

# 风云四号A星可见光反射率同化神经网络观测算子

何明峰<sup>1</sup>, 周永波<sup>2,3</sup>

1. 南京信息工程大学 应急管理学院, 南京 210044;

2. 南京信息工程大学 大气物理学院, 南京 210044;

3. 南京信息工程大学 精细化区域地球模拟与信息中心, 南京 210044

**摘要:** 全天空卫星可见光反射率资料蕴含关键的云雨信息, 具有重大的同化潜力。传统的可见光反射率资料同化观测算子基于数值方法求解辐射传输方程, 计算效率偏低, 尚不能满足资料同化的业务应用需求。鉴于此, 本研究在Scheck (2021)神经网络观测算子的基础上, 优化了神经网络参数与结构, 构建了风云四号A星 (FY-4A) 先进静止轨道辐射成像仪 (AGRI) 可见光反射率资料同化的快速观测算子NNFO。NNFO的输入参数包括液相和冰相总云水路径 (转换到对数空间)、冰相云水路径与总云水路径之比、液滴有效粒子半径、下垫面反照率、太阳天顶角、卫星天顶角、太阳与卫星的相对方位角, 输出数据为对应条件下的天顶反射率。结果表明, NNFO的计算效率是传统观测算子RTTOV-DOM的15倍 (串行) 或6倍 (并行), 并且NNFO具有与RTTOV-DOM相当的模拟精度。此外, NNFO可以较好地重构FY-4A/AGRI可见光云图, 反射率模拟结果的偏差和均方根误差分别为-0.016和0.143。因此, NNFO具有同化应用的潜力。

**关键词:** 风云四号A星, 先进静止轨道辐射成像仪, 可见光反射率, RTTOV, 数据同化, 观测算子, 神经网络, 动态学习率

**中图分类号:** P2

**引用格式:** 何明峰, 周永波. 2024. 风云四号A星可见光反射率同化神经网络观测算子. 遥感学报, 28(12): 3261-3270

He M F and Zhou Y B. 2024. A neural network-based forward operator for assimilating the FY-4A visible reflectance.

National Remote Sensing Bulletin, 28(12): 3261-3270 [DOI: 10.11834/jrs.20243348]

## 1 引言

当前卫星资料直接同化大多关注微波和红外通道辐射资料 (孟智勇等, 2002; 龚建东, 2013; Chen等, 2015; Geer等, 2018; 杨春等, 2017; Yin等, 2021)。作为微波和红外辐射资料的补充, 可见光—中波红外 ( $\leq 4 \mu\text{m}$ , 统称为短波) 的辐射资料包含了关键的云雨信息, 同样具有重大的同化潜力。与微波辐射资料相比, 短波辐射资料具有更高的空间分辨率 (Yang等, 2017), 对中小尺度同化应用具有重要价值。红外辐射资料主要提供云顶相关信息 (薛纪善, 2009; Li等, 2022)。相比之下, 短波辐射能够深入到云顶以下一定厚度范围, 可以提供云内部信息 (Nakajima和King, 1990; Zhou等, 2021)。因此, 卫星短波辐射资料正逐步

受到同化领域的重视 (Polkinghorne和Vukicevic, 2011; Schrötte等, 2020; Scheck等, 2020; Zhou等, 2022, 2023)。

在卫星短波辐射资料同化过程中, 观测算子将大气状态变量转化到观测空间, 并将观测增量 (O-B) 转换为状态变量的分析增量, 从而实现状态变量的更新。将状态变量转化为卫星辐射观测量涉及到辐射传输过程的模拟。短波辐射传输模拟涉及多次散射过程中源函数的求解, 因而计算过程相对缓慢。在高分辨率模式模拟条件下, 还需要考虑由于邻云效应导致的三维 (3D) 辐射传输效应 (Scheck等, 2018; Zhou等, 2021)。理论上, 基于3D辐射传输方案的观测算子可以进行高分辨率条件下辐射传输过程的精确模拟, 但其计算效率远不能满足实时资料同化的要求。因此,

收稿日期: 2023-08-24; 预印本: 2024-03-21

基金项目: 国家自然科学基金青年基金 (编号: 42305161); 江苏省基础 Research 计划 (自然科学基金) (编号: BK20210665)

第一作者简介: 何明峰, 研究方向为并行计算与机器学习。E-mail: 3053529702@qq.com

通信作者简介: 周永波, 研究方向为卫星遥感与资料同化。E-mail: yongbo.zhou@nuist.edu.cn

业务运行的主流观测算子在求解辐射传输方程时均采用独立像元假定,也即一维(1D)辐射传输方案,如欧洲中期天气预报中心(ECMWF)的RTTOV-DOM(Discrete Ordinate Method)和美国卫星数据同化中心(JCSDA)的CRTM观测算子。Scheck等(2018)的研究表明,1D观测算子在大多数条件下可以取得较高的精度。

尽管1D观测算子极大地提高了观测算子的计算效率,但在资料同化过程中准确而又高效地开展高时空分辨率的可见光辐射观测模拟依然充满挑战。此外,基于集合卡尔曼滤波(及其变种方法)的同化过程涉及到将多个集合成员的状态变量转化为辐射观测量的计算,这对观测算子的计算效率提出了更高的要求。为了进一步提高1D观测算子的模拟精度,不同学者分别提出了基于查找表LUT(Look-up Table)和神经网络的观测算子。

Scheck等(2016)构建了基于LUT的观测算子MFASIS。目前,MFASIS已被纳入RTTOV中作为一个独立的观测算子并投入业务应用。由于MFASIS不涉及多次散射过程的数值求解,其计算速度比RTTOV-DOM快4个数量级。然而,反射率与大气状态变量(或诊断量)之间的关系往往是非线性的。因此,Scheck(2021)提出基于神经网络构建观测算子,一方面可以避免LUT的线性插值问题,另一方面还可以更好地处理变分法或者混合同化方法中观测算子的伴随和切线性算子。

目前,中国已经具备了高精度、大范围、高时空分辨率的静止卫星短波辐射资料观测能力。中国新一代静止气象卫星风云四号A星和B星(FY-4A和FY-4B)搭载先进的静止轨道辐射成像仪AGRI(Advanced Geostationary Radiation Imager),可实现中国区域大气的高频次(全圆盘扫描时间为15 min)和高水平分辨率(0.5—2 km)观测(Yang等,2017)。AGRI包括8个短波通道,对快速演变的中小尺度天气系统的同化预报具有广泛的应用前景(Zhang等,2019)。尽管国外已有相关研究构建了基于LUT或神经网络的观测算子,但是他们的研究并不能直接推广应用到FY-4A/B星。本研究针对FY-4A/AGRI第2通道响应函数特性和中国区域的资料同化需求,在优化Scheck(2021)神经网络模型的基础上,构建了一个适用于FY-4A/AGRI第2通道可见光辐射资料同化的快速观测算子。

## 2 理论基础

### 2.1 Scheck(2021)神经网络模型的适用性分析

Scheck(2021)神经网络模型的输入参数包括液相云光学厚度 $\tau_{\text{liq}}$ ,冰相云光学厚度 $\tau_{\text{ice}}$ ,液态云滴有效粒子半径 $Re_{\text{liq}}$ ,冰晶粒子有效粒子半径 $Re_{\text{ice}}$ ,太阳天顶角 $\theta_s$ 、卫星天顶角 $\theta_v$ ,以及太阳和卫星之间的相对方位角 $\Delta\phi$ 。然而,将Scheck(2021)模型直接应用于FY-4A/AGRI第2通道观测算子的构建存在以下3方面的问题:

(1)冰晶模型亟需进一步优化。RTTOV-DOM(version 12)包括Baum等(2011)和Baran等(2014)两类冰晶模型(Saunders等,2018)(以下分别简称为Baum和Baran模型)。Scheck(2021)利用RTTOV-DOM模式和Baum模型构建了神经网络训练数据集。

Baum模型根据冰晶的质量混合比和 $Re_{\text{ice}}$ 插值得到光学参数(相函数、单次散射反照率、消光系数)。Baran模型不依赖于 $Re_{\text{ice}}$ ,而是基于质量混合比和云内温度,通过参数化方案得到冰晶的光学参数(Saunders等,2018)。在一些微物理方案组合情况下,一些数值模式输出结果并不显式地包含 $Re_{\text{ice}}$ 。在基于Baum模型的辐射传输模拟过程中,为了完成模式状态变量到观测空间的转化,需基于一些诊断方法计算 $Re_{\text{ice}}$ ,这无疑会增加资料同化过程的计算量。此外,Baum和Baran模型的冰水含量适用范围分别是 $4.98 \times 10^{-5}—0.1831 \text{ gm}^{-3}$ 和 $6.0 \times 10^{-6}—1.969 \text{ gm}^{-3}$ (Hocking等,2016)。本研究数值模式模拟结果表明,冰水含量在一些情况下超过Baum模型的冰水含量适用范围。因此,在FY-4A/AGRI第2通道观测算子的构建中采用Baum模型是次优方案。

(2)下垫面反照率 $\omega$ 的近似处理方案可能导致不适定问题。Scheck(2021)的神经网络模型并未将 $\omega$ 作为输入参数,而是分别针对 $R(0)$ 、 $D_{0.5}$ 和 $D_1$ 构建了3个独立的神经网络模型(其中 $D_1=R(1)-R(0.5)$ , $D_{0.5}=R(0.5)-R(0)$ , $R$ 表示天顶反射率,括号内数字表示下垫面反照率)。根据 $R(0)$ 、 $D_{0.5}$ 和 $D_1$ 神经网络估计结果和Jonkheid等(2012)提出的近似公式计算得到任意 $\omega$ 的天顶反射率。

上述方法适定的前提是 $D_1>0$ 。然而,当云达到一定的厚度后,云顶以上的辐射很难穿透云到

达下垫面，且下垫面反射的辐射很难穿透云到达大气顶。此时， $R(1)$ 与 $R(0.5)$ 相等，也即 $D_1=0$ （图1）。因此，Scheck（2021）的 $\omega$ 近似处理方法会导致FY-4A可见光辐射观测模拟计算中的不适定问题。




图1 在不同下垫面反照率 $\omega$ 条件下,用RTTOV-DOM模拟的FY-4A/AGRI第2通道反射率随云水路径变化示意图(模拟时有效粒子半径为 $10\text{ }\mu\text{m}$ ,太阳天顶角、卫星天顶角、太阳与卫星的相对方位角分别为 $40^\circ$ 、 $30^\circ$ 和 $140^\circ$ )

Fig.1 The variation of FY-4A/AGRI channel 2 reflectance with cloud water path for different  $\omega$  (The simulations were performed by RTTOV-DOM configured with an effective radius of  $10\text{ }\mu\text{m}$ . The solar zenith angle, viewing zenith angle, and relative azimuth angle were  $40^\circ$ ,  $30^\circ$ , and  $140^\circ$ , respectively)

(3) 云光学厚度作为观测算子输入参数不符合FY-4A可见光资料同化的实际需求。当前针对FY-4A/AGRI可见光辐射资料的同化试验大多基于WRF-DART/RTTOV同化系统展开(Zhou等, 2022, 2023)。WRF模式的状态变量不包含云的光学参数,只包括常规的大气状态变量和云微物理变量(质量混合比、有效粒子半径等)。因此,将云光学参数作为同化观测算子的输入参数不符合当前FY-4A可见光资料同化的实际需求。

## 2.2 神经网络模型参数优化方案

基于2.1节的分析,本研究在Scheck（2021）模型的基础上,从以下3个方面优化了神经网络模型的输入参数:

(1) 在神经网络模型输入参数中去除 $Re_{ice}$ 。Baran模型比Baum模型具有更大的冰水质量混合比适用范围。此外,当数值模式不能显式地模拟 $Re_{ice}$ 时,Baran模型比Baum模型具有更高的计算效率。因此,本研究中选择Baran冰晶模型构建神经

网络训练数据集,并在输入参数中去除 $Re_{ice}$ 。

值得注意的是,Baran冰晶模型的光学参数还取决于云内温度。然而,对图2(a)所示的温度廓线 $T_{ref}$ 添加 $\pm 20\text{ K}$ 的扰动,并未造成天顶反射率明显的扰动(图2(b))。因此,本项目基于图2(a)所示的 $T_{ref}$ 温度廓线构建神经网络训练数据集,并在神经网络模型输入参数中去除温度变量。

(2) 在神经网络模型输入参数中加入 $\omega$ 。由2.1节分析可知,Scheck（2021）针对 $\omega$ 的处理方法可能会导致FY-4A可见光辐射观测模拟中的不适定问题( $D_1=0$ )。为避免此类问题,本研究在神经网络模型的输入参数中加入 $\omega$ 。

(3) 将神经网络模型输入参数中的光学厚度替换为云水路径。由于RTTOV模拟过程隐式地完成了质量混合比到消光系数的转化过程,云水路径(水成物质量混合比的垂直路径积分,CWP)或云光学厚度(云消光系数的垂直路径积分, $\tau$ )作为输入参数是等价的。因此,将 $\tau$ 替换为CWP,不仅可以保证模型的精度,还避免了将数值模式的状态变量转化为云光学参数的过程,从而简化计算过程。

综上所述,本研究神经网络模型的输入参数包括冰相云水路径与总云水路径之比 $\eta$ 、总云水路径CWP(转换为对数)、 $Re_{liq}$ 、 $\omega$ 、 $\theta_s$ 、 $\theta_v$ ,以及 $\Delta\phi$ ,输出参数为对应条件下的天顶反射率 $R$ (图3)。

## 3 模型、数据与方法

### 3.1 机器学习数据集

本研究基于RTTOV-DOM辐射传输模式模拟表1所示的预设条件(神经网络的输入变量)下FY-4A/AGRI第2通道的天顶反射率(输出变量),以此构建神经网络训练数据集。RTTOV-DOM的其他参数配置与Zhou等(2022, 2023)的相同,在此不再赘述。

当卫星视场被部分云覆盖时,天顶反射率 $R$ 根据式(1)计算(Saunders等, 2018)。

$$R(\theta_s, \theta_v, \Delta\phi) = (1 - C_e)R_{clr}(\theta_s, \theta_v, \Delta\phi) + C_e R_{cld}(\theta_s, \theta_v, \Delta\phi) \quad (1)$$

式中, $C_e$ 表示气柱有效云量, $R_{clr}$ 表示晴空条件下天顶反射率, $R_{cld}$ 表示视场被云完全覆盖时天顶反射率。式(1)中 $C_e$ 参考Geer等(2009)的方法计算。




Fig. 2 Sensitivity study of FY-4A/AGRI channel 2 reflectance to temperature profiles




图 3 神经网络结构示意图 (此网络包含 5 个隐藏层, 每个隐藏层包含  $N$  个神经元。各变量的含义详见 2.2 节)

Fig. 3 The diagram of a neural network which includes 5 hidden layers, with each hidden layer configured with  $N$  nodes (The meaning of each variable is detailed in section 2.2)

3.2 神经网络模型及超参数优化试验设计

本研究用于数据训练与测试的神经网络为前馈式神经网络。基于式 (2) 对输入数据作线性归一化,

$$x' = \frac{x}{x_{\max}} \tag{2}$$

基于 Python Tensorflow 框架下 Adam 优化器进行神经网络模型训练。损失函数为均方误差。使用 90% 的数据作为训练集, 10% 的数据作为验证

集。为优化神经网络模型配置, 本研究基于表 2 的参数设置, 针对 batch-size、激活函数、隐层数、隐层节点数开展了 4 组敏感性试验。

表 1 构建训练数据集的 RTTOV-DOM 输入变量设置 (各变量含义详见第 2.2 节)

Table 1 The input variable settings of RTTOV-DOM for constructing the training dataset (The meanings of the variables are detailed in section 2.2)

| 变量                       | 取样数 | 取值                                                                            |
|--------------------------|-----|-------------------------------------------------------------------------------|
| $CWP/(\text{kg m}^{-2})$ | 12  | 0.001, 0.01, 0.0316, 0.1, 0.3162, 1, 3.1623, 10, 31.6228, 100, 316.2278, 1000 |
| $\eta$                   | 6   | 0, 0.2, 0.4, 0.6, 0.8, 1.0                                                    |
| $Re_{liq}/\mu\text{m}$   | 8   | 2, 6, 10, 14, 18, 22, 26, 30                                                  |
| $\omega$                 | 7   | 0.001, 0.05, 0.10, 0.15, 0.20, 0.25, 0.30                                     |
| $\theta_s/(\circ)$       | 8   | 0, 10, 20, 30, 40, 50, 60, 70                                                 |
| $\theta_v/(\circ)$       | 8   | 0, 10, 20, 30, 40, 50, 60, 70                                                 |
| $\Delta\phi/(\circ)$     | 10  | 0, 20, 40, 60, 80, 100, 120, 140, 160, 180                                    |

3.3 神经网络观测算子的验证与评估

神经网络观测算子 NNFO (Neural Network based Forward Operator) 的验证包括两个方面。首先, 通过 NNFO 与 RTTOV-DOM 的比较, 揭示 NNFO 在模拟精度和效率方面的性能。其次, 通过

NNFO 模拟结果与 FY-4A/AGRI 真实观测的比较，NNFO 在 FY-4A/AGRI 可见光资料同化中的应用奠定基础。

表 2 神经网络敏感性试验超参数配置

Table 2 The configuration of hyperparameters of the neural network for sensitivity studies

| 实验组 | batch-size  | 激活函数                                                                                 | 单层隐藏层节点数                               | 隐藏层数    | 学习率   |
|-----|-------------|--------------------------------------------------------------------------------------|----------------------------------------|---------|-------|
| 1   | 128、256、512 | tanh                                                                                 | 22                                     | 4       | 0.005 |
| 2   | 512         | sigmoid、hard swish、softplus、softsign、relu、elu、relu6、leaky relu、selu、crelu、tanh、swish | 22                                     | 4       | 0.005 |
| 3   | 512         | swish                                                                                | 12、17、22、27、32、37、42、47、52、57、62、67、72 | 4       | 0.005 |
| 4   | 512         | swish                                                                                | 57                                     | 3、4、5、6 | 0.005 |

### 3.3.1 基于 WRF 模式生成测试数据集

为了验证 NNFO 的模拟效果,本研究基于 WRF v4.1 (Skamarock 等, 2008) 模式生成大气背景场。模拟区域与模式微物理方案设置与 Zhou 等 (2023) 保持一致。模式模拟的起始时间为 2020 年 8 月 17 时 00 分, 终止时间为 2020 年 9 月 19 日。为了避免模式冷启动对模拟结果的不利影响, 选择 2020 年 9 月 12 日至 2020 年 9 月 19 日之间的模拟结果进行分析。

由于 FY-4A/AGRI 可见光观测只在白天提供有效数据, 分析时刻选择北京时间 (BJT) 10:00, 13:00, 以及 16:00, 分别对应上午、中午和下午的观测。这 3 个时刻的观测可以涵盖大部分太阳高度角范围, 从而保证测试结果在不同太阳—卫星角度条件下的代表性。

### 3.3.2 基于 FY-4A 观测评估 NNFO 效果

基于 FY-4A 全圆盘 4 km×4 km 分辨率云检测

$$\text{CLM} = \begin{cases} 1(\text{有云}), \exists p_i, p_i \in P, \text{clm}(p_i) = 0 \\ 0(\text{晴空}), \frac{N[\text{clm}(p_i) = 3]}{N[\text{clm}(p_i) = 1] + N[\text{clm}(p_i) = 1] + N[\text{clm}(p_i) = 3]} \geq 80\%, p_i \in P \\ -1(\text{不确定}), \frac{N[\text{clm}(p_i) = 3]}{N[\text{clm}(p_i) = 1] + N[\text{clm}(p_i) = 1] + N[\text{clm}(p_i) = 3]} < 80\%, p_i \in P \end{cases} \quad (3)$$

式中,  $P$  表示与模拟像元空间匹配的观测像元集合,  $p_i$  表示  $P$  中的任一像元,  $\exists$  表示数学中的存在符号,  $N[\text{clm}(p_i) = 3]$  表示  $P$  中 clm 观测结果为 3 (clear) 的观测像元数目, 其他变量含义以此类推。

## 4 结果与分析

### 4.1 神经网络超参数优化结果分析

基于表 2 的 4 组敏感性试验结果表明, 当 batch-size 为 512、隐藏层激活函数为 Swish 函数 (输出层无激活函数)、隐藏层为 5、每个隐藏层有

产品和反射率产品验证 NNFO 模拟结果对真实大气的代表性。FY-4A/AGRI 全圆盘扫描周期为 15 min。为了尽可能保证观测与模拟结果在时间上相匹配, 允许观测与模拟的最大时间差在 15 min 以内。此外, 为了获得与 WRF 模式水平分辨率相匹配的反射率观测结果, 对 FY-4A/AGRI 4 km×4 km L1 反射率产品与云检测产品做水平融合处理。基本的思路是, 以 WRF 模式任一格点为圆心画半径为 10 km 的圆 (WRF 模式水平格点尺度为 20 km), FY-4A 观测落在圆内的像元记为匹配像元。将所有匹配像元的反射率作平均, 即可得到与模拟空间匹配的反射率观测结果。FY-4A 云检测 clm 结果包括 0 (cloud)、1 (probably cloud)、2 (probably clear)、3 (clear)。对于任一模拟像元, 水平融合后的云检测结果 CLM 根据式 (3) 计算。

57 个神经元时, 神经网络模拟效果优于其他参数设置。此外, 本研究采用式 (4) 的动态学习率和上述超参数优化结果, 对神经网络训练 250 次得到 NNFO。

$$lr_i = \begin{cases} \frac{0.01}{\log_{4.3}(i+4)^{(4.2+0.3(i/10))}}, i \leq 35 \\ \min(lr_{i-1}, loss_{i-1}), i > 35 \end{cases} \quad (4)$$

式中,  $lr_i$  表示第  $i$  组训练对应的学习率, 每组训练对应 5 个 epoch。( $i/10$ ) 表示被 10 整除的商。  $loss_{i-1}$  表示利用第  $i-1$  组训练得到的神经网络计算的验证

集损失函数值。当 $i \leq 35$ 时,学习率在模型训练前期较大,可保证模型较快的收敛速度,在训练后期较小,可以保证模型稳定性(损失函数在局部最优解附近振荡小)。当 $i > 35$ 时,损失函数的下降速度减小,并且损失函数与学习率相近,故采用与损失函数相关的动态学习率。

## 4.2 神经网络模型测试结果

### 4.2.1 NNFO与RTTOV-DOM模式的对比

基于WRF模拟结果,分别用RTTOV-DOM和NNFO模拟对应大气状态条件下FY-4A/AGRI第2通道天顶反射率,共得到1355344个测试样本。结果表明,RTTOV-DOM和NNFO模拟结果具有较高

的一致性(图4)。在测试过程中,NNFO会输出0—1区间外的异常值。尽管异常值样本仅占总样本数的0.004%,为了使NNFO模拟结果具有实际物理意义,基于式(5)对NNFO模拟结果(记为 $r_{NN}$ )作进一步异常值后处理,

$$r_{NN} = \begin{cases} 0, & r_{NN} < 0 \\ 1, & r_{NN} > 1 \end{cases} \quad (5)$$

式中, $r_{NN}$ 与 $r_{RT}$ (RTTOV-DOM模拟结果)的偏差( $r_{NN} - r_{RT}$ 的平均值)仅为0.001。此外, $r_{NN} - r_{RT}$ 的MAE(Mean Absolute Error)和RMSE(Root Mean Squared Error)分别为0.029和0.048。因此,在一定的误差允许范围内,同化过程中可以用NNFO替代RTTOV-DOM完成状态变量到观测变量的转化。




图4 基于RTTOV-DOM与NNFO模拟的反射率(分别用 $r_{RT}$ 和 $r_{NN}$ 表示)对比分析

Fig. 4 Comparison of the reflectance simulated by RTTOV-DOM and NNFO, which are denoted by  $r_{RT}$  and  $r_{NN}$ , respectively

### 4.2.2 NNFO模拟结果与实际观测的比较

为了进一步验证NNFO模拟结果对FY-4A/AGRI第2通道观测结果(记为 $r_{obs}$ )的代表性,将 $r_{NN}$ 与 $r_{obs}$ 作对比。图5是北京时间(BJT)2020年9月15日10:00、13:00和16:00 FY-4A/AGRI第2通道观测与模拟结果的对比分析。结果表明, $r_{NN}$ 较好地还原了东亚地区大部分云场分布特征,且反射率的空间分布与FY-4A/AGRI观测结果具有较好的一致性。

需要指出的是,NNFO模拟结果的准确性除了受到神经网络模型性能的影响,还在很大程度上依赖于WRF模拟结果的准确性。因此,在定量评估NNFO模拟误差时,需要尽量避免WRF模式模

拟误差的影响。为此,基于FY-4A/AGRI云检测结果和WRF模式模拟的有云/晴空参数,摒除WRF模拟中虚报(观测无云,模拟有云)和漏报的云(观测有云,模拟无云),仅对比观测与模拟均为有云或晴空的模拟结果。

对所有测试样本经上述处理共得到911281个匹配样本。结果表明,NNFO的模拟误差较好地符合高斯分布(图6)。集合卡尔曼滤波(及其变种方法)和变分同化方法均假定观测误差符合高斯分布,这为资料同化算法中NNFO的同化应用奠定了良好的基础。总体而言, $r_{NN}$ 偏小于 $r_{obs}$ ,偏差为-0.016。为了分析造成NNFO模拟结果偏小的可能原因,本研究进一步分析了匹配样本反射率概率密度分布函数(图7)。




图5 北京时间2020年9月15日10:00、13:00和16:00观测与NNFO模拟的FY-4A/AGRI第2通道可见光云图  
Fig. 5 The observed and NNFO-simulated FY-4A/AGRI channel 2 visible imageries at 10:00, 13:00, and 16:00 BJT on 15 September 2020




图6 NNFO模拟反射率的误差概率密度分布直方图。 $r_{NN}$ 表示NNFO模拟的反射率, $r_{obs}$ 表示观测的反射率  
Fig. 6 The probability density distribution function of the error for the reflectance simulated by NNFO.  $r_{NN}$  and  $r_{obs}$  denote the simulated and observed reflectance, respectively

反射率概率密度分布函数呈现出单峰特征。模拟反射率的峰值在0.1左右,而观测反射率的峰值在0.18,表明模拟结果低估了实际观测。这一结果可能与模拟反射率未考虑气溶胶效应有关,而实际大气中气溶胶在无云或薄云条件下会增大天顶反射率(Geiss等,2021)。

当反射率在0.12—0.5之间时, $r_{obs}$ 在此区间的发生频率大于 $r_{NN}$ 。分段误差分析结果(表3)表明, $r_{NN} - r_{obs}$ 的平均偏差为-0.006,这表明模拟结果在此区间存在轻微负偏差。




图7 NNFO和RTTOV-DOM模拟的反射率(分别表示为 $r_{NN}$ 和 $r_{RT}$ )与观测反射率(表示为 $r_{obs}$ )的概率密度分布直方图  
Fig. 7 The probability density distribution function of the reflectance simulated by NNFO and RTTOV-DOM, and the observed reflectance, denoted by  $r_{NN}$ ,  $r_{RT}$ , and  $r_{obs}$ , respectively

当反射率在0.5—1.0之间时,NNFO和RTTOV-DOM模拟结果的平均偏差高达-0.137和-0.139(表3)。较大的反射率对应较厚的云。在厚云条件下,气溶胶粒子的Mie散射效应对天顶反射率的影响变小(Geiss等,2021)。 $r_{obs} > r_{NN}$ ,可能主要与WRF云模拟结果或RTTOV-DOM中云粒子光学模型存在系统性偏差有关。一方面,在相同含水量情况下,低云对反射率的贡献比高云更为明显

(Geiss 等, 2021)。因此, WRF 模拟结果可能低估了液相云或高估了冰相云。另一方面, RTTOV-DOM 中的水云或冰云光学模型对辐射传输模拟结果有直接影响, 且这种影响在厚云条件下更为明显。

总体来说, NNFO 具有与 RTTOV-DOM 相当的模拟能力 (表 3)。在南京信息工程大学精细化区

域地球模拟与信息中心服务器集群 (2.20 GHz Xeon Silver 4214 CPU) 上, 用 NNFO 模拟一副包含  $254 \times 232$  个格点卫星云图的时间仅为 50 s (包含数据读取预处理的时间), 而 RTTOV-DOM 在并行 (包含 32 个进程) 和串行条件下分别需要 5 min (并行) 和 13 min。这表明 NNFO 在保证模拟结果可靠的条件下, 有效地提高了计算效率。

表 3 NNFO 和 RTTOM-DOM 模拟反射率的误差  
Table 3 Errors of the reflectance simulated by NNFO and RTTOV-DOM

|                                  | Bias      |             |            |          | MAE       |             |            |          | RMSE      |             |            |          |
|----------------------------------|-----------|-------------|------------|----------|-----------|-------------|------------|----------|-----------|-------------|------------|----------|
| $r_{\text{obs}}$                 | [0, 0.12) | [0.12, 0.5) | [0.5, 1.0] | [0, 1.0] | [0, 0.12) | [0.12, 0.5) | [0.5, 1.0] | [0, 1.0] | [0, 0.12) | [0.12, 0.5) | [0.5, 1.0] | [0, 1.0] |
| $r_{\text{NN}} - r_{\text{obs}}$ | 0.007     | -0.006      | -0.137     | -0.016   | 0.032     | 0.098       | 0.196      | 0.091    | 0.064     | 0.139       | 0.263      | 0.143    |
| $r_{\text{RT}} - r_{\text{obs}}$ | -0.002    | -0.004      | -0.139     | -0.017   | 0.033     | 0.100       | 0.197      | 0.092    | 0.062     | 0.141       | 0.265      | 0.144    |

注:  $r_{\text{obs}}$ 、 $r_{\text{NN}}$  和  $r_{\text{RT}}$  分别表示观测反射率、NNFO 模拟反射率和 RTTOV-DOM 模拟反射率。

5 结 论

本研究针对 FY-4A/AGRI 第 2 通道可见光波段反射率资料同化过程中观测算子计算效率偏低的问题, 在优化 Scheck (2021) 神经网络观测算子模型的基础上, 构建了适用于集合滤波同化方法的神经网络快速观测算子 NNFO, 简化了短波辐射资料同化过程中涉及多次散射的辐射传输求解过程, 从而提高了计算效率。NNFO 的输入参数包括冰相和液相总云水路径、冰相云水路径占总云水路径之比、液滴有效粒子半径、下垫面反照率、太阳天顶角、卫星天顶角、太阳与卫星的相对方位角。其中, 总云水路径、冰相云水路径占总云水路径之比、液滴有效粒子半径是 WRF 模式的状态变量或状态变量的诊断量, 可支撑基于 WRF 或其他数值模式的资料同化与应用。

为了实现此目标, 首先针对神经网络主要超参数开展了一系列敏感性试验, 得到一组优化的神经网络超参数: batch-size 为 512, 隐藏层节点数为 57, 隐藏层数为 5, 隐藏层激活函数为 Swish。在此基础上, 提出了一种动态调整学习率的方法, 在训练前期设置较大的学习率, 在训练后期设置较小的学习率, 从而在模型训练过程中一方面加速神经网络的收敛速度, 另一方面保证神经网络模型的收敛效果。

基于大量样本开展了 NNFO 与 RTTOV-DOM 模拟性能的对比分析。结果表明, NNFO 与 RTTOV-

DOM 模拟反射率之间的偏差、MAE 和 RMSE 分别为 0.001、0.029 和 0.048, 且 NNFO 的模拟速度比 RTTOV-DOM 快 15 倍 (串行) 或 6 倍 (并行)。此外, 基于 FY-4A/AGRI 第 2 通道观测对 NNFO 进行了评估。结果表明, NNFO 模拟结果的误差符合高斯分布特征, 偏差、MAE 和 RMSE 分别为 -0.016、0.091 和 0.143。这些结果表明, NNFO 在模拟速度方面具有较大的优势, 并且具有与 RTTOV-DOM 相当的模拟精度, 具备同化应用的潜力。

需要指出的是, 本研究使用的训练数据集各参数分辨率较低 (如太阳方位角取值间隔  $10^\circ$ , 相对方位角取值间隔  $20^\circ$ )。因此, 当前训练数据集的代表性还有待进一步提高。此外, 当前观测算子模型中未充分考虑气溶胶粒子对模拟结果的影响, 这也是 NNFO 在一些条件下模拟误差较大的原因。目前正在构建更高分辨率、更大样本量的训练数据集, 并在输入参数中纳入气溶胶相关参数, 预计会增强神经网络观测算子的泛化性能, 从而进一步优化 NNFO 的模拟性能。此外, 在接下来的工作中, 计划将 NNFO 集成到 WRF-DART 资料同化系统中, 并开展基于 WRF-DART/NNFO 的 FY-4A/AGRI 可见光资料同化试验, 进一步检验 NNFO 在资料同化应用中的能力。

志 谢 此论文的 FY-4A/AGRI  $4 \text{ km} \times 4 \text{ km}$  全圆盘反射率观测数据与云检测产品来自国家卫星气象中心官网, 在此表示衷心的感谢!

## 参考文献 (References)

- Baran A J, Cotton R, Furtado K, Havemann S, Labonnote L C, Marengo F, Smith A and Thelen J C. 2014. A self-consistent scattering model for cirrus. II: the high and low frequencies. *Quarterly Journal of the Royal Meteorological Society*, 140(680): 1039-1057 [DOI: 10.1002/qj.2193]
- Baum B A, Yang P, Heymsfield A J, Schmitt C G, Xie Y, Bansemer A, Hu Y X and Zhang Z B. 2011. Improvements in shortwave bulk scattering and absorption models for the remote sensing of ice clouds. *Journal of Applied Meteorology and Climatology*, 50(5): 1037-1056 [DOI: 10.1175/2010JAMC2608.1]
- Chen K Y, English S, Bormann N and Zhu J. 2015. Assessment of FY-3A and FY-3B MWHS observations. *Weather and Forecasting*, 30(5): 1280-1290 [DOI: 10.1175/WAF-D-15-0025.1]
- Geer A J, Bauer P and O'Dell C W. 2009. A revised cloud overlap scheme for fast microwave radiative transfer in rain and cloud. *Journal of Applied Meteorology and Climatology*, 48(11): 2257-2270 [DOI: 10.1175/2009JAMC2170.1]
- Geer A J, Lonitz K, Weston P, Kazumori M, Okamoto K, Zhu Y O, Liu E H, Collard A, Bell W, Migliorini S, Chambon P, Fourrié N, Kim M J, Köpken-Watts C and Schraff C. 2018. All-sky satellite data assimilation at operational weather forecasting centres. *Quarterly Journal of the Royal Meteorological Society*, 144(713): 1191-1217 [DOI: 10.1002/qj.3202]
- Geiss S, Scheck L, de Lozar A and Weissmann M. 2021. Understanding the model representation of clouds based on visible and infrared satellite observations. *Atmospheric Chemistry and Physics*, 21(16): 12273-12290 [DOI: 10.5194/acp-21-12273-2021]
- Gong J D. 2013. Data assimilation: a key technology for NWP——technical review of data assimilation in ECMWF. *Advances in Meteorological Science and Technology*, 3(3): 6-13 (龚建东. 2013. 同化技术: 数值天气预报突破的关键——以欧洲中期天气预报中心同化技术演进为例. *气象科技进展*, 3(3): 6-13) [DOI: 10.3969/j.issn.2095-1973.2013.03.001]
- Hocking J, Rayer P, Rundle D, Saunders R, Matricardi M, Geer A, Brunel P and Vidot J. 2016. RTTOV v12 Users Guide[EB/OL]. [2023-09-17]. [https://nwp-saf.eumetsat.int/site/download/documentation/rtm/docs\\_rttov12/users\\_guide\\_rttov12\\_v1.3.pdf](https://nwp-saf.eumetsat.int/site/download/documentation/rtm/docs_rttov12/users_guide_rttov12_v1.3.pdf)
- Jonkheid B J, Roebeling R A and van Meijgaard E. 2012. A fast SEVIRI simulator for quantifying retrieval uncertainties in the CM SAF cloud physical property algorithm. *Atmospheric Chemistry and Physics*, 12(22): 10957-10969 [DOI: 10.5194/acp-12-10957-2012]
- Li J, Geer A J, Okamoto K, Otkin J A, Liu Z Q, Han W and Wang P. 2022. Satellite all-sky infrared radiance assimilation: recent progress and future perspectives. *Advances in Atmospheric Sciences*, 39(1): 9-21 [DOI: 10.1007/s00376-021-1088-9]
- Meng Z Y, Xu X D and Chen L S. 2002. TBB-nudging four-dimensional data assimilation method and simulations on heavy rain process in Wuhan on 20 July, 1998. *Chinese Journal of Atmospheric Sciences*, 26(5): 663-676. (孟智勇, 徐祥德, 陈联寿. 2002. 卫星亮温资料四维同化方案及其对“7·20”武汉特大暴雨的模拟试验. *大气科学*, 26(5): 663-676) [DOI: 10.3878/j.issn.1006-9895.2002.05.07]
- Nakajima T and King M D. 1990. Determination of the optical thickness and effective particle radius of clouds from reflected solar radiation measurements. Part I: theory. *Journal of the Atmospheric Sciences*, 47(15): 1878-1893 [DOI: 10.1175/1520-0469(1990)047<1878:DOTOTA>2.0.CO;2]
- Polkinghorne R and Vukicevic T. 2011. Data assimilation of cloud-affected radiances in a cloud-resolving model. *Monthly Weather Review*, 139(3): 755-773 [DOI: 10.1175/2010MWR3360.1]
- Saunders R, Hocking J, Turner E, Rayer P, Rundle D, Brunel P, Vidot J, Roquet P, Matricardi M, Geer A, Bormann N and Lupu C. 2018. An update on the RTTOV fast radiative transfer model (currently at version 12). *Geoscientific Model Development*, 11(7): 2717-2737 [DOI: 10.5194/gmd-11-2717-2018]
- Scheck L. 2021. A neural network based forward operator for visible satellite images and its adjoint. *Journal of Quantitative Spectroscopy and Radiative Transfer*, 274: 107841 [DOI: 10.1016/j.jqsrt.2021.107841]
- Scheck L, Frèrebeau P, Buras-Schnell R and Mayer B. 2016. A fast radiative transfer method for the simulation of visible satellite imagery. *Journal of Quantitative Spectroscopy and Radiative Transfer*, 175: 54-67 [DOI: 10.1016/j.jqsrt.2016.02.008]
- Scheck L, Weissmann M and Bach L. 2020. Assimilating visible satellite images for convective-scale numerical weather prediction: a case-study. *Quarterly Journal of the Royal Meteorological Society*, 146(732): 3165-3186 [DOI: 10.1002/qj.3840]
- Scheck L, Weissmann M and Mayer B. 2018. Efficient methods to account for cloud-top inclination and cloud overlap in synthetic visible satellite images. *Journal of Atmospheric and Oceanic Technology*, 35(3): 665-685 [DOI: 10.1175/JTECH-D-17-0057.1]
- Schrötte J, Weissmann M, Scheck L and Hutt A. 2020. Assimilating visible and infrared radiances in idealized simulations of deep convection. *Monthly Weather Review*, 148(11): 4357-4375 [DOI: 10.1175/MWR-D-20-0002.1]
- Skamarock W C, Klemp J B, Dudhia J, Gill D O, Barker D M, Duda M G, Huang X Y, Wang W and Powers J G. 2008. A Description of the advanced research WRF Version 3[EB/OL]. [2023-08-11]. <https://opendata.ucar.edu/islandora/object/technotes%3A500/datastream/PDF/view>
- Xue J S. 2009. Scientific issues and perspective of assimilation of meteorological satellite data. *Acta Meteorologica Sinica*, 67(6): 903-911 (薛纪善. 2009. 气象卫星资料同化的科学问题与前景. *气象学报*, 67(6): 903-911) [DOI: 10.3321/j.issn:0577-6619.2009.06.001]
- Yang C, Min J Z and Liu Z Q. 2017. The impact of AMSR2 radiance data assimilation on the analysis and forecast of typhoon Son-Tinh. *Chinese Journal of Atmospheric Sciences*, 41(2): 372-384 (杨春, 闵锦忠, 刘志权. 2017. AMSR2 辐射率资料同化对台风“山神”分析和预报的影响研究. *大气科学*, 41(2): 372-384) [DOI: 10.3878/j.issn.1006-9895.1608.16127]
- Yang J, Zhang Z Q, Wei C Y, Lu F and Guo Q. 2017. Introducing the new generation of Chinese geostationary weather satellites, Fengyun-4.

- Bulletin of the American Meteorological Society, 98(8): 1637-1658 [DOI: 10.1175/BAMS-D-16-0065.1]
- Yin R Y, Han W, Gao Z Q and Li J. 2021. 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. *Geophysical Research Letters*, 48(15): e2021GL093672 [DOI: 10.1029/2021GL093672]
- Zhang P, Zhu L, Tang S H, Gao L, Chen L, Zheng W, Han X Z, Chen J and Shao J L. 2019. General comparison of FY-4A/AGRI with other GEO/LEO instruments and its potential and challenges in non-meteorological applications. *Frontiers in Earth Science*, 6: 224 [DOI: 10.3389/feart.2018.00224]
- Zhou Y B, Liu Y B and Han W. 2023. Demonstrating the potential impacts of assimilating FY-4A visible radiances on forecasts of cloud and precipitation with a localized particle filter. *Monthly Weather Review*, 151(5): 1167-1188 [DOI: 10.1175/MWR-D-22-0133.1]
- Zhou Y B, Liu Y B, Huo Z Y and Li Y. 2022. A preliminary evaluation of FY-4A visible radiance data assimilation by the WRF (ARW v4.1.1)/DART (Manhattan release v9.8.0)-RTTOV (v12.3) system for a tropical storm case. *Geoscientific Model Development*, 15(19): 7397-7420 [DOI: 10.5194/gmd-15-7397-2022]
- Zhou Y B, Liu Y B and Liu C. 2021. A machine learning based method to account for 3D short wave radiative effects in 1D satellite observation operators. *Journal of Quantitative Spectroscopy and Radiative Transfer*, 275: 107891 [DOI: 10.1016/j.jqsrt.2021.107891]

## A neural network-based forward operator for assimilating the FY-4A visible reflectance

HE Mingfeng<sup>1</sup>, ZHOU Yongbo<sup>2,3</sup>

1. School of Emergency Management, Nanjing University of Information Science & Technology, Nanjing 210044, China;

2. School of Atmospheric Physics, Nanjing University of Information Science & Technology, Nanjing 210044, China;

3. Precision Regional Earth Modeling and Information Center (PREMIC), Nanjing University of Information Science & Technology, Nanjing 210044, China

**Abstract:** Satellite all-sky visible reflectance contains critical information on cloud and precipitation. Data Assimilation (DA) of these information has great potential to improve the forecasting skills of numerical weather prediction models. Conventional forward operators for DA of visible reflectance employ numerical methods to simulate radiative transferring processes and suffer from a high computational burden. Therefore, conventional forward operators cannot meet the needs of operational DA.

The study constructs a fast, accurate forward operator for DA of visible reflectance data provided by the Advanced Geostationary Radiation Imager (AGRI) onboard the Fengyun-4A satellite. The forward operator is comparable with conventional forward operators in terms of accuracy and outperforms the latter in terms of computational efficiency.

A feed-forward neural network is utilized to construct the forward operator. The input parameters of the Neural Network-based Forward Operator (NNFO) include the cloud water path converted into logarithmic space, mixing ratio of ice cloud water path and total cloud water path, effective radius of cloud liquid droplets, underlying surface albedo, solar zenith angle, satellite zenith angle, and relative azimuth angle between the sun and the satellite. Top-of-atmosphere reflectance is the output of NNFO. A series of sensitivity studies is performed to determine the optimal (or suboptimal) neural network settings, which include 5 hidden layers, 57 nodes in each hidden layer, the Swish activation function for the hidden layers, and batch size of 512. In addition, the neural network is trained with an adaptive learning rate depending on the training epoch and the loss for the validation dataset, which is defined by the Root Mean Square Error (RMSE).

NNFO is compared with RTTOV-DOM, a typical forward operator based on the discrete ordinate method for simulating radiative transfer processes. Results indicate that NNFO is 15 or 6 times faster than RTTOV-DOM is in serial or parallel modes. The mean difference, RMSE, and mean absolute error of the difference in reflectance simulated by RTTOV-DOM and NNFO (RTTOV-DOM minus NNFO) are 0.001, 0.048, and 0.029, respectively, implying that the simulation accuracies of the two forward operators are comparable. In addition, NNFO is validated using FY-4A/AGRI one-week reflectance observations. The results reveal that the probability density function of the simulation errors conforms to a Gaussian function, with a mean bias and standard deviation of -0.016 and 0.052, respectively.

NNFO is comparable with traditional forward operators in terms of accuracy, with a distinguished advantage in computational efficiency. However, the current version of NNFO only supports ensemble Kalman filter methods (including their variants). For four-dimensional variational methods, NNFO should be developed by including its adjoint. Moreover, NNFO could be further improved by including aerosol effects. The improvement of NNFO in the aforementioned aspects and the extension of NNFO to DA applications are ongoing.

**Key words:** Fengyun-4A satellite, Advanced Geostationary Radiation Imager (AGRI), visible reflectance, RTTOV, data assimilation, forward operator, neural network, adaptive learning rate

**Supported by** National Natural Science Foundation of China (No. 42305161); Natural Science Foundation of Jiangsu Province (No. BK20210665)