

光学学报

深度学习与辐射传输模型协同的气溶胶反演

孙晓虎, 孙林*, 贾臣, 周峰

山东科技大学测绘与空间信息学院, 山东 青岛 266590

摘要 传统气溶胶反演方法通常先基于模型假设确定地表反射率, 但反演结果会受到假设的影响; 而深度学习方法基于数据驱动, 能在气溶胶定量反演中得到更加准确、高效的结果, 但模型训练需要充足的优质样本数据支持。为此, 使用大气辐射传输模型构建模拟样本, 支持深度学习方法实现气溶胶定量反演, 旨在解决当前训练数据代表性不足、数据获取困难的问题。利用辐射传输模型模拟不同参数条件下传感器获得的辐射信息, 考虑概率组合及筛选标准限制进行模拟数据构建, 并使用深度置信网络(DBN)对模拟样本进行训练, 获得气溶胶反演模型。将模型应用于Landsat-8数据, 在中国北京地区开展气溶胶反演实验。最后使用AERONET地面站点的实测数据对反演结果进行精度验证。验证结果表明, 模型估算的气溶胶与站点测量值吻合良好, 相关系数为0.8989, 均方根误差为0.1029, 约74.05%的估算值在误差标准内。本文提供了一种基于辐射传输方程构建样本数据集的思路, 可减少样本质量与数量导致的局限性, 实现深度学习方法对气溶胶光学厚度的高精度反演。

关键词 气溶胶光学厚度; 辐射传输方程; Landsat-8卫星; 深度置信网络

中图分类号 P407 文献标志码 A

DOI: 10.3788/AOS230673

1 引言

气溶胶作为地-气系统中的重要组成成分^[1], 对地球辐射收支平衡^[2]、全球气候变化及空气质量^[3]、人体健康等诸多方面都有十分重要的影响^[3-5]。气溶胶光学厚度(AOD)作为表征气溶胶光学特性的重要参数, 可反映整层大气气溶胶的消光作用, 是监测大气气溶胶的重要指标。卫星遥感因长时间、大范围监测的能力, 为大面积AOD的估算提供了一种有效的方法。然而, 气溶胶反演属于病态反演, 即卫星数据提供的信息量无法支持气溶胶物理模型的求解。众多科学研究致力于解决这个问题^[6-7], 目前发展了多种气溶胶反演方法。

应用较为广泛的是基于物理模型的暗目标法(DT)和深蓝算法(DB)。它们通过对大气辐射传输过程中地表反射率参数的假设, 模拟地表、大气和卫星信号的关系, 构建查找表进而反演气溶胶光学厚度。暗目标法利用影像上暗目标像元在短波红外处(2.1 μm)与红、蓝波段有着一定比例关系的特点, 估算了气溶胶光学厚度^[8-10]; 深蓝算法则利用大部分地物在深蓝波段(412 nm)反射率低的特性, 建立先验地表反射率数据库, 解决了地表和大气耦合问题^[11-12]。此外, 多角度大气校正算法(MAIAC)使用时间序列分析

地表双向反射因子(BRF)和反照率, 利用时间序列的一致性要求提供了额外约束来提高估算AOD的精度^[13]。但是, 利用先验知识对反演因素进行简化会造成误差的积累与传播, 并且查找表通常是基于蓝波段或红波段构建的, 这也是对影像信息利用的极大不足。随着各类机器学习算法的涌现, 深度学习算法已成为建立AOD估算模型的首选^[14]。深度学习以强大的非线性拟合学习能力, 通过网络模型直接近似AOD和卫星表观反射率信息之间的复杂物理关系, 避免一系列先验知识假设就可实现对气溶胶光学厚度的定量化描述。2012年Ristovski等^[15]和2010年Radosavljevic等^[16]使用AERONET站点观测的AOD值和MODIS卫星遥感数据为训练样本训练得到的神经网络模型, 反演得到的AOD精度都优于MODIS官方AOD产品。2016年Huttunen等^[17]对比基于查找表的物理方法、非线性回归统计方法、深度学习方法, 发现深度学习方法能够表现出更优的性能。2017年Lanzaco等^[18]通过分析AOD误差规律, 加入气象辅助数据训练了用于修正AOD精度的神经网络, 减小了MODIS AOD产品在南美洲部分区域的误差。2021年梁天辰等^[19]在GEE云平台上利用深度置信网络对小尺度区域的气溶胶光学厚度进行了研究。2022年莫祖斯等^[20]基于广义回归神经网络, 结合气溶胶消光系数和气象要

收稿日期: 2023-03-14; 修回日期: 2023-04-19; 录用日期: 2023-05-19; 网络首发日期: 2023-06-28

基金项目: 国家自然科学基金(42271412)

通信作者: *sunlin6@126.com

素评估了南京市颗粒物质量浓度。但使用深度学习进行定量反演的前提是获取大量优良的样本数据集,2020年高迦南等^[21]将在香河地区训练的神经网络(NN)模型应用于环境差异较大的香港地区,发现模型可迁移性较差。可见训练样本的质量和代表性决定了最终模型的精度和适用范围。当前样本构建是利用站点数据和历史影像进行匹配实现的,由于地面站点(AERONET)的稀疏,训练样本缺乏代表性,一定程度上存在有偏的问题,并且由于云覆盖及卫星重放周期限制,训练样本数量也不足,这都极大程度上影响了反演模型的精度。

为解决上述问题,本文利用大气辐射传输模型模拟不同条件下卫星各波段的表观反射率,根据研究区域内参数统计关系及考虑概率分布的情况下,对不同波段及参数进行组合,构建出符合真实场景的模拟数据集,以支持深度学习方法的气溶胶遥感反演。将训练的反演模型应用于Landsat-8 OLI传感器数据,反演了北京城市地表上空的高分辨率(30 m)气溶胶影像,并对其与AERONET地面站点数据进行精度验证。所提方法可以极大程度保证样本的全面性,减小气溶胶反演的误差;高分辨率影像也给研究区域尺度范围内的气溶胶光学厚度空间分布提供了更详细的局部细节,在污染源监测等方面具有重要意义。

2 研究区和数据源

2.1 研究区域

选取北京市(115.4° E~ 117.6° E, 39.4° N~ 41.1° N)作为研究区。该地区位于华北平原北部,地貌主要由西北山地和东南平原两大地貌单元组成。北京市作为世界级城市,面临着严重的空气污染问题,由于北京市区地表类型复杂且地表反射率较高,可以用来验证算法的陆地表面适用性,但同时这也对AOD反演的准确性带来了挑战^[22]。

2.2 地面站点数据

Aerosol robotic network(AERONET)是基于地面监测的全球气溶胶观测网络,提供长期的气溶胶监测,可提供近实时气溶胶信息且观测误差只有0.02^[23]。AERONET共提供3种不同质量级别产品:1.0级别(未经筛选验证)、1.5级别(经过云剔除)、2.0级别(严格质量保证)。本文选取包括北京市区的3个站点(Beijing、Beijing-CAMS、Beijing-RADI)和位于郊区的1个站点(XiangHe),筛选卫星过境时AERONET站点的AOD实测值用于对反演结果进行定量化验证。由于数据中不提供550 nm波段处AOD测量值,因此选择受水汽影响小且距离550 nm处最近的440 nm和870 nm通道的数据,该数据由Ångström经验方程进行插值获得,

$$\tau(\lambda_0) = \beta \lambda_0^{-\alpha}, \quad (1)$$

$$\alpha = -\frac{\ln[\tau(\lambda_1)/\tau(\lambda_2)]}{\ln(\lambda_1/\lambda_2)}, \quad (2)$$

$$\beta = \frac{\tau(\lambda_1)}{\lambda_1^{-\alpha}}, \quad (3)$$

式中: $\tau(\lambda)$ 为波长 λ 处的气溶胶光学厚度; α 为波长指数; β 为Ångström浑浊度系数; λ_0 、 λ_1 、 λ_2 分别为550 nm、440 nm、870 nm。

2.3 卫星数据

Landsat-8卫星于2013年2月发射,搭载了两个传感器,包括多光谱陆地成像仪(OLI)和热红外传感器(TIRS)。其中,OLI传感器瞬时视场角为 15° ,幅宽为185 km,具有从深蓝到短波红外(SWIR)共9个波段,除了全色波段(B8)空间分辨率为15 m,其余波段分辨率都为30 m。Landsat-8 OLI为12 bit的多光谱传感器,对高反射率的明亮表面具有较高的敏感性和较低的波段过饱和性,并且辐射定标的精度优于3%,这对反演高亮地表的城市地区相关数据十分重要^[24-25]。为验证地表反射率值分布范围,应用了Landsat-8地表反射率产品,该数据由陆地表面反射率代码(LaSRC)生成,并使用了独特的辐射传输模型,辐射率不确定性从SWIR的0.11%到蓝波段的0.85%,因此具有高准确度^[26]。

3 原理与方法

3.1 气溶胶反演原理

辐射传输方程是模拟电磁波与大气、地表信息间相互耦合作用的物理模型,其过程可以描述为太阳辐射经大气作用被地表反射后,由传感器接收能量信息。卫星所获取的辐射能量 L 可表示为

$$L(\theta_s, \theta_v, \varphi) = L_0(\theta_s, \theta_v, \varphi) + \frac{\rho}{1 - \rho S} F_0 \cos(\theta_s) T^*(\theta_s) T^*(\theta_v), \quad (4)$$

式中: L_0 为大气程辐射项; ρ 为地表反射率; S 为大气下界的半球反照率; F_0 为大气顶层的辐射通量密度; $T^*(\theta_s)$ 和 $T^*(\theta_v)$ 分别表示大气下行透过率和大气上行透过率; θ_s 、 θ_v 和 φ 分别表示太阳天顶角、观测天顶角和相对方位角。通过求解该前向模型,可实现气溶胶定量反演,但未知参数的气溶胶模型与地表反射率的确定尤为困难。现有算法通常利用先验知识确定气溶胶模型,选择先验地表反射率数据产品来支持气溶胶光学厚度反演。在诸如海洋、浓密植被这类地表反射率较小且较易确定的区域上空,现有算法可以很好地实现地气解耦合的过程;而在像城市这类高亮地表区域,地表反射率高且空间异质性大, L 对气溶胶的标识性变弱,使得大气与地表信息无法分离,且先验地表反射率产品的误差也极大地影响了气溶胶反演的精度。

由于反演机理复杂,使用多层级、多节点的神经网络可以建立数据自身多输入变量与单一输出变量之间

的复杂关系。通过对大量样本数据的学习,充分挖掘信息之间的隐含关系,以复杂的深层网络结构和非线性变换算法,实现对变量间的抽象表达。本文期望充分利用卫星各波段数据信息,利用深度学习方法对辐射传输模型所构建的模拟样本数据库进行学习,挖掘气溶胶光学厚度与各输入参数间的隐含关系,从而实现对气溶胶光学厚度的定量化描述。

3.2 模拟数据构建

辐射传输方程是模拟样本构建的基础,通过分析各参数可能分布的范围对式(4)进行求解,即可获得方程中任意参量间的对应关系。根据式(4)基于回归思想,卫星获取的表观反射率及各几何参数作为自变量,气溶胶光学厚度作为因变量,即可实现对气溶胶的定量化描述。理论上,通过遍历参数所有可能分布范围,可模拟出任意条件下的样本数据。

6S (Second Simulation of Satellite Signal in the Solar Spectrum)模型因精度高、效率快而广泛应用于辐射传输模拟^[27]。6S模型考虑了大气相互作用及地表方向性反射问题,描述了太阳辐射能量携带地表光谱信息与大气耦合后,到达卫星入瞳处的过程。通过在6S模型中输入地表反射率、几何参数、550 nm气溶胶光学厚度、大气模型及气溶胶模式,可模拟计算传感器在该状态因素下所接收到的信号,即表观反射率(TOA)。因此利用6S辐射传输模型构建遥感数据可获得参数和气溶胶光学厚度之间的模拟样本。该方式获得的模拟样本数据保证了参数间关系符合辐射传输规律,既确保样本数据包含了研究区可能存在的地表因素,使得样本数据具有代表性与无偏性,同时又消除了云覆盖、重放周期导致数据量不足的缺陷,从而构建了输入参量(表观反射率和几何角度)和输出的气溶胶参数(550 nm AOD)相匹配的充足样本数据。

根据对北京地区气溶胶单次散射反照率(SSA)和不对称因子(G)的相关研究^[28],发现该区域气溶胶类型没有显著的空间变化,因此选择大陆性气溶胶模式;

且在正常大气条件下,AOD范围在2以内;对于大气模式,根据研究区所处地理位置选择中纬度夏季和中纬度冬季,确保反演模型满足不同的大气条件。图1极坐标图为研究区内Landsat-8所有可能存在的姿态(蓝色)及太阳几何(红色)参数。从图1可知:Landsat-8的瞬时视场角较小,对于每个像素,观测天顶角和观测方位角只在4°~6°的范围内变化,而太阳天顶角从20°变化到70°,太阳方位角从120°变化到165°。由于Landsat-8 OLI波段范围覆盖0.43 nm到2.29 nm,且地物的反射特征随波长不同而变化,在可见光与短波红外处更是相差巨大,因此对于不同波段需设置不同范围。对比Landsat-8地表反射率数据,所使用7个波段下的地表反射率使得设置范围应包含其值域范围。需注意的是,为满足所有地表和气候条件,参数值域应大于等于实际情况,且应尽可能合理表达参数分布,保证样本全面性的同时简化设置以改善计算效率;在考虑各输入参量的值域范围下,对不同波段及参数根据其联合概率进行组合,形成尽可能满足所有状态的真实场景,形成具有广泛代表性的样本集,具体参数设置如表1所示。

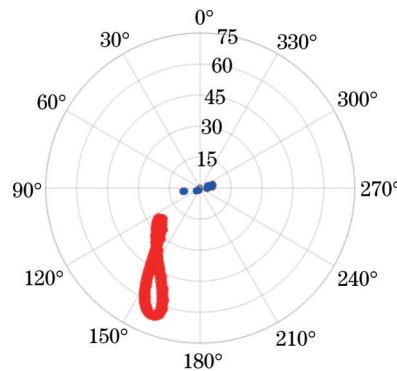


图1 北京地区Landsat-8成像时太阳(红色)和卫星(蓝色)几何形状

Fig. 1 Solar (red) and satellite (blue) geometry of Landsat-8 OLI data for study period in Beijing

表1 辐射传输模型各参数设置
Table 1 Parameter settings for radiative transfer model

Parameter	Symbol	Range or fixed value	Prior information
Sun zenith angle	asol	20°~70°	Landsat-8 metadata
View zenith angle	avis	5°	Landsat-8 metadata
Relative azimuth angle	phiv	115°~175°	Landsat-8 metadata
Atmospheric model	idatm	2, 3	Model default
Aerosol model(type)	iaer	1	Model default
AOD		0~2	AERONET site
Land surface reflectance	B1, B2 / μm	0.01~0.25	
	B3 / μm	0.02~0.35	
	B4 / μm	0.02~0.4	LaSRC
	B5, B6, B7 / μm	0.05~0.5	

3.3 模拟样本的筛选

对不同波段及参数间进行组合时虽然考虑了联合概率,模拟了尽可能多的地表场景,但也造成了不现实的组合情况,造成训练样本有偏的问题,对结果产生很大的不确定性,难以达到预期的效果。通过研究各参数之间的统计关系,发现获取特定区域数据时的太阳天顶角和相对方位角不是独立的,如图2所示,相邻波段间的TOA也存在着极大的相关性(E_{RMS}),如图3所示。通过考虑这些信息,可以将它们作为控制标准,筛选去除在目标研究区域内可能永远不会发生的组合,从而让训练的模型更加泛化、更加精确。

其中目标研究区域的太阳天顶角和相对方位角相互之间存在一定的规律性,可以用非线性函数表述;相邻波段的表观反射率也可互相表示,可见光波段间(B1_{0.435~0.451 μm}、B2_{0.452~0.512 μm}、B3_{0.533~0.590 μm}、B4_{0.636~0.673 μm})有着很强的线性关系,短波红外间(B6_{1.566~1.651 μm}和B7_{2.107~2.294 μm})可以用二次多项式来表示,而近红外波段(B5_{0.851~0.879 μm})也可用一些非线性曲线与相邻波段间(B4_{0.636~0.673 μm}和B6_{1.566~1.651 μm})相互拟合。

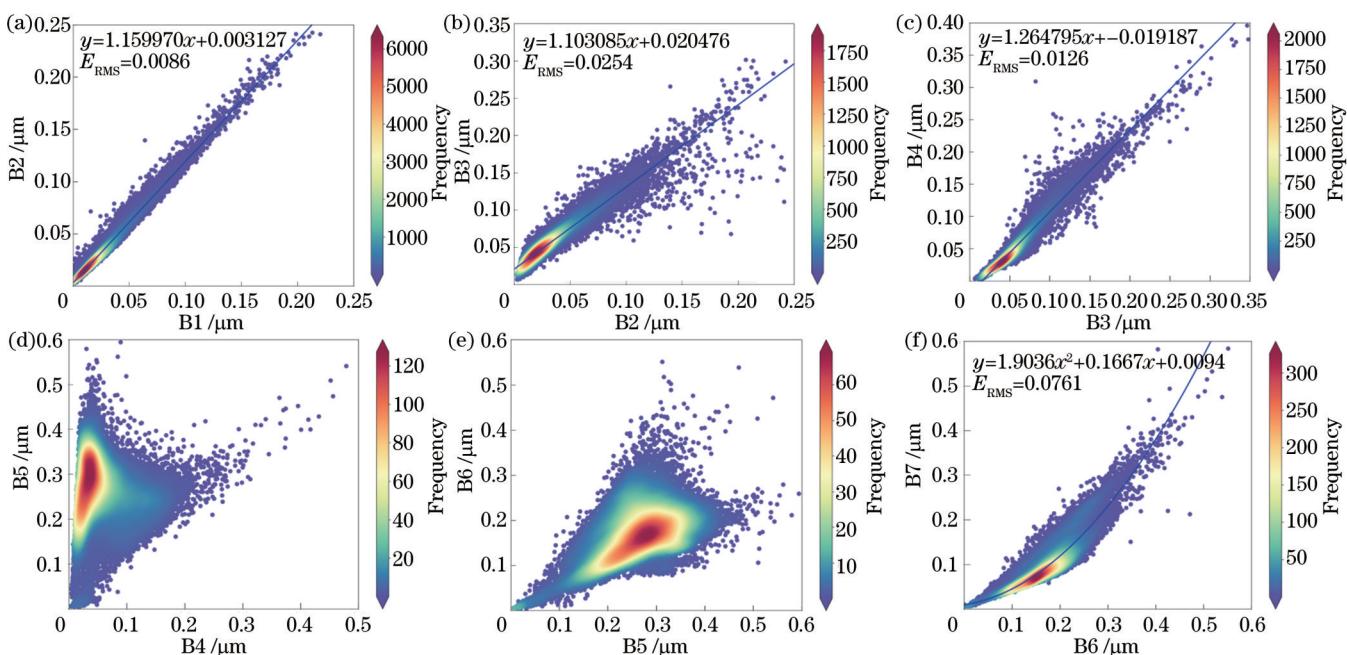


图3 相邻波段间统计关系信息间的拟合。(a) B1-B2;(b) B2-B3;(c) B3-B4;(d) B4-B5;(e) B5-B6;(f) B6-B7

Fig. 3 Fitting of statistical relationship information between adjacent bands. (a) B1-B2; (b) B2-B3; (c) B3-B4; (d) B4-B5; (e) B5-B6; (f) B6-B7

3.4 网络模型构建及训练

深度置信网络(DBN)^[29-30]是首批深度学习模型之一,它使用无监督的预训练方式表现出更好的性能。DBN通过引入受限玻尔兹曼机(RBM)探究观测变量的数据结构关系,根据贝叶斯思维,通过寻找数据的联合概率分布,获取数据隐含的深层信息。与其他深度学习算法相比,它在复杂数值回归问题中的应用具有独特的优势。DBN算法还具有学习能力强、适应不同

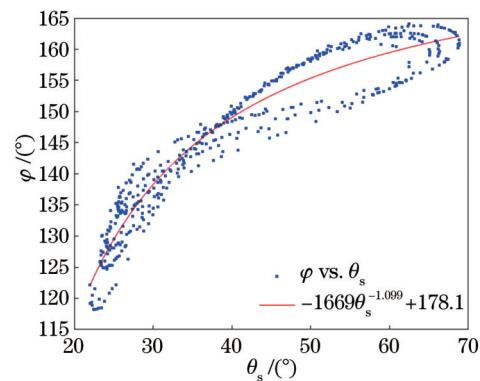


图2 研究区内卫星几何参数信息拟合关系

Fig. 2 Information fitting relationship of satellite geometric parameters in the study area

合,但由于方程的复杂程度和误差范围,这里不把近红外波段当作筛选的标准。因此,在考虑联合概率情况下对不同参数之间进行全组合,利用表2中各参数间的统计关系作为筛选标准,去除训练样本中不符合现实组合情况的参数样本,保证了样本的分布与实际数据的一致。

问题的快速调整等优点。因此,采用DBN算法来实现遥感气溶胶反演。DBN模型训练时,输入参量为模拟数据的各波段TOA和观测几何角度,输出参量为考虑大气参数范围后设置的AOD。

DBN可视为RBM^[31]的堆栈,结构如图4所示。每个RBM有两层神经元,其中可见层用于数据训练,隐藏层用于特征检测。堆叠的RBM层与层之间相互连接,而层内相互独立,前一个RBM的隐藏层被视为下

表2 参数信息拟合方程

Table 2 Fitted equations between parameter information

Statistical type	Fitting function	Selection criteria
Angular geometry	$F(\theta_s, \varphi)$	$ -1669 \times \theta_s^{-1.099} + 178.1 - \varphi < 5$
	$F(B_1, B_2)$	$ 1.159970 \times B_1 + 0.0031 - B_2 < 2 \times E_{\text{RMS } B_1, B_2}$
Visible spectrum	$F(B_2, B_3)$	$ 1.103085 \times B_2 + 0.0205 - B_3 < 2 \times E_{\text{RMS } B_2, B_3}$
	$F(B_3, B_4)$	$ 1.264795 \times B_3 - 0.0192 - B_4 < 2 \times E_{\text{RMS } B_3, B_4}$
SWIR	$F(B_6, B_7)$	$ 1.9036 \times B_6^2 + 0.1667 \times B_6 + 0.0094 - B_7 < 2 \times E_{\text{RMS } B_6, B_7}$

一个RBM的可见层,并且使用来自第一个RBM的输出来训练第二个RBM,并重复该过程,直到网络中的每一层都得到训练。通过利用权重 W_i 和偏置 b_i 即可实现由卫星遥感输入数据到输出数据的估算,即实现气溶胶反演过程。不同于其他种类的模型,DBN中每个RBM学习整个输入,提取特征并尽可能准确地重构输入。DBN采用堆叠的RBM对大量数据做逐层无监督训练^[32],提炼训练数据的本质特征,获得深度网络参数初值;再用传统的BP算法^[33]对整体DBN进行调整优化,使DBN克服易陷入局部最优的问题。模型训练时,依据样本数据对不同数值的参数进行实验,确定DBN模型的相应网络参数。其中DBN输入层的神经元数目为8,逻辑回归层预测输出的神经元数目为1,DBN模型结构包含2层隐藏层,每一层隐藏层的神经元数目是10。

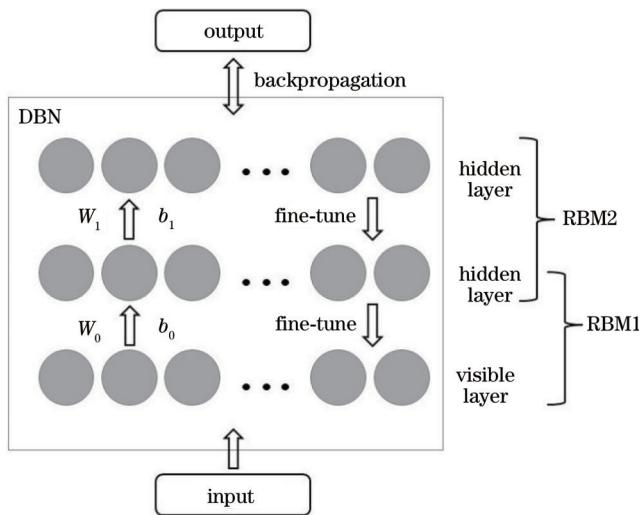


图4 DBN结构
Fig. 4 DBN structure

4 实验结果与分析

为验证气溶胶反演结果的精度,获取研究区内相近时间的AERONET站点实测数据,对结果进行定量

验证。由于地面站点与Landsat-8 AOD之间的时间和空间分辨率不同,需要采用一定的时空匹配策略获取对应AOD点对。时间匹配上,首先采取卫星数据过境时的AERONET站点值作为真实值,若数据不存在,则采用卫星过境前后的15 min范围内至少两次实测AOD的平均值代替;空间匹配上,以AERONET站点为中心的5×5区域为取样窗口。同时为尽可能减少云造成的像元污染,降低大气不稳定对验证结果的影响,剔除取样窗口上20%较大值和20%较小值,剩余像元按照QA波段进行云判断,若有效像元小于10个,则全部舍弃不参与验证,若大于等于10个,则取剩余结果的平均值作为气溶胶反演值。在目标研究区共获得343组AOD验证点对,选择Pearson相关系数(R)、平均绝对误差(MAE)和均方根误差(RMSE)三个指标定量评价反演精度,并利用MODIS期望误差(EE)分析反演结果与真实值之间的分布情况。相关指标计算公式分别为

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (5)$$

$$E_{\text{MA}} = \frac{1}{n} \sum_{i=1}^n |y_i - x_i|, \quad (6)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2}, \quad (7)$$

$$E_{\text{E}} = \pm (0.05 + 0.2 \times x_i), \quad (8)$$

式中: y_i 和 x_i 分别为模型估算值和AERONET站点观测值; \bar{y} 和 \bar{x} 分别为估算值和观测值的平均值; n 为验证点对数量。

对于用于验证反演结果的343组AOD点对,其中Beijing站共105组点对,Beijing_CAMS站共93组点对,Beijing_RADI站共38组点对,XiangHe站共107组点对,图5(a)~(d)为各站点验证结果,图5(e)为目标研究区域的总验证结果。从单个站点的验证结果来看,4个站点的反演的AOD值与AERONET实测值均

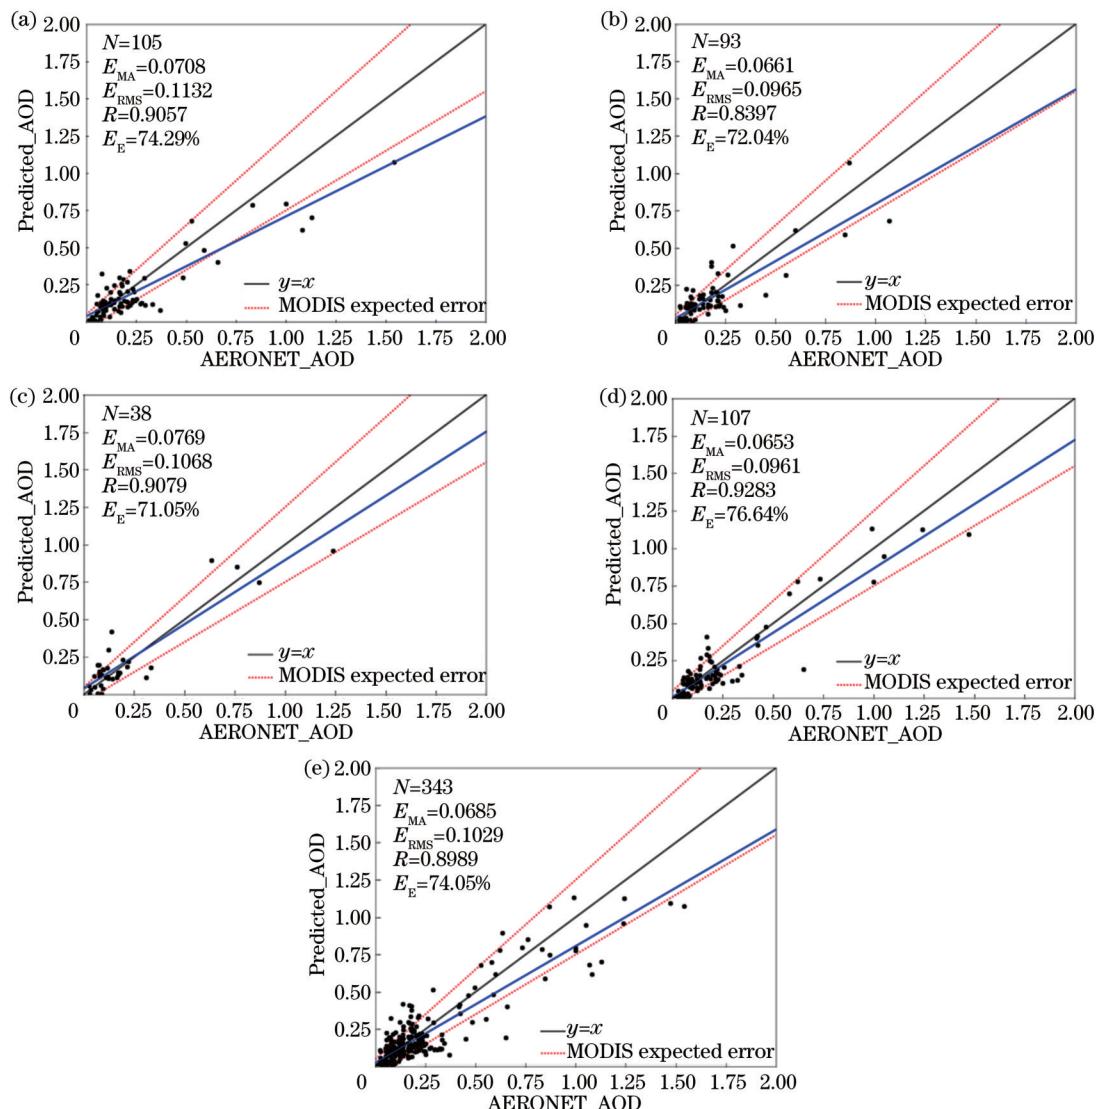


图 5 气溶胶预测结果与 AERONET 站点观测值的散点图。(a)北京站;(b)Beijing_CAMS 站;(c)Beijing_RADI 站;(d)香河站;(e)总站点

Fig. 5 Scatter distribution of aerosol inversion results matched with AERONET measured data. (a) Beijing; (b) Beijing_CAMS; (c) Beijing_RADI; (d) XiangHe; (e) total

有很强的相关性($R=0.8397\sim0.9283$),72%以上的点对位于误差期望以内,均具有比较稳定的反演结果。从研究区域整体结果来看:反演值的误差相对较小,MAE 和 RMSE 分别为 0.0685 和 0.1029,且与 AERONET 实测值相关性较高, $R=0.8989$;在总共的 343 组点对中,有 74.05% 的点对位于期望误差以内;但仍有部分结果表现出低估的现象,主要表现为 AOD 值在 0.5 以上区域。图 6 为 6S 模型模拟的 B1 波段的表观反射率随 AOD 的变化趋势,其余波段存在相似的趋势。参数设置如图例所示,不同线型代表不同地表反射率情况。由图 6 可知,当地表反射率较小时,表观反射率随着 AOD 的增大而快速增大,当地表反射率变大时,增长趋势变缓且当地表反射率大到一定条件时,表观反射率不随 AOD 增大而变化或出现显著减小的情况。由于目标研究区 AERONET 站点所处位置的

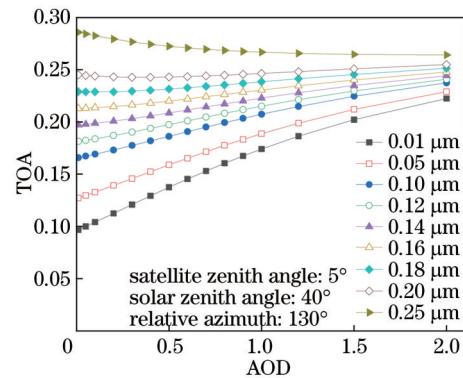


图 6 Landsat-8 表观反射率随 AOD 增大的变化趋势
Fig. 6 TOA of Landsat-8 changing with the increase of AOD

地表反射率较大,表观反射率对 AOD 的敏感性变小,且模拟样本构建时,对于地表反射率较大值处设置间

隔大, 所以导致反演误差变大, 这可能是出现低估现象的主要原因。

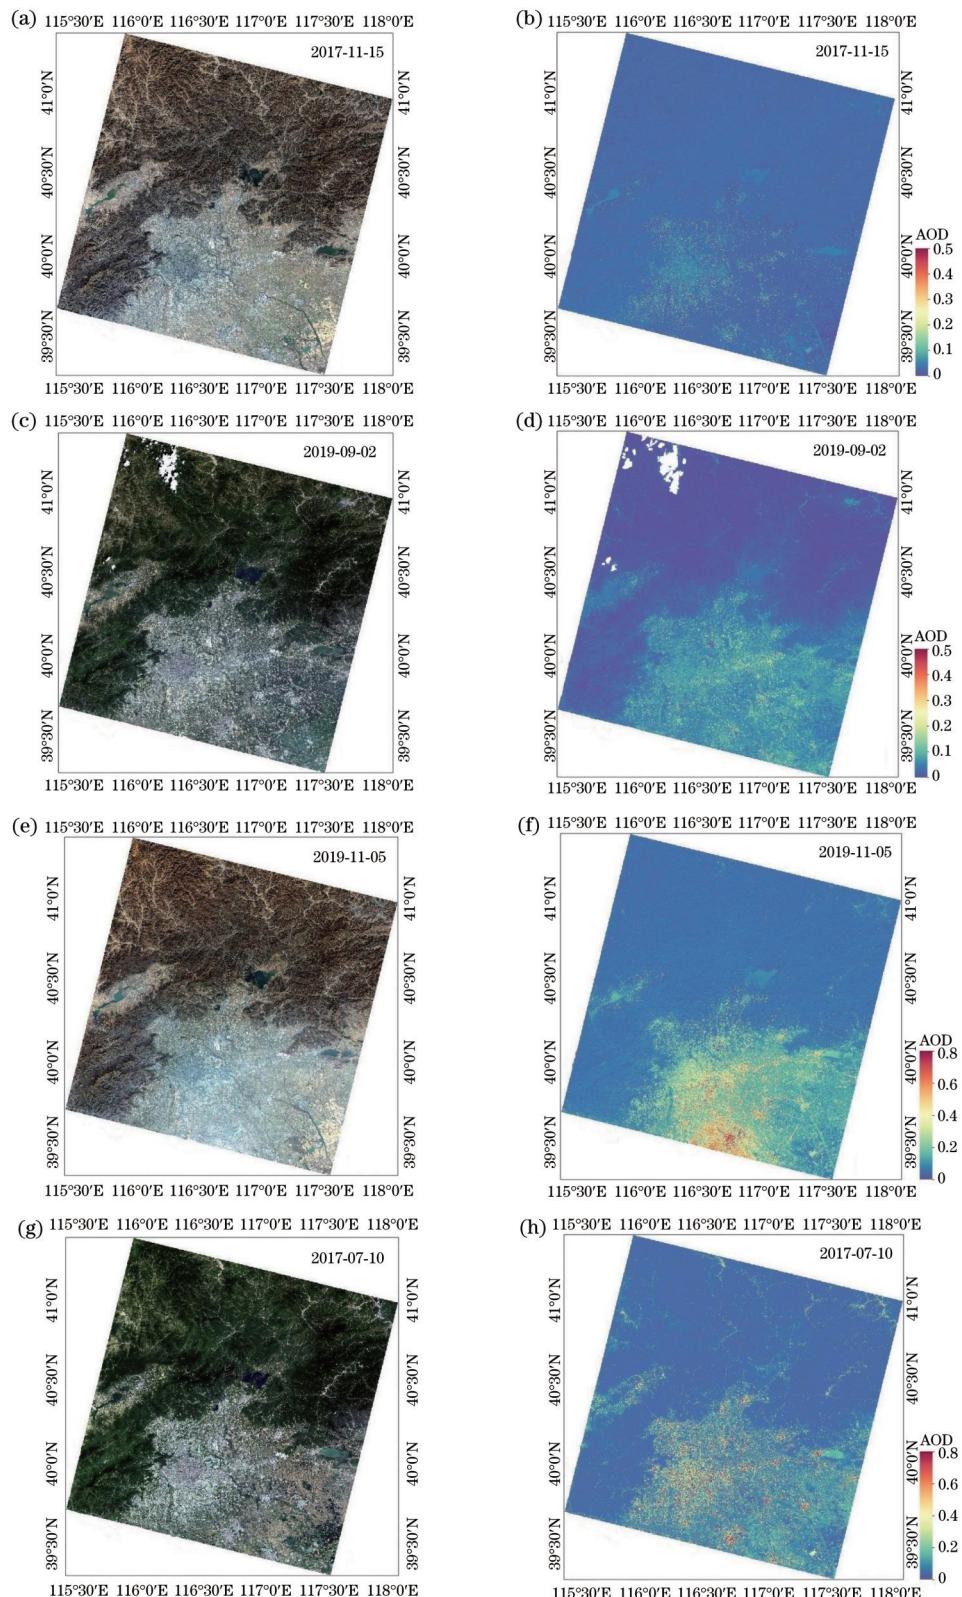


图 7 气溶胶光学厚度反演结果空间分布。(a)(b)2017-11-15 研究区一景 RGB 图与 AOD 图;(c)(d)2019-09-02 研究区一景 RGB 图与 AOD 图;(e)(f)2019-11-05 研究区一景 RGB 图与 AOD 图;(g)(h)2017-07-10 研究区一景 RGB 图与 AOD 图

Fig. 7 Spatial distribution of aerosol optical depth inversion results. (a)(b) RGB map and AOD map obtained by Lansat-8 on 2017-11-15; (c)(d) RGB map and AOD map obtained by Lansat-8 on 2019-09-02; (e)(f) RGB map and AOD map obtained by Lansat-8 on 2019-11-05; (g)(h) RGB map and AOD map obtained by Lansat-8 on 2017-07-10

图7(a)(b)为2017-11-15的真彩色影像与模型反演结果,图7(c)(d)为2019-09-02的真彩色影像与模型反演结果,图7(e)(f)为2019-11-05的真彩色影像与模型反演结果,图7(g)(h)为2017-07-10的真彩色影像与模型反演结果。需要注意的是,图7(b)(d)的AOD范围为0~0.5,图7(f)(h)的AOD范围为0~0.8。从图7可以看出:在东南部城市地区人类活动频繁,气溶胶光学厚度普遍偏大;西北部存在大量植被,空气质量好,气溶胶光学厚度较低。反演整体结果趋势合理,分布连续,并提供了全空间覆盖的气溶胶反演结果。同时30 m空间分辨率下气溶胶影像可以提供局部细节,能从中观察更详细的城市地区AOD空间分布信息,在污染源监测等方面有重要意义。

5 结 论

利用大气辐射传输模型构建样本数据集,支持深度学习算法进行Landsat-8高分辨率气溶胶反演。利用6S大气辐射传输模型模拟了不同情况下Landsat-8 OLI不同波段的表观反射率,通过对研究区域内参数的遍历及在考虑其联合概率的情况下对不同参数的组合,构建了不同情况下的真实场景,满足了样本数据无偏性。同时为解决反演过程中不适应问题,利用几何角度信息与相邻波段表观反射率间的统计信息对样本数据进行筛选,对参数间的组合情况进行限制。利用模拟的样本数据训练气溶胶反演模型,在北京地区开展气溶胶反演实验,并与AERONET气溶胶地面站点实测值进行精度验证。结果表明,利用模拟数据支持深度学习算法的方法精度较高,与实测数据间误差较小且相关性高($R=0.8989$),其中均方根误差和平均绝对误差分别为0.1029和0.0685,约有74.05%的数据落在EE线内。所提方法利用模拟数据解决了深度学习训练样本有偏性及数据量问题,能够更好地利用大量的训练数据,学习出更复杂、更准确的气溶胶光学厚度与观测参数之间的关系,从而实现更精确的反演结果。该研究仍有不确定性需要进一步改进。首先,尽管已经对模拟数据进行了筛选,但无法去除相似的光谱组合,存在冗余错误;其次,本文仅针对目标研究区进行模拟数据的构建,对于全球范围内气溶胶的反演,所考虑的参数设置也将更为复杂。

参 考 文 献

- [1] Li J, Boer G J. The continuity equation for the stratospheric aerosol and its characteristic curves[J]. Journal of the Atmospheric Sciences, 2000, 57(3): 442-451.
- [2] Sokolik I N, Toon O B. Direct radiative forcing by anthropogenic airborne mineral aerosols[J]. Nature, 1996, 381(6584): 681-683.
- [3] Charlson R J, Schwartz S E, Hales J M, et al. Climate forcing by anthropogenic aerosols[J]. Science, 1992, 255(5043): 423-430.
- [4] Boucher O, Anderson T L. General circulation model assessment of the sensitivity of direct climate forcing by anthropogenic sulfate aerosols to aerosol size and chemistry[J]. Journal of Geophysical Research: Atmospheres, 1995, 100(D12): 26117-26134.
- [5] Toon O B. How pollution suppresses rain[J]. Science, 2000, 287(5459): 1763-1765.
- [6] 丁宁,于博,颜昌翔,等.星载气溶胶被动光学遥感仪器:进展与未来展望[J].光学学报,2022,42(17): 1701002.
- [7] Ding N, Yu B, Yan C X, et al. Spaceborne aerosol passive optical remote sensing instruments: progress and future prospects [J]. Acta Optica Sinica, 2022, 42(17): 1701002.
- [8] 廖淑君,郜海阳,寇蕾蕾,等.星载激光雷达探测云与气溶胶的仿真模拟[J].激光与光电子学进展,2022,59(10): 1028001.
- [9] Liao S J, Gao H Y, Kou L L, et al. Simulation of cloud and aerosol detection based on spaceborne lidar[J]. Laser & Optoelectronics Progress, 2022, 59(10): 1028001.
- [10] Kaufman Y J, Sende C. Algorithm for automatic atmospheric corrections to visible and near-IR satellite imagery[J]. International Journal of Remote Sensing, 1988, 9(8): 1357-1381.
- [11] Holben B, Vermote E, Kaufman Y J, et al. Aerosol retrieval over land from AVHRR data-application for atmospheric correction[J]. IEEE Transactions on Geoscience and Remote Sensing, 1992, 30(2): 212-222.
- [12] Levy R C, Remer L A, Mattoo S, et al. Second-generation operational algorithm: retrieval of aerosol properties over land from inversion of moderate resolution imaging spectroradiometer spectral reflectance[J]. Journal of Geophysical Research: Atmospheres, 2007, 112(D13): D13211.
- [13] Hsu N C, Tsay S C, King M D, et al. Aerosol properties over bright-reflecting source regions[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(3): 557-569.
- [14] Hsu N C, Tsay S C, King M D, et al. Deep blue retrievals of Asian aerosol properties during ACE-Asia[J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(11): 3180-3195.
- [15] Lyapustin A, Wang Y, Laszlo I, et al. Multiangle implementation of atmospheric correction (MAIAC): aerosol algorithm[J]. Journal of Geophysical Research: Atmospheres, 2011, 116(D3): D03210.
- [16] 陈兴峰,郑逢杰,郭丁,等.气溶胶定量遥感的机器学习方法综述[J].遥感学报,2021,25(11): 2220-2233.
- [17] Chen X F, Zheng F J, Guo D, et al. Review of machine learning methods for aerosol quantitative remote sensing[J]. National Remote Sensing Bulletin, 2021, 25(11): 2220-2233.
- [18] Ristovski K, Vucetic S, Obradovic Z. Uncertainty analysis of neural-network-based aerosol retrieval[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(2): 409-414.
- [19] Radosavljevic V, Vucetic S, Obradovic Z. A data-mining technique for aerosol retrieval across multiple accuracy measures [J]. IEEE Geoscience and Remote Sensing Letters, 2010, 7(2): 411-415.
- [20] Huttunen J, Kokkola H, Mielonen T, et al. Retrieval of aerosol optical depth from surface solar radiation measurements using machine learning algorithms, non-linear regression and a radiative transfer-based look-up table[J]. Atmospheric Chemistry and Physics, 2016, 16(13): 8181-8191.
- [21] Lanzaco B L, Olcese L E, Palancar G G, et al. An improved aerosol optical depth map based on machine-learning and MODIS data: development and application in South America[J]. Aerosol and Air Quality Research, 2017, 17(6): 1623-1636.
- [22] 梁天辰,孙林,王永吉.基于深度学习反演区域气溶胶光学厚度[J].光学学报,2021,41(4): 0401002.
- [23] Liang T C, Sun L, Wang Y J. Retrieval of regional aerosol optical depth using deep learning[J]. Acta Optica Sinica, 2021, 41(4): 0401002.
- [24] 莫祖斯,卜令兵,王勤,等.基于GRNN神经网络模型结合气溶胶消光系数和气象要素评估颗粒物质量浓度[J].中国激光,

- 2022, 49(17): 1710001.
 Mo Z S, Bu L B, Wang Q, et al. Evaluation of particle mass concentration based on GRNN neural network model combined with aerosol extinction coefficient and meteorological factors[J]. Chinese Journal of Lasers, 2022, 49(17): 1710001.
- [21] 高迦南, 李丽萍, 崔廷伟, 等. 基于卫星偏振遥感的细粒子气溶胶光学厚度反演[J]. 激光与光电子学进展, 2020, 57(3): 030101.
 Gao J N, Li L P, Cui T W, et al. Retrieval of fine mode aerosol optical depth based on satellite polarization remote sensing[J]. Laser & Optoelectronics Progress, 2020, 57(3): 030101.
- [22] 贾臣, 孙林, 王永吉, 等. 京津冀地区 1 km 分辨率 AOD 产品精度验证及与大气污染的相关性分析[J]. 激光与光电子学进展, 2020, 57(23): 232802.
 Jia C, Sun L, Wang Y J, et al. Accuracy validation of 1 km resolution AOD products in Beijing-Tianjin-Hebei region and correlation analysis with air pollution[J]. Laser & Optoelectronics Progress, 2020, 57(23): 232802.
- [23] Holben B N, Tanré D, Smirnov A, et al. An emerging ground-based aerosol climatology: aerosol optical depth from AERONET[J]. Journal of Geophysical Research: Atmospheres, 2001, 106(D11): 12067-12097.
- [24] Markham B, Barsi J, Kvaran G, et al. Landsat-8 operational land imager radiometric calibration and stability[J]. Remote Sensing, 2014, 6(12): 12275-12308.
- [25] Vermote E, Justice C, Claverie M, et al. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product[J]. Remote Sensing of Environment, 2016, 185: 46-56.
- [26] Doxani G, Vermote E, Roger J C, et al. Atmospheric correction inter-comparison exercise[J]. Remote Sensing, 2018, 10(2): 352.
 [27] Vermote E F, Tanre D, Deuze J L, et al. Second simulation of the satellite signal in the solar spectrum, 6S: an overview[J]. IEEE Transactions on Geoscience and Remote Sensing, 1997, 35(3): 675-686.
 [28] 田信鹏, 孙林, 刘强, 等. 北京地区 Landsat 8 OLI 高空间分辨率气溶胶光学厚度反演[J]. 遥感学报, 2018, 22(1): 51-63.
 Tian X P, Sun L, Liu Q, et al. Retrieval of high-resolution aerosol optical depth using Landsat 8 OLI data over Beijing[J]. Journal of Remote Sensing, 2018, 22(1): 51-63.
 [29] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
 [30] Hinton G E. Deep belief networks[J]. Scholarpedia, 2009, 4(5): 5947.
 [31] Smolensky P. Information processing in dynamical systems: foundations of harmony theory[R]. Colorado: Colorado Univ at Boulder Dept of Computer Science, 1986.
 [32] Bengio Y, Lamblin P, Popovici D, et al. Greedy layer-wise training of deep networks[C]//Proceedings of the 19th International Conference on Neural Information Processing Systems, December 4 - 7, 2006, Canada. New York: ACM, 2006: 153-160.
 [33] Plaut D, Nowlan S, Hinton G E. Experiments on learning by back propagation[EB/OL]. [2023-03-06]. <https://www.cnbcm.edu/~plaut/papers/pdf/PlautNowlanHinton86TR.backprop.pdf>.

Aerosol Retrieval Using Deep Learning and Radiative Transfer Model

Sun Xiaohu, Sun Lin*, Jia Chen, Zhou Feng

College of Geodesy and Geomatics, Shandong University of Science and Technology, Qingdao 266590, Shandong, China

Abstract

Objective Atmospheric aerosols are an important component of the earth-atmosphere system, exerting significant influence on various aspects, such as climate change, air quality, and human health. Traditional aerosol retrieval methods, such as dark target (DT) and deep blue (DB) algorithms, assume surface reflectance parameters during atmospheric radiative transfer processes and construct Look-up tables to retrieve aerosol optical depth (AOD). However, these methods simplify retrieval factors based on prior knowledge, resulting in error accumulation and propagation. Additionally, Look-up tables are usually constructed based on blue or red bands to greatly limit the image information utilization. With the emergence of various machine learning algorithms, deep learning algorithms have become the preferred AOD retrieval method. The quality and quantity of the deep learning training dataset determine the accuracy and applicability of the final model. Meanwhile, current dataset construction faces the problem of biased and insufficient training datasets due to the sparsity of ground station (AERONET) data, the limitation of image cloud cover, and satellite replay cycle, which greatly affects the accuracy of the retrieval model. Therefore, we propose an atmospheric radiative transfer model to construct a simulated dataset that conforms to real scenes, supporting deep learning methods to achieve quantitative aerosol retrieval. We hope that this method can solve the difficult data acquisition, ensure the dataset comprehensiveness, and reduce the aerosol retrieval error to assist with AOD retrieval of high-resolution image aerosols.

Methods We propose an atmospheric radiative transfer model to construct a simulated dataset and support the implementation of aerosol retrieval using deep learning methods. Firstly, the apparent reflectance of satellite bands in different conditions (observation geometry, surface reflectivity, atmospheric conditions, different AODs, etc.) is simulated by the atmospheric radiative transfer model. Then, based on the statistical relationship among parameters in the

study area and the probability distribution, we combine different bands and parameters to construct a simulated dataset that conforms to real scenes. Next, we employ this dataset to perform aerosol retrieval with deep learning methods, and apply the trained retrieval model to Landsat-8 OLI sensor data and retrieve high-resolution (30 m) aerosol images above the urban surface of Beijing. To evaluate the model performance, we validate the results with AERONET ground stations and adopt four metrics including mean absolute error (MAE), root mean square error (RMSE), the Pearson correlation coefficient (R), and expected error (EE) to perform analysis and evaluation.

Results and Discussions We combine the radiative transfer model with machine learning methods, and take Beijing as an example to achieve the urban aerosol AOD retrieval. This method has higher accuracy than ground-based measurements to avoid the disadvantage of insufficient training datasets from ground-based measurements in the past. The AOD values inverted from the four stations shown in Fig. 5 (a)–(d) have a strong correlation with AERONET measurements ($R = 0.8397\text{--}0.9283$), and more than 72% of the points are within the expected error with relatively stable retrieval results. The overall results of the study area [Fig. 5 (e)] show that the error of the retrieval values is relatively small. The MAE and RMSE are 0.0685 and 0.1029 respectively, and have a high correlation with AERONET measurements, with an R value of 0.8989. 74.05% of the points are within the expected error, while some results still show the underestimation phenomenon, which is mainly manifested in regions with AOD values above 0.5. In the spatial aerosol distribution under different levels of atmospheric pollution [Fig. 7 (a)–(h)], the overall trend of the retrieval results is reasonable with a continuous distribution, providing full-space coverage of the aerosol retrieval results. Additionally, the aerosol image at 30 m spatial resolution can provide local details and provide more detailed information on the spatial AOD distribution in urban areas, which is of significance in pollution source monitoring and other aspects.

Conclusions We propose an atmospheric radiative transfer model to construct a dataset to support the retrieval of high-resolution aerosol data from Landsat-8 using deep learning algorithms. The 6S atmospheric radiative transfer model is adopted to simulate the apparent reflectance of different Landsat-8 OLI bands in different conditions. By traversing the parameters in the study area and considering the joint probability of different parameters, different real scenes are constructed to ensure the unbiased dataset. To address the ill-posed problem during the retrieval, we leverage geometric angle information and statistical information between adjacent band apparent reflectance to screen the sample data and limit the parameter combination. An aerosol retrieval model is trained using the simulated dataset, and aerosol retrieval experiments are conducted in Beijing to verify the accuracy against AERONET ground-based aerosol measurement data. The results show that the method of employing simulated data to support deep learning algorithms has high accuracy, small errors, and high correlation with the measured data ($R=0.8989$). The RMSE and MAE are 0.1029 and 0.0685 respectively, and about 74.05% of the data falls within the expected error line. The proposed method addresses the bias and data volume problems of deep learning training samples using simulated data to better employ large amounts of training data and then learn more complex and accurate relationships between AOD and observation parameters, thereby achieving more accurate retrieval results.

Key words aerosol optical depth; radiative transfer model; Landsat-8 satellite; deep belief network