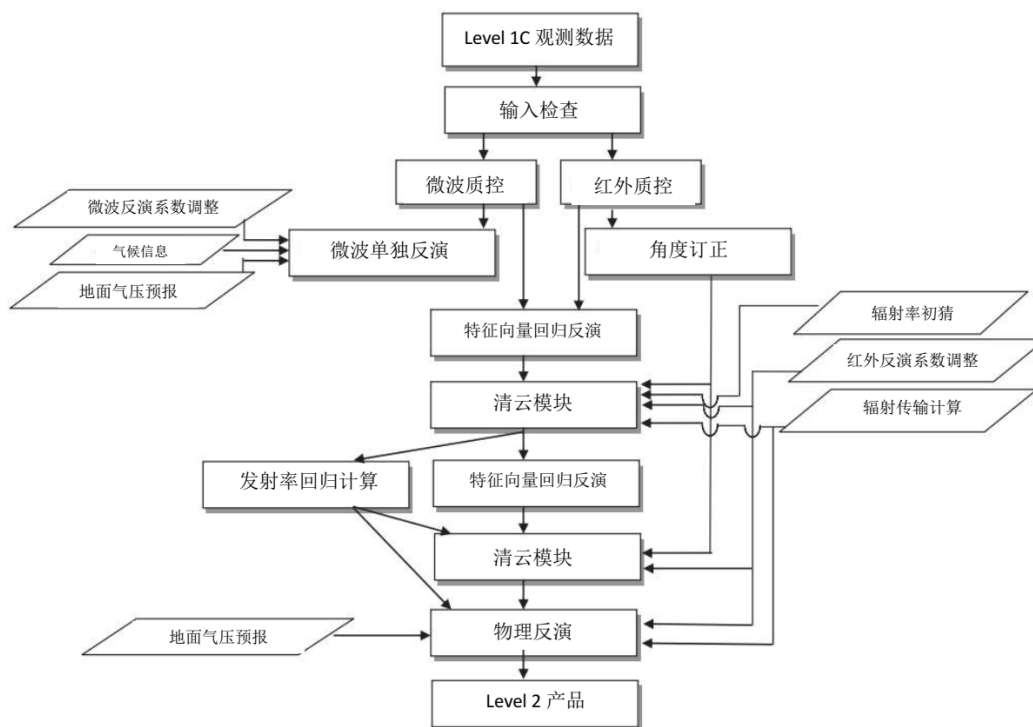


图 2.3 NUCAPS 算法流程图 (翻译自 Gambacorta 等., 2013)

Figure 2.3 Algorithm flow diagram of the NUCAPS System. Translated from (Gambacorta et al., 2013).

2.2.2 静止卫星成像观测 ABI

本章使用的静止卫星数据来自 GOES-16 卫星在 CONUS 区域的 ABI (Advanced Baseline Imager) 快速扫描观测数据。作为新一代 GOES-R 系列卫星搭载的高级基线成像仪,ABI 与以前的 GOES 成像仪相比,功能有了很大改进。首先是 16 通道成像辐射计,比以前的 GOES 成像仪多 11 个通道。ABI 还具有比之前的 GOES 成像仪更精细的空间分辨率(红外通道为 2 公里)和更高的时间分辨率(全圆盘 15 分钟,美国 CONUS 区域 5 分钟,两个独立的中尺度(MESO)区域则仅有 1 分钟)(Schmit 等., 2017)。在 16 个 ABI 通道中,来自 7 个红外通道(第 8、9、10、13、14、15 和 16 通道,即中心波长 6.2、6.9、7.3、10.3、11.2、12.3 和 13.3 μm 通道)的平均晴空亮温以及 NUCAPS 视场内晴空亮温的标准差(STD)在本章的研究中被作为预报因子自变量加入训练。这些通道包含了对应于高/中/低三个不同高度层的水汽通道(通道 8-10),以及三个不同的红外窗区通道(通道 13-15),以及一个 CO_2 通道(通道 16)。正如它们各自的权

重函数所体现的（图 2.4，引用自 Schmit 等., 2017），这些通道要么对低层大气有很高的敏感性，要么包含有关对流层内有关水汽吸收的重要信息，这些信息对于获取高精度的大气反演产品是至关重要的。尽管与 CrIS 和 ATMS 搭载于同一平台的成像仪 VIIRS（Visible Infrared Imager Radiometer Suite）具有更高的空间分辨率，但是该仪器缺少可用于大气反演的水汽通道和 CO₂ 通道(Hillger 等., 2013)，因而没有被用于联合反演应用。除此之外，业务上的 ABI 云检测数据(Heidinger 和 Straka III, 2013)被用来判断 ABI 像元上的观测是否受到云污染。在本章的研究中，针对每个来自 NUCAPS 的视场像元，采用提前于该时间的最近一次 ABI 观测值，用来代表这一视场内从 ABI 观测到的特征。由于 ABI 在 CONUS 区域保持 5 分钟的快速观测，意味着 ABI 和 NUCAPS 之间的观测时间差异不超过 5 分钟。




图 2.4 ABI 红外通道（通道 7-16）在 1976 年美国标准大气条件下(U.S. Standard

Atmosphere, 1976)的星下点权重函数及模拟亮温 (引用自 Schmit 等., 2017)。

Figure 2.4 Weighting functions of the 10 ABI IR channels for the U.S. Standard Atmosphere, 1976 and their simulated brightness temperature at nadir view. (Cited from Schmit et al., 2017)

2.2.3 实时中尺度地面分析产品 RTMA

实时中尺度分析 (RTMA) 是来自于 NOAA/NCEP 的能够准实时提供高分辨率近地面气象条件信息的分析与同化产品, 使用 2-DVar 模式下的 NCEP/EMC 格点统计插值(GSI)系统来同化常规观测和卫星等非常规观测。RTMA 目前同时在四个区域业务运行, 即 CONUS、阿拉斯加、波多黎各和夏威夷国家数值预报数据库 (NDFD) 网格, 同化了来自地面测站、航空常规天气报告 (METAR)、中尺度网络 (Mesonet)、船舶、浮标、潮汐测量仪和沿海海洋自动化网站 (C-MAN) 的观测资料(De Pondecia 等., 2011)。在本章的研究中, 具有 2.5 公里水平分辨率的 CONUS-RTMA 数据集的逐小时 2 米温度和露点分析数据被加入训练集作为两个预测因子, 以提供对于大气廓线反演很重要的近地面大气信息。由于近地表大气热力学与低层大气存在较高的相关性, RTMA 网格化数据有望通过数据融合改进近地面大气廓线的反演准确度。

2.2.4 ERA5 再分析数据

ERA5 是欧洲中尺度天气预报中心 ECMWF 开发的用于接替 ERA-Interim 的第五代再分析数据, 使用了 ECMWF 新升级的 IFS CY41R2 4D-Var 资料同化系统。该系统在垂直方向上有 137 个 sigma/气压混合模式层, 模式顶为 0.01 hPa, 相比于 ERA-Interim, ERA5 具有更高的水平和垂直分辨率, 以及更高的输出频率(Hoffmann 等., 2019; Tarek 等., 2019)。本研究所使用的是插值到从 1 到 1000 hPa 的 37 个固定等压面, 水平分辨率 0.25° , 时间分辨率 1 小时的再分析产品。在本章的训练过程中, ERA5 数据集被用作神经网络的输出值, 以及用于检验反演结果的真实值。需要指出的是, ERA5 是当前在时间、空间分辨率以及准确性上最好的再分析数据集之一, 尽管无线电探空观测作为真实观测更适合被作为模型的训练真值, 但由于其与 NUCAPS 局地通过时间的差异导致可用样本量极少,

不足以达到训练模型所需的数据量,因而本章的研究将 ERA5 的大气廓线视为训练真值,而有限的探空观测作为独立的检验数据。

2.2.5 无线电探空观测

本章中用于检验反演结果的探空数据来源于 NOAA JPSS 所支持的,由 NOAA NESDIS 卫星应用与研究办公室 (STAR) 运行的 NOAA 产品验证系统 NPROVS (NOAA Products Validation System)。该系统提供了日常的与全球常规与特殊探空观测相匹配的对于多种卫星大气温度、湿度廓线反演产品以及数值预报的垂直廓线资料的获取、匹配和对比(Sun B 等., 2017; Reale 等., 2012)。该系统的匹配方式是针对每个探空观测,找到每个产品中时空距离最近的一个廓线进行对比。本章研究中使用到的探空数据来自于 2017 和 2018 年各自的 6-8 月中与 S-NPP 卫星通过时间相匹配而发射的专用探空,分别来自位于南部大平原(SGP)的俄克拉荷马的美国能源部大气辐射测量计划站(ARM),位于马里兰州贝尔茨维尔的霍华德大学贝尔茨维尔气候观测中心 (BCCSO) 的全球高空基准观测站(GRUAN),以及位于科罗拉多州博尔德的全球高空基准观测站(GRUAN)。值得注意的是,这些专用探空观测并没有被同化到全球数值预报系统当中,因而被视为对于卫星数据定标和验证的宝贵观测数据。在本章的研究中,为了获得足够数量的探空观测以满足反演检验的需求,一些满足在 S-NPP 卫星通过 2 小时以内的常规探空也被包括在检验数据集中。因而,本研究中也使用了一些来自于 SGP 测站的常规探空观测,而这些观测也被收集在 NPROVS 系统中。

2.3 数据预处理

本章的研究工作具体使用了 2018 年 4~6 月美国大陆 CONUS 区域内的来自 5 个数据源的资料和产品(如表 2.1 所示),其中具体变量包括:(1) NUCAPS 在 200~1000 hPa 之间的大气温度和水汽反演廓线,以及对应 FOR 的地面气压;(2) GOES-16 在美国 CONUS 区域的 5 分钟 ABI 高分辨率成像观测,其中具体包括了 3 个水汽通道、3 个窗区通道和 1 个 CO₂ 通道的视场内平均晴空亮温、视场内晴空亮温标准差、以及晴空像素占比;(3) RTMA 的地面 2 米温度及露点;(4) ERA5 在 200-1000 hPa 之间的温度和水汽分布廓线;(5) 无线电探空观测的 200-1000 hPa 温度和水汽分布廓线。根据前文 2.2 节对于不同数据信息的讨论,本章

的研究中将来自 NUCAPS 的温度和水汽混合比的垂直廓线产品作为反演改进的基础, 利用 ABI 中对于中低层大气温湿结构具有代表性的 7 个通道在 NUCAPS 视场内的平均亮温及其标准差, 为反演模型分别提供了高分辨率静止卫星观测信息及其在视场内的均一化程度。考虑到卫星天顶角对辐射亮温观测的潜在影响, 模型中也将天顶角信息以 $\sec(\theta)$ 的形式加入到预报因子当中。对于部分有云条件下的视场, 在原有的预报因子中加入以 ABI 晴空像元在 NUCAPS 视场中所占面积的比率, 并采用晴空部分的 ABI 亮温观测均值及其标准差来近似表征 NUCAPS 视场中晴空部分的观测信息。除此之外, 为了更好地表现近地面大气信息, 在温湿度反演改进模型中都加入了来自 RTMA 的地面 2 米温度和露点信息作为预报因子。ERA5 作为目前准确度较好的, 被广泛信任和使用的再分析数据集, 其在 200 至 1000 hPa 之间的温度与水汽混合比的垂直廓线信息分别作为温度与湿度反演改进模型的训练真值, 也即神经网络的输出和预测对象。而探空观测数据作为对于大气的直接观测, 其对于反演结果的检验更具实际意义, 也具有完全的独立性, 但由于常规探空观测与 NUCAPS 在时间和空间上的匹配样本过少, 达不到模型训练所需要的样本量, 故没有选择其作为训练真值, 而是将其用于模型准确性的独立检验评估。在训练之前, 对于参与训练过程的数据的预处理主要包括质量控制、时空匹配以及云区处理三个部分。

表 2.1 在训练和检验中使用到的数据集与具体变量

Table 2.1 The datasets and variables used in the training and validation process

数据类型	数据源	变量	单位		
预报因子	NUCAPS	温度(200 hPa 到地面)	K		
		水汽混合比(200 hPa 到地面)	$\text{g}\cdot\text{kg}^{-1}$		
		地面气压	hPa		
	ABI	通道 6.2, 6.9, 7.3, 10.3, 11.2, 12.3 和 13.3 μm 的亮温, 和对应的视场内亮温标准差 (sub-FOR ABI Homogeneity)	K		
		卫星天顶角: $\sec(\theta)$	N/A		
		晴空像素占比 (仅用于有云状况): 晴空像素面积/有云像素面积 $\times 100\%$	%		
		RTMA	地面 2 米温度	K	
			地面 2 米露点	K	
		预报真值	ERA5	温度(200 hPa 到地面)	K
				水汽混合比(200 hPa 到地面)	$\text{g}\cdot\text{kg}^{-1}$
观测验证	RAOB	温度(200 hPa 到地面)	K		
		水汽混合比(200 hPa 到地面)	$\text{g}\cdot\text{kg}^{-1}$		

2.3.1 质量控制

对数据的质量控制主要针对来源于卫星观测的数据。对于 NUCAPS 数据, 研究中依据其自带的质量标志 (Quality Flag), 仅采用了标记为 IR+MW 反演质量合格的视场像元。对于 ABI 观测数据, 在其自带的 Quality Flag 基础之上, 使用 ABI 业务化的云检测数据(cloud mask)对于受到云污染的观测像元进行了剔除。对于 RTMA 地面分析场, 将其与 ERA5 进行格点匹配之后, 将与对应格点上 ERA5

地面分析场温度差别超过 4 K 的格点标记为有较大不确定性,排除在训练和检验过程中。此外,对于 NUCAPS 和 ERA5 大气廓线,为了实际反演的需要,依据各自的地面气压对于地面以下层次的廓线进行了订正,具体做法依据地面以上最低层次上的温湿数据,取代地面以下部分廓线并处理成等温等湿,这一部分数据将不会被包含在训练结果的统计检验之中。

2.3.2 时空匹配

在构建训练和测试数据集的过程中,对于表 2.1 中提到的预报因子变量和预报量进行了时间和空间上的匹配。对于 NUCAPS 和 ABI 的空间匹配,使用了威斯康星大学空间科学与工程中心 (Space Science and Engineering Center, SSEC) 的 SIPS (Atmosphere Science Investigator-led Processing System) 团队开发的匹配工具(Nagle 和 Holz, 2009),对于 NUCAPS 的每个 FOR(即 3×3 个 CrIS FOV),找到其覆盖范围内的所有 ABI 像元,并计算面积加权的各通道亮温均值与范围内亮温的标准差(代表 FOR 内 ABI 观测亮温的均一化程度)。在时间方面,选择了在 NUCAPS 对每个 FOR 的扫描探测时间之前,最近的一次 ABI 成像观测进行匹配,使其时间间隔小于 5 分钟。对于 RTMA 和 ERA5 等格点场,在时间上采用 NUCAPS 观测时间前后两个整点的分析数据进行时间线性插值,再将其变量在二维空间上三次样条插值到各个 FOR 的中心经纬度上,最终将各个格点分析场插值到 NUCAPS 观测与反演的时间和地点上。

2.3.3 云区处理

考虑到 NUCAPS 的视场较大(直径约 50 km),其满足晴空条件的像元在实际应用中占比极小。为了扩展其可用性,我们充分利用 ABI 观测的高空间分辨率(星下点 2 km)特点,利用云检测产品在 NUCAPS 有云的视场内找到晴空的 ABI 像元点,并根据其经纬度计算各 ABI 像元覆盖面积,以及晴空像元面积在整个 NUCAPS 视场所有 ABI 像元覆盖面积总和中内所占的比例,并将这一“晴空面积比率”作为独立的自变量匹配加入到预报因子数据集当中参与训练。值得一提的是,局地天顶角(local zenith angle, LZA)较大的 ABI 像元,相对于 LZA 较小的像元具有更大的地理覆盖面积,即更高的权重。这一“晴空面积比率”代表着计算得到的 ABI 亮温均值对于整个 NUCAPS FOR 空间范围内观测特征的代

表性，用于在部分有云的 FOR 条件下进行反演训练。图 2.5 展示的是 2018 年 4 月 1 日 0729~0735 UTC 期间 NUCAPS 在美国南部的一次观测以及与 ABI 的时空匹配结果。从 2.5(b)的窗区亮温观测可以看到，在美国大陆 35° N 以北，墨西哥湾西北部，以及佛罗里达南部地区均存在着较大范围的云系覆盖，而导致了这些地区完全晴空的 NUCAPS 较少（如图 2.5(c)所示）。在充分利用了 ABI 在云区内的晴空像元并用其近似代表整个 NUCAPS FOR 的空间分布信息之后，可用的样本量得到了显著增加。从图 1.1(c)和 1.1(d)的对比可以看出，这一应用使得在佛罗里达陆地地区及墨西哥湾西北部等地区获得了更多可用的 FOR，而在 35° N 以北以及佛罗里达东部与南部海域，由于云覆盖较为致密导致缺少晴空的 ABI 像元，因而增加的可用 FOR 相对较少。

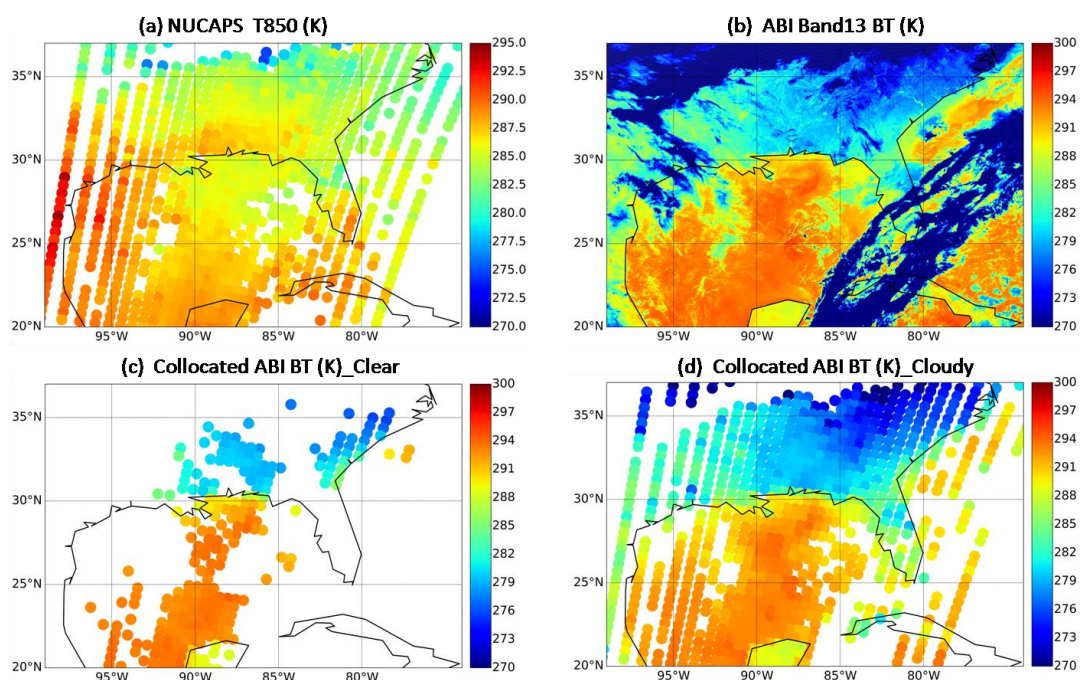


图 2.5 在有云状况下 ABI 和 NUCAPS 的匹配, (a)NUCAPS 在 2018 年 4 月 1 日 0729~0735 UTC 期间卫星轨迹范围的反演 850 hPa 温度; (b)ABI 在 2018 年 4 月 1 日 0730 UTC 第 13 通道 (10.3 μm) 的亮温; (c) 用 NUCAPS 晴空视场匹配的 ABI 亮温; (d)用 NUCAPS “晴空+部分有云” 匹配的 ABI 亮温。(单位: K)

Figure 2.5 Collocation of ABI pixels and NUCAPS FORs under partly-cloudy conditions. (a) Retrieved 850 hPa temperature from NUCAPS during the overpass of 0729~0735 UTC on April 1st, 2018. (b) Brightness temperature from band 13 (10.3 μm) of ABI at 0730 UTC,

on April 1st, 2018. (c) Collocated field of ABI brightness temperature for clear-sky NUCAPS FORs during the overpass. (d) Collocated field of ABI brightness temperature for ‘clear-sky & partly-cloudy’ NUCAPS FORs during the overpass.

2.4 神经网络设置与训练

本研究设计和训练了一个神经网络回归模型,通过融合来自 NUCAPS 探测、视场范围内(sub-FOR) 的 ABI 观测和来自 RTMA 改进 NUCAPS 对于低层大气的温湿廓线反演精度。本章采用的训练框架是类似于(Tao 等., 2018, 2016)的一个四层的全连接神经网络,其基本结构如图 2.6 所示。该网络由分层组织的神经元组成,并且神经元之间的连接贯穿各层。每一层的神经元接收来自于前一层的连接的输入信息,对这些信息进行汇总,并通过激活函数产生输出,然后再通过层与层之间的连接,将输出传递给下一层的神经元。网络中的第一层用作输入层,最后一层是给出最终预测的输出层。输入层和输出层之间的层称为隐藏层,隐藏层采用的非线性激活函数对于模型拟合非线性关系的能力至关重要。输入和输出之间的数学关系与神经元之间连接的参数有关,这些参数(权重)在开始时通常被随机初始化,并通过输入和输出样本的训练自动修改。在神经网络中,通常由一个损失函数 (loss function) 来评估在训练过程中网络的性能。当损失函数的输出超过预设阈值时,表明没有达到预期的精度,网络即开始进行误差的反向传播并修改每一层的连接权重,直到损失函数减小至目标范围内。




图 2.6 本章应用的四层全连接神经网络模型示意图。第一层是输入层，输入变量的数据在这一层被输入到模型里。第二、三层是隐藏层，用于处理非线性问题，第四层是输出层给出目标变量的预测值。 W_{ij} 代表了第 i 层和第 j 层之间不同神经元之间连接的权重，与激活函数一起作用来模拟不同输入和输出之间的关系。

Figure 2.6 The four-layer, fully-connected NN framework used in this study. The first layer is the input layer where the predictor variables are input. The second and third layers are hidden layers where nonlinear regressions take place. The fourth layer is the output layer which directly links to the target value the model is to predict. W_{ij} stands for the weights of connections between different neurons from layer i to layer j , and works with activation functions to emulate various input-output relationships.

对于本章中使用的神经网络，其输入层由训练的所有预测变量组成，包括 200 hPa 及以下所有气压层的 NUCAPS 温度/湿度值、ABI 观测变量和表 2.1 中提到的 RTMA 变量，每个预测变量都用作一个神经元。两个隐藏层的选取一方面是参考了(Zhou 和 Grassotti, 2020; Tao 等., 2018, 2016)利用神经网络在卫星观测数据反演问题上的成功经验，另一方面基于对于本研究的多次训练测试，发现与增加的计算成本和过拟合风险相比，增加额外的隐藏层对精度的提高并不显著。本章研究中所使用的网络设置如表 2.2 所示。经过多次测试，每个隐藏层中的神

经元数量设置为 100。输出层中只有一个神经元代表特定 ERA 固定气压层的温度/湿度的回归结果，最终得到的反演改进廓线则由不同气压层上的反演结果汇集而成。在将预报因子变量输入到模型之前，对每个预报因子变量进行以零为中心的归一化处理，其表达式为：

$$z = (x - u)/s \quad \dots (2.1)$$

其中 x 为单个样本某输入变量的原始值， u 为该变量在所有输入样本中的均值， s 代表该变量在所有输入样本中的标准差。这一预处理目的是消除不同自变量在数量级上的差异对于模型训练效果的影响。权重系数的初始化方面采用了 (He K 等., 2015) 开发的一种权重初始化方法，被称为 He-et-al Initialization。该方法的应用使得梯度下降的速度更快、效率更高，被广泛应用于神经网络的训练以提高训练过程的效率。除输出层不使用激活函数之外，在其它层上使用了新的激活函数 ELU (Exponential Linear Unit, Clevert 等., 2016)。该激活函数与常用的 ReLU (Rectified Linear Unit, Nair 和 Hinton, 2010) 激活函数非常相似，区别仅在于对于负值输入的处理，其表达式如下：

$$f(x) = \begin{cases} x & , x > 0 \\ \alpha (\exp(x) - 1) & , x \leq 0 \end{cases} \quad \dots (2.2)$$

在非负输入的处理上，ELU 与 ReLU 相同，但是 ELU 在负输入时可以产生负输出，这使得它可以将激活后的平均输出推向接近零，从而加快模型收敛，效果类似于批量标准化，但计算复杂度更低。在本研究的训练过程中，选择了均方误差 (MSE) 作为模型的损失函数。此外，我们使用了 Adam Optimizer 作为训练的优化器，用于优化损失函数使其最小化。Adam 是一种专为神经网络训练设计的自适应学习率优化算法，事实证明它非常适合具有大量数据和 (或) 参数的问题 (Kingma 和 Ba, 2017)。在得到了经过质量控制的、时空匹配的数据集之后，使用 Scikit-learn (Pedregosa 等., 2011) 的随机分割工具将匹配数据集随机分割成两个相互独立的数据集，分别为包含 80% 数据的训练集和包含剩余 20%

数据的独立验证集,其中前者用于训练模型和优化参数,而后者不参与训练过程,仅用于对于训练好的模型性能的检验评估。在训练结束之后,使用了训练数据集和独立验证数据集分别对训练后的模型进行测试,以确保没有过度拟合。在本研究中,只有当训练集和验证集的预测精度较为接近(测试集与训练集精度的相对误差不超过测试集绝对误差的 10%)时,模型才被认为是稳定的。

表 2.2 本章研究中使用的神经网络设置

Table 2.2 Configurations of the neural network used in this chapter

神经网络参数	参数设置
隐藏层数	2
输入层神经元数	132 (晴空), 133 (部分有云)
隐藏层神经元数	100, 100
输出层神经元数	1
激活函数	ELU
损失函数	MSE
优化器	ADAM
测试集占比	0.2
最大迭代次数	10000
最小提升阈值	0.0001
最大容忍次数	200

2.5 统计检验

2.5.1 晴空条件下的检验

首先对于晴空条件的 NUCAPS 视场数据进行了反演训练和检验。正如上文 2.4.3 所提到,在训练之前对 2018 年 4~6 月的匹配数据进行了 80%和 20%样本的随机分割,分别对应于训练集和独立的检验集。表 2.3 所示的是在晴空条件下训练集和验证集在各个输出层参与统计的有效样本量。由于我们仅对实际在地面以上有效样本进行统计,所以受到不同地区地形和近地面气象条件的影响,越接

近地面的层次有效样本量越少。为了保证统计结果的一致性和代表性，对于实际样本量小于总廓线的 50% 的层次，将不再予以讨论。图 2.7 所示的是神经网络的输出结果与真值（ERA5）之间的平均偏差（Bias）和误差标准差（Standard Deviation of Error, STDE），其中二者数学表达式分别为：

$$Bias = \frac{1}{N} \sum_{i=1}^N (x_i - y_i) \quad \dots (2.3)$$

$$STDE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i - Bias)^2} \quad \dots (2.4)$$

其中 N 表示参与统计的样本数， x_i 代表 DNN 对于样本 i 输出的预测值，而 y_i 代表 ERA5 该样本的真实值。误差标准差的含义是统计各预测样本的偏差相对于平均偏差 Bias 的离散程度。需要指出的是，本研究训练的湿度反演改进模型的训练真值和预测输出均为水汽混合比（如表 2.1 所示），用于表现出大气中的绝对水汽含量。但是由于大气中的绝对水汽含量在对流层中上层迅速降低，所以为了更好地表现模型对于不同高度层次上的大气湿度的改进能力，在统计检验过程中利用水汽混合比转化为对应的相对湿度进行展示。

表 2.3 在晴空条件下训练集和检验集当中各个等压面上的有效样本量

Table 2.3 Valid sample size for clear-sky training and validation at each pressure level

等压面 (hPa)	训练集 样本量	检验集 样本量	气压层 (hPa)	训练集 样本量	检验集 样本量
650 及以上	每层 71696	每层 17925	850	66016	16497
各层					
700	71648	17914	875	63313	15820
750	71298	17824	900	60690	15126
775	70769	17682	925	56955	14230
800	69252	17312	950	51658	12958
825	67754	16947	975	37281	9331

从统计检验的结果上看(如图 2.7a 和 2.7b), DNN 的输出结果相比于原有的 NUCAPS 在温度和相对湿度 (RH) 的准确性上都得到了提升。相比于对流层中上层, 模型对于对于低层大气反演产品准确度的提升尤为显著。对于 NUCAPS 反演产品的误差分析表明, 其温度的 STDE 在 850 hPa 及以下高度层大于 2.0 K, 而相对湿度在 800 hPa 及以下高度层则超过 15%, 而这些误差在 DNN 的输出上得到了显著的改善。其中, 在 850 hPa 及以下高度层, 温度和湿度 RMSE 的相对降低幅度超过 30%, 而 Bias 在 975 至 200 hPa 之间的绝对值则减少至约等于 0。在图 2.7 中, 同样展示了低层大气整层的平均方差 MV (Mean Variance), 定义为 700hPa 及以下垂直各层大气方差的平均值(即 $RMSE^2$)。不同于 $STDE^2$, $RMSE^2$ 的变化体现的是包含平均偏差和离散度的综合改进效果。统计结果表明, 在 700 hPa 及以下层次, 晴空区的温度和湿度的 MV 分别减小了 68.1%和 65.9%, 表明融合了 NUCAPS, ABI 和 RTMA 的 DNN 模型能够如我们预想的, 在晴空条件下改进 NUCAPS 低层大气温湿廓线的反演精度。

2.5.2 部分有云条件下的检验

如同前文在第 2.3.3 节中提到的, 为了使本研究中的模型具有更大的适用范围, 对于部分有云情况下的 FOR 通过 ABI 的云检测产品也进行了数据匹配和预处理, 并进行了单独的训练和检验。相比于晴空条件下的 DNN 模型, 在部分有云条件下的模型在预报因子的选择上主要进行了两处修改。一是对于 NUCAPS FOR 内 ABI 观测信息的处理方式, 在晴空区使用的是区域内全部 ABI 的均值和标准差, 而在部分有云区域内仅使用了晴空部分的 ABI 信息。另外, 为了表征晴空部分 ABI 信息对于整个 FOR 的代表性, 计算了每个部分有云的 NUCAPS FOR 内晴空 ABI 像元所覆盖的面积占比, 并作为一个独立的预报因子, 与其他自变量一起加入训练中。如果在整个 FOR 中没有 ABI 晴空像元, 则该 FOR 将被视为“全云覆盖”而被舍弃。表 2.4 展示的是在部分有云条件下各层的有效样本, 相比于完全晴空的样本量(表 2.3), 在本章的研究时段和区域内满足部分有云条件的 FOR 大约是晴空的 4 倍。

表 2.4 在部分有云条件下训练集和检验集当中各个等压面上的有效样本量

Table 2.4 Valid sample size for partly-cloudy training and validation at each pressure level

等压面 (hPa)	训练集 样本量	检验集 样本量	气压层 (hPa)	训练集 样本量	检验集 样本量
650 及以上 各层	每层 269883	每层 67462	850	250999	62761
700	269657	67411	875	243434	60937
750	268403	67127	900	236984	59341
775	266511	66660	925	227548	56922
800	261779	65516	950	208101	52112
825	256574	64206	975	152110	38168

部分有云条件下的温度和湿度检验结果分别由图 2.7c 和 2.7d 给出，可以看到经过数据融合的 DNN 回归模型能够在部分有云条件下对 NUCAPS 的温度和湿度在低层大气的反演精度进行显著的改进。经过改进的温度和相对湿度在 700 hPa 及以下低层大气的平均方差相比 NUCAPS 分别减小了 58.1% 和 65.5%，略逊于晴空条件下的改进幅度，但仍然十分显著。这样的结果说明了本研究开发的 DNN 数据融合回归模型，能够在部分有云的条件下利用晴空部分的 ABI 数据以及 RTMA 地面温湿信息，对低层大气的 NUCAPS 廓线反演进行改进。

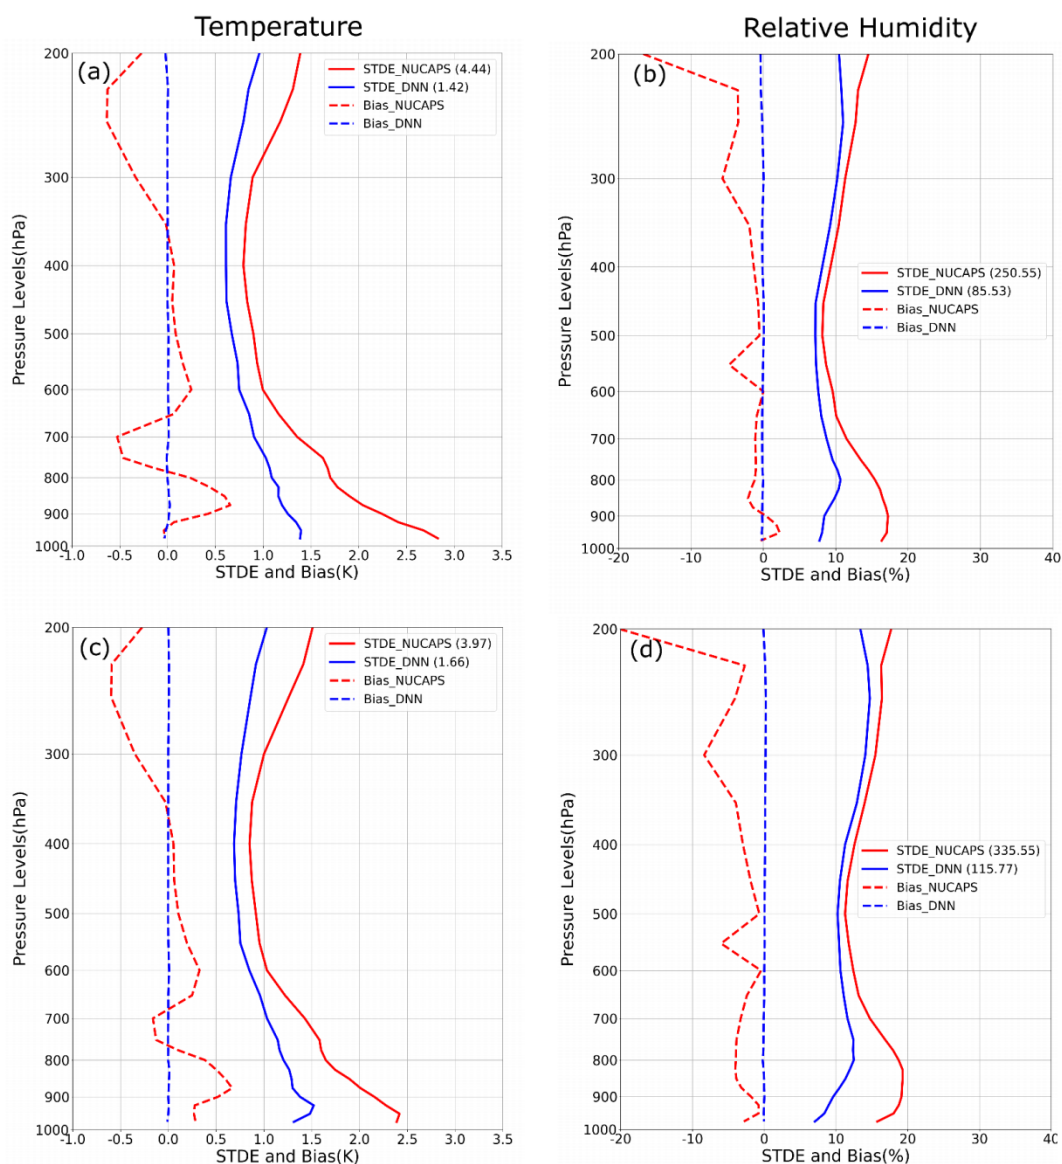


图 2.7 NUCAPS（红线）与 DNN 模型输出（蓝线）在检验数据集上统计得到的温度（a,c）和相对湿度（b,d）相对 ERA5 的 STDE（实线）与平均偏差（虚线）在晴空条件下（a,b）和部分有云条件下（c,d）的垂直廓线。括号中显示的数字为平均方差(MV= $RMSE^2$)表示的是各统计对象的温度或湿度在 700 hPa 到地面之间各层方差的平均值。

Figure 2.7 Statistics of Standard Deviation of Error (STDE, solid lines) and mean bias (dashed lines) vertical profiles for (a, c) temperature, and (b, d) relative humidity (RH) of NUCAPS (red lines) and outputs from DNN data fused model (blue lines) versus ERA5 at different pressure levels under (a, b) clear-sky and (c, d) partly cloudy conditions from the testing dataset. Shown in the brackets are the values of mean variances (MV) = $RMSE^2$ of

lower levels from 700 hPa to the surface for temperature and RH, respectively.

2.6 敏感性试验

为了进一步了解在 DNN 数据融合模型中, 各个数据源对于改进低层大气反演的相对贡献及其影响, 设计了两组敏感性试验。其中, 第一组试验致力于了解 NUCAPS, ABI, RTMA 及其组合在反演改进中的影响; 第二组试验则是研究 ABI 不同通道观测信息在反演改进中所起的作用。具体的试验设计和统计检验将在本章中加以讨论。

2.6.1 多源数据的相对贡献

针对参与到数据融合训练过程中的不同数据源的预报因子在晴空和有云状态下分别做了敏感性试验, 进而讨论 ABI 和 RTMA 在降低 NUCAPS 低层大气反演不确定性上所起的作用。所进行的三个对比试验分别为:

- (1) DNN_NUCAPS: 仅使用 NUCAPS 大气廓线作为 DNN 的预报因子;
- (2) DNN_ABI: 仅使用 ABI 观测变量作为 DNN 的预报因子
- (3) DNN_NUCAPS_ABI: 在 DNN 中使用 NUCAPS 和 ABI 预报因子, 但不包含 RTMA 地面观测。

为了保证试验样本的一致性, 这三组对比试验与包含全部预报因子的控制试验(标记为 DNN_NUCAPS_ABI_surf)采用了同样的训练集(80%)和检验集(20%)。如图 2.8 所示, 相比于 NUCAPS, DNN_NUCAPS 在各层的温湿度误差均有显著的降低。这一改进仅仅来自 DNN 模型训练本身, 并没有额外信息的输入, 说明了 DNN 能够通过提取并利用 NUCAPS 大气探测廓线在不同层次之间的相关性, 结合训练真值来对于反演准确性进行提升。与之相对的是, DNN_NUCAPS_ABI 和 DNN_NUCAPS_ABI_surf 所表现出对于廓线反演精度的进一步提升, 则来源于多源数据信息的融合。当 ABI 观测信息被加入训练, 温度和湿度廓线的准确性都有明显的提高, 其中在低层大气的改进幅度更为明显。这种现象与模型中所选取的 ABI 通道(见表 2.1)对于低层大气有较高的敏感性(见图 2.4)有关, 而在这些层次上 NUCAPS 自身的准确度是相对偏低的。当进一步加入 RTMA 的地面观测信息, 低层廓线的准确度得到了进一步的提升, 然而相比于 ABI 带来的影响, RTMA 在 600 hPa 以上的温度廓线和 800 hPa 以上的湿度

廓线并没有带来明显的影响。这一结果体现了 RTMA 提供的地面温湿信息与低层大气有较高的相关性进而为低层大气的反演做出贡献,但是这一相关性在垂直的空间上是有限的。总的来看, DNN 数据融合模型对于低层大气的反演主要来自于三个方面的贡献,分别是 DNN 模型本身, ABI 观测, 以及 RTMA 地面观测信息。与上文的讨论相类似的, 图 2.8 也计算了各个试验及 NUCAPS 从 700 hPa 到地面之间相对于真值的平均方差。基于晴空条件下的数据, 如图 2.8a 和 2.8b, 我们发现最大的改进来源是 DNN 模型本身, 对温度和湿度的方差分别降低了 55.4% 和 51.7%; 而紧随其后的是具有四个低层大气敏感通道的 ABI, 其贡献的温度和湿度方差分别降低了 7.2% 和 10.2%; 仅提供地面信息的 RTMA 使温度和湿度方差分别降低了 5.5% 和 3.9%。

图 2.8c 和 2.8d 分别展示了在部分有云条件下相应的试验结果在温度和湿度误差廓线上的呈现。与晴空的试验结果相类似, 可以看到来自 DNN、ABI 和 RTMA 的相对贡献。其中, 对于 700 hPa 以下的温度, 三种数据源依次分别降低了原有方差的 40.1%, 7.1% 和 10.9%, 而对于相对湿度, 这三个值分别为 48.4%, 8.6% 和 8.4%。与晴空条件的试验结果相一致的是, DNN 模型本身的相对贡献最大, 而在低层大气改进方面 ABI 和 RTMA 的贡献都很显著。和晴空的主要区别在于, 在有云状态下 ABI 的相对贡献值偏小, 而 RTMA 的相对贡献增加。这一现象的原因在于, RTMA 的地面观测是包含晴空和云区的全范围数据, 其受云覆盖的影响较小, 而 ABI 在有云条件下的信息贡献局限于晴空部分, 作用于明显的降低。这一现象同样可以由仅使用 ABI 观测的敏感性试验 DNN_ABI 来体现, 该试验的结果是几组试验中唯一一个在晴空和云区差异十分显著的。通过对比 2.8a 和 2.8c, 以及 2.8b 和 2.8d 可以看出, 仅用 ABI 的试验结果在有云情况下无论是温度和湿度, 其准确度相比晴空都大幅降低。这与在有云条件下晴空 ABI 观测对于整个 NUCAPS FOR 的代表性不足有关。由于在实际观测当中, 一个有云的 FOR 范围内的晴空 ABI 像元并不是均匀分布的, 而是覆盖一个特定部分的区域, 因此使用这些晴空像元的观测特性来代表 NUCAPS FOR 存在相当程度的不确定性。不过, 这些晴空部分的 ABI 观测在 DNN 模型的协助之下, 仍然会对原有 NUCAPS 的反演精度提升提供有利的信息。

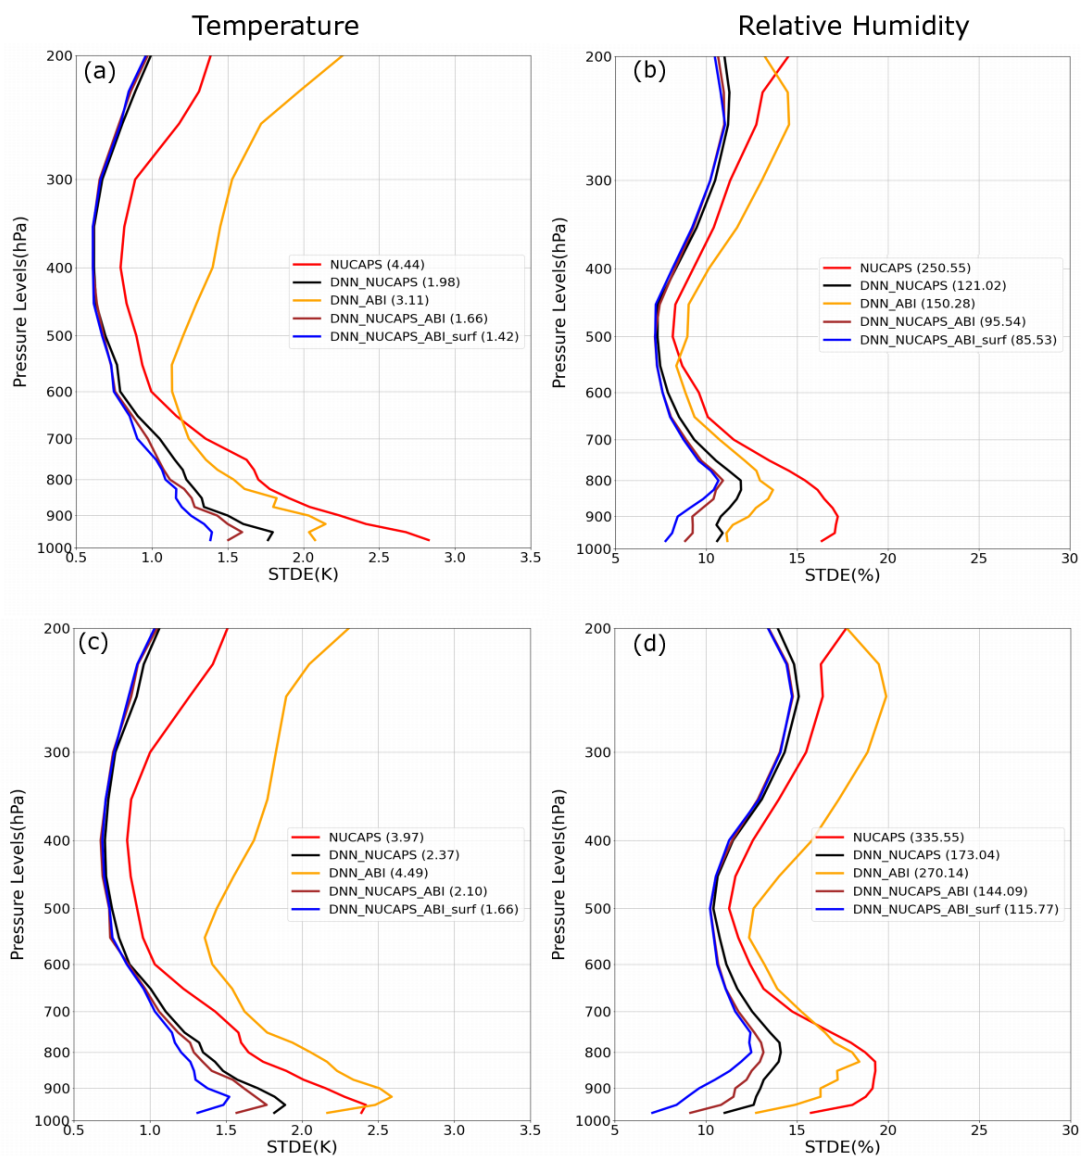


图 2.8 各个试验的输出以及 NUCAPS 相对 ERA5 的温度 (a,c) 与相对湿度 (b,d) STDE 垂直廓线。DNN_NUCAPS (黑线) 代表仅包含 NUCAPS 作为预报因子的试验; DNN_ABI (橙线) 代表仅包含 ABI 变量作为 DNN 预报因子的试验; DNN_NUCAPS_ABI (棕线) 代表包含 NUCAPS 和 ABI 作为预报因子的试验; DNN_NUCAPS_ABI_surf (蓝线) 代表包含所有匹配数据源作为预报因子的试验。检验中使用的是来自 2018 年 4 到 6 月的随机分割的 20 % 样本独立验证数据集, 其中 (a,b) 为晴空部分的样本; (c,d) 为部分有云的样本。括号中显示的数字为各试验的温度或湿度在 700 hPa 至地面之间低层大气的平均方差。

Figure 2.8 The STDE vertical profiles for (a, c) temperature and (b, d) relative humidity of (red) NUCAPS and outputs from various experiments versus ERA5. (Black) DNN_NUCAPS

is for the experiment including only NUCAPS profiles as predictors. (Orange) DNN_ABI is for the experiment including only ABI related predictors. (Brown) DNN_NUCAPS_ABI is the experiment including both NUCAPS and ABI predictors, and (Blue) DNN_NUCAPS_ABI_surf is the experiment in which all data sources are included. The randomly selected 20 % independent validation dataset from April/May/June 2018 for (a, b) clear sky samples, and (c, d) partially cloudy samples are used. Shown in the brackets are the values of mean variances (MV) of lower levels from 700 hPa to surface for temperature and RH, respectively.

2.6.2 ABI 不同通道信息在反演改进中的作用

通过 DNN_ABI 的试验结果（图 2.8 中橙色线），我们发现仅使用 ABI 观测中来自于表 2.1 的 7 个通道的亮温和相应的 STD 信息，以及 FOR 中心的 LZA（用 $\sec(\theta)$ 表示）作为预报因子，也能得到误差在一定范围内的垂直大气廓线。通过和 NUCAPS 产品的比较，我们发现了在低层大气由于近地面大气过程的复杂性，NUCAPS 产品并没有表现出 CrIS 高光谱分辨率应有的优势，而与此同时缺乏光谱分辨率的 ABI 尽管经过 DNN 的回归训练，但是在对流层中高层仍然具有很大的误差。为了进一步了解不同类型通道，即红外窗区通道（10.3、11.2 和 12.3 μm ）、水汽通道（6.2、6.9 和 7.3 μm ）、以及 CO₂ 通道的相对贡献和作用，我们以在 DNN_ABI 模型中去除相应通道信息的方式，在晴空条件下开展了对不同类型通道对大气探测信息的敏感性试验。图 2.9 所示为各个试验在温度和湿度反演结果上相对 ERA5 真值所计算的误差曲线。其中 ABI_full 为控制试验，包含了全部 7 个通道的信息，对应于图 2.8a 和 2.8b 中的 DNN_ABI 结果；ABI_w/o_WV 是在 ABI_full 的基础上，在预报因子中去除了三个水汽通道的信息，而仅保留了窗区通道和 CO₂ 通道；ABI_w/o_WV&CO₂ 试验则是在前一个试验基础上进一步去除 CO₂ 通道信息，仅保留三个窗区通道的观测。从温度反演（图 2.9a）的结果上看，CO₂ 通道相比于水汽通道具有更为显著的影响，这和 CO₂ 通道对于中低层大气的温度敏感性更强是一致的。而对于相对湿度（图 2.9b），现象则更加复杂，对于 800 hPa 及以下的低层大气，CO₂ 通道的影响超过了水汽通道，而水汽通道的影响则主要体现在 800 hPa 以上部分。这一现象可以由不同通道对于水汽的 Jacobian 分布（图 2.10）来解释，相比于三个水汽通道，中心波长位于 13.3 μm 的

CO₂ 通道不仅对于对流层低层水汽有更高的敏感性，其敏感性也超过了除 12.3 μm 通道以外的所有红外窗区通道(Li J 等., 2020)。相比于仅使用三个窗区通道的反演结果，ABI 的三个水汽通道对于低层大气（700 hPa 及以下）的温度和湿度平均方差分别减小了 8.2 %和 4.8 %，而 CO₂ 通道则分别对温度和湿度平均方差减小了 60.5 %和 42 %。

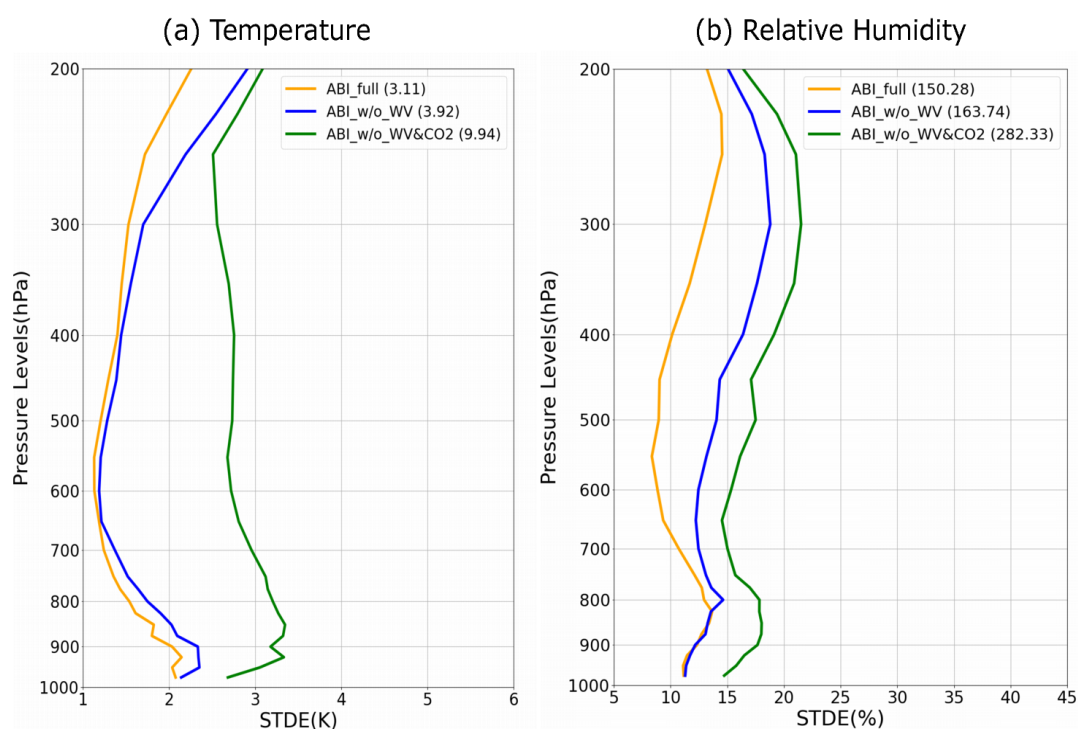


图 2.9 各个 ABI 通道试验的输出相对 ERA5 的温度 (a,c) 与相对湿度 (b,d) STDE 垂直廓线。ABI_full (橙线) 代表仅包含所选的 7 个 ABI 通道作为预报因子的试验；ABI_w/o_WV (蓝线) 代表在 ABI_full 基础上从预报因子中去掉三个水汽通道 (6.2, 6.9 and 7.3 μm) 的试验。ABI_w/o_WV&CO₂ (绿线) 代表在 ABI_full 基础上从预报因子中去掉三个水汽通道和 CO₂ 通道(13.3 μm)的试验。括号中显示的数字为温度或湿度各自在 700hPa 至地面之间低层大气的平均方差。

Figure 2.9 The STDE vertical profiles for (a) temperature and (b) relative humidity from various experiments versus ERA5. (Orange) ABI_full is for the experiment including only all seven ABI channels mentioned in this study. (Blue) ABI_w/o_WV is for the experiment without water vapor channels (6.2, 6.9 and 7.3 μm). (Green) ABI_w/o_WV&CO₂ is for the experiment without water vapor channels and the CO₂ channel (13.3 μm). Shown in the

brackets are the values of mean variances (MV) of lower levels from 700 hPa to the surface for temperature and RH, respectively.




图 2.10 在美国标准大气的条件下利用 CRTM 计算出的 ABI 各红外通道的水汽混合比（对数形式）Jacobian（引用自 Li 等., 2020）。

Figure 2.10 The water vapor mixing ratio (in term of logarithm) Jacobians from ABI IR bands calculated with CRTM using the US StandardAtmosphere as input (Cited from Li et al., 2020).

2.7 泛化能力检验

前文的研究已经证实了本章训练得到的融合 NUCAPS、ABI 以及 RTMA 观测的 DNN 回归模型，能够在 2018 年数据中被随机分割出来的 20 %验证数据集上显示出其改进低层大气温度与湿度廓线反演精度的能力。为了进一步测试该模型在完全独立的数据集上性能的稳定性的，我们采用 2017 年的数据对该模型的泛化能力进行了进一步的检验。首先对于 2017 年 4 到 6 月的 NUCAPS 在美国 CONUS 区域的数据进行了与前文 2.3 节相同的匹配和预处理过程。由于 2017 年

4 月 1 日至 19 日的 ABI 业务云检测产品缺失，导致总的样本量约为 210000 个，少于 2018 年的样本量。各气压层具体参与检验的，包括晴空和部分有云条件下的有效样本量，请参见表 2.5。与表 2.3 和 2.4 相类似地，将模型的适用性扩展到部分有云的条件，能够显著地提高可用的样本量并扩大 DNN 融合反演模型的应用范围。

表 2.5 2017 年 4-6 月数据中晴空和部分有云条件下各个等压面上的有效样本量
Table 2.5 Valid sample size for clear sky and partly cloudy validation for dataset from April to June 2017 at each pressure level

等压面 (hPa)	晴空样本量	部分有云 样本量	气压层 (hPa)	晴空样本量	部分有云 样本量
650 及以上 层次	每层 35400	每层 176867	850	33025	167362
700	35372	176769	875	31939	163483
750	35188	176075	900	31041	159667
775	34923	175123	925	29900	153004
800	34293	172564	950	27426	137772
825	33634	170101	975	20179	96760

对于 2017 年 4~6 月数据在晴空和部分有云条件下的检验结果由图 2.11 给出。总体来看，多源数据融合的 DNN 模型显著地改进了所用的 NUCAPS 数据与 ERA5 之间的误差。对于 700 hPa 及以下的低层大气，不论是在平均偏差 (Bias) 还是误差标准差 (STDE) 都有较为明显的减小。在 700 hPa 以下的平均方差的改进上，模型对于 2017 年晴空条件下 (图 2.11a 和 2.11b) 的温度和相对湿度方差分别改进了 43.0 % 和 52.2 %，在部分有云的条件下 (图 2.11c 和 2.11d) 则分别为 45.8 % 和 50.8 %。尽管这些改进幅度相对于 2018 年的统计结果有些许的下降，但是仍然非常显著，说明本章中所开发的 DNN 数据融合模型具有一定的泛化能力。但是值得注意的是，对于 500 hPa 以上的对流层中高层，模型的改进效果非常有限。特别是对于相对湿度的 STDE 几乎没有改进。考虑到这些检验数据

是与训练数据不在同一年份的、完全独立的数据，且样本量接近训练样本的大小，而所融合的数据从物理上所反映的信息主要在低层大气，这一现象是具备其合理性的。但是在实际的应用中，为了使训练出的 DNN 模型具有更好的泛化能力和应用前景，需要尽可能大的样本量以及更为充分的代表性。

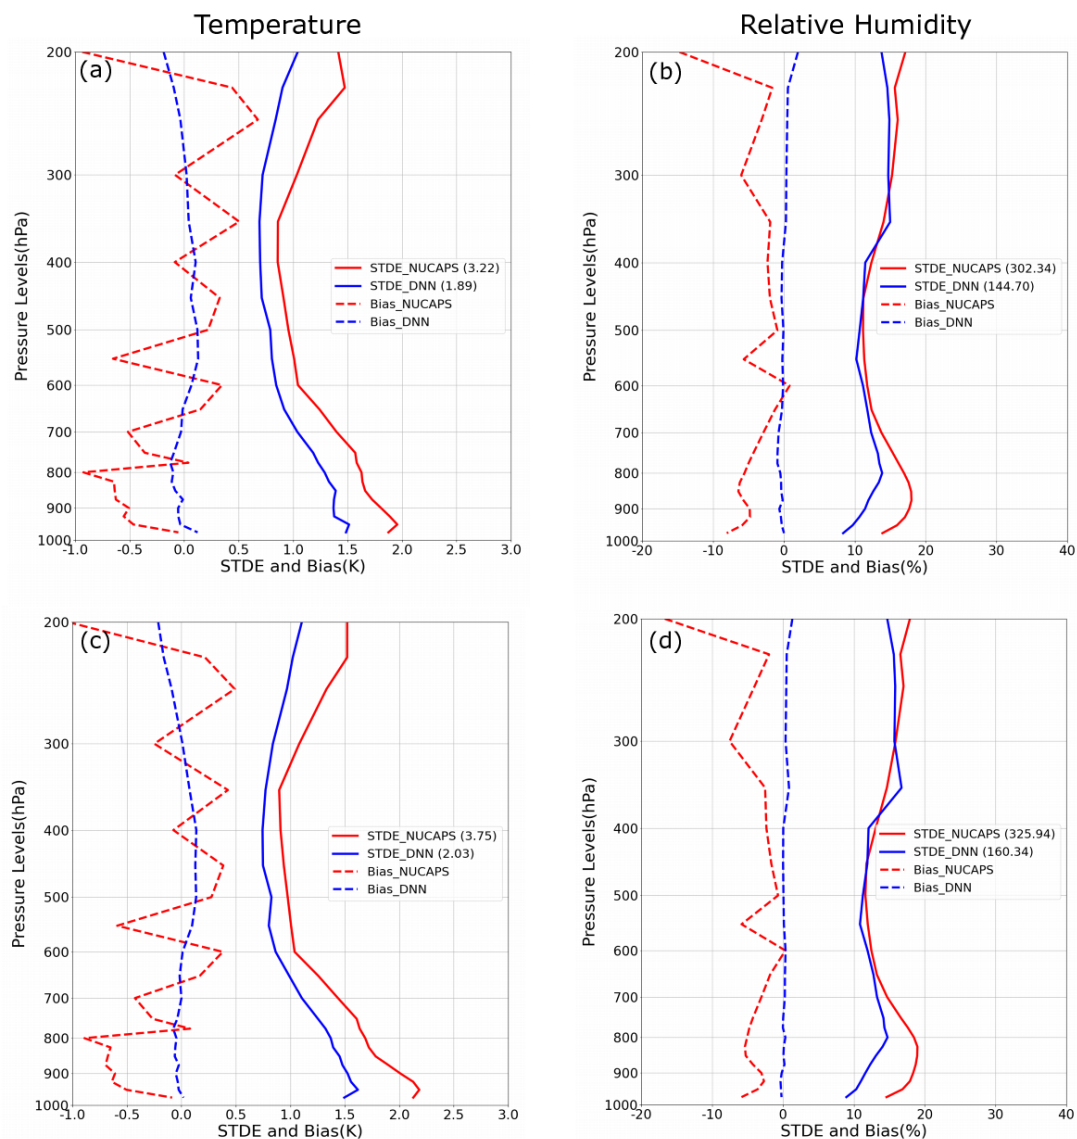


图 2.11 NUCAPS（红线）与 DNN 模型输出（蓝线）在 2017 年数据集上统计得到的温度（a,c）和相对湿度（b,d）相对 ERA5 的 STDE（实线）与平均偏差（虚线）在晴空条件下（a,b）和部分有云条件下（c,d）的垂直廓线。括号中显示的数字为平均方差(MV= $RMSE^2$)表示的是各统计对象的温度或湿度在 700 hPa 到地面之间各层方差的平均值。

Figure 2.11 Vertical profiles of the STDE (solid lines) and mean bias (dashed lines) for (a, c)

temperature, and (b, d) relative humidity of (red) NUCAPS and (blue) DNN model outputs versus ERA-5 from the 2017 dataset under (a, b) clear sky conditions, and (c, d) partly cloudy conditions. Shown in the brackets are the values of mean variances (MV) of lower levels from 700 hPa to the surface for temperature and RH, respectively.

2.8 基于探空数据的独立检验

2.8.1 统计检验

在前文的分析中，用不同年份的 ERA5 对于 DNN 融合模型的反演精度进行了检验评估。然而，由于训练时所采用的真值也是作为格点再分析数据的 ERA5，有必要采用其它格式的更为独立的观测资料进行进一步的分析验证。因而在本节中，将 2017 与 2018 年每年 4 月到 6 月的探空数据集（RAOB）作为观测真值对模型结果进行了验证。考虑到低层大气的温湿特性受到辐射日变化的显著影响，因而随时间变化明显。为尽量控制这一影响，在统计分析时只采用了观测时间与 NUCAPS 扫描时间差在 2 小时以内，距离在 120 km 以内的探空数据进行了对比研究。表 2.6 所示的是实际搜集到的满足条件的探空样本。这些筛选出来的探空观测样本与 NUCAPS 的观测时间差异平均为 60.42 分钟，其中最小的为 1 分钟，最大的为 119 分钟。探空观测点距离 NUCAPS 的 FOR 中心的水平距离的平均值为 35.36 km，最小值为 1.10 km，最大值为 115.46 km。由于满足条件的探空数据样本较少，在检验时不再区分晴空和部分有云的条件，而将与之匹配的 NUCAPS 根据自身的云覆盖情况应用相应的模型之后，将输出结果放在一起进行误差检验与统计分析。

表 2.6 与 NUCAPS 相匹配的探空观测在不同高度层的有效样本量

Table 2.6 Validation sample size for RAOB collocated with NUCAPS at each pressure level

等压面 (hPa)	2018 年样本量	2017 年样本量	总样本量
200 ~ 800	55	16	71
825 ~ 925	52	13	65
950	32	13	45

图 2.12 所示的是经过统计得到的 NUCAPS 和 DNN 输出分别相对于与之匹配的探空数据之间的不同气压层上 STDE 和平均偏差的垂直廓线。由于本章训练的 DNN 模型是以 ERA5 作为真值，即输出层次为 ERA5 等压面，为方便对比故将 NUCAPS 廓线与探空廓线均垂直插值到 ERA5 的固定等压面上。从图 2.12 可以看到，尽管由于观测时间的差异导致 NUCAPS 和探空之间的误差相对于和 ERA5 之间的误差更大，但是 DNN 数据融合模型与探空之间的温度和相对湿度 STDE 在低层明显小于 NUCAPS 与探空之间的 STDE，体现出融合了 ABI 和 RTMA 的 DNN 模型对于反演数据的改进作用。对于 700hPa 至地面之间的层次，DNN 模型对温度和相对湿度的平均方差分别减小了 42.6% 和 56%，表现出显著的改进效果，这与前文针对 ERA5 的统计检验的结论基本一致，仅在改进幅度上略有减小。

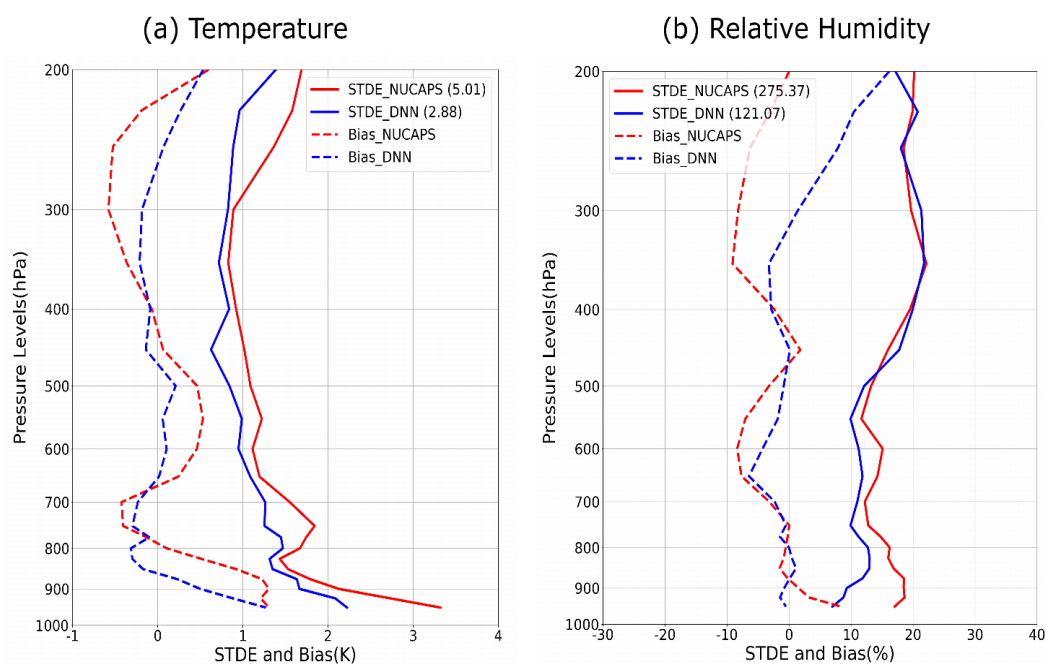


图 2.12 NUCAPS (红线) 与 DNN 模型输出 (蓝线) 相对于 2017 和 2018 年匹配到的探空观测数据集上统计得到的温度 (a) 和相对湿度 (b) 的 STDE (实线) 与平均偏差 (虚线) 的垂直廓线。括号中显示的数字为平均方差($MV = RMSE^2$)表示的是各统计对象的温度或湿度在 700 hPa 到地面之间各层方差的平均值。

Figure 2.12 Vertical profiles of the STDE (solid lines) and mean bias (dashed lines) for (a) temperature, and (b) relative humidity of (red) NUCAPS and (blue) enhanced NUCAPS soundings against collocated RAOBs in both 2017 and 2018. Shown in the brackets are the values of mean variances (MV) of lower levels from 700 hPa to the surface for temperature and RH, respectively.

与此同时,在分析中我们也发现了在相对湿度的误差廓线上,DNN 数据融合模型对于 500 hPa 以上高度的改进效果不明显。这其中关键因素在于 NUCAPS 和探空观测之间平均 1 个小时的时间差异,而观测时间上的差异将在统计结果上产生影响。尽管这种影响是对于整个廓线范围内的,但是由于本研究中的 DNN 模型对于低层大气的改进效果更为明显,因而这一影响在对流层低层表现得不如中高层那样明显。为了进一步验证这一猜想,我们设置了多个更短的 NUCAPS/RAOB 匹配时间阈值,发现了 DNN 数据融合模型对于低层大气廓线反演更为显著的改进效果,且时间阈值越小,统计得到的改进效果越显著。例如,当使用 30 分钟作为匹配的时间阈值时,温度的平均方差减小了 57.5%,而相对湿度的平均方差减小了 69.7%,明显大于图 2.12 所示的改进幅度。然而必须指出的是,当仅匹配与 NUCAPS 时间差在 30 分钟以内的探空数据时,所用到的探空观测都是针对 S-NPP 的同步特定观测,而这些探空观测来源于 GRUAN 站点拥有的经过数据标准化处理的 RS92 和 RS41 仪器观测。这两种观测数据相比于图 2.12 中所统计的其他观测具有更高的准确度,特别是在相对湿度的探测方面(Dirksen 等.,2014)。但是考虑到满足 30 分钟阈值的观测样本只有 17 个,结果并不具备统计上的显著性,在此不做更多讨论。

2.8.2 个例分析

为了研究数据融合模型对实际探空的具体影响,在验证数据集中选取了两个能够匹配到 S-NPP 特定同步探空观测的 NUCAPS 观测视场,将 NUCAPS 廓线、DNN 模型反演输出以及实际探空观测廓线一同进行对比分析。其中一个探空个例是在 2018 年 4 月 26 日的晴空条件观测,NUCAPS 观测时间为 1742 UTC,FOR 中心为 (-76.84°E,39.03°N),相匹配的探空发射时间为 1633 UTC,地点为 (-76.87°E,39.05°N)。如图 2.13a 所示,NUCAPS 的温度廓线表现出从地面到大

约 800 hPa 高度的相对深厚的边界层，其顶部存在直到 650 hPa 的深厚夹卷层。而在与之相对应的探空观测所表现出的温度廓线上，边界层相对浅薄，仅达到 900hPa 附近高度，其上的夹卷层厚度达到 750 hPa 附近。这一反演和观测的偏差导致了 NUCAPS 在 850 hPa 至 650 hPa 高度之间存在一个明显的冷偏差。DNN 数据融合模型的输出结果体现出了对低层温度廓线的显著改进，使得对于边界层和夹卷层范围和深度的表现更加符合实际观测。在湿度方面，相比于 NUCAPS 在低层大气过于平滑的曲线，DNN 融合模型在一定程度上表现出了与探空观测相一致的在 750 hPa 和 650 hPa 的两个干值区。

图 2.13b 所示的第二个探空个例是对应于 2018 年 4 月 18 日的部分有云的 NUCAPS 观测视场，其观测时间为 0710 UTC，视场中心位于(-76.58°E, 39.17°N)。探空观测发射时间为 0728 UTC，地点为 (-76.87°E, 39.05°N)。从观测探空的温度廓线上看，在 850 hPa 至 750 hPa 高度间存在一个很强的逆温层，但是在 NUCAPS 的反演廓线上完全没有体现。从数据融合模型的输出上看，不仅完整地呈现了逆温层的分布，且对于 NUCAPS 在逆温层底部 850 hPa 附近存在的暖偏差进行了修正。在湿度廓线方面，对于 NUCAPS 在低层存在的较大湿偏差，DNN 融合模型的输出成功地进行了修正，并表现出了地面至 850 hPa 之间的干层。对于这两个实际探空个例的分析说明，DNN 融合模型对于大气廓线反演的改进不局限于边界层内，也覆盖了包含逆温层在内的夹卷层，以及更高层次的大气廓线。这一改进有助于给予预报员在使用大气反演廓线产品做预报业务时更大的信心。

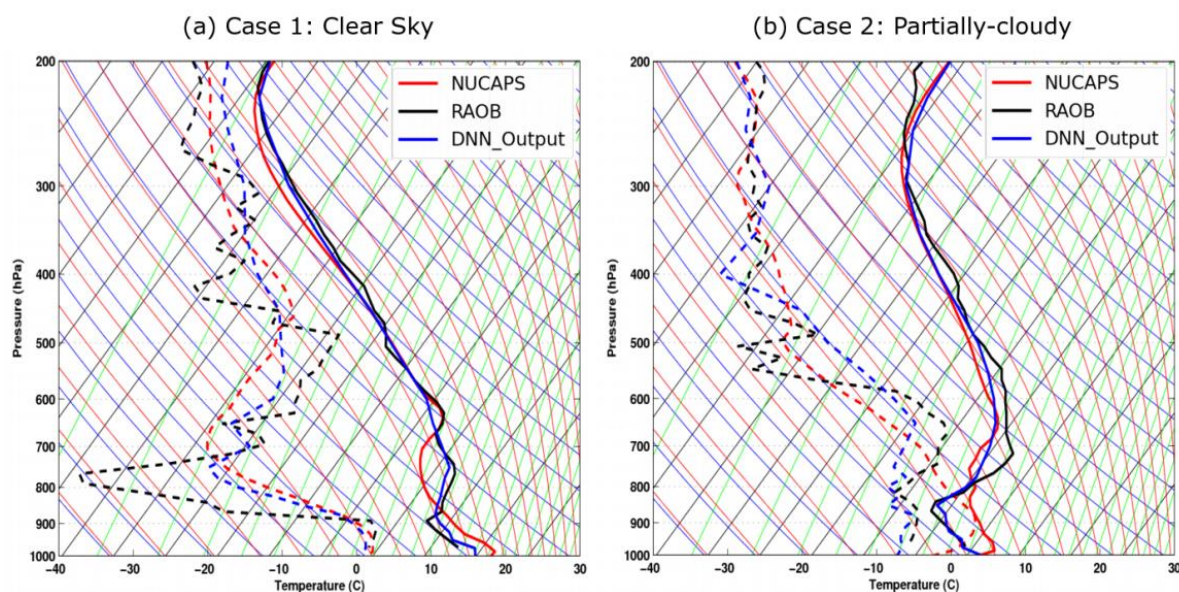


图 2.13 大气廓线中温度（实线）与露点（虚线）在 Skew-T 图上的体现：(a)2018 年 4 月 26 日晴空观测个例：NUCAPS 观测于 1742 UTC，FOR 中心位于(-76.84°E, 39.03°N),探空观测发射于 1633 UTC，发射位置为(-76.87°E, 39.05°N)；(b) 2018 年 4 月 18 日有云状况下的观测个例：NUCAPS 观测于 0710 UTC，FOR 中心位于(-76.58°E, 39.17°N),探空观测发射于 0728 UTC，发射位置为(-76.87°E, 39.05°N)。

Figure 2.13 Temperature (solid lines) and dewpoint (dashed lines) profiles plotted in skew-t diagrams for (a) clear sky case with NUCAPS at 1742 UTC, FOR centered at (-76.84°E, 39.03°N), RAOB launched at 1633 UTC from (-76.87°E, 39.05°N) on April 26, 2018, and (b) partly-cloudy case with NUCAPS sounding at 0710 UTC, FOR centered at (-76.58°E, 39.17°N), and RAOB at 0728 UTC from (-76.87°E, 39.05°N) on April 18, 2018.

2.9 数据融合反演在对流天气环境的预报应用

利用改进后的模型对于 2017 年 6 月 18 日美国东部地区一次对流前大气环境进行了联合反演应用。根据美国风暴预报中心（SPC, Storm Prediction Center）的记录，该日 1800 UTC 至次日 0000 UTC 之间在美国东部出现了多次强风暴事件，包括灾害性冰雹和大风天气。根据 SPC 的观测和中尺度分析报告 (<https://www.spc.noaa.gov/exper/archive/event.php?date=20170618>)，该日美国东部处于一个暖锋之后和一个东移冷锋之前，低层大气的暖湿结构有利于对流天气的发生发展。在 1200 UTC，东海岸的低层大气层结较为稳定，从地面计算的对流不稳定能量（SBCAPE）较低，而对流抑制能量（CIN）较高，此后随着时间的推移，CIN 逐渐减小而 SBCAPE 逐渐增大，至 1800 UTC 东海岸地区的 SBCAPE 已普遍超过 $2000 \text{ J}\cdot\text{kg}^{-1}$ ，此后一直维持高值，直至 2200 UTC 才逐步减弱。图 2.14(a) 所示的是利用 ERA5 大气温湿廓线计算的 1800 UTC 的美国东海岸 SBCAPE 分布图，可以看到 ERA5 再分析数据很好地表现出了美国东部沿着海岸线走向的 SBCAPE 高值带，且与 SPC 的观测分析结果（图略，请参见前文提到的 SPC 网站）相一致，证明 ERA5 能够较好地表现本次个例中的对流性大气环境信息。

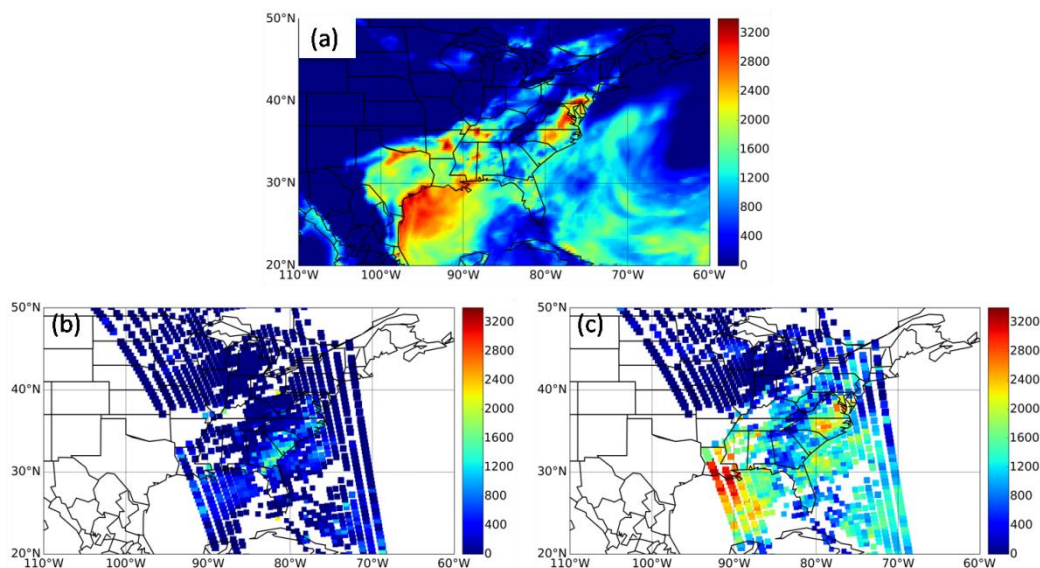


图 2.14 2017 年 6 月 18 日来自(a)1800 UTC 的 ERA5 再分析数据；以及在 1827 至 1839 UTC 的 NUCAPS 观测区域的 (b) NUCAPS 以及(c) DNN 模型预测结果计算出的计算的地面抬升 CAPE (SBCAPE)，单位： $\text{J}\cdot\text{kg}^{-1}$ 。

Figure 2.14 Surface-based CAPE (SBCAPE) ($\text{J}\cdot\text{kg}^{-1}$) from (a) ERA5 Reanalysis at 1800 UTC, and calculations from (b) NUCAPS, and (c) DNN model outputs for NUCAPS overpasses from 1827 to 1839 UTC, 18 Jun 2017.

NUCAPS 在 1827~1839 UTC 覆盖该区域，利用改进前的 NUCAPS 温湿廓线计算得到的 SBCAPE 结果（如图 2.14(b)所示）相比于 ERA5 分析场（如图 2.14(a)所示）在包括在美国大陆东海岸、南部墨西哥湾沿岸海域等区域都有明显的低估。而利用模型改进后的温湿廓线的计算结果上（如图 2.14(c)所示）则很好地重现了 ERA5 再分析数据所呈现的，在东海岸和墨西哥湾西北部的 SBCAPE 超过 $2000 \text{ J}\cdot\text{kg}^{-1}$ 的高值区。这些对于 SBCAPE 的订正表现出了融合反演结果相比原始的 NUCAPS 数据具备更好地捕捉对流发生前的大气环境条件的能力。除了 SBCAPE 之外，在抬升指数 LI (Lifted Index) 的分布上也能得到类似的结论。LI 值低于 -2 K 的区域通常被认为是不稳定且容易发生雷暴过程的区域。图 2.15 所示的是通过各视场上温湿廓线计算得到的抬升指数 LI (Lifted Index) 分布情况，能看到 NUCAPS 在这些区域上相比 ERA5 有明显的低估，导致计算出的 LI 在该区域多为 0 及以上，显得大气过于稳定而没能捕捉到美国东海岸以及路易斯安那州的大

气不稳定性。相比而言，通过数据融合反演输出的廓线计算的 LI 分布则得到了明显的改进（如图 2.15(c)），在上述区域均表现出了-2 K 及以下的 LI 值，能够揭示该地区大气存在的不稳定性。由此可见，这些经由数据融合反演模型改进后的大气温湿廓线，能够为预报员提供更为可靠的卫星大气观测信息，有利于对于对流性天气环境的分析和高影响天气的短临预报。

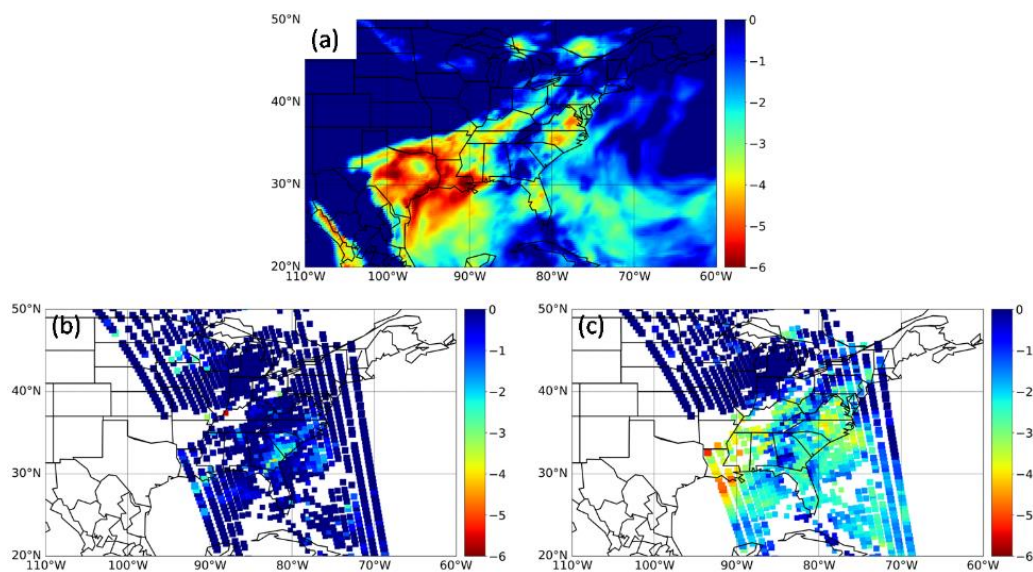


图 2.15 2017 年 6 月 18 日来自(a)1800 UTC 的 ERA5 再分析数据；以及在 1827 至 1839 UTC 的 NUCAPS 观测区域的 (b) NUCAPS 以及(c) DNN 模型预测结果计算出的计算的抬升指数 LI (Lifted Index)，单位：K。

Figure 2.15 Lifted Index (LI) (K) from (a) ERA5 Reanalysis at 1800 UTC, and calculations from (b) NUCAPS, and (c) DNN model outputs for NUCAPS overpasses from 1827 to 1839 UTC, 18 Jun 2017.

2.10 本章小结

常见搭载于极轨气象卫星上的红外高光谱探测仪与搭载于静止轨道卫星的高分辨率成像仪是观测地球大气状态和变化的主要手段。其中前者可以提供高垂直分辨率的大气温湿廓线反演数据，但是空间分辨率偏低，而且在低层大气的反演精度具有较大的误差与不确定性；而後者的时空分辨率较高可以提供大范围的连续观测，但是由于光谱分辨率有限，不能独立反演得到全高度层的反演廓线。在本章的研究中，通过将 2018 年 4~6 月的极轨高光谱反演产品 NUCAPS，与静

止轨道成像 ABI 以及地面中尺度实时分析场 RTMA, 通过一个多层神经网络模型进行数据融合, 以 ERA5 温湿廓线作为真值进行训练, 得到了一个能够在晴空和部分有云条件下改进 NUCAPS 低层大气温湿廓线准确度的大气反演改进模型, 得到的主要结论如下:

(1) 通过在独立检验数据集上的评估检验, 发现模型在晴空和部分有云的视场条件下, 能够显著降低 700 hPa 及以下层次温湿度相对于作为真值的 ERA5 之间的 Bias 和 STDE, 改进了低层大气温湿廓线的反演精度。其中在晴空条件下, 700 hPa 以下低层大气反演的平均温度方差减小了 68.1%, 相对湿度方差减小了 65.9%。而在部分有云的视场条件下, 温度平均方差减小了 58.1%, 相对湿度平均方差减小了 65.5%。模型从晴空条件向部分有云条件的扩展使得适用的有效样本量增加了大约 4 倍。

(2) 针对不同数据源的敏感性试验表明, ABI 和 RTMA 均对反演准确度的提升具有贡献。在晴空条件下, ABI 的引入减小了 700 hPa 及以下低层大气温度平均方差的 7.2% 和相对湿度平均方差的 10.2%, 而在有云条件下二者的值分别为 7.1% 和 8.6%。RTMA 在晴空区域对低层温度和湿度的平均方差减小了 5.5% 和 3.9%, 而在部分有云条件下二者的值分别为 10.9% 和 8.4%。相比于晴空区域, 在有云区域内的 ABI 贡献受到晴空区域对于总视场的代表性不足的影响而有所减弱。在影响范围上, ABI 能够改进整个对流层区域, 而 RTMA 仅对于对流层低层有影响。在本研究选取的 7 个 ABI 通道中, CO₂ 通道与窗区通道主要贡献于温度和低层水汽信息的反演, 而水汽通道则主要影响 800hPa 以上高度的湿度反演。

(3) 由于训练和验证数据集来自于对 2018 年数据集的随机分割, 通过使用 2017 年的数据对模型的泛化能力做了进一步的检验。研究结果同样发现了对于 2017 年的数据, 在晴空和部分有云情况下对低层温度与湿度廓线准确性的提升, 证明了该神经网络并没有出现对 2018 年数据的过拟合。但是, 考虑到潜在的应用前景, 应该用尽可能多的数据参与训练, 从而进一步提升其数据代表性和模型的泛化能力。

(4) 通过在 NPROVS 系统中 2017 和 2018 年与 NUCAPS 观测相匹配的探空观测数据对模型在低层大气的廓线反演改进能力进行了评估。结果发现, 本章

中训练的数据融合模型在低层大气的改进能力是稳定而可靠的。具体的评估结果受到 NUCAPS 与探空观测的时间间隔的影响, 模型对低层大气反演的改进能力在越小的时间间隔上表现得越为明显, 但由于满足时空匹配条件的探空观测太少, 在统计结果上并不具有显著性。通过两个探空个例的对比分析, 能够看出模型对于 NUCAPS 未能表达出的低层逆温条件具有较好的改进效果。

(5) 通过将数据融合反演模型应用到 2017 年 6 月美国东部一次高影响天气环境的短临预报中, 发现相比于原本的 NUCAPS 大气廓线数据, 经过数据融合的反演结果能够通过更好地表征低层大气的温湿特性, 从而反映低层大气的不稳定条件。研究中建立的基于神经网络的数据融合反演模型能够为预报员提供更为可靠的基于卫星的大气探测数据, 将有助于提升高影响天气预报的准确性。

本章的研究相比于传统的 1DVAR 反演方法主要有两个方面的优势: 一是在不需要前向算子的情况下融合多源观测数据; 二是模型的训练过程完成之后, 在实际应用中相比传统方法具有更高的计算效率。计算效率的提高对基于红外高光谱探测仪的温湿度反演尤其重要。其局限性则主要体现在两点: 首先是其高度依赖于训练数据的科学性和代表性, 数据质量在很大程度上决定了模型的准确性和适用性; 其次是输出反演数据的时间分辨率仍然受到 NUCAPS 的影响(12 小时), 这对于短生命史天气过程的预报应用仍具有局限性。随着搭载于地球静止轨道卫星的高光谱大气探测仪投入使用, 将能够实现特定范围的高光谱连续观测, 进而有机会反演得到高频次的高垂直分辨率大气廓线。本章的研究提出了基于大量卫星观测数据进行大气廓线反演的新途径, 也为将来发挥同平台多仪器观测数据联用价值提供了新的思路。

第3章 基于静止卫星高光谱探测的大气廓线反演

3.1 引言

上一章的研究已经成功地实现了利用神经网络对极轨卫星高光谱探测与静止卫星成像的联合应用,并证明了其在高光谱大气廓线的定量反演,以及强对流天气预报预警中的应用价值。然而极轨卫星的观测模式仍然导致其在同一区域的观测时间间隔较大,尽管通过多颗卫星联合应用可以实现对同一区域的每日多次观测,但仍难以实现对于快速发展系统的高频次连续观测。风云四号 A 星搭载的地球静止轨道红外干涉式高光谱探测仪(GIIRS)是世界上首个搭载于地球静止轨道的红外高光谱大气探测仪,其首次实现了在地球静止轨道上,对于的大气温度、湿度等的时间和空间变化信息进行大范围、快速的三维连续观测(Yang J 等., 2017; 张鹏 等, 2016; 董瑶海, 2016)。通过 GIIRS 具有高光谱分辨率的长波和中波红外通道观测信息,可以通过适当的反演算法得到高垂直分辨率和高时间分辨率的大气温度与湿度廓线,而这些廓线能够反映快速变化的大气环境信息,对于中小尺度天气系统的监测预警和科学研究都有极大的应用价值。

自 FY-4A 的成功发射以来,许多学者对其搭载的 GIIRS 观测资料进行了多个方面的研究。冯绚 等(2019)通过围绕 GIIRS 的一系列在轨定标试验发现,GIIRS 的光谱定标精度达到 10 ppm,且与 IASI 的辐射交叉定标检验证明 GIIRS 在长波和中波的平均亮温偏差均小于 1 K。罗双 等,(2019)对于 GIIRS 信息容量的定量分析也证实了其红外光谱对于大气温度和水汽信息的探测能力。Di 等(2018)利用有代表性的局地训练样本训练了在快速辐射传输模式中的 GIIRS 观测算子。Yin 等(2020)对 GIIRS 长波通道亮温在 GRAPES 4D-Var 系统中的观测模拟偏差进行了评估以及偏差订正。Di 等(2021)针对 GIIRS 连续观测的特点提出了考虑大气变化特性的通道选择方法。尹若莹等(2019)综合信息熵方法和权重函数法开发了针对 GRAPES 数值预报系统同化应用的长波红外通道选择方案。He M 等(2019)利用常规地面探空资料对于国家卫星气象中心(NSMC)发布的 GIIRS L2 业务大气温湿廓线产品进行了检验,结果发现在晴空和有云覆盖的情况下,温度廓线产品相对探空观测的平均 RMSE 分别为 2 K 和 3.7 K,而相对湿

度的 RMSE 分别为 18% 和 21%，而引入视场所覆盖的云类型信息有助于对反演廓线产品进行进一步的质量控制。黄艺伟等 (2021) 利用 ERA5 再分析数据集作为基准对于东海和南海地区的温度廓线产品进行检验发现，对于满足质量控制的反演产品，东海晴空区温度平均的 RMSE 为 1.71 K，而南海区域的平均 RMSE 为 1.67 K，但在有云状况下二者的值分别为 4.72 K 和 6.68 K，相比晴空而言准确度显著降低。这一研究结果与黄艺伟等 (2019) 利用探空资料对 GIIRS 反演廓线在上海台风季的检验结果相一致。

为了提高首个静止轨道高光谱探测仪 GIIRS 对于大气温湿廓线的反演精度，一些学者开展了对于定量反演算法的研究，并取得了一些有意义的成果。Xue 等 (2022) 提出了一个基于一维变分的物理反演算法，其对流层的温度反演结果与探空之间的 RMSE 小于 2 K，而比湿的 RMSE 在 $2 \text{ g}\cdot\text{kg}^{-1}$ 以内。Cai 等 (2020) 通过以 ERA-Interim 再分析数据为真值建立 BP 神经网络，训练得到了一个针对我国华北平原晴空条件下的 ANN 反演算法，其对流层温度相对于真值 (EC 再分析数据) 的 RMSE 小于 1 K，而相对湿度 RMSE 小于 10%，超过了 AIRS 廓线产品相对于同样真值的准确度。这一结果也基本达到了鲍艳松等 (2017) 基于模拟数据利用相似算法得到的反演精度。Yu 等 (2020) 也使用了类似的反演模型讨论了不同通道选择方案对温度廓线反演精度的影响。Huang 等 (2021a, b) 使用印度地区的观测数据分别对 GIIRS 的温度和湿度廓线反演使用了“ANN+1DVar”以及“CNN+1DVar”的方法，实现了物理方法与机器学习方法的结合使用。基于已有的研究不难发现，随着机器学习理论和方法的发展，以及大量观测数据的获取，以神经网络为代表的机器学习模型凭借其相对传统统计方法的能够拟合非线性关系的能力，以及相对于物理反演方法有较高计算效率等优势，已逐步成为改进大气廓线反演算法和精度的重要工具。

鉴于在上一章的研究中，作者已成功地应用神经网络实现了对极轨卫星探测的反演改进，并在试验中成功地利用 ABI 宽谱成像的多通道观测亮温得到了一些合理的反演结果，本章的研究内容是在上一章的研究基础上，利用静止卫星红外高光谱实际观测资料，与来自再分析数据的大气温湿廓线建立神经网络回归模型，并通过一次台风“玛利亚”期间的加密观测资料，建立适应于加密观测区域的大气温湿廓线反演模型，讨论 GIIRS 相对其他高光谱红外探测仪的核心优势

——高时间分辨率在大气廓线反演中的应用价值。

3.2 研究数据

3.2.1 GIIRS L1 数据

本章的研究使用了搭载于 FY-4A 上的 GIIRS 是国际上首个静止卫星红外高光谱探测仪的 L1 级观测数据。GIIRS 采用的是迈克尔逊干涉分光的方式对大气红外辐射进行观测，在长波（700-1130 cm^{-1} ）和中波（1650-2250 cm^{-1} ）红外波段共有 1650 个通道，其中包括 689 个长波红外通道和 961 个中波红外通道，光谱分辨率为 0.625 cm^{-1} (Yang J 等., 2017)。与极轨卫星探测仪不同，GIIRS 作为地球静止轨道卫星探测仪，其对地距离更远，因而在每个驻留点上采用 32×4 个视场（Field-of-views, FOVs）构成的大面阵来进行观测，视场的水平分辨率为 16 km。自 2018 年 12 月以来，GIIRS 的观测模式为以 2 小时为周期获取东亚地区的区域观测资料，观测范围是(3~55°N, 66~ 144°E)，其中在每天的 16-18 时不安排观测任务。图 3.1 所示的是 GIIRS 的常规观测模式。在每个扫描周期，GIIRS 对整个区域由北向南依次扫描 7 行，每行由西向东共 59 个驻留点，每行的扫描时间约 15 分钟，其中第 10-15 分钟为定位定标观测时间。除了对整个观测区域以 2 小时为周期的常规观测之外，GIIRS 还可以进行对于特定目标区域在特定时段的加密观测，能够进一步发挥 GIIRS 相比于传统极轨卫星大气探测所具备的高时间分辨率优势。其中，GIIRS 在 2018 年台风“玛利亚”登陆期间的 15 分钟分辨率加密观测已经成功地证实了其在减小台风预报误差方面的显著作用(Yin 等., 2021)。




图 3.1 GIIRS 常规观测区域示意图，背景为 FY4A 的多通道静止轨道辐射成像仪 AGRI 的真彩色图像。（图片来源：国家卫星气象中心，
www.nsmc.org.cn/nsmc/cn/instrument/GIIRS.html）

Figure 3.1 Schematic of the regular observation region of GIIRS, with the background true color image from FY4A Advanced Geostationary Radiation Imager (AGRI) multi-channel imager. Cited from National Satellite Meteorological Center(NSMC) website, www.nsmc.org.cn/nsmc/cn/instrument/GIIRS.html.

3.2.2 2018 年第 8 号台风“玛利亚”

1808 号“玛利亚”超强台风是 2018 年发生于西北太平洋的第一个达到萨菲尔-辛普森飓风等级 5 级强度的台风，对于关岛、琉球群岛、我国台湾岛以及华东地区造成了严重的影响。该台风于 2018 年 7 月 4 日 1200 UTC 在关岛附近洋

面生成并迅速加强，并在 2018 年 7 月 5 日 2100 UTC 发展为超强台风，并一直保持超强台风的级别至 7 月 10 日 0800 UTC，此后以强台风的级别向西北方向移动。在此期间“玛利亚”台风在 7 月 9 日的最大强度达到了 10 分钟平均风速 195 km/h，中心最低气压达到 915 hPa。在其向西北方向移动的路径中（如图 3.2 所示），先后在 7 月 10 日穿越了八重山群岛以及台湾海峡北部，并于 7 月 11 日 0110 UTC 在福建宁德登陆中国大陆。其登陆时仍然为强台风级别，移动速度大约 30 km/h，中心附近最大风力 42 m/s，中心气压 960 hPa，在福建和浙江沿海带来了约 2.5 m 的风暴潮和高达 9 m 的巨浪(Yang J 等., 2021)。在登陆之后，“玛利亚”逐渐减弱并于 7 月 11 日 1200 UTC 在我国江西境内减弱为热带低压。

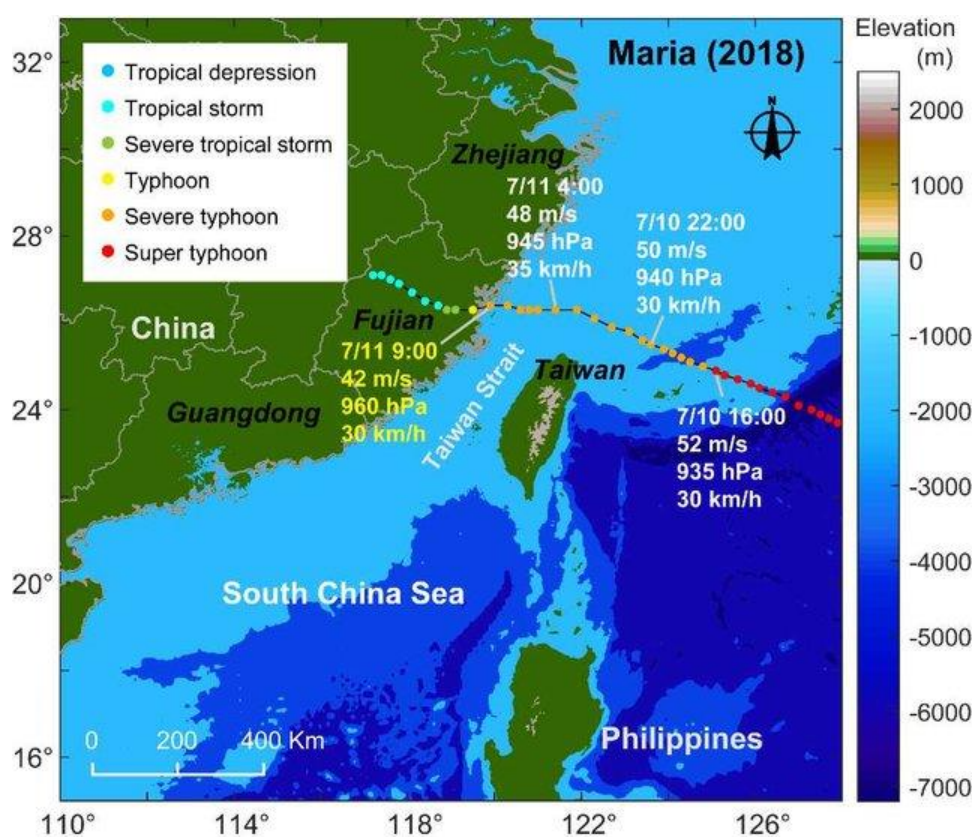


图 3.2 来自于中国台风网(<http://typhoon.weather.com.cn>)的以北京时（世界时+8）表示的台风“玛利亚”最佳路径。

Figure 3.2 Best track of Typhoon Maria described in Beijing time (UTC+8) from Chinese typhoon weather website (<http://typhoon.weather.com.cn>)

3.2.3 GIIRS 加密观测

为了更好地利用 GIIRS 的高时间分辨率与灵活机动的特点,在台风“玛利亚”登陆过程中,GIIRS 对于台风路径经过的部分区域进行了时间分辨率为 15 分钟的目标区加密观测。本研究所使用的数据是在世界时 2018 年 7 月 10 日 00~16 时,以及 21~23 时的 15 分钟分辨率加密观测。图 3.2 所示的是 GIIRS 在台风“玛利亚”期间在 2018 年 7 月 10 日 0500 UTC 开始的一次加密观测,加密观测的区域范围约为(13.7~34.5°N, 108.9~136.2°E)。在加密观测期间,GIIRS 的观测方式为如下:每 15 分钟内从北向南依次扫描 3 行,每行自西向东有 17 个驻留点,每个驻留点有 32×4 个像元,在整个加密观测区域内总共 96×68 个像元。其中每一行的观测时间约为 3 分钟,每次观测的 10~15 分钟用于观测定位定标。本研究所使用的 GIIRS 观测参数如表 3.1 所示,其观测视场的空间分辨率为 16 km,而长波和中波红外通道的光谱分辨率均为 0.625 cm^{-1} 。

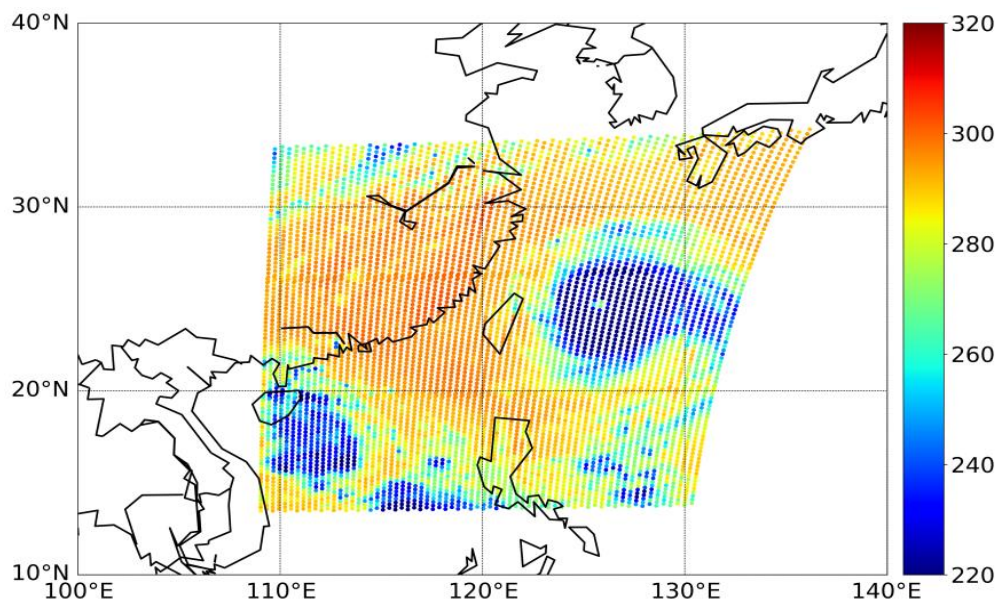


图 3.3 台风“玛利亚”期间 GIIRS 加密观测区域范围。图上变量为红外长波第 309 通道 (波长: $11.20\mu\text{m}$) 在 0500 UTC, 07/10/2018 的亮温分布(单位: K)

Figure 3.3 The target region of the intensified GIIRS observation during Typhoon Maria, shown by the brightness temperature of the No. 309 longwave IR channel (wavelength =

11.20 μm) at 0500 UTC, 07/10/2018. (Unit: K)

表 3.1 风云 4A GIRS 在台风“玛利亚”期间加密观测的相关参数

Table 3.1 Parameters of FY-4A GIRS Intensified Observations during Typhoon Maria

观测参数	指标
光谱范围	长波: 700-1130 cm^{-1} 中波: 1650-2250 cm^{-1}
光谱分辨率	0.625 cm^{-1}
通道数	长波: 689 中波: 961
空间分辨率	16 km (星下点)
时间分辨率	15 min
观测空间范围	(13.7~34.5°N, 108.9~136.2°E)
定标精度	光谱定标: 10 ppm 辐射定标: 1.5 K

3.2.4 ERA5 再分析数据

由于在加密观测区域和时段内的探空观测非常有限, 本章的研究与上一章类似地采用了欧洲中尺度天气预报中心 ECMWF 开发的 ERA5 再分析数据。相比于 ECMWF 上一版本再分析数据 ERA-Interim, ERA5 具有更高的空间分辨率以及更高的输出频率(Hersbach 等., 2020)。本研究所使用的是逐小时的, 水平分辨率 0.25° , 垂直方向在 1 hPa 至 1000 hPa 的 37 个等压面以及地面的再分析数据产品。其中来自地面分析数据的地面气压场被用于对大气温湿廓线的地面以下部分进行修正, 即以地面以上最低层次的温度与湿度特征覆盖地面以下的所有层次。在基于神经网络的反演模型的训练和检验过程中, ERA5 数据集被用作神经网络的训练真值, 以及检验反演结果的真实值。

3.2.5 GDAS 分析场

本章的研究中使用了来自美国 NCEP 的 GDAS (Global Data Assimilation

System) 分析数据作为对 GIIRS 大气廓线准确度的除 ERA5 之外的独立评估数据集。GDAS 分析场为空间分辨率为 $0.25^\circ \times 0.25^\circ$ 的格点数据, 在垂直方向上拥有从 10 hPa 到 1000 hPa 共 26 个等压面的数据。其时间分辨率为 6 小时, 于每日的 0000、0600、1200 和 1800 UTC 进行发布, 并被用作驱动 GFS 预报模式的初始场(Kanamitsu, 1989)。该数据的使用能够在一定程度上排除应用同一数据集在训练数据与独立检验数据之间所隐含的相关性, 从而对反演模型的精度做出更为独立的评估。

3.2.6 机载下投探空

为了将 GIIRS 反演的大气廓线与观测的大气实际状态进行对比, 采用了台风“玛利亚”期间的机载下投探空观测。这些探空观测是从专门用于气象观测的飞机上下落投放的, 搭载有 GPS 天线、GPS 接收器以及气压、温度和湿度传感器的探空仪, 获得的大气探空观测。观测数据被通过卫星电话传送至地面系统, 并通过 UCAR 开发的大气探空处理环境 ASPEN (Atmospheric Sounding Processing Environment) 软件对其进行了数据分析和质量控制。该类型的探空观测数据已经在许多卫星反演相关的研究中得到了广泛的应用(Liu C-Y 等., 2020, 2015, 2014)。

3.3 通道选择

由于大气温度和湿度的卫星观测信息分别主要由长波和中波通道提供, 因而需要在 GIIRS 的众多通道中分别选择能够代表垂直方向上不同高度层大气特性, 又不会带来过大的不确定性进而带来反演误差的长波和中波通道。由于 GIIRS 相比于传统的极轨卫星高光谱探测仪的最大优势在于时间分辨率, 我们在温湿度反演过程中也引入了在反演时次之前一个时次(15 分钟前)的观测, 与当前时刻一同加入作为模型训练因子, 以表征时间变化在大气廓线反演中的应用。这样在通道的选择过程中, 就不仅仅需要考虑通道在单一时刻的代表性, 也应该考虑其对大气状态的时间变化的捕捉能力。本文采用了李俊研究员团队中狄迪博士提出的改进的信息熵迭代算法, 该方法在常规的信息熵迭代算法 (Collard, 2007) 基础上加入了一个表征 Jacobian 时间变化的系数 M , 从而能够通过静止卫星高光谱大气探测捕捉大气状态的快速变化 (Di 等., 2021)。图 3.4 所示为本研究利用该

算法所选定的选取了既能在垂直方向上能够满足不同层次的代表性,又能很好地体现大气状态的时间变化信息的 338 个通道,其中包含 146 个长波通道,和 192 个中波通道。

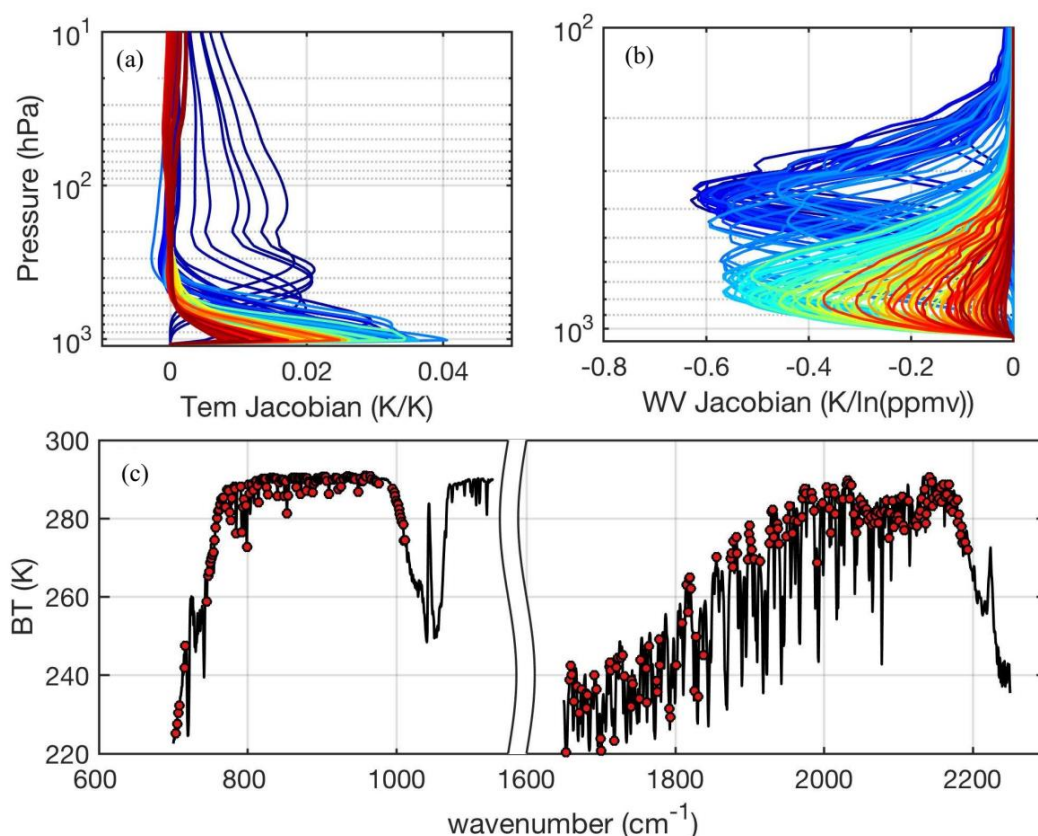


图 3.4 本研究中选择的不同用于大气温湿廓线反演的(a)长波红外通道的温度 Jacobian 和 (b) 中波红外通道的对数形式水汽混合比 Jacobian, 以及(c)以红色实心圆表示的所选通道叠加于用 1976 年美国标准大气模拟的 GIIRS 全部红外通道的亮温光谱。

Figure 3.4 (a) Selected LWIR channels and their respective temperature Jacobian, and (b) Selected MWIR channels and their respective water vapor mixing ratio (lnq) Jacobians; (c) selected channels marked with red dots overlaying on simulated brightness temperature spectrum of Geosynchronous Interferometric Infrared Sounder from 1976 U.S. Standard Atmosphere.

3.4 数据预处理

除了通道选择之外,对高光谱大气探测的观测误差订正对于大气反演的准确性也具有重要的影响。尹若莹 (2020)的研究发现,GIIRS 在光谱定标和辐射定标上分别存在着一定的误差,该误差存在日变化特征且在不同通道有不同的表现。Knuteson 等(2021)对此问题针对性地开发了一个利用光谱定标误差来对高光谱辐射进行重采样的误差订正方案。本研究使用的是在威斯康星大学麦迪逊分校(UW-Madison)的空间科学与工程中心(SSEC)针对 GIIRS 在台风“玛利亚”期间加密观测数据的定标重采样产品。与此同时,通过观测模拟偏差 O-B 的统计特征,对于 GIIRS 不同通道观测存在的阵列偏差进行了订正。除此之外,考虑到红外高光谱仪器易受到云污染的影响,进而影响大气垂直信息观测的准确性,本研究通过计算已选长波通道中波长在 11 μm 附近的 15 个长波通道亮温的平均值作为分类标准,认为该值超过 280 K 的观测视场受到云的影响较小,用于反演模型的训练和检验。

3.5 神经网络设置与训练

为了更好地利用 GIIRS 的高光谱观测数据,我们采用了机器学习算法当中的多隐层神经网络,并采用 0.25° 水平分辨率,逐小时的 ERA5 在 100 至 1000 hPa 共 27 个等压面上的温湿度廓线,在时间与空间上匹配到 GIIRS 观测视场的地理位置和对应驻留点的观测时刻,作为神经网络训练的真值。而在输入变量方面,对于温度反演模型采用的是在 3.3 节中选出的 146 个长波通道的经过阵列偏差订正的亮温信息作为预报因子,而湿度(水汽)反演模型的预报因子则是上文中通过改进信息熵算法结合数值预报模式选出的 192 个中波红外通道经过阵列偏差订正的亮温值。在完成数据匹配之后,将每个整点开始的 GIIRS 观测(00~15)作为模型中不参与训练过程的独立检验数据集,而每小时的其他三次观测(15~30, 30~45, 45~00)作为模型的训练数据集参与模型的训练和优化。在本研究中,训练集和独立检验数据集当中以 GIIRS 观测视场为单位的样本量分别为 154107 和 65919。

表 3.2 本章研究中使用的神经网络设置

Table 3.2 Configurations of the neural network used in this chapter

神经网络参数	参数设置
隐藏层数	2
输入层神经元数	146 (温度), 192 (湿度)
隐藏层神经元数	512, 512
输出层神经元数	27
激活函数	ReLU
损失函数	MSE + L2 正则化
优化器	ADAM
测试集占比	0.2
最大迭代次数	20000
最小提升阈值	0.0001
最大容忍次数	100

研究中使用的神经网络在输入层（GIIRS 观测）和输出层（100~1000 hPa 的 ERA5 温度、湿度廓线）之间共有两个隐层，每个隐层各有 512 个神经元。网络结构的设定参照了(Karsoliya, 2012)的研究结论以及已有的基于卫星观测的研究(Zhou and Grassotti, 2020; Tao 等., 2018, 2016)采用双隐层神经网络所取得的成功经验。训练中使用了 ReLU 函数(Nair 等., 2010) 作为隐藏层的激活函数，均方根误差（MSE）作为神经网络的损失函数（Loss function），并且加入了正则参数等于 1 的 L2 正则化项(Girosi 等., 1995)，对于个别神经元权重参数过大所导致潜在的模型过拟合现象进行限制。包含正则化项的损失函数在训练过程中经由 Adam 优化函数(Kingma and Ba, 2017) 进行向最小化方向的迭代优化，通过对于在训练数据集当中随机分割出的，占总样本 20 % 的测试集上的表现进行循环检验，并在 20000 的最大迭代次数内，以 0.0001 的损失函数减小幅度结合 100 次的最大容忍迭代数作为阈值，当连续未达到最小提升幅度的迭代次数超过最大容

忍次数时，模型将通过提前终止算法来提高精度并限制神经网络过拟合情况 (Glorot and Bengio, 2010)的影响。

3.6 反演结果与检验

利用与 GIRS 观测视场时空匹配的 ERA5 大气廓线对于神经网络训练的反演模型在独立检验测试集上的反演结果进行了验证。图 3.5 所示的是模型对 100~1000hPa 共 27 个等压面上温度反演结果与相应的真实值 (ERA5) 的散点分布图与误差廓线特征。其中，STDE 和 Bias 的表达式已在前文第 2.5.1 节中的式 (2.3) 和式 (2.4) 中给出，而 RMSE 的表达式为：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad \dots (3.1)$$

其中 x_i 和 y_i 分别代表模型的反演结果和与之对应的来自 ERA5 的温度或湿度真值。统计结果显示，反演得到的温度结果与真值数据相对 $y = x$ 线 (图 3.5(a) 中红色线) 分布基本均匀，且偏离程度较小。整层温度的 RMSE 为 0.639 K，而平均偏差为 0.092 K，表现出了较为理想的准确度，优于美国业务极轨卫星反演 (NPP) 的质量要求，并和 Cai 等 (2020) 利用神经网络在华北地区陆地区域的反演结果十分接近。从误差垂直廓线上可以看出，温度反演结果的 STDE 在 200 至 800 hPa 之间均小于 0.5 K，仅在 800 hPa 以下包含大气边界层的低层大气和 200 hPa 以上接近平流层的对流层高层大气有相对增大的不稳定性，在 Bias 绝对值的垂直分布方面也有类似的结果，仅在 250 hPa 以上和 850 hPa 及以下层次 Bias 的绝对值超过 0.05 K，其他层次上的 Bias 均在 0 值附近，且绝对值不超过 0.05 K。

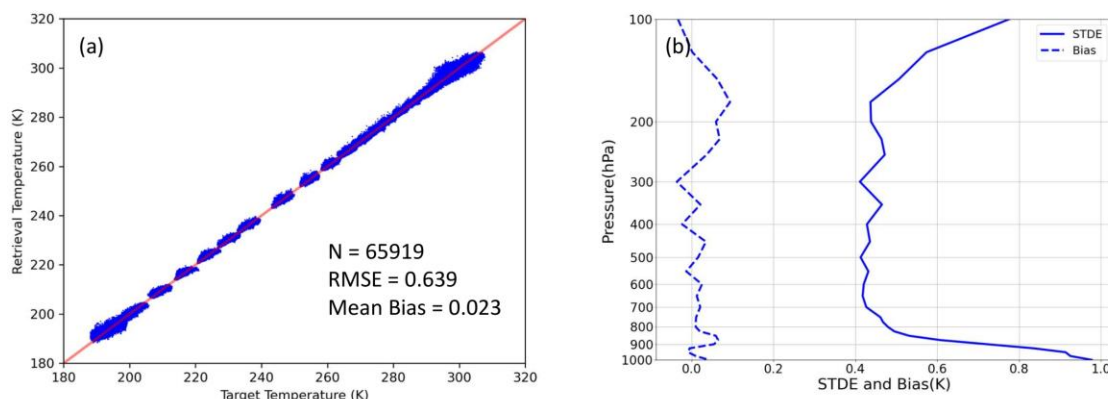


图 3.5 神经网络训练的 GIRS 温度反演模型在独立检验数据集上的反演结果相对于 ERA5 的统计检验结果，(a) 100 至 1000 hPa 所有层次的反演结果与真值分布散点图；(b) 100 至 1000 hPa 各层次的反演结果与真值间的 STDE 和 Bias 分布廓线。

Figure 3.5 Statistical validation results of GIRS temperature retrieval model developed via neural network on independent validation dataset against corresponding truth values from ERA5. (a) Scatter diagram of retrieved temperature and truth values from all levels from 100 to 1000hPa; (b) Profile of STDE and bias between retrieved temperature and truth values on each level from 100 to 1000hPa.

图 3.6 所示的是 7 月 10 日 0400 UTC 在加密观测范围内满足 280 K 的反演阈值的 GIRS 视场在 300 和 850 hPa 的反演温度场的水平分布与 ERA5 的对比。在 300 hPa 的温度分布上，反演结果与 ERA5 的误差的绝对值在区域内的绝大多数视场都小于 0.5 K，且分布形式高度一致，仅在台湾岛东北部的台风云系前缘的个别视场存在绝对值在 1 K 附近的偏冷误差，可能与台风前部的强上升运动有关。而在 850 hPa 的反演结果上，如图 3.6(f)所示，绝对值大于 1.5 K 的误差主要集中于大陆东南与海岸线平行的武夷山脉区域，以及台湾岛的中央山脉地区，而在其他大多数地区的误差绝对值都在 0.5 K 以内。将 850 hPa 的温度反演误差分布与观测区域的地形分布相对比，可以看到相比于 300 hPa 的误差分布，850 hPa 温度反演误差绝对值超过 1.5 K 的区域与地形分布存在明显的相关性。在这些存在山脉地形的下垫面上，850 hPa 等压面的距地高度相比平原地区显著减小，这将导致高光谱大气探测得到的近地面大气辐射信息与地面辐射的对比度降低，进而影响了该层次大气温度的反演精度(曾庆存, 1974)。

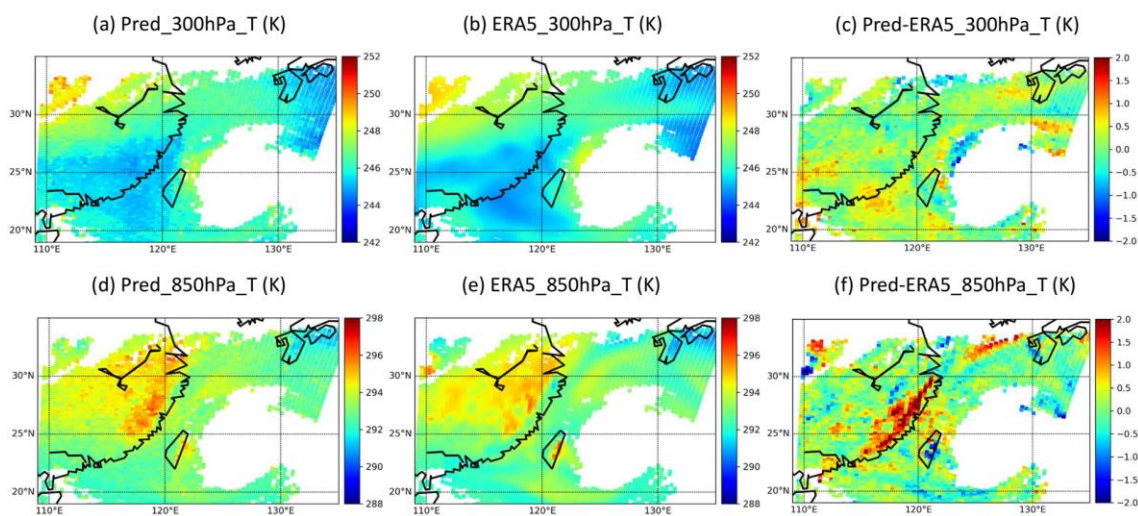


图 3.6 GIIRS 温度反演结果与 ERA5 的对比。(a) GIIRS 反演的 300hPa 温度场；(b) ERA5 在 GIIRS 晴空视场的 300hPa 温度场；(c) GIIRS 反演的 300hPa 温度结果与 ERA5 分析场之间的差异；(d) GIIRS 反演的 850hPa 温度场；(e) ERA5 在 GIIRS 晴空视场的 850hPa 温度场；(f) GIIRS 反演的 850hPa 温度结果与 ERA5 分析场之间的差异，单位：K。

Figure 3.6 Comparison of temperature retrieval results from GIIRS against ERA5. (a)300 hPa temperature field retrieved from GIIRS; (b)300 hPa temperature field from ERA5 on clear-sky FOVs of GIIRS; (c)Difference between GIIRS retrieved temperature and ERA5 at 300 hPa; (d)850 hPa temperature field retrieved from GIIRS; (e) 850 hPa temperature field from ERA5 on clear-sky FOVs of GIIRS; (f) Difference between GIIRS retrieved temperature and ERA5 at 850 hPa. Unit: K.

图 3.7 所示的是模型对于 100 至 1000 hPa 27 个等压面的比湿反演的统计检验结果。从图 3.7 (a) 可以看出，反演得到的比湿结果与真值的分布关系与 $y = x$ 线呈现基本对称的分布，整层的 RMSE 为 0.571 g/kg，而平均偏差为 0.007 g/kg。在垂直廓线方面，最大的 STDE 和 Bias 均出现在 900 hPa，分别为 0.856 g/kg 和 0.121g/kg。在 Bias 的垂直分布上，除了 875 和 900 hPa 两个层次以外，其余层次的 Bias 绝对值均小于 0.1 g/kg，其中在 400 至 825 hPa 表现为平均的负偏差，而

在 850 hPa 及以下层次则表现为正偏差。在 STDE 的垂直分布上,反演结果在 900 hPa 及以上层次随高度迅速降低,在 500 hPa 以上的 STDE 则小于 0.4 g/kg。值得一提的是,尽管以比湿所代表的绝对水汽含量的反演在大气辐射传输的物理意义上显得更为直接,但是由于大气中的水汽含量在对流层中高层迅速降低,仅靠大幅降低的比湿误差无法准确评估这些层次上相对湿度的误差分布情况,因而有必要对反演模型在相对湿度上的误差特征进行分析。

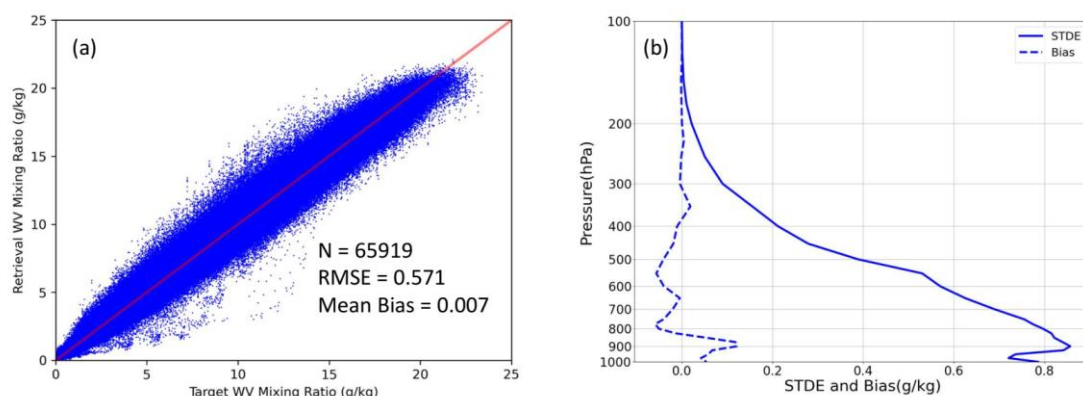


图 3.7 神经网络训练的 GIIRS 比湿反演模型在独立检验数据集上的反演结果相对于 ERA5 的统计检验结果, (a) 100 至 1000hPa 所有层次的反演结果与真值分布散点图; (b) 100 至 1000hPa 各层次的反演结果与真值间的 STDE 和 Bias 分布廓线。

Figure 3.7 Statistical validation results of GIIRS specific humidity retrieval model developed via neural network on independent validation dataset against corresponding truth values from ERA5. (a) Scatter diagram of retrieved specific humidity and truth values from all levels from 100 to 1000hPa; (b) Profile of STDE and bias between retrieved temperature and truth values on each level from 100 to 1000hPa.

由于相对湿度的值除了与空气中的水汽含量有关,也和大气温度有关,为了避免温度反演结果的误差对于相对湿度反演的影响,研究中采用了与 Cai 等 (2020) 相同的方法,即直接将 ERA5 的相对湿度信息作为真值,使用与比湿反演相同的中波红外通道观测亮温作为输入数据,训练得到能够直接从 GIIRS 观测定量反演相对湿度的神经网络模型。图 3.8 (a) 所示的是相对湿度反演结果与对应真值之间的误差分布情况。相比于比湿的反演结果,相对湿度的反演误差更为

显著，100 到 1000hPa 平均的 RMSE 为 8.666 %，而平均偏差为-0.010 %，但是对比图 3.8 (b) 所示的误差分布廓线能够看到，在 250 hPa 以下的层次，模型对相对湿度反演结果的 STDE 都小于 10 %，而在 250 hPa 以上的对流层高层至平流层部分 STDE 普遍较大。与此同时，在 Bias 的垂直廓线上也可以看到类似的分布，Bias 的绝对值在 150 hPa 等压面上出现 5.51 % 的最大值，而最大正偏差出现在 125 hPa，为 3.21 %。但是在 250 hPa 及以下的所有层次，Bias 的绝对值均小于 1 %，而在 400 至 850 hPa 之间各层的 Bias 绝对值都小于 0.4 %。然而经过统计得到，在用于检验的数据集当中，ERA5 在 250 hPa 及以上的等压面的平均比湿仅有 0.076 g/kg，而其 STD 也仅有 0.107 g/kg，然而在 500 至 850 hPa 之间，这两个值分别为 8.288 g/kg 和 3.905 g/kg，这些层次上的水汽含量远低于对流层中低层，然而由于这些层次上的温度较低，导致饱和水汽压很低，这些微小的水汽含量仍可以带来很大的相对湿度，因而在水汽含量上较小的误差将带来较大的相对湿度上的差异，这也解释了如图 3.7 (b) 所示的比湿反演结果在这些对流层高层至平流层高度上与相对湿度反演结果的不一致性。但是对于 300 hPa 及以下的大气相对湿度，反演结果与真值间的平均 RMSE 为 5.089 %，而平均偏差为 0.004 %，表现出了较为理想的准确度。

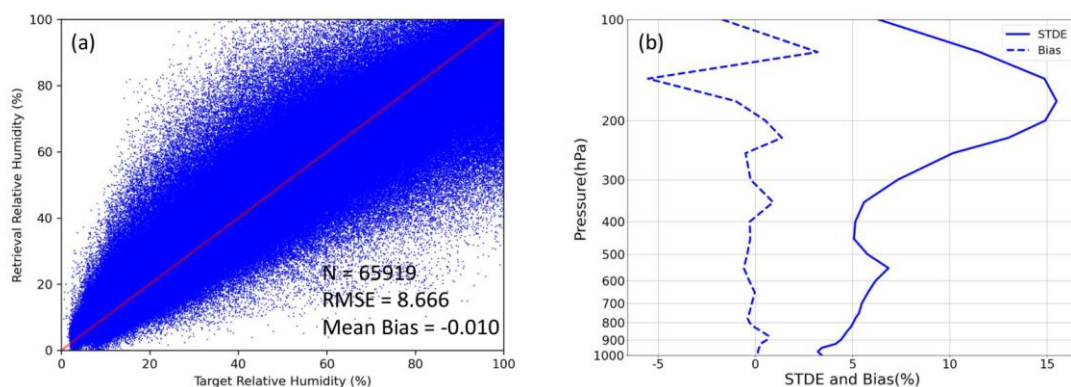


图 3.8 神经网络训练的 GIIRS 的相对湿度反演模型在独立检验数据集上的反演结果相对于 ERA5 的统计检验结果，(a) 100 至 1000hPa 所有层次的反演结果与真值分布散点图；(b) 100 至 1000hPa 各层次的反演结果与真值间的 STDE 和 Bias 分布廓线。

Figure 3.8 Statistical validation results of GIIRS relative humidity retrieval model developed via neural network on independent validation dataset against corresponding truth

values from ERA5. (a) Scatter diagram of retrieved relative humidity and truth values from all levels from 100 to 1000hPa; (b) Profile of STDE and bias between retrieved temperature and truth values on each level from 100 to 1000hPa.

除了 ERA5 之外, GDAS 分析场作为不同于训练真值数据 (ERA5) 的分析场, 可被作为更为独立的真值数据用于检验反演模型的准确度和泛化性。但是由于 GDAS 仅在每天的 0000, 0600, 1200 和 1800 UTC 有数据, 且 GIIRS 在每日的 1600~1800 UTC 不进行观测, 因而本研究仅采用前三个时次的 GDAS 和对应的 ERA5 对反演模型在这三个时次的温湿廓线反演结果进行对比检验。如图 3.9 所示, 无论是温度还是相对湿度的反演结果上, GIIRS 反演结果与 GDAS 之间的 STDE (蓝色实线) 在多数层次上都大于 GIIRS 与 ERA5 之间的 STDE (绿色实线), 而 GIIRS 与 GDAS 之间 Bias (蓝色虚线) 的绝对值也在几乎所有层次上大于 GIIRS 与 ERA5 之间的 Bias (绿色虚线)。但是参考 GDAS 和 ERA5 之间的 STDE (黑色实线) 的垂直分布, 能够看到 GDAS 与 ERA5 间的 STDE 接近甚至在某些层次上大于 GIIRS 与 GDAS 之间的 STDE。而在 Bias 的垂直廓线上, GDAS 与 ERA5 之间的 Bias 与 GIIRS 和 GDAS 之间的 Bias 基本呈现一个围绕 Bias = 0 的反向对称分布特征, 二者在绝对值上的较小差异对应于 GIIRS 和 ERA5 之间的 Bias。由此可以看出, 以 GDAS 作为真值的检验误差相对 ERA5 增大的主要来源是不同分析场之间的误差, 即检验真值之间的误差。但值得一提的是, GIIRS 反演廓线相对与非训练真值的数据集 GDAS 所表现的 STDE 仍然在合理范围内, 其中温度 STDE 在 950 hPa 及以上高度均在 1.0 K 以内, 相对湿度 STDE 在 300 hPa 及以下各层次中仅在 800 hPa 达到 10.9%, 其他层次均在 10% 以内, 误差范围比较稳定。这一方面说明了, 训练真值的选择对于反演结果的相对表现存在一定的影响, 但也同时说明了本研究中通过神经网络训练的反演模型在能够较好地体现作为训练真值的 ERA5 再分析数据准确度的基础上, 能够对应其他不同种类的分析数据保持效果的稳定性。

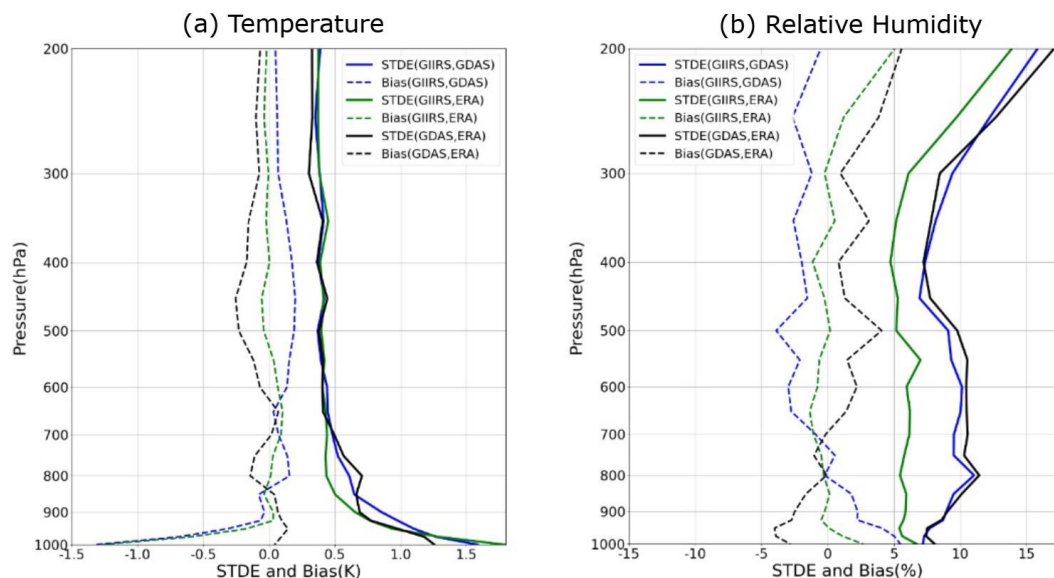


图 3.9 GIIRS 反演的 (a) 温度; 和 (b) 相对湿度结果相对于 GDAS (蓝线) 和 ERA5 (绿线), 以及 GDAS 相对 ERA5 (黑线) 的 STDE (实线) 和 Bias (虚线) 在不同等压面的分布廓线。

Figure 3.9 The Profiles of STDE (solid lines) and Bias (dashed lines) from GIIRS retrievals against GDAS (blue lines), and against ERA5 (green lines), and those from GDAS against ERA5 (black lines) on (a) temperature; and (b) relative humidity at different pressure levels.

3.7 探空分析

利用台风“玛利亚”期间的机载下投探空观测, 与匹配到的 GIIRS 观测视场上的反演结果, 以及对应的 ERA5 大气廓线进行了对比分析。图 3.10 的所示的是在加密观测区域内与 GIIRS 观测视场能够实现时间与空间匹配的两个探空观测。其中 3.10 (a) 所示的探空是 2018 年 7 月 9 日 2355 UTC 投放于 (124.41°E, 23.06°N) 的探空观测, 匹配到的 GIIRS 视场来自 7 月 10 日 0000 UTC, 视场中心位于 (124.13°E, 23.04°N)。通过反演结果与探空观测以及 ERA5 的对比能够看到, GIIRS 反演的温度廓线与 ERA5 高度重合, 而很好地表现出了探空温度廓线的走势。其中唯一的差异在于反演廓线没能表现出探空观测在 850 hPa 附近的弱逆温层以及对流层中上层存在的多个弱的震荡, 然而这些弱变化在 ERA5 的廓线中也没能被体现出来。这一方面是由于 GIIRS 反演模型与 ERA5 的垂直分辨

率不如探空观测那样精细，因而无法表现垂直方向细微的变化特征；另一方面也和下投探空仪受到大气水平运动的影响造成潜在的水平位移有关。相比于温度反演结果与探空表现出的高一致性，湿度的反演结果仍存在一定的误差。相比于探空观测，GIIRS反演结果对于650 hPa及以下部分的湿度分布与探空及ERA5较为一致，但是在600 hPa及以上与探空存在一定的误差，其中GIIRS和ERA5都没有表现出600至500 hPa，以及300至约250 hPa的两个干层，且GIIRS对500至300 hPa的深厚湿层的估计相对探空以及ERA5偏弱。在图3.10(b)所示的另一个探空对比上也能看到类似的现象，该探空是在2018年7月10日0006 UTC投放于(124.41°E, 24.35°N)，与之匹配的GIIRS观测视场来自0015 UTC，中心位置为(124.36°E, 24.34°N)。GIIRS在该视场的温度反演廓线与探空观测同样具有较高的一致性，但由于垂直分辨率的限制表现得过于光滑没有展现出探空廓线上的震荡特征以及400至200 hPa附近的偏暖层结，而作为训练真值的、垂直分辨率相同的ERA5同样没能表现出该特征。与3.10(a)的视场反演结果相类似地，3.10(b)的湿度反演结果同样在正确描述了对流层中低层的湿度分布的同时，在对流层中高层显得过于平滑而没有表现出550至350 hPa的深厚湿区。通过与ERA5廓线的对比，能够看到这些对流层中高层的湿度反演误差一方面来自观测视场与探空地点在时间与空间上的差异，因为在很多层次上ERA5的湿度反演廓线与探空也存在一定的差异，而另一方面也表现出了本研究基于GIIRS中波红外观测的湿度反演模型在对流层中高层湿度变化特征反演上存在的不足，而这一不足很可能与GIIRS中波红外通道存在的光谱定标不确定性和敏感性低等问题有关(Guo等., 2021)。

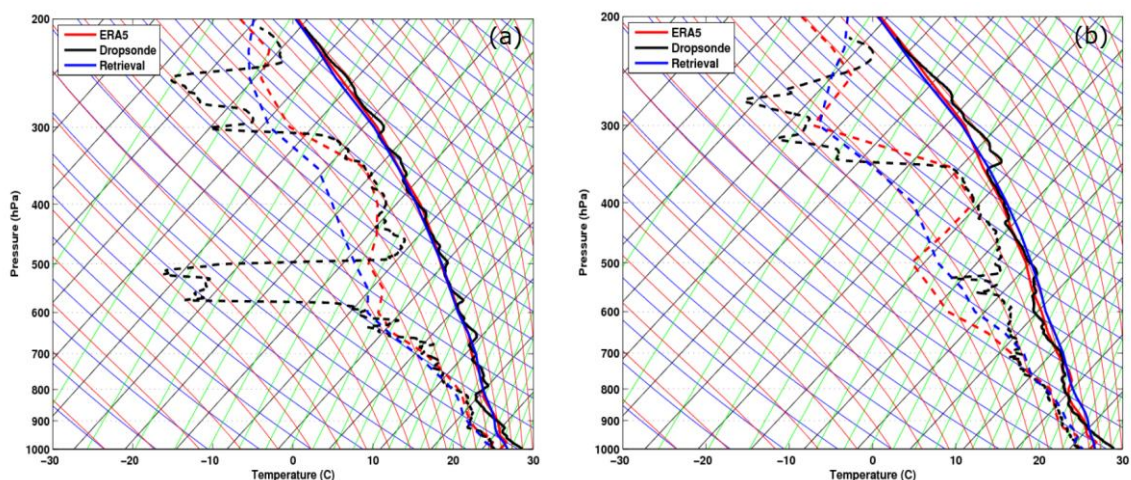


图 3.10 大气廓线中温度（实线）与露点（虚线）在 Skew-T 图上的体现：(a)2018 年 7 月 9 日 2355 UTC 投放于(124.41°E, 23.06°N)的下投探空观测，与 GIIRS 在 7 月 10 日 0000 UTC 观测的，中心在(124.13°E, 23.04°N)的视场上的大气廓线反演结果与对应的 ERA5 廓线对比；(b) 2018 年 7 月 10 日 0006 UTC 投放于(124.41°E, 24.35°N)的下投探空观测，与 GIIRS 在 7 月 10 日 0015 UTC 观测的，中心在(124.36°E, 24.34°N)的视场上的大气廓线反演结果与对应的 ERA5 廓线对比。

Figure 3.10 Temperature (solid lines) and dewpoint (dashed lines) profiles plotted in skew-t diagrams for (a) dropsonde launched at 2355 UTC from (124.41°E, 23.06°N) on July 9, 2018, compared with retrieved profiles from GIIRS observation at 0000 UTC on July 10, with FOV centered at (124.13°E, 23.04°N) and corresponding ERA5 profiles; and (b) dropsonde launched at 0006 UTC from (124.41°E, 24.35°N) on July 10, 2018, compared with retrieved profiles from GIIRS observation at 0015 UTC, with FOV centered at (124.36°E, 24.34°N) and corresponding ERA5 profiles.

3.8 时间变化信息的影响

搭载于风云四号静止卫星的 GIIRS 与国际上其他的高光谱大气探测仪相比，其核心优势在于拥有较高的时间分辨率，而台风“玛利亚”期间的加密观测使得其在特定时段的地域范围内能够获取更为精细的时间变化信息。为了探究 GIIRS 的时间变化信息对于大气温湿反演准确度的影响，特别开展了一组敏感性试验，将反演时刻前一时刻的对应通道观测信息加入到神经网络的输入变量中，与当前时刻的观测信息共同构成反演模型的预报因子，并将模型的检验结果与仅使用当

前时刻预报因子的模型反演结果进行对比。由于观测数据连续性和晴空反演条件的限制，我们仅对能够满足双时次反演条件的 **GIIRS** 观测样本进行了训练和对比检验。参与对比检验的 **GIIRS** 观测视场需要满足如下条件：首先，该观测视场要存在 15 分钟前时刻相同位置的观测数据；并且，两个时次的数据均需要满足 3.4 节提到的窗区平均亮温 280 K 的阈值，以排除云覆盖对于亮温观测信息的影响。最终参与训练和检验的样本数分别为 142287 和 35564。

图 3.11 所示的是加入时间变化信息的 **GIIRS** 反演模型与对应的使用单一时刻观测的反演模型在相同的独立检验数据集上的，在 200 至 1000 hPa 之间的温湿度反演结果相对于真值的统计检验结果。经过对独立检验数据集与对应真值（**ERA5**）的误差分析表明，使用单一时次观测的反演结果与加入时间变化的反演结果在所有研究层次上的平均温度 **RMSE** 分别为 0.524 K 和 0.475 K，而在相对湿度的平均 **RMSE** 分别为 6.410 % 和 6.170 %，加入时间变化的模型在总体上体现出了对大气温湿度廓线更好的反演精度。通过误差廓线的对比可以看出，不同模型表现出的 **Bias** 尽管存在垂直分布上差异，但都在 0 值附近，且各层次温度和相对湿度的绝对值分别不超过 0.1 K 和 1 %。二者的主要差别体现在 **STDE** 的分布上，加入时间变化信息的反演模型在 200 至 1000 hPa 的所有层次上的 **STDE** 都小于使用单一时次的反演结果。其中在温度方面，加入时间变化反演的 **STDE** 相比单一时刻模型在各等压面上平均降低 0.05 K，平均降低幅度为 9%，最大的单层 **STDE** 降低值为 0.11 K，最大降幅为 13.37%，均出现在 925 hPa 等压面上，而最小的单层 **STDE** 降幅也有 6.04%，出现在 650 hPa，该层的 **STDE** 降低了 0.02 K。在相对湿度的改进方面，通过引入时间变化信息，研究范围内各层的 **STDE** 平均减小了 0.29%，平均降幅为 4.60%，其中最大单层 **STDE** 降低值为 0.44%，出现在 925 hPa，最大 **STDE** 降幅为 8.11%，出现在 950 hPa，而在 225 和 250 hPa 改进最小，**STDE** 降低幅度小于 0.01 %。

通过对这些结果的分析可以看到，在反演模型中加入 **GIIRS** 观测的时间变化信息可以降低 **STDE**，即降低误差的离散度进而减小反演结果的 **RMSE**，从而在总体上提升神经网络反演模型对于大气温湿度廓线的精度。其中，加入时间变化信息对温度反演结果的改进幅度大于相对湿度的改进效果，而温度和相对湿度都在 925 和 950 hPa 的低层大气体现出了最大的改进。必须说明的是，由于研究使用

的样本仅来自一次个例的加密观测数据，虽然样本量并不小，但是在时间和空间范围上都存在代表性不足的问题。尽管如此，本研究的结果说明了静止卫星高光谱观测得到的时间变化信息对于反演精度具备一定的提升作用，而在更大范围数据上的具体表现仍需要更多的高时间分辨率观测加以进一步分析和验证。

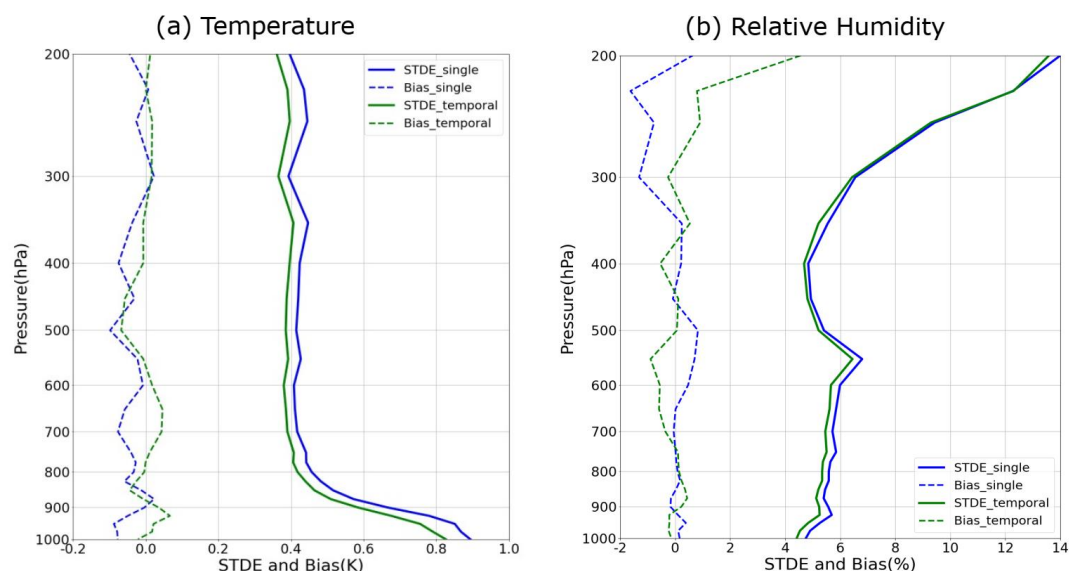


图 3.11 使用单一时次作为自变量训练的模型（蓝线）与自变量中包含时间变化的模型（绿线）的（a）温度反演结果；与（b）相对湿度反演结果相对 ERA5 的 STDE（实线）和 Bias（虚线）在不同等压面的分布廓线。

Figure 3.11 The Profiles of STDE (solid lines) and Bias (dashed lines) from GIIRS retrievals using single time observations (blue lines) against retrievals with temporal variations included in predictors (green lines), against ERA5 on (a) temperature; and (b) relative humidity at different pressure levels.

3.9 本章小结

本章的研究利用了 2018 年 7 月 10 日台风“玛利亚”发生期间 GIIRS 对特定区域的 15 分钟分辨率加密观测，通过选取能够反映大气状态及其变化信息的特征通道，将 GIIRS 高光谱红外观测数据，与时空匹配的 ERA5 温湿廓线分别作为预报因子和训练真值，构建了能够定量反演区域内大气温湿廓线的多隐层神经网络模型，主要得到以下结论：

(1) 利用独立时次的 ERA5 检验数据集对反演精度的检验表明, GIIRS 高光谱大气探测与神经网络相结合, 能够得到较高准确度的温湿廓线反演, 其中温度反演在 100 至 1000 hPa 的总体 RMSE 为 0.639 K, 误差主要存在于 200 hPa 以上和 800 hPa 以下。相对湿度的 RMSE 为 8.666 %, 误差主要存在于 300 hPa 以上的对流层高层, 而在 300 hPa 及以下层次的平均 RMSE 为 5.089 %。

(2) 通过与独立分析数据 GDAS 相对比, 发现模型相对 GDAS 的反演误差大于其相对 ERA5 的误差, 而分析表明误差主要来源于 GDAS 与 ERA5 之间的差异, 说明了反演结果与训练真值的选择有关。与此同时, 反演模型相对 GDAS 的反演误差仍在合理范围, 表现出反演模型算法具备一定的稳定性。

(3) 与探空观测个例的对比发现, GIIRS 反演的温度场能够较好地呈现与探空相一致的温度廓线, 但是存在由于以 ERA5 作为训练真值所导致的垂直分辨率不足的问题。在相对湿度的反演上, GIIRS 反演结果能够表现出对流层中低层的湿度结构, 但是对于对流层中高层的湿度变化特征则表现不足。

(4) 通过在预报因子中加入目标视场前一时刻的观测信息, 将高光谱探测的时间变化信息加入训练, 相比于相同样本利用单一时刻观测的反演结果, 模型在温度和相对湿度的反演精度都有所提升。其中温度反演的改进比相对湿度更为显著, 温度和湿度都在低层大气的改进幅度较大。尽管该试验由于样本代表性的限制而存在一定的局限性, 但是为后续充分发挥 GIIRS 特有的高时间分辨率的应用价值提供了新的思路和方法。

本章节展示的温湿度的反演精度都优于极轨卫星, 如 NUCAPS 的反演精度。这并不代表 GIIRS, 在仅仅使用 338 个长波和中波通道的情况下, 能够反演出比极轨卫星更高精度的温湿度廓线。其主要原因是因为该项研究实用了有限的数据库。尽管数据量不少, 本研究中所实用的数据来自台风“玛利亚”一天的加密观测, 而且局限于台风及其周边地区。这些数据, 由于来自同一个或者相邻的天气系统, 相互之间存在一定的关联, 使得模式的训练和检验更为容易, 产生高精度的反演。如果用不同季节和地区的数据来验证, 反演精度会下降。将来如果有更多的 GIIRS 加密观测资料, 能够更好的代表不同的天气系统, 由此训练得到的模型, 虽然其温湿度的反演精度相比本章结果会有所降低, 但是这样的模型应该有更好的泛化性。

第4章 基于静止卫星高光谱探测的四维风场反演

4.1 引言

准确的四维大气风场（不同气压层和不同时间的水平风场）观测对于数值天气预报和中尺度系统的短临预警都具有非常重要的意义。由于地面探空站在空间分布上的稀疏性，以及探空观测较长的时间间隔，难以满足快速发展的数值天气预报对进一步准确率改进所需的数据同化需求。随着卫星大气观测技术的不断发展，如今已经发展出了一系列利用高频次的静止卫星成像观测反演大气运动矢量 (AMV, Atmospheric Motion Vectors) 的方法 (Velden 等., 2005)，并在数值天气预报等多个领域内体现出了其应用价值 (Li J 等., 2020; Zhang S 等., 2018; Velden 等., 2017)。

业务上惯常使用的 AMV 反演算法通常基于在静止卫星成像的连续观测上进行特征识别和追踪，在有云覆盖的区域使用可见光和红外通道的观测信息来追踪云的移动轨迹获得“云导风”，而在晴空区则常采用对水汽敏感的观测通道来追踪水汽特征的变化进而获得“水汽导风” (Velden 等., 1998, 1997)。除特征追踪外，基于图像处理技术的光流法 (Optical Flow) 也被一些学者应用于风场的反演 (Szantai 等., 2006, 2000)，该算法随着静止卫星高频次成像观测和计算机技术的发展，也被应用于中尺度风场的反演之中 (Stettner 等., 2019; Sun F 等., 2018;)。

对于四维风场的反演和应用而言，现有 AMV 的算法存在两个方面的不足，首先是追踪得到运动矢量的定高问题。Velden 和 Bedka (2009) 的研究指出，定高误差是 AMV 产品相对观测存在误差的主要来源，主要源于卫星测量的辐射来自于一个带有厚度的气层而非离散的等压面。另外，AMV 的“追踪+定高”计算模式使得追踪到的运动矢量仅存在于单一层次，缺乏垂直廓线，这很大程度上限制了其在数值天气预报上的应用。

利用高光谱红外探测仪的湿度廓线反演产品，可以通过追踪在不同垂直层次上的湿度变化信息来部分解决定高的问题，并获得风场垂直廓线。例如 Santek 等 (2019) 利用 AIRS 在高纬度地区的连续观测，通过追踪湿度和臭氧廓线随时间的变化特征，得到了极地地区的三维大气运动矢量。不过，因为极轨卫星在中低纬

度缺乏对同一区域的连续观测,该算法仅适用于高纬度地区,其准确性也受到较大的时间间隔的影响(García-Pereda 和 Borde, 2014)。

搭载于静止轨道卫星的红外高光谱大气探测能够对高垂直分辨率的大气温度和湿度廓线信息进行连续观测和反演,其具备的三维风场(不同气压层次上的水平风场)反演的能力已经在许多模拟数据的研究中得到证明(Velden 等., 2004; Smith W 等., 2002)。GIIRS 作为国际上首个搭载于静止卫星的红外高光谱大气探测仪,能够实现对大气温湿状态的高精度三维连续观测(Yang J 等., 2017)。在本文上一章的研究中,已经证实了 GIIRS 具有在高垂直分辨率上反演大气温湿廓线及其变化的能力。本章的研究将利用时间分辨率 15 分钟的 GIIRS 加密观测资料,通过引入目标视场相关的时间和空间变化信息,通过机器学习算法建立高精度的四维风场反演模型,并利用 GDAS 以及机载下投探空观测资料对其精度进行验证。除此之外,还通过一系列的模型训练敏感性试验,讨论不同的时间间隔的观测数据,以及邻域视场信息的引进对风场反演模型准确度的影响。

4.2 资料和方法

4.2.1 数据资料

本章的研究中使用到的数据如下:

(1) GIIRS 区域加密观测资料。高频次的静止卫星高光谱探测为大气四维风场反演提供了可能,研究采用了 2018 年“玛利亚”台风期间 GIIRS 对于目标区域 15 分钟的加密观测资料,时间范围是 2018 年 7 月 10 日 0000~1600 UTC,以及 2100~2300 UTC,空间范围是 13.7~34.5°N, 108.9~136.2°E。考虑到 GIIRS 在中波波段存在的光谱定标稳定性问题(Guo 等., 2021),本章节所采用的观测数据是由威斯康星大学麦迪逊分校 (UW-Madison) 的空间科学与工程中心经过重采样的数据产品。有关台风“玛利亚”以及 GIIRS 区域加密观测的相关信息,请读者参阅前文中章节 3.2 的内容,在此不再赘述。

(2) ERA5 再分析数据。由 ECMWF 发布的 ERA5 再分析数据集同化了来自于地面站观测、无线电探空观测、下投探空观测、飞机观测以及来自卫星观测的 AMV 等风场观测信息(Hersbach 等., 2020),其风场产品在许多应用研究当中表现出了优于其他再分析数据的可靠性(Taszarek 等., 2020; Graham 等., 2019;

Olauson, 2018)。在本章的研究中, 采用了 ERA5 逐小时的, 空间分辨率为 $0.25^{\circ} \times 0.25^{\circ}$ 的, 垂直方向从在 1 到 1000 hPa 之间 37 个等压面上的 U 和 V 风场分量, 并将其在时间和空间上插值到 GIIRS 的观测视场上, 再将所得到的风廓线作为该视场在模型训练过程中的真值廓线。

(3) GFS 数值预报场。来自于 NCEP 的全球预报系统 (GFS, Global Forecast System) 的短期预报产品在本章的研究中被用于评估 GIIRS 反演的四维风场在未来资料同化应用中的潜在效用。本章中使用的 GFS 预报产品在垂直方向上从 10 到 1000 hPa 共有 26 个等压面层次, 空间分辨率为 $0.5^{\circ} \times 0.5^{\circ}$ 。GFS 每天共有四个起报时刻, 分别为 0000、0600、1200 和 1800 UTC, 其预报产品的时间分辨率为 3 小时 (Kalnay 等., 1990)。在本研究中, 我们使用来自最近起报时刻的 3-12 小时预报产品作为评估的标准。

(4) GDAS 分析场。本章的研究中使用了来自 NCEP 的 GDAS (Global Data Assimilation System) 分析场作为对反演风场准确度的另一个评估依据。GDAS 的空间分辨率为 $0.25^{\circ} \times 0.25^{\circ}$, 于每日的 0000、0600、1200 和 1800 UTC 进行四次发布, 并被用作驱动 GFS 预报模式的初始场 (Kanamitsu, 1989)。该数据的使用在一定程度上克服了由于训练和检验使用同一类别数据 (ERA5) 所带来的潜在相关性在评估结果上的影响。

(5) 下投探空仪观测。在台风“玛利亚”期间, 与 GIIRS 观测视场相匹配的机载下投探空观测数据被用作对 GIIRS 反演风场的观测检验。这些从飞机上释放的探空数据通过卫星电话传到地面, 并由 UCAR 开发的大气探空处理环境 ASPEN (Atmospheric Sounding Processing Environment) 软件进行了分析和质量控制。通过探空仪在下落过程中的水平地理位置和高度变化, 能够得到三维风场廓线信息, 类似的观测数据已经在多个研究中被广泛应用 (Chen 等., 2021; Liu C-Y 等., 2020)。

(6) AHI 的大气运动矢量 (AMV) 产品。为了将本章研究中通过神经网络训练得到的 GIIRS 与基于静止卫星成像观测的 AMV 业务产品相对比, 并且考虑到来自 FY-4A 卫星上搭载的 AGRI 的 AMV 产品在国家卫星气象中心的数据网站上仅发布有 2019 年以后的数据, 因而使用了能够覆盖同一区域的, 来自日本葵花 8 号卫星搭载的 AHI (Advanced Himawari Imager) 的三小时时间分辨率的

AMV 产品与 GIIRS 加密观测时段和对应区域内的 GIIRS 反演风场进行了对比。这些 AMV 数据是通过连续的静止卫星观测确定目标物的位移矢量，并经过向量的定高和一系列质量控制（QC）过程来得到的(Shimoji, 2017)。本研究所使用的来自 AHI 的 AMV 数据产品由美国威斯康星大学麦迪逊分校（UW-Madison）的气象卫星合作研究所（CIMSS）提供。

4.2.2 反演方法

在建立基于 GIIRS 观测的风场反演模型前，首先需要对用来反演风场的通道进行选择。由于在 GIIRS 的一千多个通道观测之间存在着较强的相关性，而且在部分通道存在相对较大的观测误差，因而需要选择观测误差较小且能够表征不同层次的大气温度和水汽信息的通道来获取足够的信息并减小风场反演过程中的冗余计算。图 4.1 所示的是在风场反演中对长波和中波红外通道的选择结果，包括在美国标准大气条件下的模拟亮温(图 4.1a)，以及所选的通道在温度(图 4.1b)和水汽(图 4.1c)的 Jacobian 廓线。由于此项工作在上一章的大气廓线反演中已经完成，通道选取的方法和结果请参阅本文第 3.3 节的相关内容，在此不再赘述。与温湿廓线反演的不同之处在于，由于来自长波红外通道的观测所提供的温度廓线和边界层湿度信息对于风廓线的反演同样具有重要价值，在本章的研究中将 GIIRS 的长波红外通道视场在空间上以最短距离为依据，对应匹配到中波通道观测的视场，使得选出的 146 个长波红外通道和 192 个中波红外通道的观测亮温一同构成用于反演风场的观测亮温光谱。

与温湿廓线反演不同的是，在动力场的反演过程中，不同时刻大气热力状态的空间分布信息对于大气运动方向和速率的判定提供重要的信息，所以本部分的研究除了将时间变化信息作为输入场以外，也将两个时刻(观测时刻与前一时刻)目标视场周围相邻的四个视场(东、西、南、北)的高光谱观测信息输入到双隐层神经网络中一同训练，用以表征不同时刻的空间变化特征。因而，对于每个用于训练和反演的 GIIRS 视场，被输入模型用于风场反演的观测信息包括来自两个时刻(当前时刻和 15 分钟之前)，每时刻五个视场(目标及四个相邻视场)，每个视场 338 个通道的观测信息，总共 3380 个自变量用于反演来自 100 至 1000 hPa 共 27 层等压面的 U、V 风场分量。

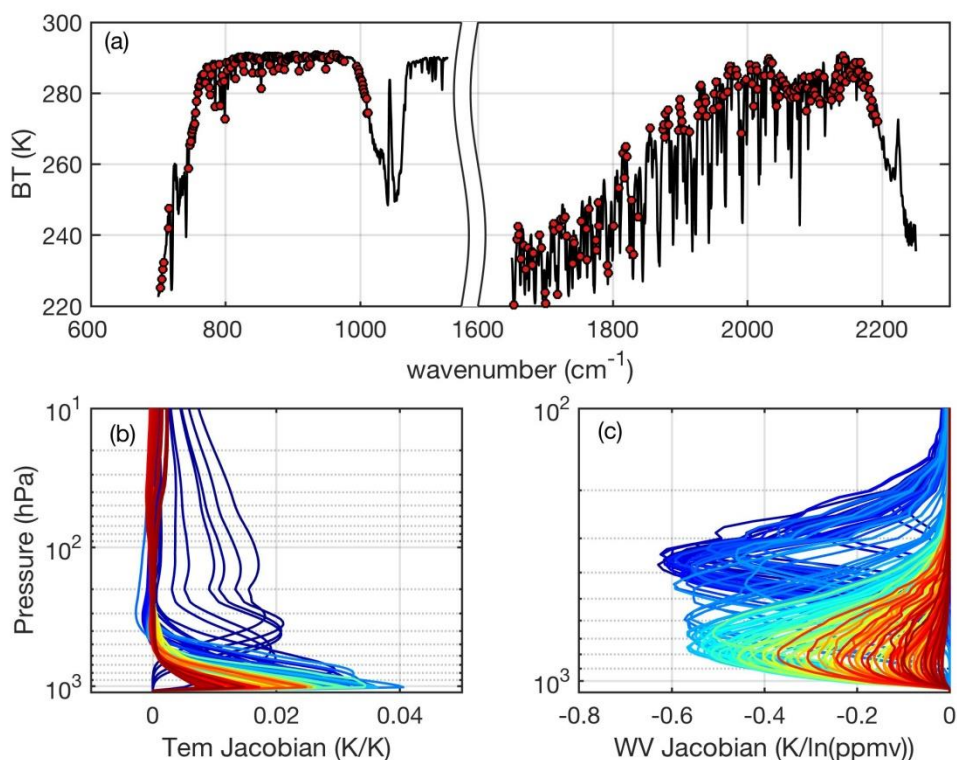


图 4.1 选择的用于风场反演的通道(红点表示)叠加在美国标准大气模拟的亮温光谱(上图); 所选长波通道的温度 Jacobian (左下); 所选中波通道的水汽混合比 (lnq) Jacobian (右下)。

Figure 4.1 Selected channels (red dots) laying over simulated BT spectrum of GIIRS from U.S. Standard Atmosphere with selected channels (upper), the temperature Jacobian of LW selected channels (lower left), and the water vapor mixing ratio (lnq) Jacobians of MW selected channels (lower right).

传统的风场反演算法依赖对目标的识别和移动追踪来进行, 但是考虑到 GIIRS 视场的空间分辨率(星下点 16 km) 相比 AMV 所使用的的静止卫星成像仪(星下点 2 km) 相对较粗, 且上一章的研究发现 GIIRS 由于中波红外通道的定标以及湿度廓线反演的准确度仍然有待提升, 本章的研究选择不采用目标追踪而使用基于多层神经网络的回归算法。这一算法使得风场反演的准确度不再完全受制于湿度廓线反演的准确性, 而更多地利用神经网络对非线性关系的拟合能力

从大量的实际观测数据中找到特征和规律(Van Gerven 和 Bohte, 2017; Feng 等., 2017; LeCun 等., 2015)。近几年来, 具有多隐层的神经网络已经在卫星遥感观测数据的气象应用研究中取得了许多成功(Zhou 和 Grassotti, 2020; Boukabara 等., 2019; Tao 等., 2018; Milstein 和 Blackwell, 2016), 本章的研究通过借鉴前人的成功经验, 采用了在输入和输出层之间具有两个隐藏层的前馈型神经网络用于实时三维风场的反演。其中, 在神经网络的输入层有 3380 个神经元, 对应于前文提到的 3380 个自变量, 包括能够反映大气温度和湿度垂直信息的长波和中波红外通道观测, 以及能够反映大气运动状态的来自多通道观测的时间和空间变化信息。神经网络的两个隐藏层, 每一层各有 512 个神经元, 并应用了整流线性激活函数 (ReLU, Nair 和 Hinton, 2010) 在该层结果输出到下一层之前进行了非线性激活, 而在输出层则应用线性激活产生输出。隐藏层的层数和神经元的数量是根据先前针对神经网络调参的若干研究提出的经验法则(Sheela 和 Deepa, 2013; Karsoliya, 2012; Shibata 和 Ikeda, 2009; Hagiwara, 1994), 结合本人在综合考虑了反演准确性、计算效率和代码效率而进行的多组比较测试结果做出的决策。在网络的输出层有 54 个变量, 包括从 100 到 1000 hPa 的 27 个气压层中风的 U 和 V 分量, 其所在的等压面分布与 ERA5 的等压面层次一致。

在训练之前, 首先将数据集划分为训练集和独立测试集。如前文在 3.2 节所描述的, GIIRS 在加密观测期间以 15 分钟的时间间隔进行区域扫描。从每小时 00 分开始的区域观测被选为测试数据, 不包括在训练过程中, 而每小时剩余的 3 次区域观测 (15, 30, 45) 被包括在训练集中用于训练反演模型。随后, 将分割出的训练集进一步随机分成 80% 的训练子集和 20% 的验证子集, 其中前者用于训练模型, 后者用于性能监控和模型优化。在训练过程中, 利用 He 初始化方案 (He K 等., 2015) 实现了对网络各层参数的初始赋值, 随着训练的进行权重和偏差通过使用 Adam 优化器 (Kingma 和 Ba, 2017) 的反向传播进行优化, 以最小化预测和“真实”值之间的损失函数 (loss function), 并采用了通过计算验证子集在连续 200 次迭代中的损失函数变化率进行提前终止的方法来结束训练过程。对于本章的研究, 神经网络选用了均方误差 (MSE) 作为基础损失函数, 并在其基础上增加了 L2 正则化 (Girosi 等., 1995), 用于防止过度拟合问题 (Glorot 和 Bengio, 2010)。在训练完成后, 使用独立的测试集评估模型的性能, 并对反演结果将使用

来自其他独立数据源（如 GDAS 分析场和下投探空仪观测）的风廓线产品进一步验证。

表 4.1 本章研究中使用的神经网络设置情况

Table 4.1 Configurations of the neural network used in this chapter

神经网络参数	参数设置
隐藏层数	2
输入层神经元数	3380
隐藏层神经元数	512, 512
输出层神经元数	54
激活函数	ReLU
损失函数	MSE + L2 正则化
优化器	ADAM
测试集占比	0.2
最大迭代次数	20000
最小提升阈值	0.0001
最大容忍次数	100

4.3 反演结果与检验

4.3.1 样本分类

如上一节所述，通过使用时间和空间匹配的 GIIRS 高光谱观测亮温及其时间、空间变化与来自 ERA5 的 U/V 风分量廓线，分别建立了用于模型训练的训练数据集和用于准确度评估的独立测试数据集。在进入神经网络训练之前，分别对两个数据进行了质量控制，对不合理的观测值（例如来自任何通道的亮温小于 100 K）以及位于观测区域边缘的那些没有足够的相邻视场的观测像元进行了剔除。考虑到视场中的云量会直接影响 GIIRS 云下特征检测的能力，根据选出的波长在 11 μm 左右的 15 个长波红外通道的平均亮温将所有样本分为三组，分别

代表了三种云覆盖的情况，即晴空与极少云覆盖（CRL, clear sky and very light cloud coverage）、低云与薄云覆盖（LNT, low and non-thick cloud coverage）以及高云与厚云覆盖（HTK, high and thick cloud coverage）。具体分类如表 4.2 所示，而训练过程是针对每组单独进行的。虽然我们研究的重点在于 CRL 类别，但也针对其他组进行了一系列实验，以评估云覆盖对 GIIRS 风反演准确性的影响。

表 4.2 数据分类依据与各类别样本量

Table 4.2 The classification basis and sample sizes of each group

分组	阈值(来自 11 μm 附近的 15 个长波通道的平均亮温)	样本量
晴空与极少云(CRL)	$BT \geq 280\text{K}$	训练集: 174,859 测试集: 43142
低云与薄云(LNT)	$BT < 280\text{K} \ \& \ BT \geq 240\text{K}$	训练集: 96459 测试集: 23606
高云与厚云(HTK)	$BT < 240\text{K}$	训练集: 29502 测试集: 6598

4.3.2 统计检验

考虑到不同云覆盖状态的样本由 GIIRS 观测到的垂直信息量不同，我们在测试数据集上利用 ERA5 作为真值进行统计检验的同时，将三个类别的样本所对应匹配的 GFS 数值预报的风场产品相对于 ERA5 的误差信息进行了统计，用于对比反映本研究所训练的神经网络模型的相对准确度和在不同条件下的适用性。图 4.2 展示了来自 GIIRS 反演的风廓线结果在三个不同类别和 ERA5 之间的均方根误差 (RMSE)，以及对应的 GFS 预报场和 ERA5 之间的 RMSE 的垂直分布状况。由图 4.2 可见，无论是对于 U 风场分量(图 4.2a)还是 V 风场分量(图 4.2b)，GIIRS 反演风场对 CRL 和 LNT 类别在所有等压面高度上的 RMSE 都小于 2 m/s，表现出了较好的准确性。相比于 GFS 的预报产品，GIIRS 在 CRL 和 LNT 类别的大多数高度层上都表现出了相对于 ERA5 更低的 RMSE，但是在 800 hPa 以下的层次上 GIIRS 反演的优势不够明显，且在 LNT 类别的 RMSE 大于 GFS 的

预报产品。一个可能的原因是，对低层大气敏感的亮温观测同样对下垫面（包括陆地表面和海表面）敏感。这些亮温随时间的变化，除了风场的原因外，下垫面的影响也是一个重要原因。比如地表和海表温度的变化，下垫面对大气的加热，地表和海表面的蒸发等，都会对亮温观测造成影响，从而影响风场的反演。特别是对于有云存在的 LNT 类别，云层覆盖薄且可能较低，但仍然会影响 GIIRS 获取云层下方信息的能力，导致了低层反演准确度下降。HTK 类别的误差分布也在一定程度上证实了这一观点，对于该类别，GIIRS 反演的 RMSE 在低于 150 hPa 的所有等压面上都远大于 GFS。尽管 GFS 在 HTK 类别的预测精度同样逊色于其在 CRL 和 LNT 类别的表现，但是 GIIRS 反演产品在 HTK 的过大误差，以及其与 GFS 在精度上的巨大差距表现出了其对于密集云区内风场廓线缺乏反演能力。值得注意的是，尽管 GIIRS 和 GFS 各自对于不同类别样本所表现出的准确性均为 CRL 最高，而 HTK 最低，但是对于 HTK 类别，GIIRS 的反演效果相比 LNT 存在明显的降低，而 GFS 的性能下降幅度不大。这主要是因为高且厚的云层阻挡了搭载于卫星上的红外探测仪对于云层下方大气的观测，导致 GIIRS 缺乏用于反演风廓线的大气状态信息，而数值模式则仍然可以通过上一时次的信息向前积分做出预报。在将来对 GIIRS 风场反演的应用上，可以通过添加质量控制，将观测信息属于 HTK 类别的视场标记出来，剔除那些存在密集厚云覆盖的区域，尤其是对流区域的误差较大的风场反演结果对实际应用造成的影响。此外，GIIRS 在 HTK 类别上的过大 RMSE 表明风场的反演的确是基于卫星的亮温观测，而不是简单的统计结果。

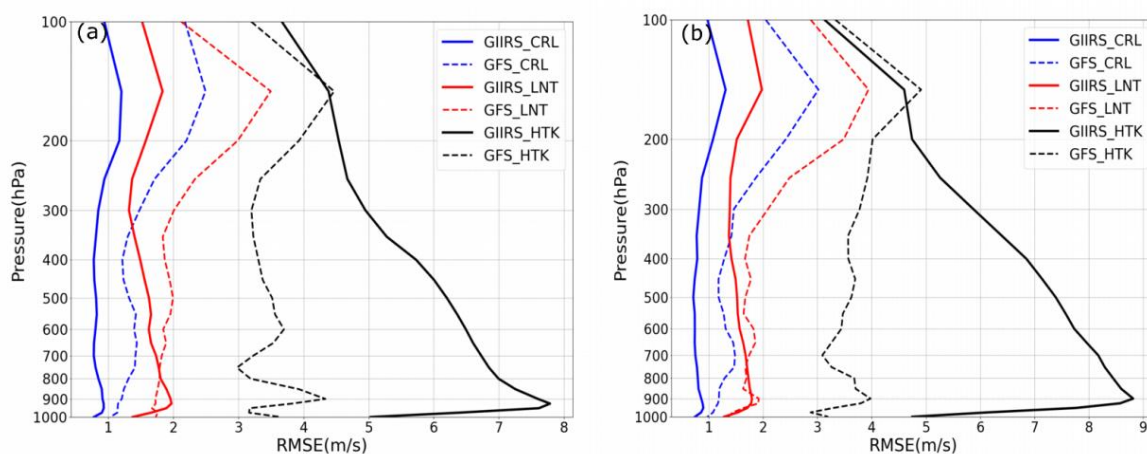


图 4.2 利用独立的测试数据集计算的的 GIIRS 反演（实线）和 GFS 预报场（虚线）的风

场各自与 ERA5 之间的均方根误差, (a)风场 U 分量; (b)风场 V 分量。

Figure 4.2 Root mean squared error of wind retrievals from GIIRS (solid lines) and GFS forecasts (dashed lines) against ERA5 analysis using the independent testing data set on 10 July 2018, for (a) U-component of wind; and (b) V-component of wind.

图 4.3 所示的是来自测试集的, 2018 年 7 月 10 日 1200 UTC 起始的 GIIRS 区域观测反演的二维风场与真值的对比。具体表现为, 绿色箭头分别代表的 GIIRS 反演风场 (左列) 和 GFS 预报场 (右列) 与红色箭头代表 ERA5 再分析数据所代表的风场真值在不同等压面上的对比。由图 4.3(a)可以看出, 对于 200 hPa 水平风场, GIIRS 在对台风西南侧的弱东南风, 以及从台风北侧延伸至中国大陆地区的强东北风的反演结果与 ERA5 差异很小, 说明 GIIRS 对这些区域的风场具有较高的反演精度。相比而言, GFS 的风场预报 (图 4.3(b) 中的绿色箭头) 与 ERA5 的风场 (红色箭头) 之间的覆盖程度较低, 说明其与 ERA5 的风场之间的差异明显大于 GIIRS 与 ERA5 的差异。类似地, 通过对比图 4.3(c) 和 4.3(d) 可以看出, 在 850 hPa 的风场反演结果上, GIIRS 对于台风北部的强东南风, 和台风西部的偏北风与东北风的反演结果也优于 GFS 的预报场。

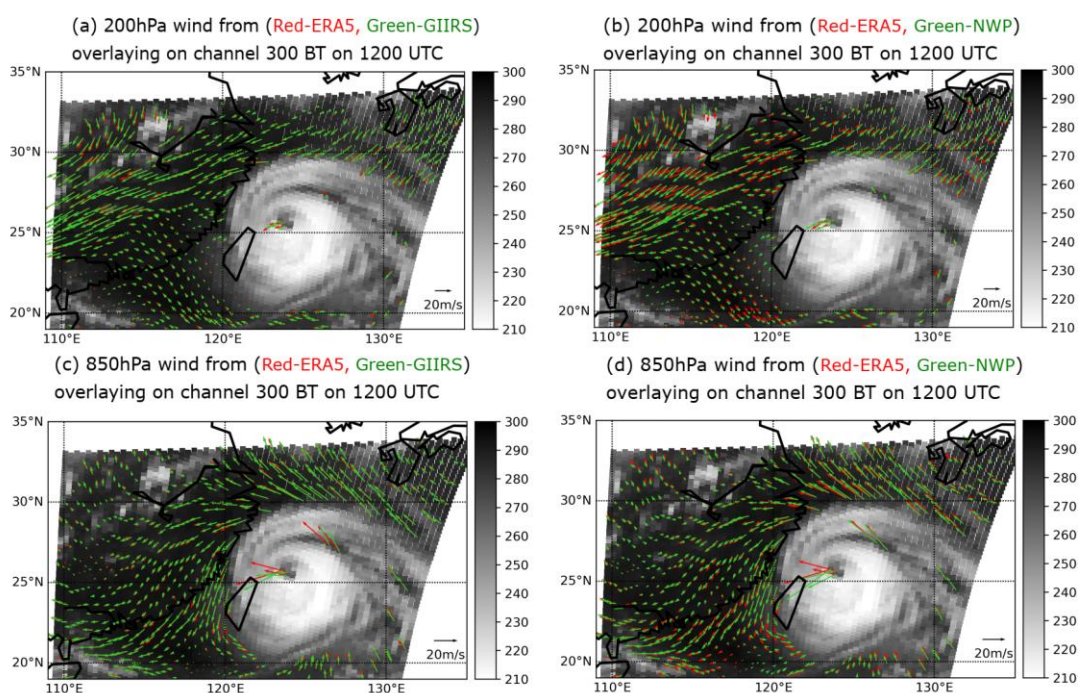


图 4.3 2018 年 7 月 10 日 1200 UTC 开始的 GIIRS 区域观测范围内来自晴空和薄云覆盖视

场的 200 hPa（第一行）和 850 hPa（第二行）以绿色箭头表示的(a,c)GIIRS 反演风场和 (b,d)GFS 数值预报风场与红色箭头表示的 ERA5 风场之间的对比，背景是 GIIRS 第 300 个长波通道（波数： 886.875 cm^{-1} ）的观测亮温（单位：K）。

Figure 4.3 200 hPa (first row) and 850 hPa (second row) wind fields using clear sky and very light cloud coverage fields of-view from (a, c) GIIRS and (b, d) GFS numerical weather predictions (green arrows) are shown against ERA5 (red arrows) overlaying on the BT from channel 300 (wavenumber: 886.875 cm^{-1}) of GIIRS observations starting at 1200 UTC on 10 July 2018.

值得注意的是，当满足 CRL 条件的绝大多数 GIIRS 视场在本研究的反演结果中显示出比 GFS 预报场更好的精度时，在图 4.3 上被夹在眼墙和外雨带之间的两个被归类为 CRL 的视场的反演结果显示出了比 GFS 预报场更大的偏差。考虑到其自身的 GIIRS 观测信息已经满足 CRL 的阈值，其反演精度的不足很可能是由于缺乏来自相邻视场和前一时刻观测的有效信息所导致。进一步的研究发现，尽管这两个视场在 $11\text{ }\mu\text{m}$ 附近的 15 个 GIIRS 长波通道的平均亮温为 283.05 K ，但是其周围的 4 个视场在当前时刻和前一时刻的窗区平均亮温分别为 271.84 K 和 269.57 K ，这些受到了云覆盖的污染的观测信息在一定程度上增加了该视场的反演误差。台风眼区的视场也存在着类似的现象，GIIRS 反演和 GFS 的数值预报都存在着与 ERA5 之间较大的不一致性，其中 GFS 的误差主要来自其作为数值模式与 ERA5 在台风中心定位上存在的差异。而对于 GIIRS 的误差，一方面是 GIIRS 反演误差主要受到台风眼周围视场深厚云墙的影响导致其缺乏邻域观测信息，另一方面是由于台风的移动使得台风眼附近的云覆盖状况不断变化而难以利用高光谱红外探测获取大气热力学性质在不同垂直层次上的时间变化信息。

这一观点也能够成功解释图 4.4 所示的，在台风已经登陆后的 2200 UTC 区域观测在 500 和 850 hPa 的 GIIRS 反演结果上存在的误差分布特征。相比于 GFS 数值预报场（图 4.4(b,d)中的绿色箭头）所体现的相对 ERA5（红色箭头）在空间上相对普遍存在的误差，GIIRS 反演的风场（图 4.4(a,c)中的绿色箭头）对于相对远离台风云系的区域，如大陆上的偏西风、台风北部的强东南风和东北部海面上 500 hPa 的偏北风和 850 hPa 的偏东风都体现出了高于 GFS 预报场的准确度，但

是对于紧靠着台风外围的视场的反演结果,如台湾海峡区域的西北风和台风后部的一个西南风视场,则具有明显超过其他区域的反演误差。这些视场的共同特征是其周围视场在当前时刻和前一时刻观测受到明显的云覆盖影响,进而对风场反演所依赖的大气时间和空间变化信息造成了污染。

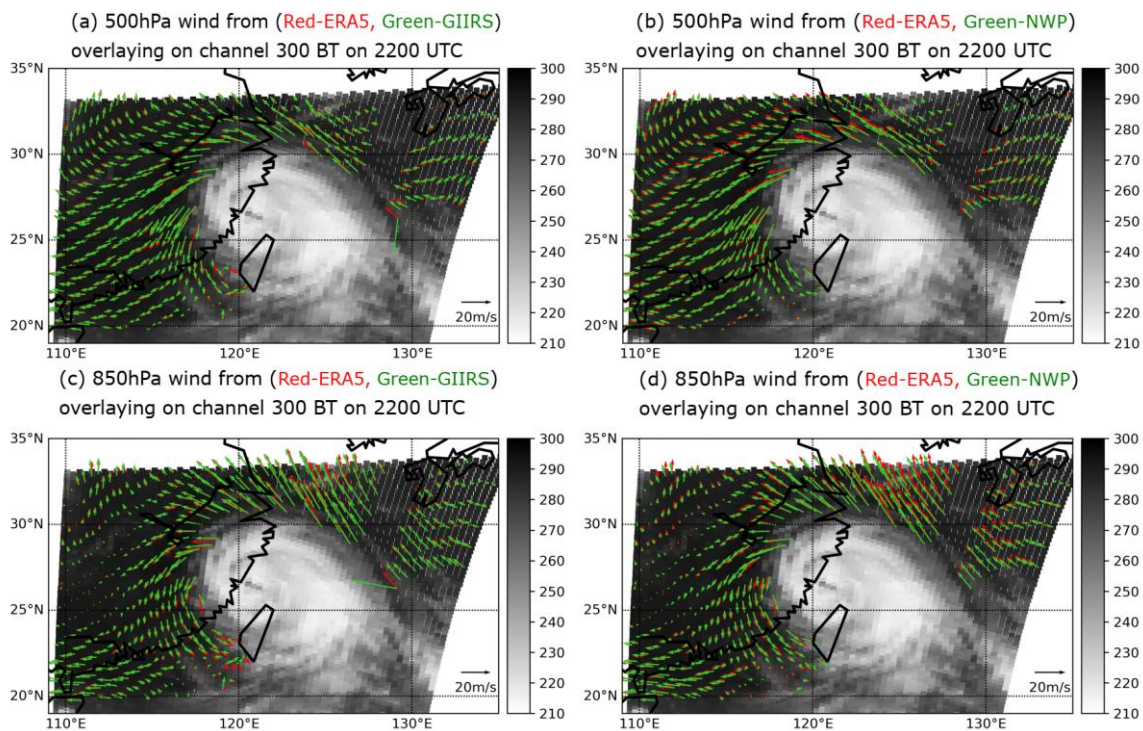


图 4.4 2018 年 7 月 10 日 2200 UTC 开始的 GIIRS 区域观测范围内来自晴空和薄云覆盖视场的 500 hPa (第一行) 和 850 hPa (第二行) 以绿色箭头表示的(a,c)GIIRS 反演风场和 (b,d)GFS 数值预报风场与红色箭头表示的 ERA5 风场之间的对比,背景是 GIIRS 第 300 个长波通道(波数: 886.875 cm^{-1}) 的观测亮温。

Figure 4.4 500 hPa (first row) and 850 hPa (second row) wind fields using clear sky and very light cloud coverage fields of-view from (a, c) GIIRS and (b, d) GFS numerical weather predictions (green arrows) are shown against ERA5 (red arrows) overlaying on the BT from channel 300 (wavenumber: 886.875 cm^{-1}) of GIIRS observations starting at 2200 UTC on 10 July 2018.

图 4.5 的上下两行依次是两个晴空视场 (113.1° E , 27.0° N) 和 (132.1° E , 31.9° N) 各自的 GIIRS 反演和 ERA5 再分析数据不同层次的风场 U 和 V

分量的时间变化序列图。这两个 GIIRS 视场分别位于台风路径前方西侧中国大陆上未被影响的区域，和台风后部西北方向上的海面上，二者的共同点是在加密观测期间全程都是晴空状态，而根据前文的分析表明，反演结果在这些位置上具有较高的可信度。由于真实的 ERA5 数据是逐小时的，并且整点开始的 GIIRS 观测被划分到独立测试集，基于数据连续性的限制，我们仅比较了在 0300~1500 UTC 之间的逐小时风场。由图 4.5 可以看出，GIIRS 对这两个视场的风场反演的总体精度是合理的（误差大多在 1 m/s 以内），并且成功地反映出了不同层次的风场变化趋势，表现出了本文基于神经网络的反演方法对于包含时间变化在内的四维风场的反演能力。

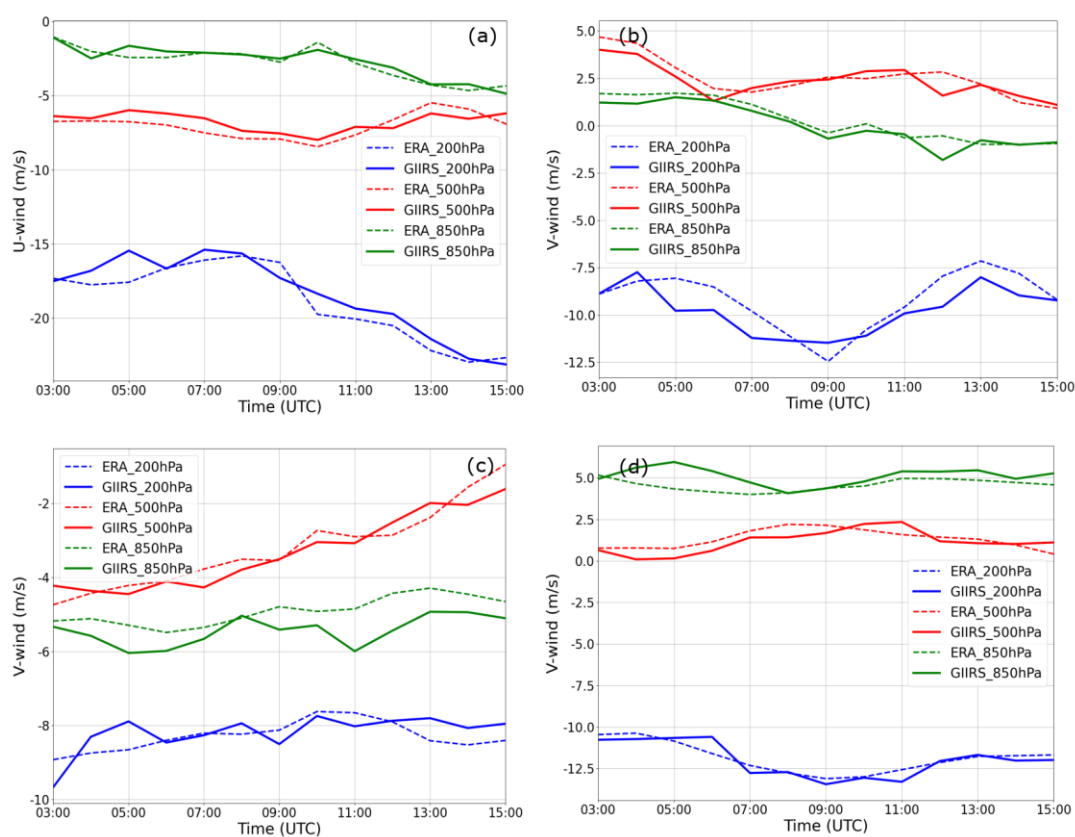


图 4.5 GIIRS 反演风场与 ERA5 风场分别在(a,b)位于(113.1°E, 27.0°N)的 GIIRS 视场, 和 (c,d)位于(132.1°E, 31.9°N) 的 GIIRS 视场的 (左列) U 风场分量和 (右列) V 风场分量在 200、500 和 850 hPa 的时间变化特征。

Figure 4.5 The comparison of time variations of (left column) U-component of wind; and (right column) V-component of wind on the levels of 200, 500 and 850 hPa at (a,b) GIIRS

FOV at (113.1°E, 27.0°N) and (c,d) GIIRS FOV at (132.1°E, 31.9°N) from GIIRS and ERA5.

通过将不同云覆盖条件的风场反演相对于 ERA5 的统计结果, 并与 GFS 数值预报的结果进行比较, 可以看到高时间分辨率的 GIIRS 观测能够在云污染较小的情况下反演得到高精度的四维风场, 并能够提高独立于数值预报的风场信息。该风场反演模型在物理上的一种解释是, GIIRS 能够通过高时间分辨率的观测从中波红外通道获取大气湿度的分布信息, 并能够从长波红外通道获取大气热力学分布状态, 而这些信息的时间变化可以提供与风场分布紧密相关的水汽移动和与热力学变化等信息, 机器学习模型则能够利用这些信息实现风速的定量反演。除此之外, 与目标视场相邻四个视场的时间变化特征可以帮助确定 U 和 V 风分量的正负性, 进而确定风向。然而, 红外高光谱观测受到云覆盖的影响较为显著, 在视场被高与厚的云层覆盖时, 云层下方的信息被云所挡住, 从而导致对 GIIRS 观测到的大气垂直信息匮乏进而反演精度显著降低。从统计检验结果所表现出的与物理判断的一致性也说明了本研究所用的机器学习模型是依据观测信息对风场进行反演, 而非单纯在数学上的相关性。与此同时, 尽管训练使用的加密观测资料在时间和空间范围上都有局限性, 导致训练数据与检验数据之间在整体之间存在相关性, 但是由于模型的反演模式是以单一视场为样本单元, 在训练之前已经进行了顺序打乱, 且训练之中并不涉及任何视场经纬度等能够标识其位置的信息, 保证了模型只能从亮温光谱和时间、空间变化特征来进行反演。由此看来, 尽管本研究中基于机器学习的风场反演模型在样本分布上存在局限性, 该算法的构建同样具备一定的物理意义和在更广泛样本中的训练应用价值。

4.3.3 GDAS 检验

考虑到上文的检验和评估中采用的独立测试集与训练数据集的真值都是来自 ERA5 分析场, 尽管其在观测样本上相互独立, 仍然在统计分布上存在一定的相关性。因此, 除了来自 ERA5 的独立测试集之外, 使用其他的、不同来源的数据集对反演结果进行进一步评估检验显得同样重要。因而, 我们在研究中采用了来自 NCEP 的 GDAS 分析场对模型的风场反演结果进行了独立检验。图 4.6 所示的是 ERA5 再分析数据、GDAS 分析数据和 GIIRS 反演风场三者中两两之

间在不同层次上的 RMSE 分布。由于 GDAS 分析场在时间分辨率的限制，我们的验证仅使用可用的 0600 和 1200 UTC 时次数据与对应的 ERA5 和 GIIRS 反演结果进行检验和对比。图 4.6(a) 和 4.6(b) 分别展示了三个数据集之间 U 和 V 风场分量的 RMSE 廓线，从中能够看出，GIIRS 反演结果与 GDAS 之间的 RMSE 大于 GIIRS 和 ERA5 之间的 RMSE，而与此同时 GDAS 和 ERA5 之间的 RMSE 介于两者之间并且更接近于 GIIRS 和 GDAS 之间的 RMSE。由此可以推断，GIIRS 反演风场和 GDAS 之间相对 ERA5 误差偏大的主要原因，来自于 GDAS 和 ERA5 之间的差异。由于 GDAS 和 ERA5 空间分辨率相同且两种分析数据来自完全相同的网格点，因此该差异直接来源于不同模型的输出差异。必须提到的一点是，尽管应用 GDAS 作为真值的检验结果所显示的误差比使用 ERA5 检验的值更大，但其计算出的在 300 hPa 及以下的对流层的各分量 RMSE 值在 1~2 m/s 的范围内，依然表明了 GIIRS 的风场反演结果具有合理精度。

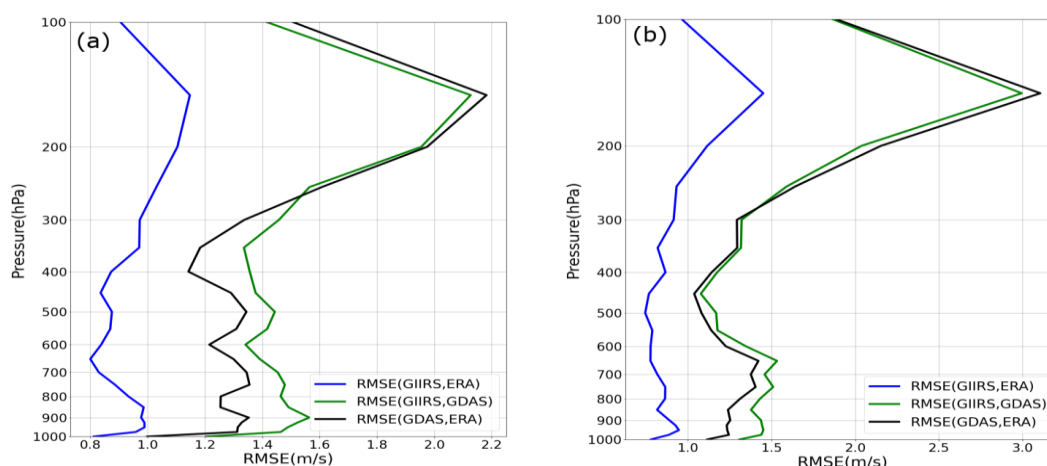


图 4.6 利用 2018 年 7 月 10 日 0600 和 1200 UTC 的晴空和薄云覆盖条件的视场对于 GIIRS, ERA5 以及全球数据同化系统分析场 (GDAS) 的 (a) 风场 U 分量, 和 (b) 风场 V 分量之间的均方根误差 (RMSE) 对比分析。

Figure 4.6 Comparison of root mean squared error (RMSE) of (a) U-component; and (b) V-component of wind from Geosynchronous Interferometric Infrared Sounder (GIIRS), ERA5 and Global Data Assimilation System (GDAS) using clear sky and very light cloud coverage samples on 0600 and 1200 UTC on 10 July 2018.

4.3.4 探空检验

在利用上述的不同分析数据对风场反演模型的准确度进行验证之后,我们也通过台风“玛利亚”期间的机载的下投探空仪观测得到的实际风场观测信息,与GIIRS反演的风场结果做了对比分析。图4.7(a)和4.7(b)是2018年7月10日0006 UTC于(124.4°E, 24.4°N)投放的下落探空仪所观测的垂直风廓线,与ERA5、GDAS和GIIRS的反演结果进行的对比。由于0006 UTC对应的GIIRS观测并没有15分钟之前的对应资料用于反演,故使用时间最为接近的0015 UTC的GIIRS反演风场参与对比。通过U和V两个风场分量廓线的对比看出,以蓝线表示的GIIRS反演结果能够较好地表现探空观测的总体廓线形态,但是在部分层次上存在一些偏差。这一方面与反演模型和探空观测之间在空间和时间上的差异有关,另一方面也和垂直分辨率的差异有关,因为被输出到ERA5相同垂直分辨率的GIIRS反演廓线与ERA5廓线(红线)之间具有比其与探空观测之间更好的一致性。在图4.7(c)和4.7(d)所示的,来自1200 UTC位于(114.2°E, 22.3°N)的探空廓线上也能看到类似的结果,即探空观测的整体走向特征在GIIRS反演廓线、GDAS以及ERA5上均能够体现,但是探空观测廓线所显示的在一些层次上的反复振荡并没有被其他任何数据所体现。比较典型的是GIIRS和两个分析场都未能表现出探空观测的风场V分量在300~700 hPa之间表现出的强烈的切变,这主要是源于探空观测与ERA5和GDAS等格点分析场之间在垂直分辨率上的不同。当GIIRS反演模型以ERA5作为真值数据进行训练时,所得到的基于机器学习的模型,垂直分辨率不会超过ERA5,所以也无法反演出在ERA5分析场无法体现的复杂振荡特征。如果有足够的探空的风场资料作为真值来训练模型,有可能会改进风场反演的垂直分辨率。

4.4 时空变化敏感性试验

上文的研究已经证明了利用GIIRS高光谱红外观测数据结合其时间和空间变化可以反演得到具备合理准确度的四维风场信息。在此基础上,我们通过改变模型训练过程中预报因子的组合,对于时间和空间变化信息在机器学习反演模型中的贡献做了进一步分析。具体试验包括:(1)通过将目前用于提供时间变化信

息的对应视场 15 分钟前的观测数据分别替换为 30 分钟前和 60 分钟前的观测数据，分析观测时间间隔对风场反演精度的影响；（2）仅使用单一视场（即目标视场）的观测信息及其时间变化作为预报因子，来分析邻域视场观测所带来的空间变化信息对风场反演的影响。

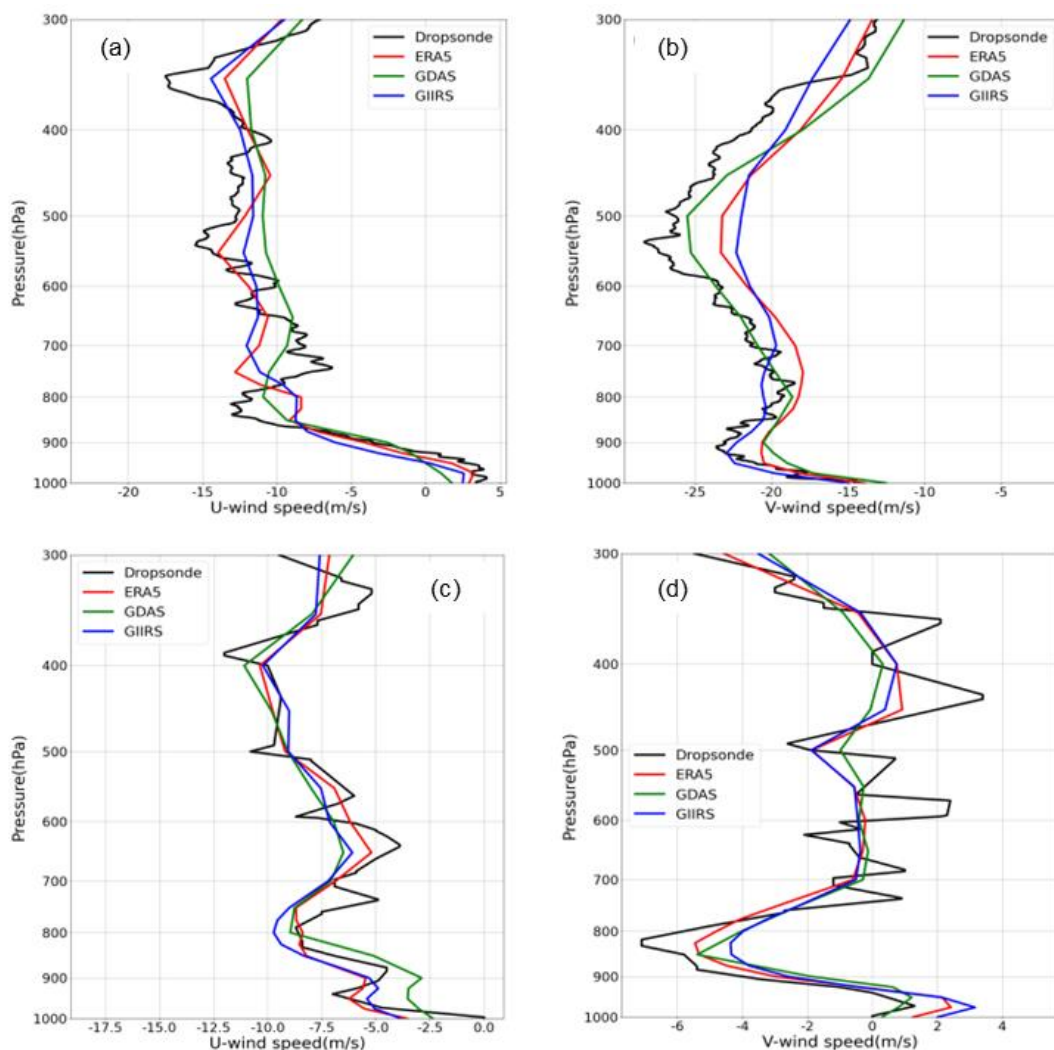


图 4.7 2018 年 7 月 10 日的机载下投探空风场观测与对应的 GIIRS 反演结果、ERA5 以及 GDAS 的(a,c)风场 U 分量, 和 (b,d)风场 V 分量廓线对比。第一行的探空观测投放于 0006 UTC, 地点为(124.4°E, 24.4°N); 第二行的探空观测投放于 1200 UTC, 地点为(114.2°E, 22.3°N)。

Figure 4.7 Comparison of (a, c) U-component; and (b, d) V-component of wind profiles from GIIRS, ERA5, GDAS and dropsonde observations at (124.4°E, 24.4°N) on 0006 UTC (upper row); and at (114.2°E, 22.3°N) on 1200 UTC (bottom row) on 10 July 2018.

如图 4.8(a) 和 4.8(b) 所示, 针对时间分辨率的实验结果表明, 使用 30 和 60 分钟作为时间间隔的反演结果与真值间的 RMSE 大于 15 分钟间隔的反演产品。随着观测时间间隔从 30 分钟增加到 60 分钟, RMSE 进一步增大, 尽管误差仍然在可以接受的范围。这说明了观测频率更高、时间间隔更短的 GIIRS 观测将有助于获得更高的风场反演精度。其可能的原因是, GIIRS 能够利用来自中波红外通道辐射观测获取水汽移动信息, 并通过长波红外通道获取大气热力性质的变化, 而这些变化率的值和空间分布与风矢量紧密相关, 因而较短的时间间隔拥有对瞬时变化率更高的代表性, 从而获取更为精确的反演结果。此外, 更短的时间能够更好的保证亮温的变化是因为风场的引起的; 更长的时间可能会发生局部的辐射吸收或者发射, 从而引起亮温的变化, 增加风场反演的不确定性。

图 4.8(c) 和 4.8(d) 展示了从单个 FOV (标记为 SGL, 即 single 的简写, 代表没有相邻 FOV) 和包含四个相邻 FOV (标记为 NBR, 即 Neighboring 的简写) 的风场 U 和 V 分量的反演精度对比。相比于 NBR, SGL 试验结果与真值间的 RMSE 显著增大, 表明相邻四个 FOV 观测信息的引入对风场反演存在显著的正贡献。

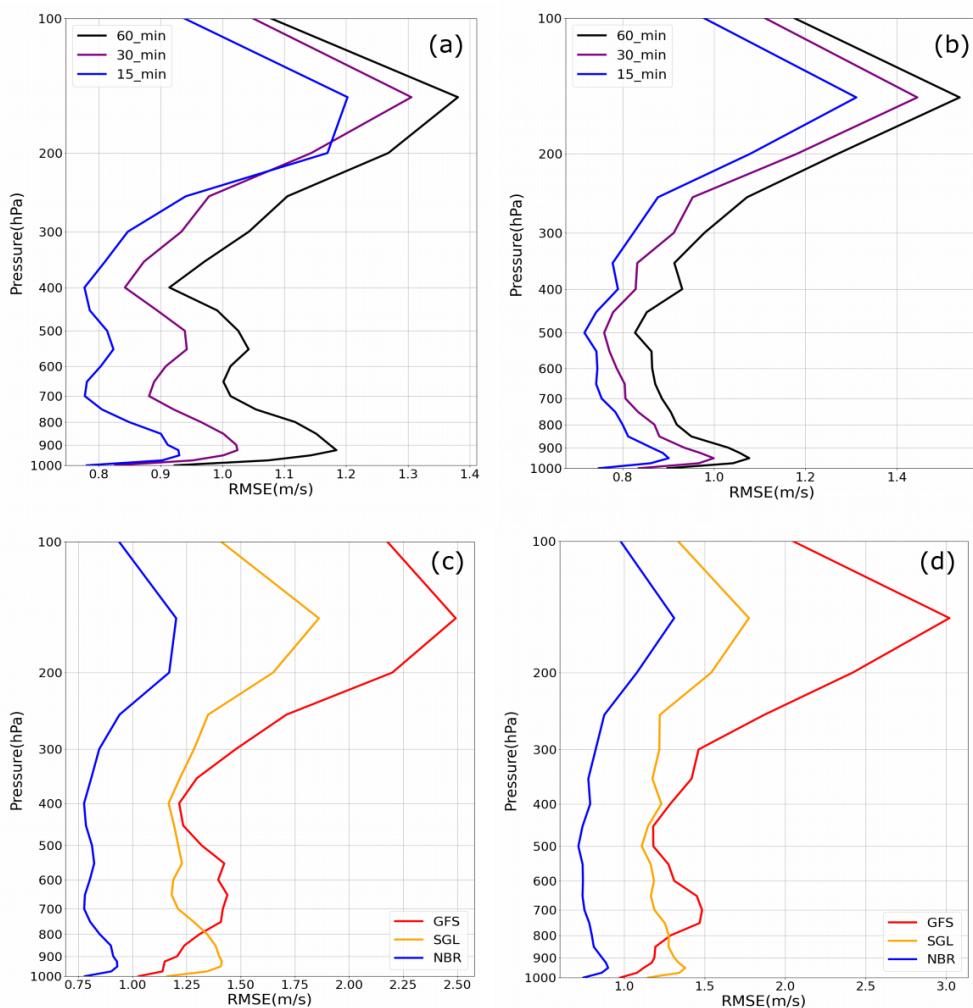


图 4.8 利用 2018 年 7 月 10 日的 GIRS 观测数据通过不同训练方式获得的(a,c)风场 U 分量, 和 (b,d)风场 V 分量反演结果与 ERA5 之间的均方根误差分布廓线对比。其中, 第一行是使用不同时间间隔的观测训练的模型之间的对比; 第二行是单一视场和加入邻近视场训练模型与对应的 GFS 数值预报产品的对比。

Figure 4.8 Comparison of root mean squared error (RMSE) profiles of (left column) U-component; and (right column) V-component of wind retrieved from model trained with different time intervals (upper row); and with single and neighboring fields-of-view included against numerical weather predictions from Global Forecast System on 10 July 2018.

4.5 与 AMV 产品的对比

为了分析 GIIRS 相比于目前主流业务算法在风场反演的能力和应用前景,有必要将本研究所训练得到的基于神经网络的风场反演产品与“目标追踪+定高”的 AMV 产品做对比分析。但是,目前尚没有针对 GIIRS 应用直接追踪方法的风场反演算法,且同搭载于 FY-4A 上的 AGRI 的 AMV 产品也是从 2019 年才开始发布,因而本研究使用同时段来自日本葵花 8 号卫星成像仪 AHI 的 AMV 产品作为代替进行了对比。由于 AHI 的 AMV 时间分辨率为 3 小时,考虑到与 GIIRS 加密观测时段的匹配,本节采用了 0300、0600、0900、1200 和 1500 UTC 的 AMV 数据与对应的 GIIRS 进行时间和空间上的匹配。具体匹配方式为:(1)在垂直方向上,根据 AMV 数据的定高结果选择与 GIIRS 风廓线反演输出的固定层次(即 ERA5 的层次)差距绝对值在 10 hPa 以内的 AMV 数据;(2)在水平方向上,选择与同时次的 GIIRS 观测视场中心的水平距离在 25 km 以内的 AMV 数据与对应的 GIIRS 视场反演产品进行匹配。由于 AMV 产品为在不同等压面上处于不同位置的单点数据,没有垂直廓线,因而在比较与 GIIRS 比较时,仅针对可用的 AMV 数据匹配在该层次上对应的 GIIRS 风产品,而不考虑不同等压面层次间的一致性。因为 GIIRS 在高云厚云覆盖条件下的反演精度受到明显的限制,在对比中也仅采用晴空和薄云覆盖的 GIIRS 视场参与匹配。此外,考虑到在 GIIRS 风场反演过程中并没有用到可见光通道的观测,因而在 AHI 的 AMV 产品当中只选择了来自红外窗区通道和水汽通道追踪得到的 AMV 数据产品。

表 4.3 所示的是经过匹配后的 AHI 与 GIIRS 的风场数据在不同层次上以对应 ERA5 为真值的统计误差结果。其中,有效样本量在 10 以内的层次由于代表性不足而并没有列出。在统计中主要分析了 U 和 V 风分量相对于 ERA5 的 Bias 和 STDE,二者分别代表了样本相对真值的平均偏差和误差离散度,其具体表达式已在前文 2.5.1 节的公式(2.3)和(2.4)中给出。从分析结果上能够看出,来自 AHI 的 AMV 数据在对流层的 Bias 在绝大多数层次都在 1.5 m/s 以内,STDE 则在 1.5 到 4 m/s 之间,而 GIIRS 结合神经网络的反演结果在所有层次的 Bias 都在 1 m/s 以内,而 STDE 在 1.5 m/s 以内。尽管 AHI 的 AMV 在对流层低层也能够表现出合理的准确度,GIIRS 反演结果在研究时段内结果体现出了比 AMV 更好的准确性,特别是在对流层中高层。然而,必须提到的是,由于机器学习模型的训练真值与用于评估的真值均来自 ERA5,尽管用于检验的数据集并没有被包含在

训练中，由于总共仅有一天的数据，其与训练数据存在的相关性仍然会使得这一检验结果对 **GIIRS** 反演模型的精度存在一定的高估。另外，由于高时间分辨率的 **GIIRS** 观测资料仅针对一次台风过程，在时间和空间范围上的局限性使得对于 **AHI** 的 **AMV** 资料评估缺乏代表性。因此，未来在获取更多的 **GIIRS** 加密观测的基础上，仍需要使用更长时段和更大的空间范围的数据，才能获得对于两种风场反演算法精度的更为全面的对比评估。

表 4.3 对 AHI 的 AMV 产品和 GIIRS 的机器学习反演结果以 ERA5 为基准的的误差统计对比

Table 4.3 Statistical Comparisons of differences between AMVs from AHI and ML products from GIIRS against ERA5

等压面 (hPa)	样本量	数据源	U-Bias (m/s)	U-STDE (m/s)	V-Bias (m/s)	V-STDE (m/s)
200	1843	AHI	-0.05	2.91	-1.37	2.87
		GIIRS	-0.32	1.19	-0.09	1.20
250	366	AHI	-0.69	5.51	0.72	3.49
		GIIRS	-0.04	1.09	-0.01	1.04
300	210	AHI	-1.03	3.40	-0.79	4.00
		GIIRS	0.11	0.79	0.06	0.78
350	90	AHI	3.56	7.41	-0.26	4.39
		GIIRS	-0.37	1.00	0.07	0.60
400	28	AHI	3.24	2.96	1.18	2.70
		GIIRS	0.17	0.58	-0.65	0.80
750	43	AHI	-0.11	1.99	-0.43	1.82
		GIIRS	-0.24	0.58	-0.07	0.60
800	71	AHI	0.10	1.47	-0.02	1.36
		GIIRS	-0.11	0.47	-0.10	0.38
850	120	AHI	0.22	1.58	0.16	1.39
		GIIRS	0.13	0.60	-0.31	0.73
900	47	AHI	0.56	1.35	-0.01	1.77
		GIIRS	0.24	0.42	-0.07	0.24

图 4.9 所示的是 2018 年 7 月 10 日 1200 UTC 的来自 AHI 的 AMV 产品与 GIIRS 反演的三维风场产品在 GIIRS 加密观测范围内的三维空间分布图。根据上文对于不同云覆盖条件的反演精度对比，GIIRS 的反演目前仅在 CRL 和 LNT

条件下具有可用性，故在图 4.9(b)中仅包含这两个组别的反演结果，即未包含 HTK 条件的视场。在区域内的总数据量方面，来自 AHI 的 AMV 具有 4169 个不同位置、不同高度上的风场产品，而 GIIRS 的数据量多达 153306 个，约是 AHI 的 36.8 倍。通过图 4.9 中 AHI 和 GIIRS 的风场产品分布能够看到，AHI 的 AMV 空间分布较为稀疏，且主要分布于 200 hPa 附近的对流层高层，而在 600 hPa 及以下的对流层中低层的可用数据量很低，在不同高度层次之间的水平分布几乎不具备对应关系。相比而言，GIIRS 作为搭载于静止卫星的红外高光谱大气探测，其反演产品的三维空间分布具有更为显著的立体性，在对流层不同高度层次上分布均匀且具备完整的水平分布对应关系，不仅能够提供基于成像仪的 AMV 产品所不具备的风场垂直分布信息，也在很大程度上增加了在高频次观测区域内的可用数据量。

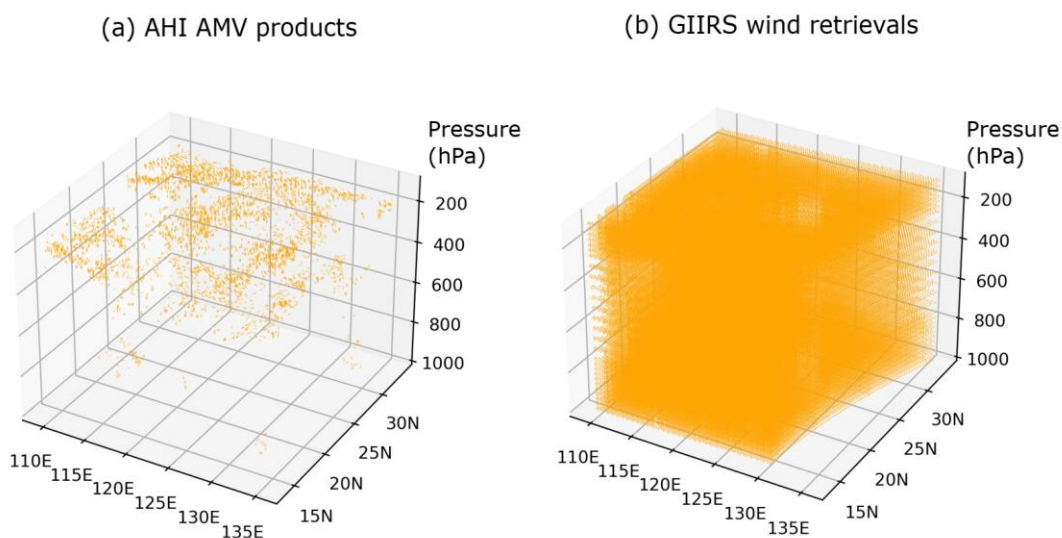


图 4.9 2018 年 7 月 10 日 1200 UTC 的来自于(a)AHI 基于直接追踪算法的 AMV 产品，与(b)GIIRS 使用本章的机器学习算法的风场反演结果的三维空间分布图。

Figure 4.9 Three-dimensional distribution of (a) AMV products from AHI using direct tracking method and (b) retrievals from GIIRS using the ML methodology introduced in this study at 1200 UTC, 10 July 2018.

图 4.10 所示的是 AHI 的 AMV 产品与 GIIRS 的反演风场在 200 和 300 hPa 等压面的分布情况。正如前文提到的，AMV 产品定高并非在固定的等压面，因而我们将定高与与 GIIRS 对应等压面差异在正负 10hPa 以内的 AMV 数据视为在同一气压层内，并在图 4.10 中给出了对应的水平分布状况。通过 AHI 与 GIIRS 的对比，可以看出尽管 AHI 在 200 hPa 的 AMV 产品在晴空和有云覆盖的区域都有分布，但是仍然较为稀疏，且在晴空区域存在大量数据空白，而 GIIRS 则在包含台风眼和云隙的非厚云覆盖区域都能够给出风场反演结果。二者在 300 hPa 的分布对比则更加明显，AHI 的 AMV 产品在该层次更为稀疏，主要是由于 AMV 产品定高在垂直分布的不均匀性所致，而 GIIRS 则能够保持与 200 hPa 同样密度的分布。结合上文的图 4.9(a)能够得知，相比于以 200 hPa 为代表的对流层高层，AMV 产品在对流层中低层的空间分布密度会进一步降低，而 GIIRS 的水平分布能够在所有垂直层次上保持一致，这也更加凸显了 GIIRS 反演风场在三维空间分布密度上的独特优势。

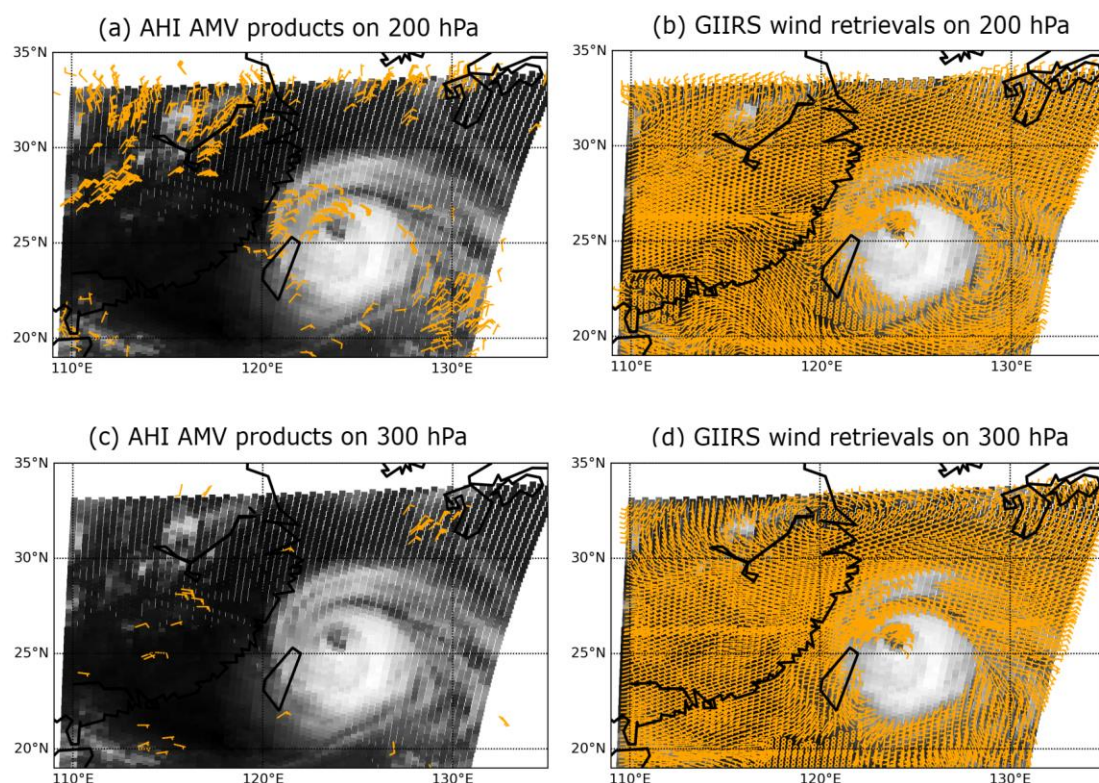


图 4.10 2018 年 7 月 10 日 1200 UTC 的 AHI 基于直接追踪算法的 AMV 产品（左列）与来自 GIIRS 使用本章的机器学习算法的风场反演结果（右列）在 (a,b) 200 hPa 和 (c,d) 300 hPa 的对比，背景是 GIIRS 第 300 个长波通道（波数： 886.875 cm^{-1} ）的观测亮温

(单位: K)。

Figure 4.10 Comparison of AMV products from AHI using direct tracking method (left column) and retrievals from GIRS using the ML methodology introduced in this study (right column) on the pressure levels of (a,b) 200 hPa, and (c,d) 300 hPa, overlaying on the BT from channel 300 (wavenumber: 886.875 cm^{-1}) of GIRS observations starting at 1200 UTC on 10 July 2018.

4.6 本章小结

研究利用 2018 年 7 月台风“玛利亚”登陆过程中 GIRS 的 15 分钟分辨率加密观测资料,通过将观测信息的时间变化与空间分布信息相结合,用 ERA5 的 U、V 风场作为训练真值建立了一个基于双隐层神经网络框架的风场反演模型。通过与独立的 ERA5 测试集、GDAS 分析场以及下投探空观测进行验证,发现高频次的静止轨道高光谱探测数据可以反演得到高分辨率的四维水平风场。其中,定量反演得到的风场 U 和 V 分量在对流层高度内相对于 ERA5 的均方根误差小于 2 m/s。风场反演的信息来源是来自于 GIRS 中波红外通道连续观测包含的水汽移动信息,以及长波红外通道观测包含的与风场分布有关的大气热力性质。本章的研究在训练得到四维风场反演模型的同时,也对于高分辨率 GIRS 观测数据对于数值预报的大气背景场的潜在价值,以及时间和空间信息在风场反演的相对贡献,得到的主要结论如下:

(1) 高时间分辨率的 GIRS 观测可以定量反演得到四维风场信息。通过将风场反演产品相对 ERA5 的准确度与 GFS 的数值预报场相比较,发现 GIRS 反演风场能够对数值预报产品有潜在的改进作用。

(2) 本研究的反演算法在晴空和非厚云覆盖的视场有较好的准确性和应用价值,而对于厚云覆盖的情况,由于存在对于云下信息的较大观测误差,其反演应用仍需要进一步的研究。研究的最终目标是在保持合理的准确性的前提下,尽可能拓展其可用范围。

(3) 反演得到的四维风场产品能够表现出与 ERA5 较为接近的时间变化信

息，证实了静止卫星红外高光谱大气探测对于大气动力学特征的反演能力。

(4) 通过敏感性试验发现，相比于较低的时间分辨率，高时间分辨率的静止轨道高光谱大气探测能够通过对于瞬时的水汽移动和分布情况的更为精确的表述，反演得到更为准确的风廓线信息。通过引入与目标视场相邻的视场观测及时间变化情况而获取的空间变化特征也对于风廓线反演的准确度起着重要的作用。

(5) 通过将本研究的风场反演产品与来自 AHI 的 AMV 产品进行比较，发现尽管高分辨率的 AMV 产品在低层大气也有相对 ERA5 较高的准确性，GIIRS 的反演结果在准确性和三维空间分布的密度上体现出了优势。然而，当前的对比分析存在一定的局限性，仍需要更长时间和更大范围的对比分析来对于两种风场产品的质量进行更为全面的对比评估。

尽管本章的研究在台风“玛利亚”期间的加密观测数据上体现出了较好的风场反演结果，当前的研究仍然存在一些局限性。首先，由于数据样本在时间和空间的分布上较为局限，使得训练结果在其它时段和地区缺乏代表性。然而，考虑到 15 分钟的高频次 GIIRS 观测至今仅在“玛利亚”台风的加密观测中得到了开展，对于风场反演模型精度和适用性的进一步评估需要更多 15 分钟分辨率的加密观测可用的情况下配合进行。除此以外，由于风云四号 A 星上 GIIRS 视场的空间分辨率为 16 km，对于中小尺度的环流特征而言过于粗糙，无论采用何种反演方法，这一分辨率在需要利用空间变化特征的风场反演与应用当中都是不利因素。随着风云四号 B 星的 GIIRS 水平分辨率提高到 12 km，以及欧洲将要在 2024 年发射的 MTG 卫星所搭载的将有 4 km 分辨率的静止卫星高光谱探测仪 IRS，将有助于利用更为复杂的算法如卷积神经网络（CNN）等来进行风场反演 (Holmlund 等., 2021)，进而有机会获得更为准确的四维水平风场。

第5章 静止卫星高光谱探测与成像观测相结合的短临预报应用

5.1 引言

前面章节的定量反演研究已经证明了, 静止轨道高光谱大气探测能够提供兼具高时间分辨率与高垂直分辨率的三维大气动力学和热力学信息。这些三维大气信息及其时间变化能够通过资料同化进入数值天气预报模式并提高数值预报的准确性(Li J 等., 2022), 也能够通过大气廓线的反演得到对流前环境下的大气稳定度特征及其变化, 有利于在对流触发之前进行对高影响天气的短临预警(Li J 等., 2012, 2011)。前文的研究已经通过个例研究证实了通过高光谱探测与高分辨率的静止卫星成像的联合反演可以通过对于低层大气结构的准确描述, 能够在对流性天气发生前给出有利的预报信息。在实际的对流预警业务中, 由于对流初生(CI)的先兆信号通常存在于较小的时间和空间范围内, 因而需要依靠高时空分辨率的成像仪在对流发生前, 尤其是地面雷达观测到目标之前对于 CI 的预报目标进行识别和追踪, 例如使用美国 GOES 卫星多通道成像观测及其变化特征来实现 CI 预报的 SATCAST 模型(Mecikalski 和 Bedka, 2006), 引入目标追踪方法的 SATCASTv2(Walker 等., 2012), 以及使用“盒状平均”追踪云顶变化信息的 UWCI 模型(Sieglaff 等., 2011)等。与此同时, 静止卫星成像观测缺乏在垂直方向上的大气环境信息, 而许多研究发现通过引入能够提供大气环境信息的数值预报产品能够提高短临预报模型的准确度(Liu Z 等., 2019; Mecikalski 等., 2015)。具有高时间分辨率的静止卫星高光谱观测既能提供成像仪所不具备的大气垂直信息, 又在一定程度上克服了数值模式预报结果的不确定性, 通过与静止卫星成像观测在目标识别和追踪上的优势相结合, 将有利于进一步提高对于强对流系统初生和发展的预报和预警。

本章的研究结合国家卫星气象中心此前开发的基于静止卫星成像仪和数值预报产品的对流初生短临预报模型 SWIPE (Storm Warning in Pre-convection Environment, Liu Z 等., 2019), 在对该模型的追踪和训练框架进行优化的基础之上, 使用 ERA5 的温湿廓线数据作为静止高光谱大气探测 (GeoHIS) 数据产品的代用资料, 结合机器学习中的随机森林算法进行了观测系统模拟试验 (OSSE,

Observing System Simulation Experiment) , 并对 GeoHIS 在对流初生的预报预警准确度上的潜在贡献进行了有限度地分析。

5.2 研究数据

本研究使用了以下几种资料和数据产品:

(1) 高分辨率的静止卫星成像观测: 本章采用了来自 GOES-16 静止卫星的 ABI 在美国 CONUS 区域的高分辨率观测资料(Schmit 等., 2017), 空间分辨率为星下点 2km, 时间分辨率为 5 分钟。本章的研究范围是 (60~140°W, 20~55°N)。ABI 共有 16 个通道, 本研究使用了来自其中第 7~16 共 10 个红外通道的观测。

(2) GFS 数值预报场: 来自美国全球预报系统 (GFS)的数值预报场被用来提供短临预报所需要的大气环境背景信息。该数据空间分辨率为 0.5°×0.5°, 提供垂直方向从 10 到 1000 hPa 共 26 个等压面的数据, 其初始场间隔 6 小时, 预报数据间隔 3 小时(Kanamitsu, 1989)。本研究使用了对流潜势能量(CAPE)、对流抑制能量(CIN)、K 指数、抬升指数(LI)等反映不稳定程度的大气热力信息, 水汽混合比(MR)、可降水量(TPW)等水汽信息, 以及水平散度、位势涡度(PV)等大气动力条件信息。该数据与静止卫星成像观测数据一同作为 SWIPE 短临预报模型的预报因子。

(3) 降水分析数据: 本章使用了来自美国气候预测中心的 CMORPH (CPC Morphing technique) 格点化降水分析产品 (Joyce 等., 2004) (<ftp://ftp.cpc.ncep.noaa.gov/precip/>)。本研究使用的是 V1.0 CRT 版本, 该版本是由 CMORPH-RAW 的初始估计值经过与陆地上的站点降水以及海洋上 GPCP (Global Prediction Climatology Project)分析场进行误差订正之后的产品(Xie 等., 2017, 2011)。该数据的空间分辨率 8 km, 时间分辨率 30 分钟, 覆盖全球 60°S~60°N 区域, 该数据提供的最大降水强度信息被用来标示对流强度。

(4) 来自 ECMWF 的 ERA5 再分析资料的大气温湿廓线, 以及三维风场信息。在本研究中, 该数据被用于模拟静止轨道高光谱探测的大气动力和热力廓线, 并以 OSSE 的形式评估未来的高分辨率静止轨道高光谱大气探测在强风暴的短临预报预警中的潜在贡献。

5.3 对流初生模型及改进

5.3.1 SWIPE 模型框架与不足

本研究的基础是 Liu Z 等 (2019) 开发的, 利用静止卫星成像观测结合数值预报的大气环境场信息, 通过随机森林算法 (Breiman, 2011) 建立的能够预测对流初生的短临预报模型 SWIPE 的基础之上。该算法的框架主要包含以下三个部分:

(1) 对流识别与追踪。对流样本的确定是由红外窗区通道 (AHI 当中的 $10.4\mu\text{m}$ 通道) 的基于目标追踪的连续云顶降温率来识别判定的。其识别过程主要包含三个部分: 1) 对于每幅观测数据, 利用连通区域标记法识别出低于 273 K 的冷云区, 并且去除水平范围小于 10 个像元或大于 600 km^2 的目标云, 以排除随机像元与非局地的天气尺度系统的降水云; 2) 利用面积重合法 (Morel 等., 2002), 依据前后时刻重叠像元的比例来判定后一时刻的目标云是否由前一时刻的某个目标云移动而来。本研究采用大于 0.1 的重合率作为判定追踪的标准; 3) 利用追踪的目标云对象, 计算其前后两个时刻的云顶最低亮温减温率, 如公式 (5.1) 和 (5.2) 所示,

$$R_1 = \frac{\min(BT_{A2,1}, BT_{A2,2}, \dots, BT_{A2,N}) - \min(BT_{A1,1}, BT_{A1,2}, \dots, BT_{A1,N})}{t_2 - t_1} \quad \dots (5.1)$$

$$R_2 = \frac{\min(BT_{A3,1}, BT_{A3,2}, \dots, BT_{A3,N}) - \min(BT_{A2,1}, BT_{A2,2}, \dots, BT_{A2,N})}{t_3 - t_2} \quad \dots (5.2)$$

其中 $BT_{A2,1}$ 的三个下标分别代表目标云代号、观测时间, 和目标云中的像元代号。当且仅当 R_1 与 R_2 均小于等于 -16 K/h 时, 认为该目标云具有发展为对流系统的潜在可能, 将其进行标记与编号。这一阈值的选取依据了 Sieglaff 等 (2011) 基于统计研究得出的 $4\text{ K}/15\text{min}$ 的可以用于指示对流初生可能性的红外窗区亮温减温率; 4) 对于被识别编号的目标云, 计算各个卫星观测预报因子, 并且将 GFS 预报数据匹配至 t_3 时刻, 构成预报因子数据集并保存, 用于进一步的匹配与训练。

(2) 数据匹配。当通过目标识别和追踪确定了预报预警对象之后, 将这些目标云的来自静止卫星观测的多通道观测信息与数值预报信息进行匹配, 共同构成模型的预报因子数据集。与此同时, 从在该样本被捕捉到的时刻 (式 5.2 中的

t_3)之后最近的降水分析场上,寻找该目标云范围内最大降水强度,并根据每个样本对应的最大降水强度所处的范围分成强、中、弱三个等级(具体分类标准请见(Liu Z 等., 2019)),作为训练和检验过程中的真值标签。在匹配过程中,作为格点数据的数值预报场和降水分析场会被插值到静止卫星成像观测的像素点上,从而建立一个以单个对流样本为基本单元的,可用于机器学习训练和检验评估的数据集。

(3) 随机森林训练。在完成了数据集的构建之后,将数据集随机分割成包含 80%样本的训练数据集,和一个包含其余 20%样本的检验数据集,二者互不重叠。其中前者用于随机森林模型的训练和参数优化,后者用于对模型的效果进行独立检验和评估。在训练过程中,为了避免单一类别样本(此研究中为弱对流样本)占比过多所造成的单一类别过拟合问题,使用了下采样方式将加入训练的三种类别的样本量调整为 1:1:1,而在独立检验集当中则保持原状。最终根据不同超参数组合的评估结果确定模型并进行预测应用。

该预报模型曾经成功地在国家卫星气象中心运行,并在东亚地区的对流初生识别和强度预报中展示出了较好的计算效率,在实际的对流短临业务预报中也取得了一些较好的预报结果(Liu Z 等., 2019)。然而,该模型的设计框架上仍存在着一些有待改善的不足之处,其中包括:

(1) 在匹配最大降水强度的过程中,采用的是目标识别时刻的云区范围,而没有考虑目标云的移动所带来的位置和范围变化。这将导致对于云区最大降水强度的判断出现误差。特别是对于覆盖范围较小或移动速度较快,以至于实际最大降水强度的出现位置已经移出原有目标区域的样本而言,将可能造成潜在的样本标记误差进而影响训练模型的准确性。

(2) 在构建训练数据集的真值标签时,仅考虑了最近一个时次的降水数据。由于 Liu Z 等 (2019)所使用的 AHI 观测数据的时间分辨率是 10 分钟,而降水分析数据(GPM 或 CMORPH)的时间分辨率为 30 分钟,这使得在数据匹配过程中,预报因子与其对应的降水强度之间的时间间隔实际上为 10~30 分钟。然而,考虑到很多对流系统在对流初生信号与达到其最大强度之间需要更长的时间,如果该目标云在所选取的降水分析时刻尚未达到其最大强度,那么其所匹配到的真值标签将无法正确代表该对流系统真实的潜在发展强度,经过训练之后中会对模

型的预测准确性产生影响。

5.3.2 模型框架的改进

本研究在继承 SWIPE 模型研究思路的同时, 利用来自美国 GOES-16 卫星的先进基线成像仪 (ABI) 的在 CONUS 区域的高频次多通道红外观测资料, 与在该区域有较高准确性的 CMORPH 数据相结合, 建立了应用于美国大陆 (CONUS) 区域的对流过程的短临预报模型, 并针对现有的问题对该模型从以下几个方面进行了改进:

(1) 利用 ABI 在 CONUS 区域的高时间分辨率, 通过 ABI 第 13 通道 ($10.3 \mu\text{m}$ 通道) 的连续观测, 结合 SWIPE 的追踪识别算法, 通过实时地连续迭代追踪给出每 5 分钟一次的对流云预警信息。由于该时间分辨率相比 AHI (10 分钟) 有明显的提高, 使得在同样的阈值 (-16 K/h) 之下, 模型具有更大的几率提前获取局地对流的初生信号, 并且更为准确地使用面积重合法对潜在目标云的移动和变化进行追踪。图 5.1 所示的是 2018 年 7 月 1 日 1940 UTC 的 SWIPE 模型经由面积重合法结合阈值诊断的目标云追踪过程。从图 5.1(f) 中可以看到, 并不是所有的对流性云体都会被视作目标云。对于云顶已经发展到对流层顶附近的云体, 其在当前时次的云顶亮温变化率并不能达到所要求的 -16 K/h 的阈值。比较典型的就是从苏必利尔湖延伸到伊利诺伊州北部的东北—西南走向的对流云带, 其在连续三个时刻的云顶亮温最低值都低于 220 K , 但是其所计算出的 R_1 和 R_2 均为正值, 说明该云体是已经发展成熟的对流云而非 CI。

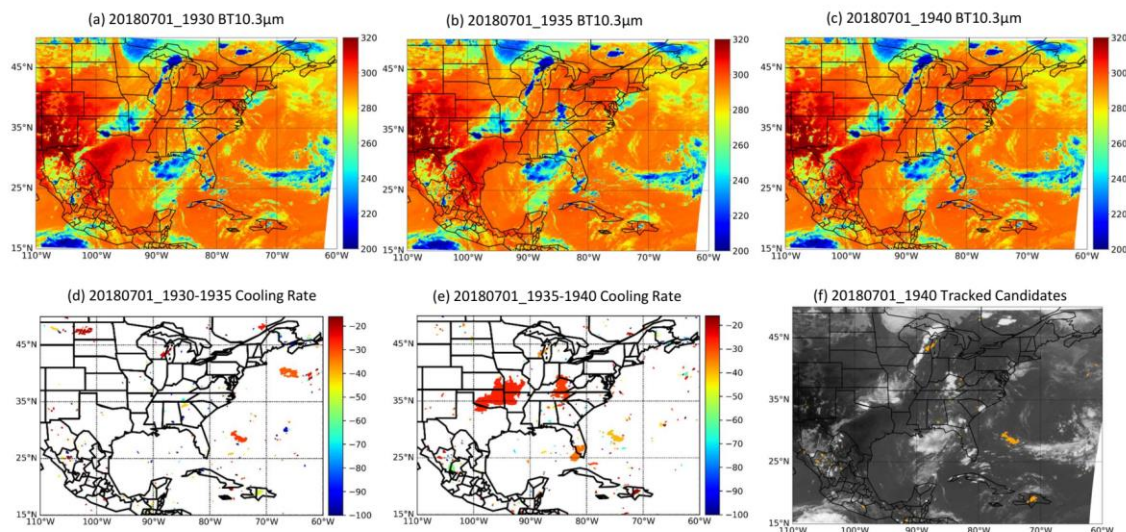


图 5.1 SWIPE 在 2018 年 7 月 1 日 1940 UTC 在 CONUS 区域内追踪到的对流初生目标云，(a-c) ABI 10.3 μm 通道在连续三个时次的观测亮温（单位：K）；(d-e) 通过追踪得到的达到 -16 K/h 的目标云的云顶最大冷却率（单位：K/h）；(f) 追踪和识别到的潜在对流目标云（用橙色标记显示），这些目标云将会是 RF 模型进行目标监测和短临预报的对象。

Figure 5.1 Tracked convective storm candidates by SWIPE at 1940 UTC on 07/01/2018 over CONUS. Subplots are (a-c) the three consecutive brightness temperature (unit: K) imagery of band 10.3 μm from ABI, (d-e) the maximum cooling rates (unit: K/h) calculated from tracked cloud candidates that exceeded -16 K/h, and (f) the identified potential convective candidates (masked by orange) to be monitored and nowcasted through the RF framework.

(2) 在实况降水信息的匹配上，相比于原模型在追踪时的目标云区域内判定降水强度，增加考虑了目标云的位置移动和范围变化，使得在目标云与降水数据的匹配过程中，能够在降水分析场对应时刻的实际目标云范围内得到其最大降水强度，相比目标识别的原始区域更能反映真实状况。与此同时，为了避免匹配的首个降水分析时刻 t_4 与目标识别时刻 t_3 之间的距离过近导致模型缺乏预报意义，将 t_4 与 t_3 之间的时间间隔设定在 15 分钟以上，并且为了保证面积重合法应用时的准确性，同时设定 t_3 与 t_4 的时间间隔不超过 45 分钟。考虑到降水分析时刻与目标识别时刻的时间间隔远大于静止卫星观测的频次（5 分钟），研究中引

入了经典的稠密光流 (Dense Optical Flow) 算法(Farneback, 2003)来对目标云的移动趋势进行预测,该方法能够通过连续两幅图像的特征变化给出基于像素的特征运动估测。在本研究中,我们在通过 $t1\sim t3$ 三个时刻的 ABI 高分辨率成像观测,依据式 (5.1) 和 (5.2) 确定追踪对象之后,利用 $t2$ 和 $t3$ 两个时刻的观测图像信息输入到光流(OF, Optical Flow)运算中,能够得到二维方向上各像素的移动矢量 F_x, F_y ,再根据时间匹配过程中的降水数据滞后时间差 Δt ,通过公式(5.3)和(5.4)估算出基于目标云位置变化的水平位移矢量 Δx 和 Δy ,其中 Δt_0 为光流计算时的时间间隔 5 分钟,进而通过外推得到在降水时刻 $t4$ 的目标云范围估计。

$$\Delta x = \frac{\sum_{i=1}^N F_{x,i}}{N} \times \frac{\Delta t}{\Delta t_0} \quad \dots (5.3)$$

$$\Delta y = \frac{\sum_{i=1}^N F_{y,i}}{N} \times \frac{\Delta t}{\Delta t_0} \quad \dots (5.4)$$

利用这一经由光流法估测的目标云范围与 $t4$ 时刻实际的 ABI 成像观测再次使用面积重合法,即能确定目标云的实际范围,并在此范围内确定样本匹配的降水强度与等级。图 5.2 所示为经过改进的 SWIPE V2 在降水强度匹配过程与原版本 SWIPE V1 在不同类型的目标云上的对比示意图。通过与 SWIPE V1 的对比能够看出,改进后的降水匹配算法能够更为准确地确定训练数据中的降水强度信息,从而通过减小训练数据集当中的误差而增加机器学习模型的代表性和准确性,并且在实际的业务预警应用中能够依据目标云的移动情况,实时地给出其未来的移动趋势预测。

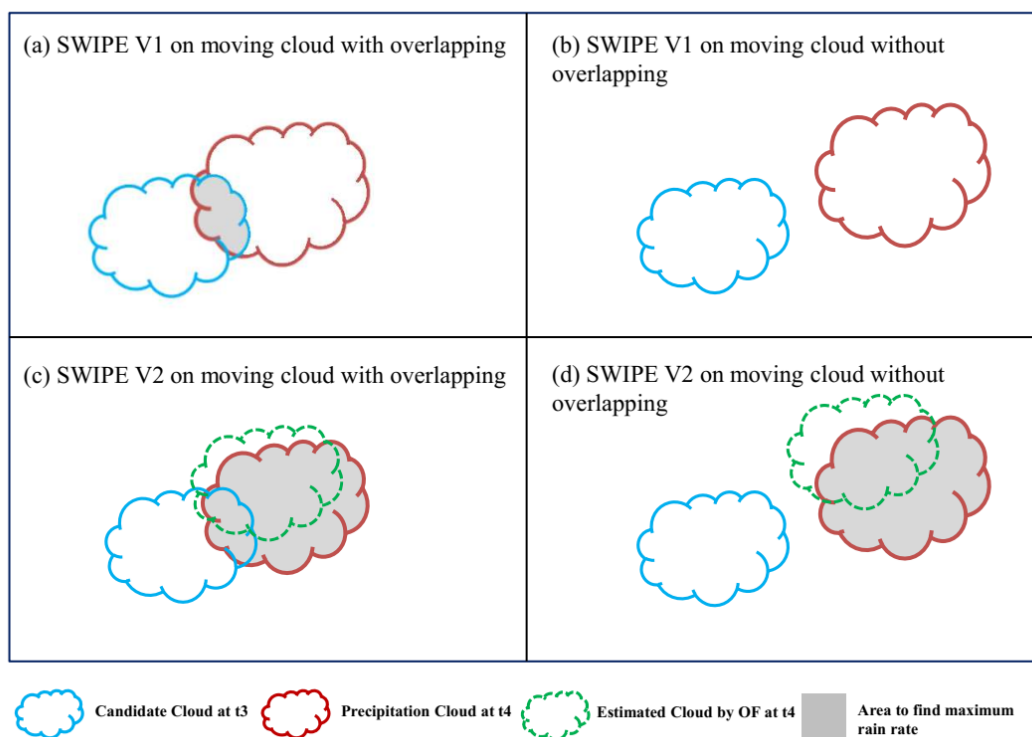


图 5.2 应用光流法结合面积重合法对快速移动的目标云进行降水匹配的示意图。对于在降水时刻的覆盖区域与识别时刻覆盖区域存在重合的目标云，(a) Liu Z 等 (2019) 在 SWIPE V1 中的最大降水强度匹配范围是二者的重叠区域，而 (b) 改进的 SWIPE V2 能够通过面积重合法与 t_4 时刻的 ABI 成像观测进行匹配从而确定整个降水云团的位置，进而在全云团范围内进行匹配。对于移动后与原所在范围没有重叠的目标云，(c) SWIPE V1 无法找到对应的最大降水强度，而 (d) SWIPE V2 则能够通过利用光流法 (OF) 预测的目标云位置，与 t_4 时刻的 ABI 成像观测经由面积重合法进行匹配并成功地找到目标降水云团的完整范围。

Figure 5.2 Schematics of the application of optical flow and area-overlapping in collocating precipitation data for fast moving cloud candidates. For a moving cloud that has some overlapping with its original area at the time of identification, (a) the SWIPE V1 by Liu Z et al., (2019) searches for the maximum rain rate within the overlapped area., while (c) the enhanced SWIPE V2 is able to locate the whole area of the precipitation cloud through application of area-overlapping with actual ABI imagery at t_4 in the collocation process. For a moving cloud that doesn't have any overlapped area with its original area, (c) SWIPE V1 fails to find the corresponding rain rate, while (d) the enhanced SWIPE V2 is able to

collocate the ABI image at t_4 with an estimated cloud area provide by OF, and successfully find the whole area of target precipitation cloud.

(3) 由于目标云系统所产生的最大降水强度不一定发生在 t_4 代表的 CMORPH 降水分析时刻, 也可能在 30 分钟之后的下一时次 (t_5) 或者 1 小时之后 (t_6) 的降水分析场上。因此, 我们在确定了 t_4 时刻的降水云团实际范围之后, 将匹配算法进一步扩展到此后的两个 CMORPH 降水分析时刻, 并在同一目标云所匹配到的三个不同时刻的降水分析场中, 选择最大的降水强度作为该样本最终的强度标签。图 5.3 所示的是改进后的 SWIPE V2 完整的目标识别与数据匹配过程, 将降水匹配时次由 1 个时次扩展到了 3 个时次, 并在每一次的匹配过程中增加了质量控制过程, 以确保该目标云在后一个 CMORPH 数据时刻相对前一个时刻有所发展或保持在近似的云顶高度。在连续匹配过程中, 只有当某个样本在前一个时次成功匹配到满足条件的目标云才会进入下一个时次的降水匹配, 否则降水匹配过程将停止并以之前一个或两个时次的匹配结果来确定最终强度。在完成对于 t_5 及之后时刻的降水云团匹配之后, 若匹配得到的云团云顶最低亮温比前一个时刻高出 3 K 及以上, 认为该对流云团已经处于消散过程, 或匹配到的云团并非原有目标云发展而来, 因而不再继续对其位置和降水变化进行追踪和匹配。在此基础上, 对于不满足上述条件而导致在 t_6 之前停止追踪的样本, 将会对其在最强降水时刻的 ABI 窗区通道观测亮温进行检验, 若其最低亮温未能达到 -32°C 或更低, 将认为该目标云不具备对流特征, 因而直接标记为弱对流样本。这一检验阈值参考了 Maddox (1980) 提出的中尺度对流复合体 (MCC) 的概念, 但是并不对其范围和持续时间做出要求, 其主要目的是去除由于瞬时云顶降温率达到阈值的非对流性层云降水所带来的影响。通过引入光流法以及对于目标云发展的持续追踪, 能够更好地在训练数据集中建立以降水表征的对流强度与对流前大气环境与卫星观测特征的相关关系, 进而通过机器学习训练获得更为有效的对流初生预报模型。

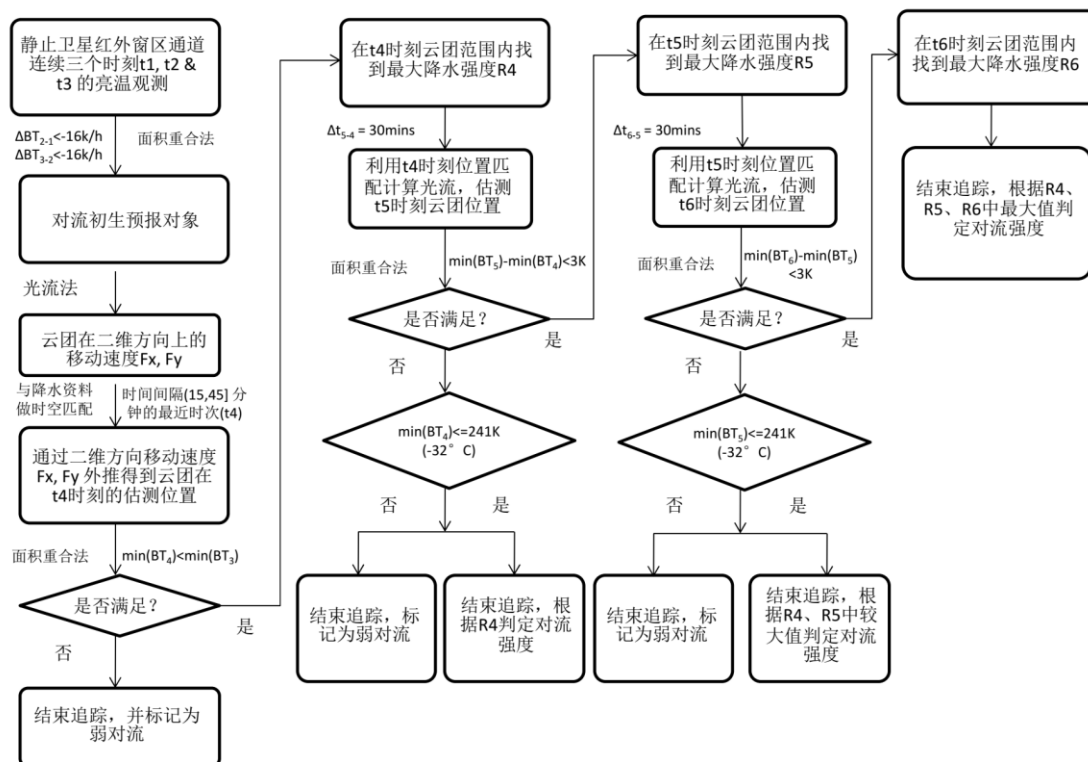


图 5.3 改进后模型的追踪与数据匹配流程示意图。这里提到的 t1, t2 和 t3 代表 ABI 在 CONUS 区域 5 分钟间隔的连续观测，t4, t5 和 t6 代表以 30 分钟为间隔的 CMORPH 降水分析数据。通过在 t5 和 t6 时刻对于目标云团降水的连续追踪提高了模型对于风暴最大降水强度的捕捉能力。

Figure 5.3 The flowchart of the enhanced tracking and collocation framework to build up the dataset for model training. Here t1, t2 and t3 are times for ABI CONUS images with a time interval of 5 minutes. t4, t5 and t6 are times for CMORPH precipitation data with a time interval of 30 minutes. Note that the continuous tracking for CMORPH precipitation at t5 and t6 enhances the chance to capture the true storm intensity based on precipitation rate.

5.4 数据集构建与模型训练

结合上述改进后的 SWIPE V2 识别与追踪算法, 本研究利用 ABI 红外 10.3 μm 通道的观测亮温作为识别对象, 对于 2018 年 3~10 月在美国 CONUS 区域共 7 个月的对流样本进行了识别和追踪, 共获得了 801112 个对流初生样本。这些样本在其识别时刻 (t3) 的多通道亮温观测与数值预报产品的相关变量 (如表 5.1 所

示) 共同构成 SWIPE 预报模型的预报因子数据集。其中既包括了来自 ABI 观测的云顶降温率、对流云面积、窗区通道亮温, 以及对流触发时刻的不同红外通道之间的亮温差异信息, 也包括了来自 GFS 数值预报产品的与对流触发相关的大气背景信息, 包括能够表征大气热力学和动力学特征, 以及大气稳定性性质的多种变量。

表 5.1 经过匹配用于随机森林训练与短临预测模型的预报变量。对于每个变量使用其在目标云范围内的最大、最小以及平均值 (除了最大降温率与云覆盖面积这两个可以直接作为输入的变量) 来作为随机森林模型的输入。

Table 5.1 Predictor variables collocated for random forest training and prediction in the nowcasting model. The maximum, minimum and mean values of each predictor variable in the domain of candidate cloud (except maximum cooling rates and area coverage that are used directly) are used as inputs of the RF model.

数据来源	变量	描述
ABI CONUS	Maximum cooling rate (R1 and R2)	云顶降温率
	Area	目标云的大小
	BT10.3	窗区亮温
	BT difference (3.9-10.3)	不同红外通道的亮温差
	BT difference (6.2-10.3)	
	BT difference (6.9-10.3)	
	BT difference (7.3-10.3)	
	BT difference (8.4-10.3)	
	BT difference (9.6-10.3)	
	BT difference (11.2-10.3)	
BT difference (12.3-10.3)		
BT difference (13.3-10.3)		

续表 5.1

数据来源	变量	描述
ABI CONUS	BT difference (3.9-7.3)	不同红外通道的亮温差
	BT difference (3.9-11.2)	
	BT difference (8.4-11.2)	
	BT difference (11.2-12.3)	
GFS NWP	T (Temperature)	500 至 925hPa 等压面之间的大气温湿廓线
	MR (Water vapor mixing Ratio)	
	DIV (divergence)	850 和 925hPa 等压面上低层大气动力和热力特征
	Θ_{se} (Pseudo-equivalent potential temperature)	
	DIV10 (divergence at 10 meters above surface)	
	Tsur (Surface temperature)	地面和近地面大气动力、热力特征
	PV (Potential Vorticity)	
	K-Index	在 $\Theta = 320K$ 等熵面的位势涡度
	CAPE (Convection Available Potential Energy)	大气稳定性和湿度信息
	LI (Lifted Index)	
CIN (Convective Inhibition)		
EBS (Effective Bulk Shear)		
TPW (Total Precipitable Water)		

在对样本降水强度的分类上, 采用了美国气象学会(AMS)对于降水强度的定义, 将追踪到的全部样本依据其匹配到的最大降水强度分为了三个等级。其具体分类方式为: 将云区最大降水强度小于 2.5 mm/h 的个例标记为弱对流, 大于等于 2.5 mm/h 且小于 7.6 mm/h 的标记为中等强度, 大于 7.6 mm/h 的标记为强对流

个例(AMS Glossary, 2012)。在对应的分类和标记工作完成之后,将已匹配得到的对流数据集随机分为一个包含 80%样本的训练集用于模型的训练和优化,而剩余的 20 %数据作为独立测试集用于模型的验证和评估。表 5.2 所示的是不同数据集和不同强度类别的样本量。总的来看,总样本中 94.3 %的样本是弱对流或非对流性样本,显著高于样本量占总样本 3.0 %的中等强度对流和占总样本量 2.7 %的强对流样本。值得注意的是,本研究所提到的样本是指以与 ABI 观测相同的 5 分钟的时间分辨率,根据前文所述的识别与追踪算法被模型识别出来用于后续监测和短临预测的目标云对象,而非天气学意义上的对流风暴系统。作为 CI 短临预报模型,其所捕捉的这些目标云中的很大部分并不会成长为真正的对流系统,而对于一些保持长时间快速发展增强的对流目标云,则可能在连续多个时次被视为识别和追踪的样本,并依据其在不同同时次的观测特征给出连续的模型预测结果。

表 5.2 SWIPE 模型在 2018 年 3 到 10 月之间在 CONUS 区域追踪到的对流预报目标样本量

Table 5.2 Sample sizes for convective candidates tracked by SWIPE in CONUS during March to October 2018

数据集	强对流样本	中等对流样本	弱对流或非对流样本	样本总数
总数据集	21519	24096	756497	802112
训练集	17188	19288	605213	641689
验证集	4331	4808	151284	160423

与 SWIPE V1 相一致地,本研究也采用了随机森林算法作为 CI 短临预报模型的机器学习训练框架。随机森林分类模型是通过应用不同预测因子,在不同的训练子集上训练一系列的决策树分类器,并利用各决策树预测结果的平均来获得集合的分类预测结果,其具体的算法原理和细节内容请参考(Breiman, 2001)。已有研究表明,当建立分类模型时,若训练集的某一类别样本量远大于其余类别时,基于机器学习得到的模型会过多地关注多数类而牺牲少数样本的准确性 (Sun Y 等., 2009)。基于 AHI 的 SWIPE V1 模型也表现出了在各类别样本数持平的训练

集当中效果最佳(Liu Z 等., 2019)。我们在研究中也沿用了同样的下采样训练策略,即在样本量较大的类别内进行随机采样,使得进入训练的各类别样本数达到平衡,再利用随机森林方法通过迭代主要参数对模型进行训练和优化。除此之外,我们还对比了三分(弱对流和非对流/中等对流/强对流)框架与双分类(非强对流/强对流)框架所训练的模型在人们最为关注的强对流类别上的预报能力。其中,双分类模型的分类标准是将三分类模型中除强对流之外的两类合并,构成与强对流相对应的非强对流组别,并利用随机森林以双分类模型的框架进行训练。

表 5.3 所示的是本研究在训练过程中所对比的四个模型训练框架及各自的总体泛化性与在测试集上的准确性表现,其中 2C 和 3C 分别代表二分类和三分类模型,UB 和 BA 分别代表未进行样本平衡处理的模型(unbalanced)和经过样本平衡处理的模型(balanced)。在本研究中,模型的训练过程是利用免费且高效的 Scikit-learn 工具(Pedregosa 等., 2011)来进行的,训练中调整和优化的三个主要超参数分别为决策树总数(n_estimators),最大树深度(max_depth),以及寻找分裂点时考虑的最大特征数目(max_features)。三个超参数的遍历范围依次是为 'n_estimators': [100, 200, 300, 400, 500, 1000]; 'max_depth': [10, 20, 30, 40, 50]; 'max_features': [5, 10, 20, 30, 40, 'sqrt', 以及 'log2']。对于不同的超参数组合,使用了袋外评分,即 OOB score(Out-Of-Box score)来评估对应模型的泛化能力。袋外评分是随机森林模型的一种交叉验证方法,采用的是在构建决策树时在训练样本里随机抽取三分之一的样本不进入训练而用于评估模型的性能,使得模型得以在训练过程中实时地对其泛化能力做一个无偏估计,关于袋外评分的算法和原理请参见(Hastie 等., 2009)。与此同时,不同模型在独立测试集上的分类准确率信息也在表 5.3 中给出。总体而言,模型在所有训练场景下的袋外评分及准确率的标准差(括号内数值)均显著小于其对应的均值,说明本研究的各个训练场景对于模型的超参数组合并不敏感,而影响模型效果的主要因素在于不同的分类框架以及样本平衡技术的使用。比较不同的训练场景中能够看到,相比于三分类模型,二分类模型显示出更高的袋外评分和更高的准确率,意味着更小的分类误差和更高的稳定性。而相比于经过样本平衡的场景,在各自分类框架下使用原始样本分布的场景显示出更高的袋外评分和分类准确度,但是考虑到弱对流样本占总样本的比重高达 94%,这在很大程度上是源于整体样本分布的不平衡性。例如,

如果模型盲目地将所有样本均预测为弱对流,在三分类模型的总体准确率仍可以达到 94 %。作为对流初生短临预报模型,其针对能给人类生活带来影响的强对流样本的预报能力,比模型的总体分类准确率更具备对于模型预报能力的指示性,因而下文的研究将主要针对强对流类别的预报效果进行分析。

表 5.3 不同训练场景所对应的分类框架与采样信息,以及各自场景下通过不同超参数组合训练得到的模型的袋外评分以及在测试集上的分类准确性的统计平均值以及标准差(在括号中表示)

Table 5.3 The classification and sampling methodologies for different scenarios, and the mean value and standard deviations (in brackets) of their respective OOB scores and overall accuracy on validation dataset.

	分类	样本平衡	袋外评分	测试集准确率
Scenario-3CUB	三分类	否	0.951 (0.0003)	0.951 (0.0002)
Scenario-3CBA	三分类	是	0.663 (0.0053)	0.794 (0.0022)
Scenario-2CUB	双分类	否	0.978 (0.0001)	0.979 (0.0001)
Scenario-2CBA	双分类	是	0.876 (0.0016)	0.867 (0.0016)

注:表中三分类指的是(弱对流和非对流/中等对流/强对流),而双分类指的是(非强对流/强对流)。样本平衡指的是通过下采样的方式使得在训练数据集当中不同类别的样本量相同。

5.5 预测结果与评估

基于上述的讨论,我们采用针对强对流类别样本的预报效果作为在不同场景下对模型性能的评估,具体采用了二分类混淆矩阵的方法,同时考虑了命中率(POD, Probability of Detection)、虚警率(FAR, False Alarm Rate),以及关键成功指数(CSI, Critical Success Index),从而以不同的角度综合评估模型在强对流样本预测的准确性,各评估指标的定义在表 5.4 和表 5.5 中给出。

表 5.4 本研究中在分类问题中针对某一特定类别以预测值和对应的真实标签表示的混淆

矩阵

Table 5.4 Confusion matrix for predictions and actual labels of a specific class in a classification task in this study

		实际值	
		1	0
预测值	1	A	C
	0	B	D

表 5.5 研究中用于评估随机森林分类模型对某一特定类别的预报能力的指标

Table 5.5 The metrics used to evaluate the performance of the random forest classification model on a specific class

名称	表达式	变化范围	最优值
命中率 (POD)	$A/(A+B)$	[0,1]	1
虚警率 (FAR)	$C/(A+C)$	[0,1]	0
关键成功指数 (CSI)	$A/(A+B+C)$	[0,1]	1

表 5.6 所示的是不同情景下训练得到的最佳模型对于独立测试数据集中不同类别样本的预测评估结果。可以看到, 在不同分类框架下的样本平衡模型 (3CBA 和 2CBA) 都表现出高于其对应的非平衡模型 (3CUB 和 2CUB) 在强对流类别上更高的 POD, 但是也伴随着相对较高的 FAR。相比之下, 非平衡模型尽管具有较高的 CSI, 但是其对于强对流类别样本的 POD 小于 0.4, 意味着漏报了大多数的强对流样本。这种情况的产生与前文提到的训练集样本量不平衡有关, 但是考虑到 SWIPE 模型作为对流初生预报模型, 其预报关键在于尽早地捕捉对流初生信号并给出相应的预警信息。考虑到在研究时段的总样本中, 强对流样本仅占 2.7%, 我们认为在大量的目标云样本当中尽可能多地对强对流样本信号进行捕捉和预测是应该被优先考虑的, 而其所造成的虚警空报可以通过后续发展阶段的雷达回波等实际观测信息加以剔除。从这个角度来看, 经过样本平衡的模型

(3CBA 和 2CBA) 所体现出的在强对流样本的预报能力具有更高的应用价值。二者相比, 2CBA 在各模型中具有对于对于强对流类别最高的命中率, 但 3CBA 展示出了模型在降低了虚警率的同时也保持了 0.63 的命中率, 接下来的研究将对两种模型在强对流样本的预报能力差异进行进一步的分析。

表 5.6 不同训练情景下训练和优化得到的短临预报分类模型的统计评估结果

Table 5.6 Statistics on the performance metrics of the storm nowcasting classification model trained and optimized under different scenarios

	类别	POD	FAR	CSI
Scenario-3CUB	弱/非对流	0.99	0.04	0.95
	中等对流	0.03	0.55	0.03
	强对流	0.39	0.35	0.32
Scenario-3CBA	弱/非对流	0.81	0.01	0.80
	中等对流	0.58	0.90	0.09
	强对流	0.63	0.66	0.28
Scenario-2CUB	非强对流	0.99	0.02	0.98
	强对流	0.31	0.25	0.28
Scenario-2CBA	非强对流	0.87	0.01	0.87
	强对流	0.90	0.84	0.15

为了进一步研究不同情境下的模型对于强对流样本的预报能力, 将独立检验数据集当中的所有样本依据其在识别时刻的目标云覆盖面积划分成了三类, 分别是面积在 1000 km^2 以内的小目标云, 面积在 1000 至 5000 km^2 的中等目标云, 以及面积在 5000 km^2 及以上的大目标云。图 5.4 (a) 所示的是不同面积范围内的强对流与非强对流样本的发生频次分布。可以看到, 面积较大的目标云发生强对流的频次高于面积较小的目标云。对于覆盖面积在 1000 km^2 以内的目标云样本, 其非强对流的样本量是强对流样本的 101.75 倍, 而对于 5000 km^2 及以上的目标

云样本，非强对流样本量仅为强对流的 4 倍。而在测试数据集的强对流样本当中，面积达到 5000 km^2 及以上的大目标云的占比最大，占到了其中大约 45% 的样本量。图 5.4 (b-d) 所示是不同情景下训练的模型对于不同面积大小的强对流样本的预报能力。通过各模型对不同面积组别的目标的准确性比较，能够看到所有模型在大目标云类别（图 5.4 (d)）的 POD、FAR 和 CSI 都是各自模型在三个不同组别的最优。相比之下，各模型在小目标云类别（图 5.4 (b)）的预报精度均为各自模型的最低。这说明了 SWIPE 模型的目标识别、追踪和预报方法对于 5000 km^2 及以上的潜在强对流样本具有比小范围的对流样本更好的预报结果，而这一特点并不随着训练框架的不同而变化。

对比不同的训练情景可以看到，2CBA 模型对于大对流样本的 POD 达到 0.99，意味着该模型对于几乎所有的强对流样本都给出了成功的预测和预警。但是与此同时，2CBA 达到 0.63 的 FAR 也在四个模型当中相对偏高，意味着该模型在正确的预警信号以外也有许多的空报产生，而这些空报很大程度上影响了该模型在 CSI 上的表现。相比之下，3CBA 模型的 FAR 相对较低，仅为 2CBA 的三分之二，同时也保持了高达 0.85 的 POD，在大对流样本的预报中具有更为均衡的表现。尽管 3CUB 和 2CUB 模型由于较低 FAR，仍然能够在 POD 相对偏低的情况下得到较高的 CSI，但是它们在中等对流样本和小对流样本上的 POD 过低，意味着它们对于中小样本的 CI 信号捕捉能力很差。尤其是对于面积在 1000 km^2 以内的小对流样本，如图 5.4 (b) 所示，3CUB 和 2CUB 几乎没有对于强对流样本的预测能力，因而在实际的业务预警应用中将受到很大的限制。相比之下，3CBA 和 2CBA 模型虽然在中小对流样本的预测准确性也有不同程度的降低，但是仍然能保持一定的 POD。尤其是 2CBA，尽管其在小对流样本上的虚警率偏高，但考虑到在小样本类别中的强对流样本仅占总样本的 0.97%，其实际给出的强对流预警信号仅占全部输入预报样本的约 9.1%，仍然具备一定的对流识别和预警能力，而进一步的质量控制可以通过后续的雷达观测等进行订正。

经过对于 3CBA 和 2CBA 模型及预测结果的进一步分析发现，在 3CBA 正确预测的所有强对流样本当中，100% 的大对流样本、99.85% 的中等对流样本，以及 98.96% 的小对流样本同时被 2CBA 模型所成功预测。与此同时，在 3CBA 所造成的虚警当中，99.42% 的大对流样本、99.21% 的中等对流样本和 95.16% 的

小对流样本也在 2CBA 模型的所预报的虚警当中。这说明了二者的预报结果具有较高的一致性，区别在于 3CBA 给出相对保守的预警结果，同时虚警空报也相对较少；而 2CBA 给出更为广泛的预警信息，同时伴随着更多的虚警空报。基于这些分析结果，在未来的预报应用中将考虑采用集合预报的思想，综合使用两个模型的预测结果来获得对于预报员最为有利的预警信息。一种可行的运行方式是使两个模型在服务器上同时运行，从而实时得到来自两个模型各自的预报结果，当一个目标云被两个模型均预测为强对流时，将对其标记为“强对流预警”，而如果仅有一个模型预测其为强对流，就将其标记为“潜在强对流”，二者都没有强对流预警信息则不做标记。在后文中也将给出改进后的 SWIPE 模型在实际个例预测中的应用效果展示。

不同训练场景的模型均表现出的在面积较小的对流样本上预报精度偏低的现象，这在一定程度上和 SWIPE 目前所使用的大气背景场分辨率有关。对于以 1000 km^2 为阈值的小范围目标样本，其最大范围约是 $32 \text{ km} \times 32 \text{ km}$ ，已经低于了 SWIPE 模型中用于提供大气环境背景信息的 GFS 数值预报场的水平分辨率 ($0.5^\circ \times 0.5^\circ$)，这将带来对于此类目标云样本在大气背景信息上的系统性偏差，而导致模型只能依赖卫星成像观测来进行预报。这也在一定程度上体现出，尽管高时空分辨率的静止卫星观测能够有利地在对流前环境中捕捉 CI 信号，对于三维大气动力学和热力学特征的准确表达，对于对流初生预报的准确度仍然具有重要的影响。除此之外，空间尺度较小的目标样本相比大样本而言，其追踪和匹配过程也面临着更大的不确定性。对于此类的目标样本，只能依赖具有相对较高 POD 的 2CBA 模型来捕捉信号，再通过后续的持续雷达监测来对空报进行修正。




图 5.4 (a)强对流样本与非强对流样本在小目标云类别（面积小于 1000 km²）、中等目标云类别（面积在 1000 到 5000 km² 之间）以及大目标云类别（面积在 5000 km² 及以上）内的样本量。(b-d)各训练场景得到的模型对(b)小目标云；(c)中等目标云；和(d)大目标云的 POD、FAR 和 CSI 评分。四种训练场景的定义请参见表 5.3。

Figure 5.4 (a) Sample sizes of non-severe and severe cases for group small (area smaller than 1000 km²), group medium (area in the range of 1000 to 5000 km²) and group large (area no less than 5000 km²) in the validation dataset. (b-d) POD, FAR, and CSI scores for the severe cases with (b) group small, (c) group medium and (d) group large, respectively.

Refer to Table 5.3 for the definition of the 4 scenarios.

5.6 对流个例预报应用

由于本研究改进的 SWIPE 模型是用 2018 年的数据进行训练和统计检验的，我们使用该模型对 2019 年 8 月的真实数据进行业务化的预报应用试验。SWIPE

模型以与 ABI 在 CONUS 观测频次相同的 5 分钟时间分辨率对于预测目标进行识别追踪，并以同样的时间分辨率给出预测结果。SWIPE 模型在每个时次从读入数据到给出预报结果的平均耗时约为 2 分钟。基于上文对于不同试验模型的评估结果，我们最终采用了 3CBA 和 2CBA 同时运行，并对其结果以集合预报的方法对于潜在的强对流云进行预报。当某个目标云被两个模型同时预测为强对流时，将会被标记为“Severe”即强对流，而当且仅当其中一个模型预测为强对流时，该云被标记为“Potential”即潜在强对流，弱非这两种情况则不输出预警信号。在实际业务应用中，当一个预警信号被给出后，一个附加的追踪模块将持续追踪该目标云直至其被雷达观测所识别到。这将有助于预报员对于被给出强对流预警的目标云，在其经过发展导致云顶降温率不再满足 SWIPE 的识别阈值的情况下，仍然能够实现对其的连续监测。由于该独立模块仅用于纯粹的目标追踪，仅用于实际业务预报显示使用，在本节的研究中暂不做详细讨论。本节选取了被美国风暴预测中心 SPC (Storm Prediction Center) 记录的 2019 年 8 月的两个典型的强风暴事件来介绍 SWIPE 模型的实际预报应用效果。

如图 5.5 所示，经过改进的 SWIPE 模型成功地识别到了世界时 2019 年 8 月 1 日北卡罗莱纳州的一个局地对流目标，依据相关报告，该目标最终发展成了局地的强雷暴系统，并在该地区造成了强降水和大风灾害。图 5.5 的第一行是 SWIPE 的实时预测结果，可以看到，模型最早在 1605 UTC 对于该系统给出了预警信号，预警等级为“潜在强对流”。而在同一时间，ABI 在 $10.3\mu\text{m}$ 通道观测到的亮温仅为 260 K 左右，在 1600 UTC 的 CMORPH 降水分析场也没有出现对应的降水。随着系统的发展，在 1635 UTC，该目标云的云顶亮温最低值已经低于 240 K，发展出了对流性的云顶特征，且在 1630 UTC 的 CMORPH 分析场已经出现了与该系统对应的降水。到了 1720 UTC，目标云面积显著增大且窗区亮温在 240 K 以下的冷云顶区域也显著增大，对应 1730 UTC 的 CMORPH 分析场显示该系统对应的最大降水强度首次超过 7.6 mm/h，达到了 SWIPE 模型的强对流分类定义。这也意味着对于该对流个例，SWIPE 成功地提前了 1 小时 25 分钟给出了相应的预警信息。该系统此后继续发展，并在 1900 UTC 的降水强度首次超过 16 mm/h，并一直持续到 8 月 2 日的 0030 UTC 才逐步减弱。但是由于其已经发展较为成熟，达不到 SWIPE 对快速发展的要求而没有作为预报对象，因而也

没有继续的给出预警（1900 UTC 的 SWIPE 输出结果是对另一个对流目标的预警）。尽管 SWIPE 模型对该个例给出的预报仅为“potential”，但是通过对于同一目标云多次重复的预警信号能够提高预报员对这一潜在对流系统的认识，从而在相比常规预报更早于对流发生的时段做出正确的决策。

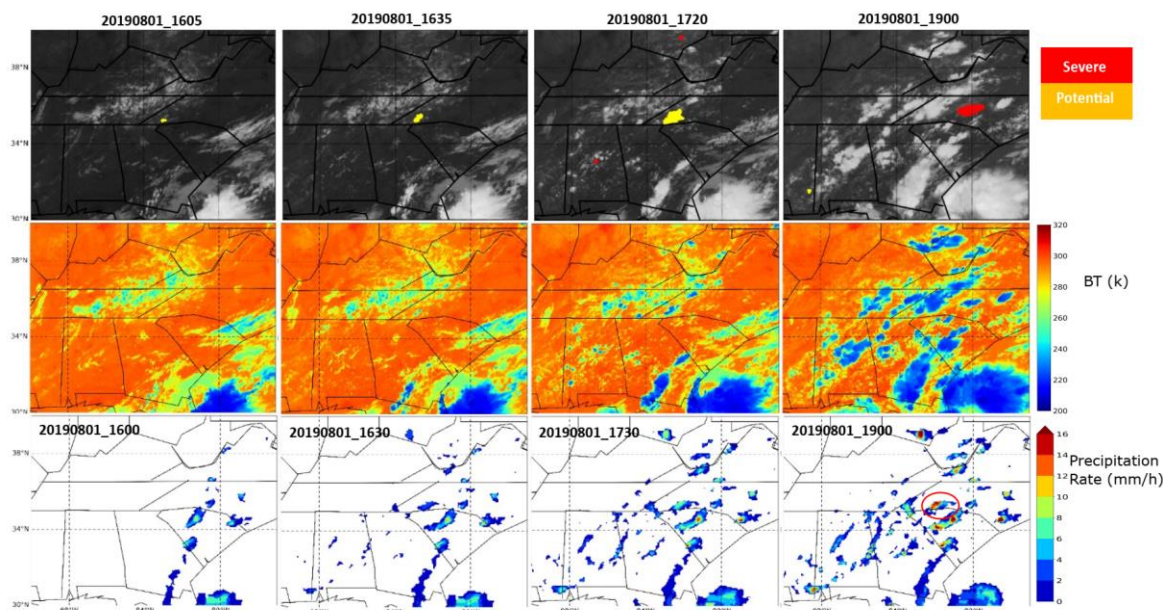


图 5.5 SWIPE 模型于 2019 年 8 月 1 日在北卡罗莱纳州追踪到的一次强风暴个例。第一行所示为 SWIPE 模型的预警结果，叠加于以灰度表示的 ABI 10.3 μm 通道亮温观测，其中“Severe”表示 3CBA 模型与 2CBA 模型对于强风暴分类的一致判定，而“Potential”表示仅其中一个给出强风暴判定。第二行所示为填色形式表示的 ABI 10.3 μm 通道亮温观测（单位：K）。第三行为所示时次的 CMORPH 降水（单位：mm/h）。

Figure 5.5 A severe convective storm case tracked by the enhanced SWIPE model on 01 August 2019 in North Carolina. The first row shows the greyscale BT of ABI 10.3 μm channel, overlaid by the results predicted by the enhanced SWIPE model with ‘severe’ indicating unanimous classification decision of severe from both model 3CBA and 2CBA, while ‘potential’ indicates split decision from the two models with severe predicted by only one of them. The second row shows the colored observed BT(K) from ABI 10.3 μm channel. The third row shows the precipitation rate (mm/h) at the given time from CMORPH.

SWIPE 模型在世界时 2019 年 8 月 7 日在威斯康星州以 30 分钟的时间间隔先后捕捉到了两个潜在的对流云目标并分别给出了强对流预警。这两个云目标后面经历了合并发展过程，最终发展成一个范围较大的对流系统，并在威斯康星州东北部造成冰雹、大风以及强降水等灾害性天气。SWIPE 对于该个例的预报结果如图 5.6 所示。模型在 1655 UTC 首先在威斯康星州东北部识别出一个对流云目标，并给出了级别为“Severe”的预警信号。此时该系统的窗区最低亮温在 250 K 左右，而 CMORPH 在前一时次仅有不到 2 mm/h 的小雨。在 1725 UTC，SWIPE 在该目标云的西侧识别出另一个目标云，并给出了级别为“Severe”的强对流预报。两个系统彼此独立，并且各自在 CMORPH 降水分析场上有自己对应的降水区域和强度。此刻东侧的对流云已经相对成熟，云顶亮温在 230 K 左右。至 1800 UTC，两个目标云都有向东发展和移动，其中西侧目标云的移动速度更快，其东侧开始与东侧目标云合并，而此刻 CMORPH 显示对应区域的最大降水强度首次超过 7.6 mm/h，达到模型的强对流分类阈值。这意味着 SWIPE 模型提前 1 小时 5 分钟对该个例做出了成功的预警。此后，两个目标云完成合并，并在 1930 UTC 达到了超过 12 mm/h 的降水强度，也是该对流系统在 CMORPH 上显示的最大降水强度，该时刻也同时出现了冰雹和大风天气的记录。对于造成这次威斯康星州的冰雹、大风以及强降水的局地强对流系统，SWIPE 模型不仅成功地在合并与对流增强开始前识别出了参与合并的两个目标云，并且在对流最大强度之前超过 2.5 小时给出了准确的强对流预警。

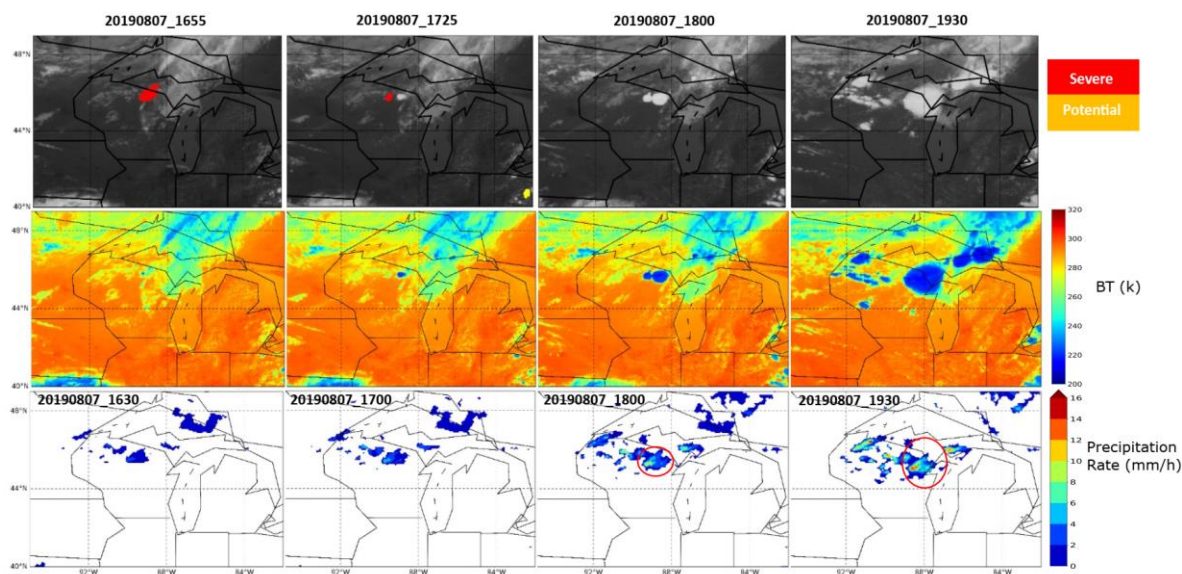


图 5.6 SWIPE 模型于 2019 年 8 月 7 日在威斯康星州追踪到两个对流云合并成一个强对流云的过程。第一行所示为 SWIPE 模型的预警结果，叠加于以灰度表示的 ABI 10.3 μm 通道亮温观测，其中“Severe”表示 3CBA 模型与 2CBA 模型对于强风暴分类的一致判定，而“Potential”表示仅其中一个给出强风暴判定。第二行所示为填色形式表示的 ABI 10.3 μm 通道亮温观测（单位：K）。第三行为所示时次的 CMORPH 降水（单位：mm/h）。

Figure 5.6 Two convective cloud candidates that merged into a severe convective storm case tracked by the enhanced SWIPE model on 07 August 2019 in Wisconsin. The first row shows the greyscale BT of ABI 10.3 μm channel, overlaid by the results predicted by the enhanced SWIPE model with ‘severe’ indicating unanimous classification decisions of severe from both model 3CBA and 2CBA, while ‘potential’ indicates split decisions from the two models with severe predicted by only one of them. The second row shows the colored observed BT(K) from ABI 10.3 μm channel. The third row shows the precipitation rate (mm/h) at the given times from CMORPH.

5.7 预报因子的重要性评分

在经过随机森林模型训练得到的短临预测模型之后，利用 Scikit-learn 工具库 (Pedregosa 等., 2011) 中的特征重要性评分 (IS, Importance Scores) 对短临预报模型中各个预报因子的相对重要性进行了评估。表 5.7 所示的是 3CBA 和 2CBA 模型当中，分别来自 ABI 成像观测和 GFS 数值预报 (NWP) 大气环境场各自评分最高的 10 个预报因子，以及它们对应的评分和排名情况。通过重要性评分排名情况可以看到，在 3CBA 和 2CBA 模型中排名前 5 的预报因子均来自于 ABI 观测，并且排名首位的预报因子均为目标云在 ABI 的 6.2 μm 和 10.3 μm 通道之间亮温差的最大值。这一排名情况对应了前人研究发现的，水汽通道与窗区通道的亮温差异能够表征发展中的云顶与对流层顶的相对高度，从而指示潜在的对流过程 (J Schmetz 等., 1997; Mecikalski 和 Bedka, 2006; Mecikalski 等., 2008; Ai 等., 2017)。其余排名靠前的预报因子还包括了 ABI 的 6.9/7.3/9.6 μm 通道与窗区 10.3 μm 通道之间的亮温差。3CBA 和 2CBA 模型在预报因子重要性排名上的不同之处主要在于 NWP 变量的相对重要性。尽管 NWP 变量在两个模型的重要性评分

综合都小于 ABI 变量，但是 NWP 变量在 3CBA 当中的贡献大于在 2CBA 模型中的贡献。相比于 3CBA 模型，尽管 2CBA 在重要性排名前 25 的预报因子中含有更多的 NWP 变量，但是排名前两位的变量重要性合计超过了 0.35，远超过其余变量。这说明了尽管两种模型都更多地依赖 ABI 观测超过 NWP，2CBA 模型的预测结果更加依赖来自 ABI 的窗区亮温与 6.2/9.6 μm 通道间的观测差异。Mecikalski 等 (2015) 的研究曾经发现，在基于卫星观测的 CI 预报模型中引入数值模式预报的大气环境条件信息能够减少虚警率。在本研究的模型中，NWP 变量特征重要性更高的 3CBA 数据也表现出了相对 2CBA 较小的虚警率，但同时也牺牲了一部分命中率。

表 5.7 随机森林训练得到的模型 3CBA 和 2CBA 的预报因子重要性评分排名情况。

Table 5.7 Importance scores and rankings of the top ranked predictor variables of RF models 3CBA and 2CBA

模型	变量类别	变量名及评分	排名	变量名及评分	排名	类别总分
ABI		dBT(6.2-10.3)max = 0.0346	1	dBT(13.3-10.3)max = 0.0285	6	0.610
		dBT(7.3-10.3)max = 0.0327	2	BT(10.3)mean = 0.0210	7	
		dBT(6.9-10.3)max = 0.0319	3	Area = 0.0175	9	
		dBT(9.6-10.3)max = 0.0309	4	dBT(11.2-12.3)min = 0.0174	10	
		BT(10.3)min = 0.0292	5	dBT(7.3-10.3)mean = 0.0170	11	
3CBA		K-index max = 0.0178	8	DIV (925) min = 0.0128	25	0.390
		MR (850) max = 0.0156	15	LI min = 0.0109	28	
	GFS	DIV (10m) min = 0.0150	18	CIN max = 0.0107	31	
NWP		Øse (850) max = 0.0131	23	TPW max = 0.0104	34	0.390
		K-index mean = 0.0129	24	Øse (850) mean = 0.0104	36	

续表 5.7

模型	变量	变量名及评分	排名	变量名及评分	排名	类别	总分
ABI		dBT(6.2-10.3)max = 0.1804	1	dBT(6.9-10.3)max = 0.0291	7	0.721	
		dBT(9.6-10.3)max = 0.1706	2	Cooling rate (R2) = 0.0095	12		
		dBT(7.3-10.3)max = 0.0654	3	dBT(3.9-11.2)max = 0.0088	13		
		BT(10.3)min = 0.0607	4	Area = 0.0077	15		
		dBT(13.3-10.3)max = 0.0315	5	dBT(11.2-12.3)min = 0.0071	17		
2CBA		Θse (850) max = 0.0314	6	TPW max = 0.0080	14	0.279	
		K-index max = 0.0221	8	DIV (925) min = 0.0073	16		
	GFS	MR (850) max = 0.0197	9	DIV (10m) mean = 0.0069	18		
	NWP	DIV (10m) min = 0.0166	10	LI min = 0.0068	20		
		CIN max = 0.0124	11	K-index mean = 0.0068	21		

注：表中 ‘dBT(a-b)’ 表示以中心波长 a 和中心波长 b 的红外通道观测亮温之间的差异，NWP 变量后面的数字代表该变量所在的等压面，‘min, max, mean’ 表示目标云覆盖范围内该变量的最小值、最大值和平均值。总分数指的是同一类别所有变量（不限于前 10 变量）重要性评分的累加求和。

5.8 GeoHIS 观测在 SWIPE 模型中的敏感性试验

上一节的研究发现，来自 GFS 的数值预报大气背景场信息在模型中的相对重要性不如 ABI 成像观测，其原因可能存在于两个方面，一方面是高时空分辨率的静止卫星成像观测能够更有利于发现范围较小和快速变化的对流初生信号，另一方面也可能与 NWP 数据对于对流初生时刻的大气环境预报准确度有关。前面几章的研究已经证明了，搭载于静止卫星的高光谱探测仪 (GeoHIS) 能够反演得到高垂直分辨率的大气动力学和热力学特征信息，将能够为 SWIPE 模型提供更为准确的大气背景信息。本研究使用 ERA5 再分析数据的大气动力学与热力学廓线，作为未来全球覆盖的高分辨率高质量静止卫星高光谱大气探测数据的代用资料，模拟评估了 GeoHIS 在对流初生短临预报模型 SWIPE 中的潜在效用。表

5.8 所示的是在常规的 SWIPE 模型中预报因子中加入的 ERA5 动力学和热力学信息，其中包括了对流层内高垂直分辨率的动力学与热力学信息，以及与对流触发关系密切的大气稳定度指数等变量信息。

表 5.8 由 ERA5 作为代用数据的静止卫星高光谱大气探测产品预测因子

Table 5.8 Predictor variables from ERA5 as proxy of sounding products from geostationary hyperspectral sounder

变量类型	变量	描述
Thermodynamics	Temperature	200 至 1000hPa 的大气
	Water Vapor Mixing Ratio	廓线
	Relative Humidity	
	Surface Temperature	地面信息
	TPW (Total Precipitable Water)	大气可降水量和不稳定
	LI (Lifted Index)	条件信息
	CAPE (Convection Available Potential Energy)	
Dynamics	CIN (Convective Inhibition)	
	U-wind component	200 至 1000hPa 的大气
	V-wind component	廓线
	DIV (Divergence)	
	PV (Potential Vorticity)	

本研究通过将预报因子中加入以 ERA5 作为代用的 GeoHIS 观测变量的试验结果与原有的 SWIPE 模型预测结果相对比，评估了 GeoHIS 在对流预警模型中的潜在影响。与此同时，也通过进行一组仅使用 ABI 观测的对比试验，分析了来自 GFS 的数值预报场对于 SWIPE 模型预测效果的影响。通过将 GeoHIS 对当前的 SWIPE 模型预测效果的改进与 NWP 大气背景场在 SWIPE 模型中的相对贡献相比较，能够更直观地体现 GeoHIS 观测的大气温湿度信息在对流天气的短临预报上的相对贡献。表 5.9 所示的即是各组试验的设置情况，其中“2C”和“3C”

分别代表二分类和三分类模型，“A”代表该试验的预报因子中有且仅有 ABI，“AN”代表该试验预报因子构成为 ABI+NWP，“ANS”代表该试验预报因子构成为 ABI+NWP+GeoHIS。所有试验的训练和参数优化过程与本文 5.4 节中所介绍的相一致，且用于模型训练的训练样本以及用于模型效果评估的独立测试样本也各自来源于相应的同数据集。

表 5.9 通过机器学习框架评估卫星观测在对流预警中影响的试验设置

Table 5.9 Experiments settings to evaluate the satellite measurements on storm warning via a ML framework

试验名	分类方式	采样方式	GEO-Imager (ABI)	NWP (GFS)	GEO-sounder (ERA5 as proxy)
3CA	Triple	Balanced	✓	×	×
3CAN	Triple	Balanced	✓	✓	×
3CANS	Triple	Balanced	✓	✓	✓
2CA	Double	Balanced	✓	×	×
2CAN	Double	Balanced	✓	✓	×
2CANS	Double	Balanced	✓	✓	✓

5.9 GeoHIS 观测在 SWIPE 对流预警中的潜在贡献

表 5.10 所示的是各试验得到的模型在相同的独立测试数据集上的统计检验结果，对比了不同模型在强对流样本预测中的命中率 (POD)、虚警率 (FAR) 和关键成功指数 (CSI)。能够看到，通过在单纯由 ABI 观测的短临模型中加入 GFS 数值预报的大气背景信息，能够对于不同分类模型在强对流样本的 POD 带来显著提高，包括从 3CA 的 0.56 提高到 3CAN 的 0.63，以及从 2CA 的 0.84 提高到 2CAN 的 0.90。进一步在模型中加入 GeoHIS 观测信息，也能够看到一定的 POD 提升，包括从 3CAN 的 0.63 提高到 3CANS 的 0.67，以及从 2CAN 的 0.90 提高到 2CANS 的 0.91。由于 GFS 的数值预报场已经提供了对大气动力和热

力学条件的基本预测信息，因而 GeoHIS 所带来的改进幅度显得不如前者那样显著。在仅有 ABI 观测数据的模型中加入数值预报信息，其体现的大气垂直环境信息从无到有的变化，而作为 GeoHIS 代用资料的 ERA5 数据的改进效果则在一定程度上体现了实际大气探测信息对于这些环境预报信息的改进与修正作用。这些体现在检验结果上的提升证明了 GeoHIS 观测在提高 SWIPE 模型的强对流预报能力方面的潜在价值。在特征重要性方面，在代表三分类框架的 3CANS 模型中，ABI、GFS 和 GeoHIS 变量各自的重要性评分总和分别为 0.406、0.213 和 0.381，而在二分类的 2CANS 模型中，三者的值分别是 0.583、0.183 和 0.234。GeoHIS 的总评分超过 GFS 揭示了来自静止卫星的高光谱大气探测信息能够提供相比分辨率较粗的 GFS 预报场更为有效的大气环境信息，从而提高对于对流系统的短临预报能力。

表 5.10 不同试验模型在强对流样本中的评估结果以及各自模型中来自 ABI、GFS 和 GeoHIS 变量的重要性评分总和。

Table 5.10 Validation metrics of different experiments on severe classes and the accumulated importance scores from ABI, GFS and GeoHIS variables of the respective models.

试验名	POD	FAR	CSI	重要性评分总和 (ABI/ GFS/ GeoHIS)
3CA	0.56	0.65	0.27	1 / 0 / 0
3CAN	0.63	0.66	0.28	0.610 / 0.390 / 0
3CANS	0.67	0.66	0.29	0.406 / 0.213 / 0.381
2CA	0.86	0.85	0.14	1 / 0 / 0
2CAN	0.90	0.84	0.15	0.721 / 0.279 / 0
2CANS	0.91	0.84	0.16	0.583 / 0.183 / 0.234

为了进一步分析 GeoHIS 观测在强对流预测模型中的改进效果，对于不同试验在不同面积大小的强对流云目标预测中的准确度进行了对比。如图 5.7 所示，

试验中的所有模型都对面积在 5000 km^2 及以上的强对流云具有较好的预报准确度，而对于中等范围和小范围的云目标的准确率则依次递减，这和 5.5 节所得到的结论相一致。通过比较 3CANS 和 3CAN 在不同组别的结果可以看到，在模型中加入 GeoHIS 观测将能够对不同大小的强对流云目标的预测准确度都有提升作用。例如其对于大目标云的 POD 从 0.85 提升到了 0.87，而并未牺牲 FAR，而对中等目标云和小目标云的 POD 提高的同时也降低了 FAR，体现出了 GeoHIS 对于 SWIPE 在强对流目标预报能力上的全面提高。相比于在三分类模型中的影响，GeoHIS 在二分类模型中的改进效果不是那么显著，仅对 1000 km^2 以下的小目标云的 POD 有所提高。这可能是由于二分类模型当中 ABI 的重要性更高而大气背景场的重要性偏低，使得 GeoHIS 带来的改进作用受限。不同类别中最大的改进幅度出现在对三分类模型对中等大小目标云的预测上，其 POD 从 3CAN 的 0.57 增长到 3CANS 的 0.64，与此同时 FAR 也从 3CAN 的 0.70 减小至 3CANS 的 0.68。该现象可以解释为，当在模型中加入 GeoHIS 信息，原本由 NWP 预报因子提供的大气垂直信息精度得到了提高，而相比于面积在 5000 km^2 及以上的大目标云，面积在 1000 至 5000 km^2 的中等目标云由于尺度更小，对于大气环境条件的预测误差敏感性更高，而 GeoHIS 对大气垂直信息的描述能够减小 NWP 产品与真实大气状态之间的误差，从而得到了更好的改进效果。值得一提的是，对于 1000 km^2 以下的小目标云，在仅有 ABI 的模型中引入 GFS 所带来的改进相对中等目标云和大目标云更为显著，而在此之上引入 GeoHIS 所带来的相对改进幅度则小于 GFS 所带来的改进。这种现象可能与作为 GeoHIS 代用数据的 ERA5 数据分辨率有关，由于 ERA5 再分析产品的原始水平分辨率为 31 km ，尽管高于 GFS 数值预报场的 50 km 分辨率，但是该分辨率仅仅与小目标云类别中最大目标样本的尺度（约 33 km ）相当，使得无论 ERA5 还是 GFS 都无法很好地呈现小尺度目标云的详细特征。与此同时，从本质上来说，ERA5 与 GFS 均为数值预报场，且相互之间存在信息上的重叠，导致在 GFS 预报场上叠加 ERA5 的改进有限。想要进一步提高对于小尺度的对流系统的短临预报能力将需要同时具备高垂直分辨率和高水平分辨率的大其探测产品，以求达到对于大气动力学和热力学特征更为准确的观测和表征。以欧洲 MTG (Meteosat Third Generation) 卫星将要搭载的 IRS (InfraRed Sounder) 为代表的新一代静止卫星高光谱探测仪的水平分辨率达

到了 4 km，这些观测仪器投入使用之后将会进一步提高中小尺度强风暴的短临预报水平。




图 5.7 各试验得到的模型对于独立检验测试集中不同大小的强对流目标云样本预报中统计得到的 POD、FAR 和 CSI。(a) 面积不小于 5000 km^2 的大目标云；(b) 面积在 1000

至 5000 km² 之间的中等目标云；(c) 面积在 1000 km² 以内的小目标云。各试验的详细说明请参见表 5.9。

Figure 5.7 POD, FAR, and CSI scores for the severe cases with (a) large samples with area no less than 5000 km², (b) medium samples with area between 1000 and 5000 km², and (c) small samples with area less than 1000 km², calculated from results on validation dataset from trained RF models for each experiment. Refer to Table 5.9 for the details of each experiment.

5.10 本章小结

本研究利用 ABI 在美国 CONUS 区域的高频次观测结合 GFS 数值预报产品，在 Liu Z 等 (2019) 开发的 SWIPE V1 版本的基础之上，通过改进目标追踪和匹配算法结合 CMORPH 降水分析数据，利用随机森林模型建立了改进版的基于卫星观测和数值预报产品的对流初生短临预报模型 SWIPE V2。本研究对 SWIPE 模型的改进主要体现在以下两个方面：(1) 通过引入光流法得到目标云移动路径的估测，再利用估测的目标位置取代原目标云的位置，与实际观测的对流云进行匹配，使模型对于目标云的追踪和对应的降水匹配更加符合真实情况，从而减小系统性的误差；(2) 在每个目标云的对流强度判定方面，将原有在单一降水分析时次的匹配，改进为匹配后续连续三个降水分析时次的降水强度中的最大值，使数据集的对流强度标签更能代表该系统在其生命史的实际最大强度。

利用改进后的追踪与匹配算法，对 2018 年 3 到 10 月 CONUS 区域的对流初生样本进行了识别和预测，并在不同的训练情景下分析了其对不同类型对流云目标的预报效果，并利用 ERA5 再分析数据的温湿廓线产品，对静止卫星高光谱探测数据在对流初生短临预报准确度的影响进行了模拟研究，并讨论了其在不同训练框架，对于不同大小的对流目标的预报改进和影响。研究得到的主要结论如下：

(1) SWIPE 模型对于识别时刻面积在 5000 km² 及以上的对流样本表现比小面积对流样本更高的准确性，其中训练数据经过样本平衡处理的二分类模型 (2CBA) 对于此类样本的 POD 为各模型中最高，而三分类样本平衡模型 (3CBA) 则在具有较高的 POD 同时保证相对较低的 FAR。对于面积在 5000 km² 以内的对

流样本,各模型的准确度相比大面积样本都显著下降,其中二分类平衡模型相对更为实用,尽管其 FAR 较高,但能够保持较高的 POD,而其他模型的 POD 都出现了显著的降低,其中在训练中未经样本平衡处理的模型(2CUB 和 3CUB)对于面积在 1000 km^2 的对流目标的 POD 极低,不具备预报能力。因而在实际应用中,考虑将 2CBA 和 3CBA 同时运行,利用二者对强对流的预警结果进行集合预报,给出两个不同等级的强对流预警信号。

(2) 改进后的 SWIPE 模型针对 2019 年 8 月的两个实际对流个例进行了成功的识别和短临预警。对于 8 月 1 日和 8 月 7 日的两个对流个例,模型能够在对流发生前捕捉实现对目标云的识别,并分别在降水强度首次达到 7.6 mm/h 的时间提前一个小时以上实现强对流预警,比实际最大降水强度发生时刻提前了超过两个小时。

(3) 通过对模型中各预报因子的重要性评分(IS)进行分析发现,来自 ABI 观测的变量的 IS 总和高于 GFS 数值预报变量。其中重要性排名最高的单一变量为 ABI 观测的 $6.2 \mu\text{m}$ 通道亮温和 $10.3 \mu\text{m}$ 通道亮温之差在目标云范围内的最大值。在数值预报变量中,与大气稳定性和水汽含量有关的预报因子排名相对靠前。对比不同模型发现,对强对流样本有更高 POD 的 2CBA 模型相比 3CBA 模型的 ABI 变量重要性更高,而数值预报变量重要性更高的 3CBA 模型的 FAR 相对较低。

(4) 利用 ERA5 的大气廓线信息对于 GeoHIS 观测在短临预报上的潜在效用进行评估,发现其改进效果体现在 POD 的提升超过了对 FAR 的降低,并且在数值预报因子具有更高重要性的三分类模型中对预报结果有更明显的改进。预报因子重要性评分的对比发现,GeoHIS 大气探测数据在短临模型中的重要性评分超过了现有的数值预报变量,意味着其能够提供比当前的 GFS 预报场更有效的对流前大气环境信息,并改进对流预警准确度。

(5) 通过敏感性试验发现,在仅采用 ABI 观测作为预报因子的模型中加入 GFS 数值预报场,以及在此基础上加入用 ERA5 作为代用数据的 GeoHIS 信息,都能够对模型的准确性带来提升,两者的改进幅度在面积大于 5000 km^2 的大对流样本和面积在 1000 至 5000 km^2 的中等对流样本上体现得基本相当。对于 1000 km^2 以内的对流样本,在 SWIPE 模型中加入 GeoHIS 信息的相对改进效果不如

GFS 数值预报信息带来的改进效果那样显著。这很大程度上是由于模型中添加的 ERA5 廓线的水平分辨率与对流样本的尺度相当,因而对于中小尺度大气环境的代表性有限。未来即将投入应用的,具备更高水平分辨率的静止轨道高光谱观测设备将有机会对中小尺度对流系统的短临预报带来更大的提升。

第6章 总结与展望

6.1 全文总结

搭载于极轨气象卫星上的红外高光谱大气探测仪与搭载于静止气象卫星上的高分辨率成像仪是气象卫星观测地球大气的两种重要手段。其中前者能够提供高垂直分辨率的大气温湿廓线,提供大气垂直结构与稳定度状态,但是观测频次低,无法对同一区域的大气变化信息进行连续观测;而后者通过高时间分辨率的连续观测,能够捕捉局地大气状态的快速变化信息,但是由于光谱分辨率有限而缺乏对大气垂直结构的观测。因此,将两种观测手段的优势加以联合应用,将有助于实现对三维大气动力和热力信息的高频次观测,进而对数值天气预报和高影响天气的短临预警提供更大的促进作用。搭载于风云四号 A 星的 GIIRS 是国际上首个搭载于静止轨道气象卫星的红外高光谱大气探测仪,兼具高光谱分辨率与高时间分辨率的优势,能够提供高时空分辨率的三维大气观测信息。本研究首先利用传统的极轨卫星高光谱反演产品,与静止卫星成像观测相融合,开发了能够融合两者优势的联合反演算法,并利用国际上首个静止卫星高光谱红外探测仪 GIIRS 的实际观测数据训练了大气热力学和动力学廓线的定量反演算法,最后利用 ERA5 的大气廓线作为代用数据讨论了静止轨道高光谱大气探测在对流初生短临预报中的潜在效用。研究内容和结果总结如下:

(一) 极轨卫星高光谱探测与静止卫星成像观测的联合反演应用。

本研究通过将美国 CONUS 区域在 2018 年 4~6 月的极轨高光谱反演产品 NUCAPS,与静止轨道成像仪 ABI 以及地面中尺度实时分析场 RTMA,通过一个多层神经网络模型进行数据融合,以 ERA5 温湿廓线作为真值进行训练,得到了一个能够在晴空和部分有云的条件下改进 NUCAPS 低层大气温湿廓线准确度的大气反演改进模型,并利用独立检验数据集与无线电探空观测对模型效果进行了检验评估,结果显示:

(1) 基于神经网络的数据融合模型在晴空和部分有云的视场条件下,能够显著降低 700 hPa 及以下层次温湿度相对于作为真值的 ERA5 之间的 Bias 和 STDE,改进了低层大气温湿廓线的反演精度。其中在晴空条件下,700 hPa 以下低层大

气反演的平均温度方差减小了 68.1%，相对湿度方差减小了 65.9%。而在部分有云的视场条件下，温度平均方差减小了 58.1%，相对湿度平均方差减小了 65.5%。

(2) 针对不同数据源的敏感性试验表明，ABI 和 RTMA 均对反演准确度的提升具有贡献。在晴空条件下，ABI 的引入减小了 700 hPa 及以下低层大气温度平均方差的 7.2% 和相对湿度平均方差的 10.2%，而在有云条件下二者的值分别为 7.1% 和 8.6%。RTMA 在晴空区域对低层温度和湿度的平均方差减小了 5.5% 和 3.9%，而在部分有云条件下二者的值分别为 10.9% 和 8.4%。相比于晴空区域，在影响范围上，ABI 能够改进整个对流层区域，而 RTMA 仅对于对流层低层有影响。通过对不同 ABI 通道的改进效果进行敏感性试验，发现在本研究选取的 7 个 ABI 通道中，CO₂ 通道与窗区通道主要贡献于温度和低层水汽信息的反演，而水汽通道则主要影响 800 hPa 以上高度的湿度反演。

(3) 通过 2017 和 2018 年每年 4~6 月与 NUCAPS 观测时空匹配的探空观测数据对模型在低层大气的廓线反演改进能力进行了评估。证实了以 ERA5 作为真值训练的数据融合模型在低层大气的改进能力是稳定而可靠的。具体的评估结果受到 NUCAPS 与探空观测的时间间隔的影响，模型对低层大气反演的改进能力在越小的时间间隔上表现得越为明显。

(5) 通过将数据融合反演模型应用到实际对流环境的预报中，发现联合反演模型的结果相比于原本的 NUCAPS 大气廓线产品，能够通过更好地表征低层大气的温湿特性，得到更为准确的 SBCAPE 和 LI 等指数信息，从而更好地反映低层大气的不稳定条件，将有助于提升高影响天气环境预报的准确性。

(二) 基于静止卫星高光谱探测的大气温湿廓线反演。

风云四号 A 星搭载的 GIIRS 作为国际上第一个静止轨道高光谱大气探测仪，既拥有高光谱探测仪在大气反演中所具备的高垂直分辨率，又具备静止卫星对同一区域连续观测的优势，其拥有 689 个长波红外通道和 961 个中波红外通道，能够用于反演大气温度和湿度垂直廓线。本研究利用 GIIRS 在 2018 年 7 月台风“玛利亚”登陆期间的 15 分钟分辨率高频次区域观测资料，通过权重函数峰值法结合改进的信息熵迭代法，选择出了对于大气不同层次温度和湿度具有代表性

的长波和中波红外通道，并分别使用长波和中波通道的观测亮温，以再分析资料 ERA5 的温湿廓线作为训练真值，通过神经网络分别训练了 GIIRS 在局地范围内的温度和湿度定量反演模型，并讨论了 GIIRS 观测的时间变化信息对大气廓线定量反演准确度的影响。具体发现包括：

(1) 利用 GIIRS 高光谱大气探测与神经网络相结合，能够得到较高准确度的温湿廓线反演。独立检验结果表明，温度反演在 100 至 1000 hPa 的总体 RMSE 为 0.639 K，平均偏差为 0.092 K。而相对湿度在 300 hPa 及以下层次的平均 RMSE 为 5.089 %，平均偏差为 0.004 %，但在 300 hPa 以上的对流层高层误差显著增大。

(2) 利用独立分析数据 GDAS 对反演模型的检验结果表明，模型相对 GDAS 的反演误差大于其相对 ERA5 的误差，而分析表明误差主要来源于 GDAS 与 ERA5 之间的差异，说明了反演结果与训练真值的选择有关。与此同时，反演模型相对 GDAS 的反演误差仍在合理范围，表现出反演模型算法具备一定的稳定性。

(3) 与探空观测个例的对比发现，GIIRS 反演的温度场能够较好地呈现与探空相一致的温度廓线，仅存在由于以 ERA5 作为训练真值所导致的垂直分辨率不足的问题。在相对湿度的反演上，GIIRS 反演结果能够表现出对流层中低层的湿度结构，但是对于对流层中高层的湿度变化特征则表现不足。

(4) 通过在预报因子中加入目标视场前一时刻的观测信息，将高光谱探测的时间变化信息加入训练，相比于仅使用单一时刻观测的反演结果，模型在温度和相对湿度的反演精度都有所提升。其中温度反演的改进比相对湿度更为显著，温度和湿度都在低层大气的改进幅度较大。尽管该试验由于样本代表性的限制而存在一定的局限性，但是为后续充分发挥 GIIRS 特有的高时间分辨率的应用价值提供了新的思路和方法。

(三) 基于静止卫星高光谱探测的四维大气水平风场反演。

由于 GIIRS 兼具高垂直分辨率与高时间分辨率的特点，使得对于四维风场的反演成为可能。本研究利用 GIIRS 在 2018 年 7 月台风“玛利亚”期间的 15 分钟分辨率区域加密观测资料，选择对不同层次的温度和湿度具有代表性的特征通道，

结合 ERA5 再分析资料的 U、V 风场信息，通过神经网络训练了能够通过 GIIRS 高频次观测的亮温信息及其时空变化特征实时定量反演三维大气水平风场的回归模型，并利用 ERA5 独立检验数据集、GDAS 分析场以及下投探空观测对于模型的反演效果进行了检验评估，并与传统的基于“追踪+定高”的 AMV 产品进行了对比分析，结果显示：

(1) 高时间分辨率的 GIIRS 观测可以定量反演得到四维风场信息，独立检验集的验证结果表明，GIIRS 反演的 U、V 风分量在晴空和部分有云的条件下，在对流层各等压面相对 ERA5 的 RMSE 都在 2 m/s 以内。通过将风场反演产品相对 ERA5 的准确度与 GFS 的数值预报场相比较，发现 GIIRS 反演风场能够对数值预报产品有潜在的改进作用。

(2) 本研究的反演算法在晴空和非厚云覆盖的视场有较好的准确性和应用价值，而对于厚云覆盖的情况，由于云下信息的减少，其反演应用仍需要进一步的研究。研究的最终目标是在保持合理的准确性的前提下，尽可能拓展其可用范围。

(3) 反演得到的四维风场产品能够表现出与 ERA5 较为接近的时间变化信息，证实了静止卫星红外高光谱大气探测对于大气动力学特征的反演能力。

(4) 通过敏感性试验发现，相比于较低的时间分辨率，高时间分辨率的静止轨道高光谱大气探测能够通过对于瞬时的水汽移动和分布情况的更为精确的表述，反演得到更为准确的风廓线信息。通过引入与目标视场相邻的视场观测及时间变化情况而获取的空间变化特征也对于风廓线反演的准确度起着重要的作用。

(5) 通过将本研究的风场反演产品与来自 AHI 的 AMV 产品进行比较，发现尽管高空间分辨率的 AMV 产品在低层大气也有相对 ERA5 较高的准确性，GIIRS 的反演结果无论在准确性和三维空间分布的密度上都体现出了相对 AMV 的优势。然而，当前的对比分析存在一定的局限性，仍需要更长时间和更大范围的对比分析来对于两种风场产品的质量进行更为全面的对比评估。

(四) 静止卫星高光谱探测与成像观测相结合的短临预报应用。

在通过定量反演研究证实了静止卫星高光谱大气探测对于三维大气动力学和热力学信息的表征能力之后，将其与高时空分辨率的静止卫星成像观测相结合，

讨论了其在对流初生短临预报中的潜在效用。研究基于卫星气象中心曾经开发的基于静止卫星成像观测与数值预报场相结合的对流初生短临预报模型 SWIPE, 对其现有的不足进行了改进, 并利用 ABI 在美国 CONUS 区域的 5 分钟高频观测, 结合 CMORPH 降水分析数据, 根据美国 AMS 的降水强度分类标准, 结合随机森林模型发展了针对美国 CONUS 区域的以最大降水强度为标准的对流初生短临预报模型 SWIPE V2, 并用实际的对流个例进行了验证。利用 ERA5 的大气动力学和热力学廓线产品模拟静止卫星高光谱探测数据, 在改进后的 SWIPE V2 模型基础上, 针对不同范围大小的对流样本结合不同的训练情景, 讨论了静止卫星高光谱大气探测在对流初生短临预报和预警中的潜在作用。研究结果表明:

(1) 利用 ABI 高分辨率观测结合 GFS 数值预报场的 SWIPE 模型对于识别时刻面积在 5000 km^2 及以上的强对流样本表现出相对小面积样本更高的准确性, 其中训练数据经过样本平衡处理的模型相对于利用原始样本分布的模型表现出对于强对流样本更好的捕捉和预测能力。对于面积在 5000 km^2 以内的强对流样本, 利用二分类框架结合样本平衡处理的模型仍然具有一定的预测命中率(POD), 但是虚警率(FAR)大幅提升。

(2) 通过对模型中各预报因子的重要性评分排名, 发现来自 ABI 观测的预报因子重要性总分显著高于 GFS 的数值预报因子, 其中重要性评分最高的预报因子是 ABI 观测的 $6.2 \mu\text{m}$ 与 $10.3 \mu\text{m}$ 通道亮温差在目标云范围内的最大值, 其余排名靠前的预报因子包括来自 ABI 的 $6.9/7.3/9.6 \mu\text{m}$ 通道与窗区 $10.3 \mu\text{m}$ 通道的亮温差。在数值预报变量中, 与大气稳定性和水汽含量有关的预报因子排名相对靠前。

(3) 利用 ERA5 的大气廓线信息对于静止卫星高光谱探测资料在短临预报上的潜在效用进行评估, 发现在不同的训练情景下, 模型对强对流样本的预测准确性都有不同程度的提高, 并且在数值预报因子具有更高重要性的三分类模型中对预报结果有更明显的改进。通过对预报因子重要性评分的对比发现, 静止卫星高光谱大气探测数据在短临模型中的重要性评分总和超过了现有的数值预报变量, 意味着其能够提供比当前的 GFS 预报场更有效的对流前大气环境信息, 并改进对流预警准确度。

(4) 通过对 GFS 数值预报场与静止卫星高光谱大气探测在 SWIPE 模型中

的敏感性试验发现, 在仅采用 ABI 观测作为预报因子的模型中加入 GFS 数值预报场, 以及在此基础上加入用 ERA5 廓线模拟的静止卫星高光谱大气探测资料, 都能够对模型的准确性带来提升, 两者的改进幅度在面积大于 5000 km^2 的较大对流样本和面积在 1000 至 5000 km^2 的中等对流样本上体现得基本相当。对于 1000 km^2 以内的对流样本, 在 SWIPE 模型中加入 GeoHIS 信息的相对改进效果不如 GFS 数值预报信息带来的改进效果那样显著。这很大程度上是由于模型中添加的 ERA5 廓线的水平分辨率与对流样本的尺度相当, 不足以捕捉尺度较小的大气动力学和热力学变化, 因而对于中小尺度大气环境的代表性有限。未来即将投入应用的, 具备更高水平分辨率的静止轨道高光谱观测仪器将有机会对中小尺度对流系统的短临预报带来更大的提升。

6.2 未来展望

卫星红外高光谱大气探测的定量应用一直是卫星气象学、数值预报以及天气学研究上的重要课题。传统的极轨卫星高光谱探测资料能够提供覆盖全球范围的大气垂直探测信息, 弥补了地面探空数据在高原、山地、海洋等下垫面条件下的观测不足。但是由于极轨卫星在中低纬度地区的观测频次较低, 能够实现局地高频次连续观测的静止卫星高光谱探测资料对于快速变化的中小尺度天气系统的监测以及区域数值模式的快速循环同化应用具有重要的价值。尽管本研究利用实际观测资料与再分析资料, 取得了一些定量反演和预报应用的研究结果, 但仍存在一些不足之处需要在未来的研究工作中进一步发展和完善, 主要包括:

(1) 研究中大量用到了神经网络等机器学习算法来训练模型, 模型的准确性和适用性很大程度上依赖于所用到的训练数据的科学性与代表性。对于 NUCAPS 与 ABI 的联合反演, 研究中已经使用不同年份的数据进行了泛化性检验, 但是对于其他区域和季节的适用性仍有待于通过更有代表性的数据来进行进一步的探究。此外, 随着卫星遥感器性能的改变, 如针对来自最新的 NOAA-20 极轨卫星观测的 NUCAPS 3.0 版本产品, 本文反演方法的适用性也需要进一步验证。除此之外, 作为多源数据融合的反演改进模型, 通过将来自数值预报场的大气廓线信息加入预报因子当中, 并分析其对反演结果的影响和贡献也是一个值得后续研究的工作。

(2) 对于研究中利用 GIIRS 观测所做的热力学和动力学定量反演研究, 所用资料是 GIIRS 于台风“玛利亚”期间在局地范围内的加密观测, 尽管在划分的独立检验集上取得了良好的效果, 但在更长时段和更大范围的角度上仍缺乏代表性。考虑到 GIIRS 在中波红外波段的光谱和辐射定标仍存在着不确定性, 而本文通过有限数据集结合机器学习训练的模型在反演精度上会存在一定的高估, 因而这些算法在 2 小时分辨率的 GIIRS 全区域常规观测中的适用性仍有待研究。然而, 由于到目前为止, GIIRS 的 15 分钟时间分辨率的资料仅在台风“玛利亚”的加密观测期间可以获得, 研究中有关时间变化信息的研究结论在未来风云四号 B 星的 GIIRS 定标精度进一步提高, 且得到更多高频次观测资料的条件下仍需要进一步的验证和优化。

(3) 对于搭载于同一平台上的高光谱探测仪 GIIRS 与成像仪 AGRI, 本研究中尚未发展二者的联合反演模型。根据研究中利用 NUCAPS 和 ABI 联合反演的成功经验, 通过将二者的观测信息进行时空匹配, 在模型中引入时空分辨率更高的 AGRI 水汽及红外多通道观测信息作为预测因子, 将可能有助于改善研究中体现的 GIIRS 在低层大气的温度反演和中高层湿度反演存在的不确定性。

(4) 研究中对于 GIIRS 视场晴空条件的判断较为粗糙, 仅采用了 $11\ \mu\text{m}$ 附近的 15 个通道观测的平均亮温进行了简单的判识。在未来的研究中, 应充分利用搭载于同一平台上的 AGRI 的云检测产品, 将 GIIRS 视场与范围内的 AGRI 观测像元进行时空匹配, 获得更为精确的云覆盖信息, 并应用到部分有云条件下的大气温湿廓线和风场反演当中。同时, 对于密实云区覆盖的视场, 也可以与 AGRI 的云顶气压产品相结合, 对于云上部分层次的动力和热力信息进行反演, 进一步增加 GIIRS 观测资料在空间上的可用范围。

(5) 在四维风场的反演中, 由于 GIIRS 视场的空间分辨率 $16\ \text{km}$, 对于中小尺度的环流特征而言过于粗糙, 无论采用何种反演方法, 这一分辨率在需要利用空间变化特征的风场反演与应用当中都是不利元素。随着风云四号 B 星的 GIIRS 水平分辨率提高到 $12\ \text{km}$, 以及欧洲将要在 2024 年发射的 MTG 卫星所搭载的将有 $4\ \text{km}$ 分辨率的静止卫星高光谱探测仪 IRS, 将有助于利用更为复杂的算法如卷积神经网络 (CNN) 等进行风场反演(Holmlund 等., 2021), 进而有机会获得更为准确的四维水平风场。除此之外, 本研究中仅采用了两个时刻的观测信息作

为输入,在未来拥有更多高频次观测资料的条件下,将尝试输入更多时刻的观测资料,以得到精度更高的四维水平风场。

(6) 本研究中训练的基于静止卫星观测的对流初生预报模型仅考虑了最大降水强度作为对流强度的标签,而没有考虑其他不产生强降水,但仍然产生例如冰雹和大风等高影响天气的对流系统。因此,该模型仅对于与强降水相关的对流初生预警更为有效,而对于其他类型的对流系统则可能产生预报误差。后续的研究可以结合历史天气报告,对于冰雹、大风以及龙卷等灾害性天气进行分类的训练和分析。

(7) 对于静止卫星高光谱探测在短临模型中的影响分析上存在着几个局限性。一方面来说,以 ERA5 廓线直接作为高光谱观测产品的代用数据,忽略了在实时大气廓线反演中的误差,从而产生了对其相对影响的高估;在另一方面,水平分辨率 31 km, 逐小时的 ERA5 数据在空间和时间分辨率上过于粗糙,使用该数据又在一定程度上低估了未来高时空分辨率探测仪器对于中小尺度对流预报所能带来的潜在效用。由于高光谱探测仪的时空分辨率对于其捕捉大气状态变化的能力具有重要影响(Di 等., 2021), 在未来更高时空分辨率的观测资料投入使用之后,将用实际观测的辐射或亮温光谱信息取代大气廓线加入到 SWIPE 模型进行了评估和预报应用。

参考文献

- 鲍艳松, 汪自军, 陈强, 等. FY-4A 星 GIIRS 大气温度廓线反演模拟试验研究[J]. 上海航天, 2017, 34(4): 28 - 37.
- 董超华, 李俊, 张鹏. 卫星高光谱红外大气遥感原理和应用[M]. 北京: 科学出版社. 2013
- 董佩明, 薛纪善, 黄兵, 等. 数值天气预报中卫星资料同化应用现状和发展[J]. 气象科技, 2008, 36(1): 1-7.
- 董瑶海. 风云四号气象卫星及其应用展望[J]. 上海航天, 2016, 33(2): 1-8.
- 方翔, 许健民, 张其松. 高密度云导风资料所揭示的发展和不对称热带气旋的对流层上部环流特征[J]. 热带气象学报, 2000, 16(3): 218 - 224.
- 方宗义, 许健民, 赵凤生. 中国气象卫星和卫星气象研究的回顾和发展[J]. 气象学报, 2004, 62(5): 550 - 560.
- 冯绚, 李利兵, 陈博洋, 等. 风云四号 A 星干涉式大气垂直探测仪在轨定标及性能评价[J]. 红外与毫米波学报, 2019, 38(5): 648 - 654.
- 官莉. 利用 AIRS 卫星资料反演大气廓线 I. 特征向量统计反演法[J]. 南京气象学院学报, 2006, 29(6): 756 - 761.
- 侯青, 许健民. 卫星导风资料所揭示的对流层上部环流形势与我国夏季主要雨带之间的关系[J]. 应用气象学报, 2006, 17(2): 138 - 144.
- 黄亦鹏, 李万彪, 赵玉春, 等. 基于雷达与卫星的对流触发观测研究和临近预报技术进展[J]. 地球科学进展, 2019, 34(12): 1273.
- 黄艺伟, 陈淑仪, 何敏, 等. 我国台风高发期东海和南海海区 GIIRS/FY-4A 温度反演廓线精度研究[J]. 热带气象学报, 2021, 37(2): 277 - 288.
- 黄艺伟, 刘琼, 何敏, 等. 基于探空资料的上海台风季 GIIRS/FY-4A 卫星温度廓线反演精度研究[J]. 红外, 2019, 40(9): 28 - 38.
- 蒋德明, 曹思沁, 屈佑铭. 利用神经网络方法从高光谱分辨率红外遥感资料反演大气温度廓线[J]. 热带气象学报, 2010, 26(6): 819 - 824.
- 蒋尚城. 应用卫星气象学[M]. 北京: 北京大学出版社. 2006
- 李俊, 方宗义. 卫星气象的发展——机遇与挑战[J]. 气象, 2012, 38(2): 129 - 146.
- 李俊, 曾庆存. 晴空时大气红外遥感及其反演问题 I. 理论研究[J]. 大气科学, 1997, 21(1):

1 - 9.

- 刘启汉, 陈受钧. 梅雨锋云带内 α -中尺度对流系统周边水汽风的分析[J]. 气象学报, 2004, 62(2): 237 - 242.
- 刘瑞, 翟国庆, 王彰贵, 等. FY-2C 云迹风资料同化应用对台风预报的影响试验研究[J]. 大气科学, 2012, 36(2): 350 - 360.
- 刘正光, 喻远飞, 吴冰, 等. 利用云导风矢量的台风中心自动定位[J]. 气象学报, 2003, 61(5): 636 - 640.
- 卢乃锰, 谷松岩. 气象卫星发展回顾与展望[J]. 遥感学报, 2016, 20(5): 832 - 841.
- 罗双, 狄迪, 崔林丽. 基于信息容量的 FY-4A/GIIRS 红外光谱探测能力研究[J]. 红外与毫米波学报, 2019, 38(6): 765 - 776.
- 孟智勇, 张福青, 罗德海, 等. 新中国成立 70 年来的中国大气科学研究: 天气篇[J]. 中国科学:地球科学, 2019, 49(12): 1875 - 1918.
- 漆成莉, 顾明剑, 胡秀清. 风云三号卫星红外高光谱探测技术及潜在应用[J]. 气象科技进展, 2016, 6(1): 88 - 93.
- 谭永强, 费建芳. 支持向量机方法反演温湿廓线[J]. 解放军理工大学学报: 自然科学版, 2010, 11(6): 676 - 680.
- 王栋梁, 梁旭东, 端义宏. 云迹风在热带气旋路径数值预报中的应用研究[J]. 气象学报, 2005, 63(3): 351 - 358.
- 王萍, 宋振龙, 孔秀梅, 等. 基于云导风场的形成期台风定位[J]. 模式识别与人工智能, 2005, 18(6): 752 - 757.
- 王新, 唐世浩, 魏彩英. 风云气象卫星天气应用回顾和展望[J]. 科技导报, 2021, 39(15): 23 - 30.
- 王振会, 许建明, Kelly, G. 基于傅立叶相位分析的卫星云图导风技术[J]. 气象科学, 2004, 24(1): 9 - 15.
- 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
- 许健民, 杨军, 张志清, 等. 我国气象卫星的发展与应用[J]. 气象, 2010, 36(7): 94 - 100.
- 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.
- 许健民, 张其松, 方翔. 用红外和水汽两个通道的卫星测值指定云迹风的高度[J]. 气象学报, 1997, 55(4): 408 - 417.

- 薛纪善. 气象卫星资料同化的科学问题与前景[J]. 气象学报, 2009, 67(6): 903 - 911.
- 杨军, 董超华, 卢乃锰, 等. 中国新一代极轨气象卫星——风云三号[J]. 气象学报, 2009, 67(4): 501 - 509.
- 姚志刚, 陈洪滨. 利用神经网络从 118.75 GHz 附近通道亮温反演大气温度[J]. 气象科学, 2006, 26(3): 252 - 259.
- 尹若莹. 风云四号高光谱探测资料质量控制与同化应用研究[D]. 中国科学院大学. 2020
- 尹若莹, 韩威, 高志球, 等. 基于 FY-4A 卫星探测区域模式背景误差和观测误差估计的长波红外通道选择研究[J]. 气象学报, 2019, 77(5): 898 - 910.
- 俞小鼎, 郑永光. 中国当代强对流天气研究与业务进展[J]. 气象学报, 2020, 78(3): 391 - 418.
- 曾庆存. 大气红外遥测原理[M]. 北京: 科学出版社. 1974
- 曾庆存. 天气预报——由经验到物理数学理论和超级计算[J]. 物理, 2013, 42(05): 300 - 314.
- 张鹏, 郭强, 陈博洋. 我国风云四号气象卫星与日本 Himawari-8/9 卫星比较分析[J]. 气象科技进展, 2016, 6(1): 72 - 75.
- 张守峰, 王诗文. 在台风业务系统中使用卫星云导风资料的试验[J]. 气象, 1999a, 25(8): 22 - 25.
- 张守峰, 王诗文. 应用卫星云导风进行台风路径预报试验[J]. 热带气象学报, 1999b, 15(4): 347 - 355.
- 张雪慧, 官莉, 王振会, 等. 利用人工神经网络方法反演大气温度廓线[J]. 气象, 2009, 35(11), 137 - 142.
- 周兵, 徐海明, 吴国雄, 等. 云迹风资料同化对暴雨预报影响的数值模拟[J]. 气象学报, 2002, 60(3): 309 - 317.
- 朱平, 王振会, 许建明. TCFM 导风技术介绍及其初步试验研究[J]. 遥感学报, 2007, 11(4): 538 - 544.
- 庄照荣, 薛纪善. 云迹风资料的三维变分同化及对台风预报的影响试验[J]. 热带气象学报, 2004, 20(3): 225 - 236.
- Adkins, J., Alsheimer, F., Ardanuy, P., et al. Geostationary Extended Observations (GeoXO) Hyperspectral InfraRed Sounder Value Assessment Report[J/OL]. NOAA/NESDIS Technical Report, 2021: 103pp.
- Ai, Y., Li, J., Shi, W., et al. Deep convective cloud characterizations from both broadband imager and hyperspectral infrared sounder measurements[J]. Journal of Geophysical Research:

- Atmospheres, 2017, 122(3): 1700–1712.
- Aires F, Chedin A, Scott N A, et al. A regularized neural net approach for retrieval of atmospheric and surface temperatures with the IASI instrument[J]. *Journal of Applied Meteorology and Climatology*, 2002, 41(2): 144-159.
- AMS Glossary. Glossary of Meteorology, American Meteorological Society[ER/OL]. <https://Glossary.Amet Soc.Org/Wiki/Rain>, 2012.
- Anderson, R. K. Application of meteorological satellite data in analysis and forecasting (Vol. 51)[M]. National Oceanic and Atmospheric Administration, 1974.
- Bauer P, Thorpe A, Brunet G. The quiet revolution of numerical weather prediction[J]. *Nature*, 2015, 525(7567): 47-55.
- Bengio, Y. Learning deep architectures for AI[J]. *Foundations and Trends® in Machine Learning*, 2009, 2(1): 1–127.
- Bessho K, Date K, Hayashi M, et al. An introduction to Himawari-8/9—Japan’s new-generation geostationary meteorological satellites[J]. *Journal of the Meteorological Society of Japan. Ser. II*, 2016, 94(2): 151-183.
- Blackwell W J, Milstein A B. A neural network retrieval technique for high-resolution profiling of cloudy atmospheres[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(4): 1260-1270.
- Bloch C, Knuteson R O, Gambacorta A, et al. Near-Real-Time Surface-Based CAPE from Merged Hyperspectral IR Satellite Sounder and Surface Meteorological Station Data[J]. *Journal of Applied Meteorology and Climatology*, 2019, 58(8): 1613-1632. DOI:10.1175/JAMC-D-18-0155.1.
- Blumstein D, Chalon G, Carlier T, et al. IASI instrument: Technical overview and measured performances[C]//*Infrared Spaceborne Remote Sensing XII: Vol. 5543*. SPIE, 2004: 196-207.
- 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.
- Boukabara S A, Krasnopolsky V, Stewart J Q, et al. Leveraging Modern Artificial Intelligence for Remote Sensing and NWP: Benefits and Challenges[J]. *Bulletin of the American Meteorological Society*, 2019, 100(12): ES473-ES491.
- Breiman, L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5–32.

- Cai X, Bao Y, Petropoulos G P, et al. Temperature and Humidity Profile Retrieval from FY4-GIIRS Hyperspectral Data Using Artificial Neural Networks[J]. *Remote Sensing*, 2020, 12(11): 1872.
- Cardinali C. Monitoring the observation impact on the short-range forecast[J]. *Quarterly Journal of the Royal Meteorological Society*, 2009, 135(638): 239-250.
- Chahine, M. T. Inverse problems in radiative transfer: Determination of atmospheric parameters[J]. *Journal of Atmospheric Sciences*, 1970, 27(6): 960–967.
- Chahine M T, Pagano T S, Aumann H H, et al. AIRS: Improving weather forecasting and providing new data on greenhouse gases[J]. *Bulletin of the American Meteorological Society*, 2006, 87(7): 911-926.
- Chen S Y, Liu C Y, Huang C Y, et al. An Analysis Study of FORMOSAT-7/COSMIC-2 Radio Occultation Data in the Troposphere[J]. *Remote Sensing*, 2021, 13(4): 717.
- Clevert D A, Unterthiner T, Hochreiter S. Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs)[J/OL]. arXiv:1511.07289 [cs], 2016, <http://arxiv.org/abs/1511.07289>.
- Dahl G E, Yu D, Deng L, et al. Context-dependent pre-trained deep neural networks for large-vocabulary speech recognition[J]. *IEEE Transactions on audio, speech, and language processing*, 2011, 20(1): 30-42.
- Daniels J, Bresky W. Validation of GOES clear-air water vapor winds[C]//Preprints, 11th Conf. on Satellite Meteorology, Madison, WI, Amer. Meteor. Soc. 2001: 248-251.
- Daniels J, Velden C, Busby W, et al. Status and development of operational GOES wind products[C]//Proc. Fifth International Winds Workshop. 2000: 1023-0414.
- Daniels J, Velden C, Bresky W, et al. Status and development of GOES wind products at NOAA/NESDIS[C]//Proceedings of 6th International Winds Workshop, EUMETSAT. 2002: 71-80.
- De Ponca MSFV, Manikin GS, DiMego G, et al. The Real-Time Mesoscale Analysis at NOAA's National Centers for Environmental Prediction: Current Status and Development[J]. *Weather and Forecasting*, 2011, 26(5): 593–612.
- Di D, Li J, Han W, et al. Enhancing the Fast Radiative Transfer Model for FengYun-4 GIIRS by Using Local Training Profiles[J]. *Journal of Geophysical Research: Atmospheres*, 2018, 123(22): 12-583.
- Di D, Li J, Li Z, et al. Can current hyperspectral infrared sounders capture the small scale

- atmospheric water vapor spatial variations?[J]. *Geophysical Research Letters*, 2021, 48(21): e2021GL095825.
- Di D, Li J, Han W, et al. Geostationary Hyperspectral Infrared Sounder Channel Selection for Capturing Fast-Changing Atmospheric Information[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021. PP(99):1-10.
- Di Paola F, Ricciardelli E, Cimini D, et al. MiRTaW: an algorithm for atmospheric temperature and water vapor profile estimation from ATMS measurements using a random forests technique[J]. *Remote Sensing*, 2018, 10(9): 1398.
- Dirksen R, Sommer M, Immler F, et al. Reference quality upper-air measurements: GRUAN data processing for the Vaisala RS92 radiosonde[J]. *Atmospheric Measurement Techniques*, 2014, 7(12): 4463-4490.
- Dunion J, Velden C. Using the GOES 3.9 μ m shortwave infrared channel to track low-level cloud-drift winds[C]//Proc. Sixth Intl Winds Workshop. Madison, WI, 2002: 277-282.
- Eyre, J. Inversion of cloudy satellite sounding radiances by nonlinear optimal estimation. I: Theory and simulation for TOVS[J]. *Quarterly Journal of the Royal Meteorological Society*, 1989, 115(489): 1001–1026.
- Farneback G. Two-Frame Motion Estimation Based on Polynomial Expansion[G]. BIGUN J, GUSTAVSSON T. *Image Analysis*, Springer Berlin Heidelberg, 2003, 2749: 363–370.
- Feltz M L, Borg L, Knuteson R O, et al. Assessment of NOAA NUCAPS upper air temperature profiles using COSMIC GPS radio occultation and ARM radiosondes[J]. *Journal of Geophysical Research: Atmospheres*, 2017, 122(17): 9130-9153.
- Feng Y, Peng Y, Cui N, et al. Modeling reference evapotranspiration using extreme learning machine and generalized regression neural network only with temperature data[J]. *Computers and Electronics in Agriculture*, 2017, 136: 71-78.
- Francis, J. A. Validation of reanalysis upper-level winds in the Arctic with independent rawinsonde data[J]. *Geophysical Research Letters*, 2002, 29(9): 29–1.
- Gambacorta A, Nalli N, Barnet CD et al. The NOAA unique CrIS/ATMS processing system (NUCAPS): Algorithm theoretical basis documentation[J]. NOAA Center for Weather and Climate Prediction (NCWCP), Version, 2013, 1.
- García-Pereda J, Borde R. The impact of the tracer size and the temporal gap between images in the

- extraction of atmospheric motion vectors[J]. *Journal of Atmospheric and Oceanic Technology*, 2014, 31(8): 1761-1770.
- Girosi F, Jones M, Poggio T. Regularization theory and neural networks architectures[J]. *Neural computation*, 1995, 7(2): 219-269.
- Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks[C]//*Proceedings of the thirteenth international conference on artificial intelligence and statistics. JMLR Workshop and Conference Proceedings*, 2010: 249-256.
- Goldberg M D, Kilcoyne H, Cikanek H, et al. Joint Polar Satellite System: The United States next generation civilian polar-orbiting environmental satellite system[J]. *Journal of Geophysical Research: Atmospheres*, 2013, 118(24): 13-463.
- Graham R M, Hudson S R, Maturilli M. Improved performance of ERA5 in Arctic gateway relative to four global atmospheric reanalyses[J]. *Geophysical Research Letters*, 2019, 46(11): 6138-6147.
- Guo Q, Yang J, Wei C, et al. Spectrum calibration of the first hyperspectral infrared measurements from a geostationary platform: Method and preliminary assessment[J]. *Quarterly Journal of the Royal Meteorological Society*, 2021, 147(736): 1562-1583.
- Hagiwara M. A simple and effective method for removal of hidden units and weights[J]. *Neurocomputing*, 1994, 6(2): 207-218.
- Han Y, Revercomb H, Crompton M, et al. Suomi NPP CrIS measurements, sensor data record algorithm, calibration and validation activities, and record data quality: CRIS SENSOR DATA RECORD QUALITY[J/OL]. *Journal of Geophysical Research: Atmospheres*, 2013, 118(22): 12,734-12,748.
- Hannon S E, Strow L L, Mcmillan W W. Atmospheric infrared fast transmittance models: A comparison of two approaches[C]//*Optical Spectroscopic Techniques and Instrumentation for Atmospheric and Space Research II: Vol. 2830. International Society for Optics and Photonics*, 1996: 94-105.
- Hastie T, Tibshirani R, Friedman J. *Elements of statistical learning* Ed. 2[M]. Springer, 2009.
- Hayden, C. M. GOES-VAS simultaneous temperature-moisture retrieval algorithm[J]. *Journal of Applied Meteorology*, 1988, 27(6): 705-733.
- He K, Zhang X, Ren S, et al. Delving Deep into Rectifiers: Surpassing Human-Level Performance

- on ImageNet Classification[C]. 2015 IEEE International Conference on Computer Vision (ICCV), 2015 Santiago, Chile: 1026–1034.
- He M, Wang D, Ding W, et al. A Validation of Fengyun4A Temperature and Humidity Profile Products by Radiosonde Observations[J]. *Remote Sensing*, 2019, 11(17): 2039. DOI:10.3390/rs11172039.
- Heidinger A, Straka III W. Algorithm theoretical basis document: ABI cloud mask. NOAA/NESDIS[J]. Center for Satellite Applications and Research Tech. Rep, 2013.
- 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.
- Hillger D, Kopp T, Lee T, et al. First-light imagery from Suomi NPP VIIRS[J]. *Bulletin of the American Meteorological Society*, 2013, 94(7): 1019-1029
- Hinton G E. Reducing the Dimensionality of Data with Neural Networks[J]. *Science*, 2006, 313(5786): 504-507.
- Hoffmann L, Günther G, Li D, et al. From ERA-Interim to ERA5: the considerable impact of ECMWF’s next-generation reanalysis on Lagrangian transport simulations[J]. *Atmospheric Chemistry and Physics*, 2019, 19(5): 3097-3124.
- Holmlund K, Grandell J, Schmetz J, et al. Meteosat Third Generation (MTG): Continuation and Innovation of Observations from Geostationary Orbit[J]. *Bulletin of the American Meteorological Society*, 2021, 102(5): E990-E1015.
- Huang P, Guo Q, Han C, et al. An Improved Method Combining ANN and 1D-Var for the Retrieval of Atmospheric Temperature Profiles from FY-4A/GIIRS Hyperspectral Data[J]. *Remote Sensing*, 2021a, 13(3): 481. DOI:10.3390/rs13030481.
- Huang P, Guo Q, Han C, et al. An Improved Method Combining CNN and 1D-Var for the Retrieval of Atmospheric Humidity Profiles from FY-4A/GIIRS Hyperspectral Data[J]. *Remote Sensing*, 2021b, 13(23): 4737.
- Hubert L F, Whitney L F. Wind estimation from geostationary-satellite pictures[J]. *Monthly Weather Review*, 1971, 99(9): 665-672.
- Joyce R J, Janowiak J E, Arkin P A, et al. CMORPH: A method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution[J]. *Journal of hydrometeorology*, 2004, 5(3): 487-503.

- Kalnay E, Kanamitsu M, Baker W. Global numerical weather prediction at the National Meteorological Center[J]. *Bulletin of the American Meteorological Society*, 1990, 71(10): 1410–1428.
- Kanamitsu, M. Description of the NMC global data assimilation and forecast system[J]. *Weather and Forecasting*, 1989, 4(3): 335–342.
- Kaplan, L. D. Inference of atmospheric structure from remote radiation measurements[J]. *Journal of the Optical Society of America*, 1959, 49(10): 1004–1007.
- Karsoliya S. Approximating Number of Hidden layer neurons in Multiple Hidden Layer BPNN Architecture[J]. *International Journal of Engineering Trends and Technology*, 2012, 3(6): 714-717.
- Key J R, Santek D, Velden C S, et al. Cloud-drift and water vapor winds in the polar regions from MODISIR[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41(2): 482-492.
- King J I. The radiative heat transfer of planet earth. Scientific use of earth satellites[M]. Ann Arbor, Michigan: University of Michigan Press, 1956.
- Kingma D P, Ba J. Adam: A Method for Stochastic Optimization[J]. arXiv:1412.6980 [cs], 2017.
- Knuteson R, Han W, Loveless M, et al. Quality Assessment of the Radiometric and Spectral Calibration of the FY4A Geostationary Interferometric Infrared Sounder (GIIRS) using NOAA-20 CrIS and METOP-B IASI as On-Orbit Reference Sensors[C]//Proceedings of the 23st International TOVS Study Conference, virtual, International TOVS Working Group, 2021.
- Le Marshall J, Pescod N, Seaman B, et al. An operational system for generating cloud drift winds in the Australian region and their impact on numerical weather prediction[J]. *Weather and Forecasting*, 1994, 9(3): 361-370.
- Le Marshall J, Jung J, Derber J, et al. Impact of Atmospheric Infrared Sounder observations on weather forecasts[J]. *Eos, Transactions American Geophysical Union*, 2005, 86(11): 109-116.
- Le Marshall J, Jung J, Derber J, et al. Improving global analysis and forecasting with AIRS[J]. *Bulletin of the American Meteorological Society*, 2006, 87(7): 891-894.
- Lecun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444. DOI:10.1038/nature14539.
- Leese J A, Novak C S, Clark B B. An automated technique for obtaining cloud motion from geosynchronous satellite data using cross correlation[J]. *Journal of Applied Meteorology and*

- Climatology, 1971, 10(1): 118-132.
- Lerner J A, Weisz E, Kirchengast G. Temperature and humidity retrieval from simulated Infrared Atmospheric Sounding Interferometer (IASI) measurements[J]. Journal of Geophysical Research: Atmospheres, 2002, 107(D14): ACH-4.
- Li J, Li J, Velden C, et al. Impact of Rapid - Scan - Based Dynamical Information From GOES - 16 on HRRF Hurricane Forecasts[J]. Journal of Geophysical Research: Atmospheres, 2020, 125(3).
- Li J, Huang H L. Retrieval of Atmospheric Profiles from Satellite Sounder Measurements by Use of the Discrepancy Principle[J]. Applied Optics, 1999, 38(6):916-923.
- Li J, Wolf W W, Menzel W P, et al. Global soundings of the atmosphere from ATOVS measurements: The algorithm and validation[J]. Journal of Applied Meteorology, 2000, 39(8): 1248-1268.
- Li J, Li J, Otkin J, et al. Warning Information in a Preconvection Environment from the Geostationary Advanced Infrared Sounding System—A Simulation Study Using the IHOP Case[J]. Journal of Applied Meteorology and Climatology, 2011, 50(3): 776-783.
- Li J, Liu C Y, Zhang P, et al. Applications of Full Spatial Resolution Space-Based Advanced Infrared Soundings in the Preconvection Environment[J]. Weather and Forecasting, 2012, 27(2): 515-524.
- Li J, Wolf W W, Menzel W P, et al. Global soundings of the atmosphere from ATOVS measurements: The algorithm and validation[J]. Journal of Applied Meteorology, 2000, 39(8): 1248-1268.
- Li J, Geer A J, Okamoto K, et al. Satellite all-sky infrared radiance assimilation: Recent progress and future perspectives[J]. Advances in Atmospheric Sciences, 2022, 39(1): 9-21.
- Li Z, Li J, Wang P, et al. Value-added Impact of Geostationary Hyperspectral Infrared Sounders on Local Severe Storm Forecasts—via a Quick Regional OSSE[J]. Advances in Atmospheric Sciences, 2018, 35(10): 1217-1230.
- Liu C Y, Liu G R, Lin T H, et al. Using surface stations to improve sounding retrievals from hyperspectral infrared instruments[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(11): 6957-6963.
- Liu C Y, Li J, Ho S P, et al. Retrieval of atmospheric thermodynamic state from synergistic use of radio occultation and hyperspectral infrared radiances observations[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 9(2): 744-756.

- Liu C Y, Chiu C H, Lin P H, et al. Comparison of Cloud-Top Property Retrievals From Advanced Himawari Imager, MODIS, CloudSat/CPR, CALIPSO/CALIOP, and Radiosonde[J]. *Journal of Geophysical Research: Atmospheres*, 2020, 125(15): e2020JD032683.
- Liu J N, Hu Y, You J J, et al. Deep neural network based feature representation for weather forecasting[C]//*Proceedings on the International Conference on Artificial Intelligence (ICAI)*. The Steering Committee of The World Congress in Computer Science, Computer Engineering and Applied Computing (WorldComp), 2014: 1.
- Liu Q, Wolf W, Reale T, et al. NUCAPS: NOAA Unique Combined Atmospheric Processing System Environmental Data Record (EDR) Products[J]. 2014.
- Liu Y, Chen X, Peng H, et al. Multi-focus image fusion with a deep convolutional neural network[J]. *Information Fusion*, 2017, 36: 191-207.
- Liu Z, Min M, Li J, et al. Local Severe Storm Tracking and Warning in Pre-Convection Stage from the New Generation Geostationary Weather Satellite Measurements[J]. *Remote Sensing*, 2019, 11(4): 383.
- Lorenz A C. Analysis methods for numerical weather prediction[J]. *Quarterly Journal of the Royal Meteorological Society*, 1986, 112(474): 1177-1194.
- Maddox, R. A. Mesoscale convective complexes[J]. *Bulletin of the American Meteorological Society*, 1980: 1374–1387.
- McNally A, Watts P, A. Smith J, et al. The assimilation of AIRS radiance data at ECMWF[J]. *Quarterly Journal of the Royal Meteorological Society*, 2006, 132(616): 935-957.
- Mecikalski J R, Bedka K M. Forecasting Convective Initiation by Monitoring the Evolution of Moving Cumulus in Daytime GOES Imagery[J]. *Monthly Weather Review*, 2006, 134(1): 49-78.
- Mecikalski J R, Bedka K M, Paech S J, et al. A Statistical Evaluation of GOES Cloud-Top Properties for Nowcasting Convective Initiation[J]. *Monthly Weather Review*, 2008, 136(12): 4899-4914.
- Mecikalski J R, Williams J K, Jewett C P, et al. Probabilistic 0–1-h Convective Initiation Nowcasts that Combine Geostationary Satellite Observations and Numerical Weather Prediction Model Data[J]. *Journal of Applied Meteorology and Climatology*, 2015, 54(5): 1039-1059.
- 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.

- Menzel W P, Purdom J F. Introducing GOES-I: The first of a new generation of geostationary operational environmental satellites[J]. *Bulletin of the American Meteorological Society*, 1994, 75(5): 757-782.
- Menzel W P, Smith W, Stewart T. Improved cloud motion wind vector and altitude assignment using VAS[J]. *Journal of Applied Meteorology and Climatology*, 1983, 22(3): 377-384.
- Menzel W P, Holt F C, Schmit T J, et al. Application of GOES-8/9 soundings to weather forecasting and nowcasting[J]. *Bulletin of the American Meteorological Society*, 1998, 79(10): 2059-2078.
- Menzel W P, Schmit T J, Zhang P, et al. Satellite-based atmospheric infrared sounder development and applications[J]. *Bulletin of the American Meteorological Society*, 2018, 99(3): 583-603.
- Michael B, Kristin C. GOES-R and JPSS Proving Ground Demonstration at the 2017 Summer Experiment—Experimental Warning Program (EWP)[Z]. NOAA Hazardous Weather Testbed (HWT), 2017.
- Milstein A B, Blackwell W J. Neural network temperature and moisture retrieval algorithm validation for AIRS/AMSU and CrIS/ATMS[J]. *Journal of Geophysical Research: Atmospheres*, 2016, 121(4): 1414-1430.
- Morel C, S en esi S, Autones F. Building upon SAF-NWC products: Use of the Rapid Developing Thunderstorms (RDT) product in M et eo-France nowcasting tools[C]//Proc. The. 2002: 248-255.
- Nagle F W, Holz R E. Computationally efficient methods of collocating satellite, aircraft, and ground observations[J]. *Journal of Atmospheric and Oceanic Technology*, 2009, 26(8): 1585-1595.
- Nair V, Hinton GE. Rectified linear units improve restricted Boltzmann machines[C]. *Proceedings of the 27th international conference on machine learning (ICML-10)*, 2010: 807–814.
- Nalli N R, Barnet C D, Reale A, et al. Validation of satellite sounder environmental data records: Application to the Cross-track Infrared Microwave Sounder Suite[J]. *Journal of Geophysical Research: Atmospheres*, 2013, 118(24): 13-628.
- Nalli N R, Gambacorta A, Liu Q, et al. Validation of Atmospheric Profile Retrievals From the SNPP NOAA-Unique Combined Atmospheric Processing System. Part 1: Temperature and Moisture[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(1): 180-190.
- Okamoto K, Owada H, Fujita T, et al. Assessment of the Potential Impact of a Hyperspectral Infrared

- Sounder on the Himawari Follow-On Geostationary Satellite[J]. SOLA-Scientific Online Letters on the Atmosphere, 2020, 16: 162-168.
- Olauson J. ERA5: The new champion of wind power modelling?[J]. Renewable energy, 2018, 126: 322-331.
- Pedregosa F, Varoquaux G, Gramfort A, et al. Scikit-learn: Machine Learning in Python[J]. Journal of Machine Learning Research, 2011, 12: 2825-2830.
- Pu Z, Li X, Velden C S, et al. The impact of aircraft dropsonde and satellite wind data on numerical simulations of two landfalling tropical storms during the tropical cloud systems and processes experiment[J]. Weather and Forecasting, 2008, 23(1): 62-79.
- Purdom J F. Some uses of high-resolution GOES imagery in the mesoscale forecasting of convection and its behavior[J]. Monthly Weather Review, 1976, 104(12): 1474-1483.
- Rao P K, Holmes S J, Anderson R K, et al. Weather satellites: Systems, data, and environmental applications[M]. Boston, MA: Amer Meteor Soc., 1990.
- Reale T, Sun B, Tilley F H, et al. The NOAA Products Validation System (NPROVS)[J]. Journal of Atmospheric and Oceanic Technology, 2012, 29(5): 629-645.
- Roberts R D, Rutledge S. Nowcasting Storm Initiation and Growth Using GOES-8 and WSR-88D Data[J]. Weather and Forecasting, 2003, 18: 23.
- Santek D, Nebuda S, Stettner D. Demonstration and Evaluation of 3D Winds Generated by Tracking Features in Moisture and Ozone Fields Derived from AIRS Sounding Retrievals[J]. Remote Sensing, 2019, 11(22): 2597.
- Schmetz J, Tjemkes S, Gube M, et al. Monitoring deep convection and convective overshooting with METEOSAT[J]. Advances in Space Research, 1997, 19(3): 433-441.
- Schmetz J, Holmlund K, Hoffman J, et al. Operational cloud-motion winds from Meteosat infrared images[J]. Journal of Applied Meteorology and Climatology, 1993, 32(7): 1206-1225.
- Schmit T J, Li J, Li J, et al. The GOES-R Advanced Baseline Imager and the continuation of current sounder products[J]. Journal of Applied Meteorology and Climatology, 2008, 47(10): 2696-2711.
- Schmit T J, Li J, Ackerman S A, et al. High-Spectral- and High-Temporal-Resolution Infrared Measurements from Geostationary Orbit[J]. Journal of Atmospheric and Oceanic Technology, 2009, 26(11): 2273-2292.

- Schmit TJ, Griffith P, Gunshor MM, et al. A Closer Look at the ABI on the GOES-R Series[J]. Bulletin of the American Meteorological Society, 2017, 98(4): 681–698.
- Schmit T J, Lindstrom S S, Gerth J J, et al. Applications of the 16 spectral bands on the Advanced Baseline Imager (ABI)[J]. J. Operational Meteor., 2018, 6(4): 33-46.
- Schmit T J, Li J, Lee S J, et al. Legacy Atmospheric Profiles and Derived Products From GOES-16: Validation and Applications[J]. Earth and Space Science, 2019, 6(9): 1730-1748.
- Seltzer M L, Yu D, Wang Y. An investigation of deep neural networks for noise robust speech recognition[C]//2013 IEEE international conference on acoustics, speech and signal processing. IEEE, 2013: 7398-7402.
- Sheela K G, Deepa S N. Review on Methods to Fix Number of Hidden Neurons in Neural Networks[J]. Mathematical Problems in Engineering, 2013: 425740.1-425740.11.
- Shibata K, Ikeda Y. Effect of number of hidden neurons on learning in large-scale layered neural networks[C]//2009 ICCAS-SICE. IEEE, 2009: 5008-5013.
- Shimoji K. Introduction to the Himawari-8 Atmospheric Motion Vector Algorithm[J]. Meteorological Satellite Center Technical Note, 2017, 62: 73-77.
- Sieglaff J M, Schmit T J, Menzel W P, et al. Inferring Convective Weather Characteristics with Geostationary High Spectral Resolution IR Window Measurements: A Look into the Future[J]. Journal of Atmospheric and Oceanic Technology, 2009, 26(8): 1527-1541.
- Sieglaff J, Cronic L, Feltz W, et al. Nowcasting Convective Storm Initiation Using Satellite-Based Box-Averaged Cloud-Top Cooling and Cloud-Type Trends[J]. Journal of Applied Meteorology and Climatology, 2011, 50(1): 110–126.
- Smith A, Atkinson N, Bell W, et al. An initial assessment of observations from the Suomi-NPP satellite: data from the Cross-track Infrared Sounder (CrIS): Initial assessment of CrIS data from the Suomi-NPP satellite[J]. Atmospheric Science Letters, 2015, 16(3): 260-266. DOI:10.1002/asl2.551.
- Smith W L. Iterative solution of the radiative transfer equation for the temperature and absorbing gas profile of an atmosphere[J]. Applied Optics, 1970, 9(9): 1993-1999.
- Smith W L, Harrison F W, Hinton D, et al. GIFTS-the precursor geostationary satellite component of the future Earth Observing System[C]//IEEE International Geoscience and Remote Sensing Symposium: 卷 1. IEEE, 2002: 357-361.

- Smith W L, Revercomb H, Bingham G, et al. Evolution, current capabilities, and future advance in satellite nadir viewing ultra-spectral IR sounding of the lower atmosphere[J]. *Atmospheric Chemistry and Physics*, 2009, 9(15): 5563-5574.
- Smith W L, Revercomb H, Howell H, et al. GHIS—the GOES high-resolution interferometer sounder[J]. *Journal of Applied Meteorology and Climatology*, 1990, 29(12): 1189-1204.
- Smith W L, Revercomb H, Zhou D, et al. Geostationary imaging Fourier transform spectrometer (GIFTS): science applications[C]//*Multispectral, Hyperspectral, and Ultraspectral Remote Sensing Technology, Techniques, and Applications: Vol. 6405*. Goa, India: SPIE, 2006: 73-85.
- Smith W L, Suomi V, Menzel W, et al. First sounding results from VAS-D[J]. *Bulletin of the American Meteorological Society*, 1981, 62(2): 232-236.
- Smith W L, Weisz E, Kireev S V, et al. Dual-regression retrieval algorithm for real-time processing of satellite ultraspectral radiances[J]. *Journal of Applied Meteorology and Climatology*, 2012, 51(8): 1455-1476.
- Smith W L, Woolf H. The use of eigenvectors of statistical covariance matrices for interpreting satellite sounding radiometer observations[J]. *Journal of Atmospheric Sciences*, 1976, 33(7): 1127-1140.
- Smith W L, Woolf H M, Jacob W J. A regression method for obtaining real-time temperature and geopotential height profiles from satellite spectrometer measurements and its application to Nimbus 3 “SIRS” observations[J]. *Monthly Weather Review*, 1970, 98(8): 582-603.
- Smith W L, Zhang Q, Shao M, et al. Improved Severe Weather Forecasts Using LEO and GEO Satellite Soundings[J]. *Journal of Atmospheric and Oceanic Technology*, 2020, 37(7): 1203-1218.
- Soden B J, Velden C S, Tuleya R E. The impact of satellite winds on experimental GFDL hurricane model forecasts[J]. *Monthly weather review*, 2001, 129(4): 835-852.
- Stettner D, Velden C, Rabin R, et al. Development of enhanced vortex-scale atmospheric motion vectors for hurricane applications[J]. *Remote Sensing*, 2019, 11(17): 1981.
- Strow L L, Motteler H, Tobin D, et al. Spectral calibration and validation of the Cross-track Infrared Sounder on the Suomi NPP satellite[J]. *Journal of Geophysical Research: Atmospheres*, 2013, 118(22): 12-486.
- Strow L L, Hannon S E, De Souza-Machado S, et al. An overview of the AIRS radiative transfer

- model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(2): 303-313.
- Sun B, Reale A, Tilley F H, et al. Assessment of NUCAPS S-NPP CrIS/ATMS sounding products using reference and conventional radiosonde observations[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(6): 2499-2509.
- Sun F, Min M, Qin D, et al. Refined typhoon geometric center derived from a high spatiotemporal resolution geostationary satellite imaging system[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 16(4): 499-503.
- Susskind J, Barnett C D, Blaisdell J M. Retrieval of atmospheric and surface parameters from AIRS/AMSU/HSB data in the presence of clouds[J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(2): 390-409.
- Szantai A, Désalmand F, Desbois M, et al. Tracking low-level clouds over land on Meteosat images[C]//Proc. Fifth International Winds Workshop, Lorne, Australia (28 Feb.-3 March 2000). EUMETSAT, EUM P: Vol. 28. 2000: 245-252.
- Szantai A, Héas P, Mémin E. Comparison of atmospheric motion vectors and dense vector fields calculated from MSG images[C]//Proceedings of the 8th International Winds Workshop, Beijing, China. Citeseer, 2006: 24-28.
- Szejwach G. Determination of semi-transparent cirrus cloud temperature from infrared radiances: Application to METEOSAT[J]. Journal of Applied Meteorology and Climatology, 1982, 21(3): 384-393.
- Tao Y, Gao X, Hsu K, et al. A Deep Neural Network Modeling Framework to Reduce Bias in Satellite Precipitation Products[J]. Journal of Hydrometeorology, 2016, 17(3): 931-945.
- Tao Y, Hsu K, Ihler A, et al. A Two-Stage Deep Neural Network Framework for Precipitation Estimation from Bispectral Satellite Information[J]. Journal of Hydrometeorology, 2018, 19(2): 393-408.
- Tarek M, Brissette F P, Arsenault R. Evaluation of the ERA5 reanalysis as a potential reference dataset for hydrological modeling over North-America[R/OL]. Catchment hydrology/Modelling approaches, 2019. <https://hess.copernicus.org/preprints/hess-2019-316/hess-2019-316.pdf>.
- Taszarek M, Pilgus N, Allen J T, et al. Comparison of convective parameters derived from ERA5 and MERRA2 with rawinsonde data over Europe and North America[J]. Journal of Climate,

2020: 1-55.

Van Gerven M, Bohte S. Artificial neural networks as models of neural information processing[J]. *Frontiers in Computational Neuroscience*, 2017, 11: 114.

Velden C, Bedka K M. Identifying the Uncertainty in Determining Satellite-Derived Atmospheric Motion Vector Height Attribution[J]. *Journal of Applied Meteorology and Climatology*, 2009, 48(3): 450-463.

Velden C, Daniels J, Stettner D, et al. Recent Innovations in Deriving Tropospheric Winds from Meteorological Satellites[J]. *Bulletin of the American Meteorological Society*, 2005, 86(2): 205-224.

Velden C, Dengel G, Dengel R, et al. Determination of wind vectors by tracking features on sequential moisture analyses derived from hyperspectral IR satellite soundings[C]//preprints, 13th AMS Conf. on Satellite Meteor. And Ocean., Amer. Meteor. Soc. 2004.

Velden C, Hayden C M, Nieman S J W, et al. Upper-tropospheric winds derived from geostationary satellite water vapor observations[J]. *Bulletin of the American Meteorological Society*, 1997, 78(2): 173-196.

Velden C, Lewis W E, Bresky W, et al. Assimilation of High-Resolution Satellite-Derived Atmospheric Motion Vectors: Impact on HWRF Forecasts of Tropical Cyclone Track and Intensity[J]. *Monthly Weather Review*, 2017, 145(3): 1107-1125. DOI:10.1175/MWR-D-16-0229.1.

Velden C, Olander T L, Wanzong S. The impact of multispectral GOES-8 wind information on Atlantic tropical cyclone track forecasts in 1995. Part I: Dataset methodology, description, and case analysis[J]. *Monthly Weather Review*, 1998, 126(5): 1202-1218.

Velden C, Stettner D, Daniels J. Wind vector fields derived from GOES rapid-scan imagery[C]//Proc. 10th Conf. on Satellite Meteor. and Oceanogr., Long Beach California, Amer. Meteor. Soc. 2000: 20-23.

Walker J R, Mackenzie W M, Mecikalski J R, et al. An Enhanced Geostationary Satellite-Based Convective Initiation Algorithm for 0–2-h Nowcasting with Object Tracking[J]. *Journal of Applied Meteorology and Climatology*, 2012, 51(11): 1931-1949.

Wang P, Li Z, Li J, et al. Added-value of geo-hyperspectral infrared radiances for local severe storm forecasts using the hybrid OSSE method[J]. *Advances in Atmospheric Sciences*, 2021, 38(8):

- 1315-1333.
- Weisz E, Smith N, Smith W L. The use of hyperspectral sounding information to monitor atmospheric tendencies leading to severe local storms[J]. *Earth and Space Science*, 2015, 2(9): 369-377.
- Weng F, Zou X, Wang X, et al. Introduction to Suomi national polar-orbiting partnership advanced technology microwave sounder for numerical weather prediction and tropical cyclone applications[J]. *Journal of Geophysical Research: Atmospheres*, 2012, 117(D19).
- Weng F, Zou X, Sun N, et al. Calibration of Suomi national polar-orbiting partnership advanced technology microwave sounder[J]. *Journal of Geophysical Research: Atmospheres*, 2013, 118(19): 11-187.
- Wu X, Li J, Zhang W, et al. Atmospheric profile retrieval with AIRS data and validation at the ARM CART site[J]. *Advances in Atmospheric Sciences*, 2005, 22(5): 647-654.
- Xie P, Yoo S H, Joyce R, et al. Bias-corrected CMORPH: A 13-year analysis of high-resolution global precipitation[C]//*Geophysical Research Abstracts: Vol. 13. 2011: EGU2011-1809*.
- Xie P, Joyce R, Wu S, et al. Reprocessed, bias-corrected CMORPH global high-resolution precipitation estimates from 1998[J]. *Journal of Hydrometeorology*, 2017, 18(6): 1617-1641.
- Xu J, Holmlund K, Zhang Q, et al. Comparison of two schemes for derivation of atmospheric motion vectors[J]. *Journal of Geophysical Research: Atmospheres*, 2002, 107(D14): ACL-4.
- Xue Q, Guan L, Shi X. One-Dimensional Variational Retrieval of Temperature and Humidity Profiles from the FY4A GIIRS[J]. *Advances in Atmospheric Sciences*, 2022: 1-16.
- Yang J, Lin C, Liu H, et al. Effects of island topography on storm surge in Taiwan strait during Typhoon Maria[J]. *Journal of Waterway, Port, Coastal, and Ocean Engineering*, 2021, 147(2): 04020057.
- Yang J, Zhang Z, Wei C, et al. Introducing the New Generation of Chinese Geostationary Weather Satellites, Fengyun-4[J]. *Bulletin of the American Meteorological Society*, 2017, 98(8): 1637-1658.
- Yin R, Han W, Gao Z, et al. The evaluation of FY4A's Geostationary Interferometric Infrared Sounder (GIIRS) long-wave temperature sounding channels using the GRAPES global 4D-Var[J]. *Quarterly Journal of the Royal Meteorological Society*, 2020, 146(728): 1459-1476.
- Yin R, Han W, Gao Z, et al. Impact of high temporal resolution FY-4A Geostationary Interferometric

- Infrared Sounder (GIIRS) radiance measurements on Typhoon forecasts: Maria (2018) case with GRAPES global 4D-Var assimilation system[J]. *Geophysical Research Letters*, 2021, 48(15): e2021GL093672.
- Yu P, Shi C, Yang L, et al. A New Temperature Channel Selection Method Based on Singular Spectrum Analysis for Retrieving Atmospheric Temperature Profiles from FY-4A/GIIRS[J]. *Advances in Atmospheric Sciences*, 2020, 37(7): 735-750.
- Zhang P, Hu X, Lu Q, et al. FY-3E: The first operational meteorological satellite mission in an early morning orbit[J]. *Advances in Atmospheric Sciences*, 2022, 39(1): 1-8.
- Zhang S, Pu Z, Velden C. Impact of Enhanced Atmospheric Motion Vectors on HRRF Hurricane Analyses and Forecasts with Different Data Assimilation Configurations[J]. *Monthly Weather Review*, 2018, 146(5): 1549-1569.
- Zhang X, Sun J, Zheng Y, et al. Progress in severe convective weather forecasting in China since the 1950s[J]. *Journal of Meteorological Research*, 2020, 34(4): 699-719.
- Zhou D K, Smith Sr W L, Bingham G E, et al. Ground-based measurements with the Geosynchronous Imaging Fourier Transform Spectrometer (GIFTS) engineering demonstration unit-experiment description and first results[J]. *Journal of Applied Remote Sensing*, 2007, 1(1): 013528.
- Zhou Y, Grassotti C. Development of a Machine Learning-Based Radiometric Bias Correction for NOAA's Microwave Integrated Retrieval System (MiRS)[J]. *Remote Sensing*, 2020, 12(19): 3160.

附录

缩略词

缩略词	英文全称
ABI	Advanced Baseline Imager
AGRI	Advanced Geostationary Radiation Imager
AHI	Advanced Himawari Imager
AIRS	Atmospheric Infrared Sounder
AMS	American Meteorological Society
AMSU	Advanced Microwave Sounding Units
AMV	Atmospheric Motion Vector
ANN	Artificial Neural Network
ARM	Atmospheric Radiation Measurement
ASPEN	Atmospheric Sounding Processing Environment
ATMS	Advanced Technology Microwave Sounder
ATOVS	Advanced TIROS Operational Vertical Sounder
BCCSO	The Beltsville Center for Climate System Observation
BP	Back Propagation
BT	Brightness Temperature
CAPE	Convective Available Potential Energy
CI	Convective Initiation
CIMSS	Cooperative Institute for Meteorological Satellite Studies
CIN	Convective Inhibition
CMORPH	The Climate Prediction Center morphing technique
CNN	Convolutional Neural Network

CONUS	Continental United States
CrIS	Cross-track Infrared Sounder
CRL	Clear sky and very light cloud coverage
CSI	Critical Success Index
DNN	Deep Neural Network
EBS	Effective Bulk Shear
ECMWF	European Centre for Medium-Range Weather Forecasts
ELU	Exponential Linear Unit
EOS	Earth Observing System
ERA5	ECMWF Reanalysis version 5
EUMETSAT	European Organisation for the Exploitation of Meteorological Satellites
FAR	False Alarm Rate
FOV	Field-of-View
FOR	Field-of-Regard
GDAS	Global Data Assimilation System
GeoHIS	Geostationary Hyperspectral Infrared Sounder
GeoXO	Geostationary and Extended Observations
GFDL	Geophysical Fluid Dynamics Laboratory
GFS	Global Forecast System
GHIS	GOES High Resolution Interferometer Sounder
GIFTS	Geostationary Imaging Fourier Transform Spectrometer
GIIRS	Geostationary Interferometric Infrared Sounder
GOES	Geostationary Operational Environmental Satellite
GRAPES	Global/Regional Assimilation and Prediction System
GRUAN	Global Reference Upper Air Network
GSI	Gridpoint Statistical Interpolation
HIRAS	Hyperspectral Infrared Atmospheric Sounder

HIRS	High Resolution Infrared Radiation Sounder
HTK	High and Thick cloud coverage
HWRP	Hurricane Weather Research and Forecast
IASI	Infrared Atmospheric Sounder Interferometer
IRAS	Infrared Atmospheric Sounder
JPSS	Joint Polar Satellite System
LI	Lifted Index
LNT	Low and Non-Thick cloud coverage
LSS	Local Severe Storm
LW	Long-wave
MERSI	Medium Resolution Spectral Imager
ML	Machine Learning
MODIS	Moderate Resolution Imaging Spectroradiometer
MTG	Meteosat Third Generation
MW	Mid-wave
MWHS	Microwave Humidity Sounder
MWRI	Microwave Radiation Imager
MWTS	Microwave Temperature Sounder
NASA	National Aeronautics and Space Administration
NESDIS	National Environmental Satellite Data and Information Service
NN	Neural Network
NOAA	National Oceanic and Atmospheric Administration
NPP	National Polar-orbiting Partnership
NPROVS	NOAA Products Validation System
NSMC	National Satellite Meteorological Center
NUCAPS	NOAA Unique Combined Atmospheric Processing System
NWP	Numerical Weather Prediction

OSSE	Observing System Simulation Experiment
POD	Probability of Detection
PV	Potential Vorticity
RAOB	Radiosonde Observation
ReLU	Rectified Linear Units
RMSE	Root Mean Squared Error
RTMA	Real-Time Mesoscale Analysis
SATCAST	Satellite Convection Analysis and Tracking
SGP	Southern Great Plains
SIPS	Atmosphere Science Investigator-led Processing System
SIRS	Satellite Infrared Spectrophotometer
SPC	Storm Prediction Center
SSEC	Space Science and Engineering Center
STAR	NOAA Center for Satellite Application and Research
STDE	Standard Deviation of Error
SWIPE	Storm Warning in Pre-convection Environment
TPW	Total Precipitable Water
UWCI	University of Wisconsin Convective Initiation
VAS	Visible and Infrared Spin Scan Radiometer Atmospheric Sounder
WMO	World Meteorological Organization

致 谢

伴随着即将完稿的论文，我充实的博士求学生涯也即将告一段落。回首自己自入学以来走过的路，我感慨万分，但又不知该从何说起，因为有太多的人需要感谢，有太多的故事难以忘怀。在这里请允许我以有限的文字表达对所有在我的读博生涯中给予过关心、帮助和支持的人的无尽感谢！

首先要诚挚感谢我在大气所的导师孙建华研究员。感谢孙老师接受我的考博申请，让我在经过两次考博之后终于获得来到大气所学习的机会。孙老师严谨的治学态度、诲人不倦的师德风范和精益求精的工作作风都使我得到了很深的触动。孙老师对待学生包容温和，她尊重每一个人的个性发展，给予了我很大的自主性。记得在我刚入所的时候，就指导我针对具体的科学问题自主调研，并在我汇报调研结果时予以肯定和鼓励，让刚刚踏上科研之路的我获得了极其宝贵的自信心和动力，这对于我的整个博士学习期间产生了深远的影响。孙老师还凭借她独到的学术视野，为我指明了卫星气象学这一兼具学术性与应用价值的研究方向，并积极鼓励我出国交流学习，引荐我认识了当时在美国威斯康星大学麦迪逊分校工作的卫星气象学资深科学家—李俊老师，让我有机会跟随李老师进行更为深入的学习和研究工作。在我去美国访学的准备过程中，也要感谢大气所的王立志老师，王老师和孙老师共同为我提供了一部分访学经费支持，并在我成功申请国科大国际合作培养计划项目的过程中给予了重要的帮助。

我在 2019 年的生日当天来到麦迪逊，加入了李俊老师的课题组并开展了我博士研究的主要工作。麦迪逊作为一个静谧安逸的小城，缺少了大城市的繁华和喧嚣，但也带给了我心无旁骛的科研环境。李老师睿智而豁达，拥有渊博的学术知识和研究经验，以及开拓创新的研究精神，同时具备敏锐的学术洞察力以及杰出的前瞻性。作为他的学生，我时常感慨自己的科研思维和动手能力跟不上李老师的想法，以至于在进组的初期有较强的挫败感。但是李老师对我一直保持着很高程度的耐心，并且支持我参加美国气象学会的年会并做了口头报告，让我有机会开拓视野并积累信心，一直到我的期刊论文发表并在科研上渐入佳境。在此也要格外感谢李俊老师课题组的李正龙博士，每次和正龙针对科研细节问题的讨论都

让我受益匪浅。无论是疫情前的办公室还是疫情期间的居家办公，不管是上午 10 点还是晚上 10 点，当我遇到难以解决的问题时，正龙总能“碰巧”在线。在交流学习期间，我也要感谢李老师课题组的李金龙博士、王培博士、Jung-Rim Lee、SuJeong Lee，以及薛允恒师姐、孟德明师兄和林翰在科研和生活上给予我的帮助和支持。我要特别感谢当时同在麦迪逊的韩威研究员，与韩老师的多次学术讨论每次都能让我收获颇丰。我也要感谢 Bob Knuteson、Dave Santek 以及 Steve Wanzong 等美国科学家在我访学研究期间提供的数据和产品支持，对我的科研工作提供了重要的推动作用。在工作之余，我要感谢 Jung-Rim 姐姐和我打台球、喝红酒渡过开心的业余时间，感谢优秀的允恒师姐让我知道跟不上李老师思路的不止我一个人，感谢大方的德明老兄时常给我搭便车的机会，感谢林翰在疫情期间一路辗转回国之路上的互相支持。我还要感谢所有我在美国访学期间认识的朋友们，我们一起在异国他乡的风景中玩过笑过，也在复杂动荡的环境中互相支持过。

在论文的完成过程中，我要感谢孙老师课题组的傅慎明研究员和张元春副研究员，两位老师在每周的组会上对于学生的工作总能提出独到的意见和建议，让包括我在内的各位学生都受益匪浅。在此我也要感谢课题组的赵思雄老师、卫捷老师、汪汇洁师姐、徐广阔师兄、杨新林师兄、田付友师兄、杨如意师姐以及麦子师姐表示诚挚的谢意，感谢各位老师和师兄师姐在我博士期间不同时段给予我的关心和帮助。感谢大气所夏江江老师及其课题组成员在机器学习算法及应用上对我的启蒙和帮助。我也要感谢李老师团队的闵敏老师、李博老师、郑婧老师、狄迪师姐、巩欣亚师姐、刘子菁师弟和韦晓澄师妹在我的研究工作中给予的帮助。感谢孙继明研究员、冉令坤研究员、田向军研究员、罗亚丽研究员、郑永光研究员、赵琳娜研究员在我开题和中期报告中提出的宝贵意见。感谢研究生部的孙鹏宇老师、付建建老师、张予老师以及实验室的赵芹老师对我们的日常学习和生活提供的便利和帮助。

都说患难见真情，就在我毕业论文即将完稿之际，我意外地受伤造成脚踝骨折，并且由于疫情管控，我的家人没有办法来到我的身边。孤身一人在北京的我，在最为痛苦、无助、失落、孤独的时刻迎来了援助之手。我由衷地感谢实验室的李舒文同学、出国前的舍友李海山同学和现舍友任鑫冰同学在我博士期间第一次

的急诊经历中给予的无私帮助，更要感谢张敬萍师姐、付亚男大哥在我先后两次门诊复查期间给予我的无微不至的关怀。在上述之外，我也要感谢办公室的刘翠、汤欢、孟亚楠、孙雪倩、张思、杨雯婷、课题组的魏倩、已毕业的同门姜立智、马若赟，以及舍友任鑫冰、毕明浩在我受伤期间给予我的各种形式的帮助，让我能够坚强地面对生活。感谢大气所闫元老师和物业李建雅经理的积极协调，帮我解决了基本的生活需求问题。在此要特别感谢刘登亮先生所带领的大气所保安团队，每天不辞辛苦地帮我送饭，哪怕这本不在他们的职责范围内。我从心底里对他们表示由衷的感激和敬佩，在他们的身上我看到了在钢筋水泥的冰冷下绽放着的人性温情之花。在受伤之后行动不便的日子里，正是这些来自不同的人的点点滴滴的关怀，支撑我克服暂时的困难，并能够有更充沛的勇气和信心来迎接未来工作和生活中的各种挑战。

最后，我要感谢我的家人，感谢你们对我的关心和支持。特别是我的妈妈，感谢您一直能够站在我的角度体谅我，支持我的决定。最后祝愿我所有的老师、亲人、同学、朋友、以及所有遇到过和帮助过我的人，希望你们永远健康快乐！

2022 年 4 月于大气所

作者简介及攻读学位期间发表的学术论文与研究成果

作者简介:

2010年9月——2014年6月,在南京信息工程大学大气科学学院(系)获得学士学位。

2014年9月——2017年6月,在南京信息工程大学大气科学学院(系)获得硕士学位。

2018年9月——2022年6月,在中国科学院大气物理研究所攻读博士学位。

2019年4月——2021年7月,在美国威斯康星大学麦迪逊分校,中国科学院大学公派项目加导师课题组项目,联合培养博士研究生。

已发表(或待发表)的学术论文:

Ma Z, Li Z, Li J, Schmit T J, Cucurull L, Atlas R, Sun B. Enhance Low Level Temperature and Moisture Profiles Through Combining NUCAPS, ABI Observations, and RTMA Analysis[J]. *Earth and Space Science*, 2021, 8(6): e2020EA001402

Ma Z, Li J, Han W, Li Z, Zeng Q, Menzel W P, Schmit T J, Di D, Liu C-Y. Four-dimensional wind fields from geostationary hyperspectral infrared sounder radiance measurements with high temporal resolution[J]. *Geophysical Research Letters*, 2021, 48(14): e2021GL093794.

Ma Z, Li Z, Li J, Min M, Sun J, Wei X, Schmit T J, Cucurull L. Evaluation of Satellite Measurements on Storm Warning and Nowcasting in Pre-convection Environment - via a Machine Learning Framework[J]. Submitted to *Remote Sensing of Environment*.

Yang W, Fu S, Sun J, Zheng F, Wei J, **Ma Z**. Comparative Evaluation of the Performances of TRMM-3B42 and Climate Prediction Centre Morphing Technique (CMORPH) Precipitation Estimates over Thailand[J]. *Journal of the Meteorological Society of Japan. Ser. II*, 2021, 99(6): 1525–1546.

Li J, Zhang Y, Di D, **Ma Z**, Li Z, Schmit T J, Menzel W P. The influence of sub-footprint cloudiness on three-dimensional wind from geostationary hyperspectral infrared sounder observations[J]. Accepted by Geophysical Research Letters.

Li Z, **Ma Z**, Wang P, Lim A, Li J, Jung J A, Schmit T J, Huang A. Optimized quality control of surface contamination observations for ABI water vapor radiance assimilation[J]. Submitted to Journal of Geophysical Research – Atmospheres.