

基于人工智能技术的云遥感 反演



复旦大学 大气与海洋科学系

■ 卷积核的物理意义

任何一个汉字都是由基本笔画"横竖撇捺点"构成的,如:犬&术&





捺

3

3

꾓

撇



点

横

撇



2 -

棤



撇



4

撇







5 \

捺

基本**笔画的不同组合**,构成了 近10万汉字。

卷积核就是图像中的基本笔画, 构成了无数图片

即任何一张图片都是由基本线 条构成的,即局部放大后是各 种斜线或圆点,这些基本线条 就是卷积核。

■ 卷积核的物理意义

Features learned from training on different object classes.



从上到下:万物局部放大之后都是卷积核 从下到上:同样的卷积核的不同组合勾勒出万物



每一张图是由RGB三种颜色 通道构成,其数值0~1(255), 表示由黑到白的灰度值。 卷积核就除了线形外也包含 灰度



人眼看到的是色彩纹理,电脑看到的是数值 ^{红绿向理}



全部通道(RGB)都显示时 的屏幕颜色	只显示红色通道(R)时的屏 幕颜色	只显示绿色通道(G)时的屏 幕颜色	只显示蓝色通道(B)时的屏 幕颜色
R: 255 G: 0 B: 0	R: 255 G: 255 B: 255	R: 0 G: 0 B: 0	R: 0 G: 0 B: 0
R: 0 G: 255 B: 0	R: 0 G: 0 B: 0	R: 255 G: 255 B: 255	R: 0 G: 0 B: 0
R: 0 G: 0 B: 255	R: 0 G: 0 B: 0	R: 0 G: 0 B: 0	R: 255 G: 255 B: 255

■ 池化

池化计算过程pooling





卷积+池化,就是在确定每个局部是哪个线条/卷积 核主导即**池化就是在抓主要特征**

卷积和池化后的效果







https://zhuanlan.zhihu.com/p/67206089









云遥感研究背景

云在地气系统中的重要性



● 调节







● 预警



云反演进展和存在的科学问题

≻ 传统物理算法

 τ : Cloud optical thickness (COT) r_e: Cloud effective radius (CER)



 $r_e = 2 \mu m$

 $r_e = 20 \ \mu m$

云反演进展和存在的科学问题

> 深度学习方法



卷积神经网络 (CNN) (Xinyue Wang, et al. *RSE*, 2022)



卷积神经网络 (CNN) (Quan Wang, et al. *RSE*, 2022)



深度神经网络 (DNN) (Wenwen Li, Feng Zhang*, et al. *TGRS*, 2022)



深度神经网络 (DNN) (Wenwen Li, Feng Zhang*, et al. *TGRS*, 2024)

云遥感研究背景

卫星遥感已成为获取云物理特性的主要途径







仪器	FY4A/H8 (AGRI/AHI)	Aqua/Terra (MODIS)
轨道高度	~36000km	~ 705km
空间分辨率	4km/5km (热红外通道)	1km (热红外通道)
时间分辨率	15min/10min	一天两次过境
观测特点	观测范围广; 观测频次高	光谱分辨率高;轨道高度低

H8: Himawari-8 satellite; AHI: Advanced Himawari Imager; FY4A: Fengyun-4A satellite; AGRI: Advanced Geostationary Radiation Imager; MODIS: Moderate Resolution Imaging Spectroradiometer;



≻ 1. 结合静止卫星和极轨卫星观测优势



> 2. 采用深度学习网络建立面到面的映射关系









(Xuan Tong, Jingwei Li, Feng Zhang*, et al. *GRL*, 2023; Jingwei Li, Feng Zhang*, et al. *TGRS*, 2023; Zhijun Zhao, Feng Zhang*, et al. *arXiv*, 2024)



> ResUnet框架: 语义分割网络 (Unet) + 残差网络 (Resnet)



跳跃连接和残差连接:

有助于缓解随着网络深度增加而出现的梯度消失和梯度爆炸等问题

(Xuan Tong, Jingwei Li, Feng Zhang*, et al. GRL, 2023; Zhijun Zhao, Feng Zhang*, et al. TGRS, 2023)

FY4A/AGRI云物理特性反演结果评估

≻ CLP识别混淆矩阵

AGRI (Official)



(b) OA = 78.97%Clear 70.02 28.81 1.17 Water 2.21 93.75 4.04 Ice 5.25 16.80 77.94 Clear Water Ice MODIS (Official)

AHI (Official)

AGRI (Pre-trained Model)



AGRI (Our Method)

以MODIS官方云产品为基准



> 云检测整体准确率

云检测	AGRI (Official)	AHI (Official)	AGRI (Pre-trained Model)	AGRI (Our Method)
整体准确率	79.54%	84.57%	82.09%	88.12%

(Zhijun Zhao, Feng Zhang*, et al. TGRS, 2023; Zhijun Zhao, Feng Zhang*, et al. arXiv, 2024)

FY4A/AGRI云物理特性反演结果评估



以MODIS官方云产品为基准



(Zhijun Zhao, Feng Zhang*, et al. TGRS, 2023; Zhijun Zhao, Feng Zhang*, et al. arXiv, 2024)

FY4A/AGRI夜间云物理特性反演结果评估

以CALIOP官方云产品为基准



(Zhijun Zhao, Feng Zhang*, et al. arXiv, 2024)

个例分析(UTC_2020-04-26 00:00)



全天时云物理特性反演产品展示

◆ 2022年08月07日云物理特性的全天时变化



✓ 全圆盘

- 大范围空间连续
- 空间分辨率:4km
- ✓ 全天时
- 全天时时间连续
- 可获取全日的连续变化特征
- ✓ 高频次
- 时间分辨率较高
- 时间分辨率: 15min
- ✓ 高效率
- 反演速度比较快
- 可在1min内反演整个全盘
- ✓ 高精度
- 云产品精度较高
- 云极轨卫星云产品相一致

青藏高原地区云时空分布特征分析



与MODIS和AHI官方云产品数据相比,基于我们方法反演的日间全时段(BJT08:00-18:00) 云分数和云特性空间分布特征具有较大差异

(Zhijun Zhao, Feng Zhang*, et al. arXiv, 2024)

青藏高原地区云时空分布特征分析



诗性





- 传感器辐射定标
- 气体吸收(瑞利散射)
- 云的吸收散射
- 气溶胶吸收散射
- 地表海表特性



适用于遥感应用的快速辐射模式 "大禹"







冰云:六棱柱 (solid hexagonal column)水云: Mie散射理论

对于特定波长, 多项式拟合函数为

 $\gamma_{op}(\lambda) = \sum_{i=0}^{10} a_i(\lambda) L_{eff}^{5-i}$

 $\gamma_{op}(\lambda)$:光学特性 $a_i(\lambda)$: 拟合系数 L_{eff} : 有效直径

 $\phi(\lambda)$:光谱响应函数 $B(\lambda, T_c)$:普朗克函数 $F_{solar}(\lambda)$:太阳常数



(Wenwen Li, Feng Zhang* et al., *OE*, 2020, 2023) ²⁶



其中, 2N 是流数; $\mu_i = -\mu_{-i}$ (i = 1, 2, ..., N), $\mu_j = -\mu_{-j}$, $a_j = a_{-j}$ (j = 1, 2, ..., N)。



多层传输中同时处理太阳直射和普朗克发射

可见光到红外(包括太阳-红外光谱重叠区)的辐射传输过程

(Wenwen Li, Feng Zhang* et al., *OE*, 2020, 2023) ²⁸



(Wenwen Li, Feng Zhang* et al., *OE*, 2020, 2023) ²⁹

冰云

水云



(Wenwen Li, Feng Zhang* et al., *OE*, 2020, 2023) ³⁰



不同辐射算法计算时间的对比

	Dayu (OMCKD+ 4DDA)	Dayu (OMCKD+ 8DDA)	Dayu (OMCKD+ 16DDA)	OMCKD+ 16DISORT	OMCKD+ 64DISORT	LBLRTM+ 64DISORT
短波	1	5	33	1177	5667	2104025
太阳光-热红外 光谱重叠通道	1	4	26	1149	4233	2663256
长波	1	2	6	354	449	89823

标准

1二、1

在短波或光谱重叠通道,与标准模式相比,"大禹"模式计算效率高了约三个数量级 <mark>在热红外通道</mark>,与标准模式相比,"大禹"模式计算效率高了约五个数量级

(Wenwen Li, Feng Zhang* et al., *OE*, 2020, 2023) ³¹



"大禹"辐射模式应用流程图

(Wenwen Li, Feng Zhang* et al., *OE*, 2020, 2023) ³²



利奇马台风 (Lekima) 时间: 20190808, 06 UTC 地区: 15-35°N, 117-137°E



利奇马台风的云的光学性质 (a) 云光学厚度, (b)云有效半径, (c)云 顶气压, (d)云相态。



"大禹" 模式应用案例

"大禹"模式模拟反射率与卫星观 测反射率的对比

观测反射率与模拟反射率空间分布 高度一致,证明模式在晴空和有云 大气下都具有较好的反射率模拟能 力。

左图为AHI观测亮温 (a-c) 与 IERTM模拟亮温 (d-f) 在B02 (0.51 μm), B04 (0.86 μm), B06 (2.3 μm) 通道的对比, (g-i) 为两者之差。



"大禹" 模式应用案例



左图为AHI观测亮温 (a-d) 与IERTM 模拟亮温 (e-h) 在B07 (3.9 μm), B09 (6.9 μm), B12 (9.6 μm), B15 (12.4 μm) 通道的对比, (i-l) 为两者 之差。

✓ 传统的云检测算法通常是基于一系列阈值测试和决策树实现的。

 ✓ 对于云相态分类,传统的算法主要是基于冰云和水云散射和吸收 特性随光谱变化的差异发展的,算法中采用了各种阈值测试,例 如反射率差(e.g., 2.1和1.6 μm),或亮温差(8.5和11 μm)。 (Pilewskie等(1987), Wang 等(2018), Baum等(2000); Pavolonis 等(2010))

✓ 目前已有的多层云识别算法多是基于 SWIR 通道和 LWIR 通道对 上层冰云和下层水云的敏感性存在差异实现的。(Wang等(2019))

机器学习方法非常适用于处理涉及复杂非线性问题并受多种因素影响 的云遥感相关的难题。(Wang等(2020); Tan等, (2022))





反射率之差

亮温之差

 ho_{λ_1,λ_2}

$\mathrm{BT}_{\mathrm{obs},\lambda_1} - \mathrm{BT}_{\mathrm{clr},\lambda_1}$	BT _{obs,λ} : 观测亮温		单层冰云
$\rho_{\lambda_1,\lambda_2} = \frac{1}{BT_{obs,\lambda_2} - BT_{obs,\lambda_2}}$	BT		单层水云
$=-003, \pi_2$ = $-011, \pi_2$			单层混合相态云
		_	多层云(上层冰云,下层水云)

算法流程



考虑不同的输入因子下云分类模型综合指标得分

	Model	Model input	Precision	Recall	F1-measure measure	
	All-day model without considering clear-sky radiance	BT[6.9-13.3 μ m], μ_{SAZ}	0.76	0.76	0.75	
全天的模型	All-day model considering clear-sky radiance	$BT[6.9-13.3\mu m],$ $BT-BT_{clear}[6.9-13.3\mu m]$	0.81	0.81	0.81	M
	Daytime model without considering clear-sky radiance	$\frac{\text{BT}[6.9-13.3\mu\text{m}]}{\text{R}[0.47-2.3\mu\text{m}]},\\ \mu_{\text{SOZ}}, \ \mu_{\text{SAZ}}, \ \mu_{\text{SAA}-\text{SOA}}$	0.83	0.82	0.82	
日间的模型	Daytime model considering clear-sky radiance	BT[6.9-13.3 μ m], BT-BT _{clear} [6.9 - 13.3 μ m], R[0.47-2.3 μ m],	0.85	0.84	0.84	M

Note that μ_{SAZ} is the cosine of satellite zenith angle; SOZ is solar zenith angle; SAA is satellite azimuth angle; SAA is solar azimuth angle.

考虑晴空亮温可提升神经网络模型的云分类精度,尤其在 全天的模型上提升更加显著。

Himawari-8 AHI成像仪云检测和云分类研究

多层云识别

COT>1



(a) 以CPR/CALIOP观测为标准, DNN模型以及MODIS和AHI官方产品中 单层云和多层云的识别比例。左图和右图分别是总COT (来自CALIOP 5km 云层产品) 大于和小于1下的结果。

COT<1

Himawari-8 AHI成像仪云检测和云分类研究

实际案例应用



辐射模式与AI联合的多层云定量反演



已有的多层云研究多基于最优估计方法, 如lwabuchi等(2016, 2017), Teng 等(2020, 2023)

辐射模式与AI联合的多层云定量反演

模型评估







模型评估



TABLE II

EVALUATION SCORES FOR CTH RETRIEVALS BY THE CNN_TL AND CNN_BL MODELS (WITHOUT TL) USING DIFFERENT PREDICTORS

Model		Evaluation	Single-	Multilayer			
		Metrics	layer	upper- ice	lower- water		
	CNN_TL (all predictors)	Pearson RMSE	0.988 0.845	0.900 1.219	0.842 0.863	-	
CTH _ (km) -	CNN_BL (all predictors)	Pearson RMSE	$0.987 \\ 0.871$	0.896 1.242	$\begin{array}{c} 0.837\\ 0.881 \end{array}$		
	$CNN_BL (BT_{obs} + BT_{clr})$	Pearson RMSE	0.987 0.915	0.894 1.251	0.804 0.953		
	CNN_BL (BT _{obs})	Pearson RMSE	0.971 1.332	0.859 1.435	$0.748 \\ 1.066$		

Note that all predictors include VNIR measurements (R_{obs}), observed BTs (BT_{obs}), RTM-simulated clear-sky BTs (BT_{clr}), as well as solar/satellite geometries (omitted in the table).

使用迁移学习方法可有效降低云顶高度的反演误差。 考虑晴空亮温可显著提升云顶高度的反演精度。

辐射模式与AI联合的多层云定量反演

微观特性(第一行光学厚度、第二行有效粒子半径)

单层云

模型评估

多层云(上层冰云) 多层云(下层水云)





模型评估



TABLE III

EVALUATION SCORES FOR COT AND CER RETRIEVALS BY THE CNN_TL AND CNN_BL MODELS (WITHOUT TL) USING DIFFERENT PREDICTORS

		Fyaluation	Single-	Multilayer		
	Model	Metrics	layer	upper- ice	lower- water	
	CNN_TL (all predictors)	Pearson RMSE	0.790 5.274	0.781 5.046	0.659 8.915	
COT	CNN_BL (all predictors)	Pearson RMSE	$0.781 \\ 5.360$	0.776 5.097	0.652 9.141	
COT	$CNN_BL (R_{obs}+BT_{obs})$	Pearson RMSE	$0.782 \\ 5.346$	0.769 5.165	0.651 9.155	
	CNN_BL (R _{obs})	Pearson RMSE	$0.782 \\ 5.378$	$0.762 \\ 5.313$	0.639 9.230	
	CNN_TL (all predictors)	Pearson RMSE	0.828 9.461	0.819 9.850	0.627 14.584	
CER (μ m)	CNN_BL (all predictors)	Pearson RMSE	0.824 9.565	0.817 9.931	0.598 15.234	
	$CNN_BL (R_{obs}+BT_{obs})$	Pearson RMSE	0.819 9.717	0.792 10.566	0.573 15.809	
	CNN_BL (R _{obs})	Pearson RMSE	$0.800 \\ 10.217$	0.595 14.602	0.565 16.150	

 ✓ 使用迁移学习方法可有效 提升微物理特性的反演精 度,特别是下层云的光学厚 度和有效粒子半径

辐射模式与AI联合的多层云定量反演

CNN-TL模型 实际案例应用



辐射模式与AI联合的多层云定量反演

CNN-TL模型 实际案例应用



CPR/CALIOP联合产品沿轨道线的云相态垂直廓线图。CNN-TL模型(红色/青色)、MODIS (紫色)和AHI(黑色)官方产品结果分别以不同符号在图中标记。特别地,青色点标记了多层 云存在情况下CNN-TL模型反演的下层水云CTH的位置。

✓ 1) CNN-TL模型反演的台风云系CTH与主动雷达观测具有较高的一致性,而
MODIS产品特别是AHI产品整体上低估了CTH。

✓ 2)当多层云存在时,MODIS和AHI产品倾向于忽略上层较薄的冰云,给出下层 水云的CTH。









传统的天气预报









-17.1

-1.6

14.0

29.5

-32.6





数值预报 vs 人工智能



RTX 4090

人工智能方法在气象领域的应用

研究方向	研究内容	人工智能方法	参考文献
地球系统建模	使用机器学习仿真器改善对流参数化。	人工神经网络 (ANN) 。	Gentine等 (2018)
地球系统建模	提高全球气候模型参数化的速度。	人工神经网络 (ANN) 。	Krasnopolsky等(2005)
地球系统建模	模拟气候模型,以增加可用于气候模型的参数值的范围。	一系列反演方法,包括Ensemble Kalman反演和Markov Chain Monte Carlo(MCMC)算法。	<u>Schneider等(2017)</u>
地球系统建模	根据地球观测数据(卫星)对土地覆盖进行分类。	随机森林 (RF) 。	Rodriguez-Galiano等 (2012)
地球系统建模	确定欧洲-大西洋地区的数值天气预报模型的相空间的首选区域。	聚类。	<u>Dawson等 (2012)</u>
地球系统建模	模拟复杂的气溶胶大气模型,以测试有效参数的不同潜在值。	高斯过程 (GP) 仿真。	<u>Lee等 (2013)</u>
遥相关	捕获Madden-Julian振荡(MJO)的动力学和结构。	自组织地图 (SOM) 。	Chattopadhyay等 (2013)
遥相关	确定与太平洋年代际振荡(PDO)的陆地热带联系。	聚类,经验正交函数(EOF)。	Yang等 (2019)
遥相关	确定SST指数及其对陆地气候的影响。	共享倒数最近邻 (SRNN) 和基于图的方法。	<u>Liess等 (2017)</u>
天气预报	使用AI对天气预报进行后处理,以帮助人类预报员。	随机森林 (RF) , 梯度增强回归树 (GBRT) 。	<u> McGovern 等(2017)</u>
未来气候情景	通过按技能加权模型来合并多个季节性气候预测。	贝叶斯线性回归。	罗等(2007)
未来气候情景	通过他们的技能对气候模型加权可以产生比整体平均更好的性能。	广义隐马尔可夫模型(HMM)。	<u>Monteleoni</u> 等(2011)
气候影响	评估气候变化对地上生物量的影响。	支持向量机 (SVM) ,人工神经网络 (ANN) , 广义回归神 经网络 (GRNN) 。	<u>Wu等 (2019)</u>
气候影响	评估气候变化对全球水文循环的影响,重点是蒸散量的变化。	模型树合奏(MTE)。	
气候影响	评估未来气候变化对印度水文(包括河流流量)的影响。	主成分分析(PCA)和模糊聚类。相关向量机(RVM)。	Ghosh和Mujumdar (2008)
气候影响	根据印度的气象变量(降水,温度)输入预测水文变量(蒸散量)。	模糊逻辑,最小二乘支持向量回归(LS-SVR),人工神经网络(ANN),自适应神经模糊推理系统(ANFIS)。	<u>Goyal等(2014)</u>
气候影响	确定不同气候系统中缺水(干旱)的影响。	模型树合奏(RF,随机森林)。	Yang等 (2016)
つ 低 に 低 影 响 の し し し し し し し し し し し し し	很掂上星致掂怕异作初广重。 确定气候驱动因素对半千里地区沙尘沉积的影响。	苍枳伸空网络(CNN)。高期过程(GP)凹归。 人工神经网络(ANN)。	Azzari寺(<u>2017</u>),Burke和Lobeli(<u>2017</u>) Buckland等(2019)
气候数据集	产生一个长期的,全球一致的径流数据集,以评估水文趋势和变异性。	随机森林 (RF) 。	Ghiggi等(2019)
气候数据集	使用基于卫星的检索(PERSIANN)来提供全球一致的降水估计。	人工神经网络(ANN)。	Hsu等(<u>1997</u>),Hong等(<u>2007</u>),Nguyen等 (<u>2018</u>)
气候数据集	针对不完整的时间序列改进最低和最高温度的估计。	装有马尔可夫链蒙特卡洛 (MCMC) 方法的高斯过程 (GP) 模型。	<u>Rischard</u> 等(2018)_
气候数据集	将GCM降水场缩减到适合影响评估的规模。	内核回归 (KR) 。	<u>Salvi等(2017)</u>
极端气候	在全球气候模型的输出中识别极端天气事件。	卷积神经网络(CNN); 3D卷积编码器/解码器。	<u>Liu等(2016)</u>
饭端飞候 极端气候	使用气家和气味指数作为潮入米顶测十年指数。 相据卫星数据预测气象和农业千早状况	1211111111111111111111111111111111111	<u>Deo和Jsahin(2015)</u> Park 等 (2016)
极端气候	使用以前的埃塞俄比亚气象信息来预测气象干旱。	人工神经网络 (ANN); 支持向量回归 (SVR); 小波变换。	Mishra和Desai(2006),Belavneh等(2016)

如何学习非局部特征?





0.3 0.1

0.4

0.4

向量4

0.8 0.1 0.8 0.1 0.1

0.4 0.6

0.4

0.1

0.6

向量5

向量1向量2向量3向量4向量5

+ w₅×



人工智能通常被视为不可洞悉原理的"黑箱"; 数据驱动的AI,有时会从数据中得到无意义的联系,存在问题

图片识别 是否有马?

网页标签, 被作为重要 信息

<u>红色: 有马</u> 蓝色: 无马 黑色: 用不到



www.heatmapping.org



感谢聆听!

请各位老师同学批评指正!