基于人工智能的地球物理参数反演范式理论及判定条件

毛克彪^{1,2,3*}, 张晨阳⁴, 施建成⁵, 王旭明², 郭中华², 李春树², 董立新⁶, 吴门新⁷, 孙瑞静⁶, 武胜利⁶, 姬大彬³, 蒋玲梅⁸, 赵天杰³, 邱玉宝³, 杜永明³. 徐同仁⁸

(1. 中国农业科学院农业资源与农业区划研究所北方干旱半干旱耕地高效利用全国重点实验室,北京100081;2. 宁夏大学物理与电子电气工程学院,宁夏银川750021;3. 中国科学院空天信息创新研究院 遥感科学国家重点实验室,北京100094;4. 北京大学环境科学与工程学院,北京100871;5. 中国科学院国家空间科学中心,北京100190;
6. 国家卫星气象中心,北京100081;7. 国家气象中心,北京100081;8. 北京师范大学地理科学部,北京100875)

摘 要: [目的/意义] 人工智能(Artificial Intelligence, AI) 技术已在学术和工程应用领域掀起了研究高潮,在 地球物理参数和农业气象遥感参数反演方面也表现出了强大的应用潜力。目前大部分AI技术在地学和农学的应用 还是"黑箱",没有物理意义或缺乏可解释性及通用性。为了促进AI在地学和农学的应用和培养交叉学科的人才, 本研究提出基于AI耦合物理和统计方法的地球物理参数反演范式理论。[方法]首先基于物理能量平衡方程进行 物理逻辑推理,从理论上构造反演方程组,然后基于物理推导构建泛化的统计方法。通过物理模型模拟获得物理 方法的代表性解以及利用多源数据获得统计方法代表性的解作为深度学习的训练和测试数据库,最后利用深度学 习进行优化求解。[结果和讨论] 判定形成具有通用性和物理可解释的范式条件包括:(1) 输入与输出变量(参 数)之间必须存在因果关系;(2)输入和输出变量(参数)之间理论上可以构建闭合的方程组(未知数个数少于 或等于方程组个数),也就是说输出参数可以被输入参数唯一确定。如果输入参数(变量)和输出参数(变量)之 间存在很强的因果关系,则可以直接使用深度学习进行反演。如果输入参数和输出参数之间存在弱相关性,则需 要添加先验知识来提高输出参数的反演精度。此外,本研究以农业气象遥感中的关键参数地表温度、发射率、近 地表空气温度和大气水汽含量联合反演作为案例对理论进行了证明,分析结果表明本理论是可行的,并且可以辅 助优化设计卫星传感器波段组合。「结论】本理论和判定条件的提出在地球物理参数反演史上具有里程碑意义。 关键词:人工智能;深度学习;反演范式;物理逻辑推导;可解释;农业气象遥感 中图分类号:TP181:P313.3 文献标志码: A 文章编号: SA202304013

引用格式:毛克彪,张晨阳,施建成,王旭明,郭中华,李春树,董立新,吴门新,孙瑞静,武胜利,姬大彬,蒋玲梅,赵天杰,邱玉宝,杜永明,徐同仁.基于人工智能的地球物理参数反演范式理论及判定条件[J].智慧农业(中英文),2023,5(2):161-171.

MAO Kebiao, ZHANG Chenyang, SHI Jiancheng, WANG Xuming, GUO Zhonghua, LI Chunshu, DONG Lixin, WU Menxin, SUN Ruijing, WU Shengli, JI Dabin, JIANG Lingmei, ZHAO Tianjie, QIU Yubao, DU Yongming, XU Tongren. The paradigm theory and judgment conditions of geophysical parameter retrieval based on artificial intelligence[J]. Smart Agriculture, 2023, 5(2): 161-171.

1 引 言

以 ChatGPT 为代表的生成式人工智能(Artificial Intelligence, AI)的出现和升级使得 AI 进一步

受到人们的广泛关注,AI成为新一轮产业变革的核 心驱动力,将进一步释放科技创新的巨大能量,并 创造新的强大引擎。AI与具体的行业结合将催生新 技术和新产品,深刻改变人类思维和生产模式,实

收稿日期: 2023-04-24

基金项目:风云卫星应用先行计划(FY-APP-2022.0205);第二次青藏高原综合科学考察研究(2019QZKK0206XX-02);遥感科学国家重点 实验室开放基金(OFSLRSS202201)

^{*}通信作者:毛克彪,博士,研究员,研究方向为人工智能在地学和农学中的应用。E-mail: maokebiao@caas.cn

现社会和行业生产力的整体跃迁。深度学习是目前 AI领域最重要的技术之一,在学术领域和工程应用 掀起了研究高潮,并在自然语言生成模型、计算机 视觉、语音识别等多个领域取得了显著的研究成 果。鉴于深度学习在地学和农学领域的应用潜力和 重要性,为促进AI在地学和农业领域的应用,必 须加快AI与遥感技术的深度融合,为气象预报、 农情监测和农业灾害预报等提供关键技术支撑^[15], 为全球灾害监测和国家粮食安全服务。

根据2022年《国家统计年鉴》,中国年均农业 气象灾害受灾面积达1207.16万公顷,仅2022年气 象灾害造成的直接经济损失就高达2386亿人民币。 因此,快速准确获取农业气象关键参数信息对于科 学指导农业气象防灾减灾、作物估产确保国家粮食 安全等具有重要意义^[68]。美国、日本和欧盟等相 继研发气象卫星关键参数反演系统,中国自20世 纪90年代开始研究气象卫星参数反演技术,虽然 都已经取得了很大的进展,但仍然遇到一些瓶颈, 如未知数多于方程的个数、相对入射角变化和混合 像元等问题^[9]。近年来,在计算机硬件技术和AI 技术迅速发展相互辅助下,AI显示出了强大的优 势^[10]。因此研究如何将AI技术与地学,特别是与 农业气象遥感参数传统反演物理和统计方法结合, 发展具有物理意义和可解释的AI算法对提升遥感 参数反演精度和对完善地球物理参数反演范式理论 具有重要意义,同时为智慧农业和智慧地球提供关 键的监测参数^[11-14]。

2 地球物理参数反演范式理论与判定 条件

建立学科体系知识一般遵循三个步骤:首先从 物理角度观察现象,其次用数学方法描述物理现 象,最后从工程的角度去解决数学问题。"AI地球 物理参数反演范式理论"可以表述为:如果目标信 息(问题)在理论或物理逻辑上可以用数学方程描 述(即可以在空间中可以形成唯一的解曲线),那 么AI方法可以通过大数据学习和优化计算耦合物 理方法和统计方法求解方程。这使得耦合方法不但 具有物理方法和统计方法各自的优势,同时充分利 用了深度学习的优化计算能力,最大限度地提高了 地球物理参数的反演精度。这样保证了反演范式不 仅具有通用性,而且具有物理意义和可解释性。具 体地,本研究提出的地球物理参数反演范式理论是 使深度学习的输入参数(变量)和输出参数(变 量)之间可以构建一套完整的闭合方程组。如果输 人参数 (变量)和输出参数 (变量)之间存在强因 果关系,则可以直接使用深度学习进行反演并获得 高精度的反演结果。如果输入参数和输出参数之间 存在弱相关性,则需要添加强相关性的先验知识和 交叉迭代来提高输出参数的反演精度。可以通过物 理模型模拟得到物理方法的大量代表性解,然后使 用深度学习通过训练获得解的曲线函数。因此通过 大数据模式的深度学习可以重复该物理方法。同时 很多物理方法不能描述所有情况,为了克服物理方 法的不足,基于物理逻辑推理,进一步构建泛化的 统计方法,并通过多源数据获得统计方法的解来弥 补物理方法的不足。其实从信息流传递的角度来 说,深度学习网络更能符合现实情况,物理方法和 统计方法是其中的部分表现形式。这些方法本质上 一致,均是人们用来认识世界的一种手段,在不同 认知程度上解读和解决现实问题。

判定基于深度学习的地球物理参数反演形成是 否具有通用性和物理可解释范式的条件有两个:

(1)深度学习的输入与输出变量(参数)之间 必须存在因果关系,即在其他条件不变的情况下, 改变任何一个输入变量,输出变量会发生变化。设 深度学习输入变量为x_i,输出变量为y_i,则因果关 系表示为公式(1)。

$$y_i = f(x_i) \tag{1}$$

其中, *i*=1, 2, …, *n*; *j*=1, 2, …, *m*; *f*表 示某种因果关系函数。

(2)深度学习的输入和输出变量(参数)之间理论上可以构建闭合的方程组(未知数个数少于或等于方程组个数),也就是说输出参数可以被输入参数唯一确定,用数学方程可以表示为公式(2)。

$$\boldsymbol{F}(\boldsymbol{x},\,\boldsymbol{y}) = \boldsymbol{0} \tag{2}$$

其中, $x = x_1, x_2, \dots, x_n; y = y_1, y_2, \dots, y_m;$ F表示一个由k个方程组成的向量函数。

为了使输出参数可以被输入参数唯一确定,需 要满足*k*≥m这个条件。为论证深度学习的使用具 有物理意义,在研究时必须进行物理逻辑推理。输 入变量和输出变量之间存在因果关系且理论上也能 构造足够的方程组时,如果输入变量和输出变量之 间存在强相关性,则可以进行直接反演计算且可以 保持高精度;但如果输入变量和输出变量之间是弱 关系,要保证获得较高精度则需要利用强相关性变 量作为先验知识。

深度学习的应用不能脱离具体的问题或对象, 如图1所示,本研究在解决某个应用问题时,首先 要对问题对象进行物理逻辑推理,从理论上构造方 程,确定输入变量和输出变量之间的因果关系;其 次从方程里面的未知数个数确定方程组的个数,也 就是确定几个输入参数能唯一确定输出变量;再次 通过分析确定利用物理模型是否可以模拟得到所有 代表性的解,如果得不到,则构建基于物理逻辑推 理的泛化的统计方法^[10,12],利用多源数据补充代表 性的解;然后利用大数据技术和深度学习优化求解 物理和统计方法解的空间曲线函数;最后进行验证 和反复迭代,达到精度后停止优化计算^[12,13,15]。如 果应用深度学习时,没有证明或不能证明存在上述 两个条件,则一般认定深度学习的应用为"黑 箱"^[16,17]。如果能证明输入和输出参数之间肯定不 存在闭合的关系(未知数个数大于方程组个数), 那么这样的应用只适合于局部区域,不能通用和很 难具备移植性,因此不能称为范式。



图1 地球物理参数反演范式理论与判定条件

Fig. 1 The paradigm theory and judgment conditions of geophysical parameter retrieval

3 地球物理参数反演范式理论案例分 析论证

3.1 物理逻辑推理

农业气象遥感关键参数是地球物理参数的重要 组成部分,本研究以农业气象遥感关键参数为例对 地球物理参数反演范式理论进行论证。

首先进行物理逻辑推理。地表热辐射在通过大 气达到卫星传感器的过程中,主要受地表类型和土 壤水分(Soil Mositure, SM)、地表温度(Land Surface Temperature, LST)、近地表空气温度 (Near Surface Air Temperature, NSAT)和大气水汽 含量(Water Vapor Content, WVC)等的影响。地 表温度和土壤水分反演是基于地表热辐射传导及其 通过大气到达传感器的传送物理过程,其反演方程 通常可以用公式(3)描述,如图2所示。



注:参数为土壤水分、地表温度、近地表空气温度和大气水汽含量 图 2 农业气象遥感参数之间的关系 Fig.2 The relationship between agricultural meteorological remote sensing parameters

公式(3)中, $B_{\lambda}(T_{\lambda})$ (已知数)为卫星接收 的星上辐射, $(1 - \tau_{\lambda}(\theta))(1 + (1 - \varepsilon_{\lambda})\tau_{\lambda}(\theta))B_{\lambda}(T_{a})$ 为 大气辐射贡献, $B_{\lambda}(T_{s})\tau_{\lambda}(\theta)\varepsilon_{\lambda}$ 为地表辐射。其中, $\tau_{\lambda}(\theta)$ 为大气透过率(未知数), T_{s} 为地表温度(未 知数), T_{a} 为近地表空气温度(未知数), ε_{λ} 为地表 发射率(未知数),即一个方程至少有4个未知数。 需要说明的是观测角度其实也是一个未知数,每个 像元中不同地物的组合导致相对入射角变化很大, 很难被准确地确定。由于地球物理参数之间存在内 在的制约关系,可以利用卫星参数之间的相互制约 关系减少一个未知数^[18-21]。从图2可以看出,不同 的参数之间是相互影响和纠缠的。氮、磷、钾溶解 在土壤水分里面,土壤水分的变化影响介电常数变 化,从而改变发射率,发射率变化影响地表的辐射 效率, 而地表温度变化决定土壤水分的蒸发速度, 从而影响与近地表空气的能量交换和改变近地表空 气温度以及大气剖面温度。理论上讲,土壤水分的 变化也会影响热红外波段发射率的变化,但传统算 法中没有考虑到这一点,一般认为热红外波段的发 射率是相对不变的,其实也随土壤和植被含水量的 变化而变化。因此在降雨比较多的地方,热红外遥 感传统方法反演地表温度的精度波动相对较大,但 AI方法可以克服这个困难。近地表空气温度的变化 影响大气剖面,从而影响大气平均作用温度。在地 表热辐射经过大气时,被大气水汽吸收,然后到达 卫星传感器。因此,从物理逻辑推理可知^[9,10,12,14], 单个方程中有4个未知数。如果没有先验知识,必 须至少有4个热红外窗口波段从理论上构建反演方 程:如果有大气水汽作为先验知识,也可以只需要 3个热红外波段。以往大部分研究主要是针对单个 参数进行反演,由于不同参数之间相互纠缠,利用 AI方法进行联合反演和交叉迭代可以提高反演精 度^[9,10]。在进行物理逻辑推理后确定物理方法的理 论构建后,在实际应用研究中发现,只利用物理模 型建立的方法精度不是十分可靠,因为物理模型对 真实世界进行了简化,而且很多地学模型也只适合 部分情况^[1-5]。因此,为了尽可能地满足更多的情 况,还要基于物理逻辑推理进一步建立泛化的统计 方法,这样才能保证方法的完整性和精度的可 靠性[7-13]。

MODIS卫星传感器是目前热红外波段数量和 质量最好的传感器之一,本研究将针对 MODIS 的 热红外波段进行模拟和论证分析。选定 MODIS 波 段 27/28/29/31/32/33 (6.5~13.5 µm),其中 MODIS 波段 27、28 和 29 在是热红外波段的水汽吸收区, 波段 31 和 32 在热红外波段的窗口区,33 波段在热 红外波段窗口区的边缘上。将利用 JPL (http://speclib.jpl.nasa.gov)测量的地物波普曲线在 MODIS 波 段 27/28/29/31/32/33 的发射率作为 MODTRAN4 的 输入参数,地表温度变化范围为 273~325 K,近地 表空气温度变化范围为 273~320 K,大气水汽含量 变化范围0.1~4.0 g/cm²,模拟观测角为0~45°。当 模拟观测角度过大时,由于斜路径上的水汽过大 导致透过率过低,因此对这部分模拟数据进行了 去除。将模拟数据随机分成两部分:训练数据 45,650组,测试数据16,550组。根据传感器上获得 不同参数信息量的多少,将不同的参数反演划分成 三组,分别对地球物理参数理论和判别条件进行论 证分析。第一组反演地表温度和发射率,主要分析 和论证输入变量和输出变量之间的方程组个数和因 果关系对反演精度影响;第二组反演近地表空气温 度,主要分析和论证利用输入和输出变量之间强相 关性变量作为先验知识,提高弱关系反演变量的精 度;第三组反演大气水汽含量,主要分析论证当输 入和输出变量之间存在强相关性时,添加先验知识 可以提高反演稳定性,但对精度提高不明显。

3.2 地表温度和发射率反演

在3.1节的物理逻辑推理中可知,反演地表温 度至少需要4个热红外波段组成辐射传输方程组, 意味着当输入热红外波段少于4个时,反演精度不 高。表1是MODIS波段29、31和32组合在给定条 件下的理论反演精度。从表1中可以看出,当隐含 层是9层且每层隐含节点都为700时,平均理论精 度最高为1.13 K,标准差为1.17 K,相关系数为 0.988。

表1 波段29-31-32组合时地表温度反演误差

 Table 1 Retrieval errors of surface temperature for band

 29-31-32 combination

隐						隐含	节点					
含		600			700			800			900	
层	M/K	SD/K	R									
7	1.51	1.41	0.912	1.32	1.25	0.985	1.26	1.84	0.95	1.36	1.23	0.961
8	1.42	1.32	0.925	1.22	1.21	0.985	1.24	1.81	0.951	1.61	1.56	0.960
9	1.33	1.25	0.932	1.13	1.17	0.988	1.21	1.32	0.963	1.37	1.36	0.962
10	1.27	2.04	0.912	1.23	2.48	0.910	2.46	3.11	0.879	2.34	3.77	0.896
注:	M为]平均	误差;	SD 2	为标准	偏差;	R为	相关	系数			

表 2 是 MODIS 波段 28-29-31-32 组合反演的误差信息表。从表 2 中可以看出,当隐含层是 9 并且每层节点为 800 时反演精度最高。最高平均精度为 0.45 K,标准差为 0.53 K 和相关系数为 0.998。从表 1 和表 2 可以看出,当用 4 个热红外波段时,平均精度提高了 0.68 K。MODIS 波段 28 是水汽吸

收波段,增加热红外水汽吸收波段可以提高反演精 度。当只用两个热红外波段(波段31和32)反演 时,反演误差接近2K,因此传统劈窗算法必须获 得大气水汽和地表发射率作为先验知识。而反演精 度要达到1K以内,至少需要4个热红外波段,或 者2个热红外波段加高精度的地表发射率和水汽作 为先验知识,也就证明了基于AI的热红外遥感地 表温度高精度反演需要理论上满足方程闭合的 条件。

表2 波段28-29-31-32 组合时地表温度的反演误差

Table 2 Retrieval errors of surface temperature for band28-29-31-32 combination

隐	隐含节点												
含		600			700			800		900			
层	M/K	SD/K	R										
7	0.76	0.68	0.987	0.89	1.13	0.984	0.77	0.71	0.988	0.66	0.68	0.987	
8	0.97	2.25	0.956	0.82	0.84	0.986	0.53	0.58	0.991	0.71	0.72	0.985	
9	0.79	0.78	0.986	0.82	0.79	0.986	0.45	0.53	0.998	0.78	0.73	0.981	
10	0.83	0.89	0.986	0.71	0.78	0.987	1.03	2.63	0.928	1.14	1.56	0.963	

表3是MODIS波段27-28-29-31-32波段组合时 反演的地表温度误差信息表,从表3中可以看出当 隐含层数9、每层隐含节点是900时,反演精度最 高。平均最高精度是0.44 K,标准差是0.52 K,相 关系数是0.999。MODIS 27波段也是水汽波段,增 加水汽吸收波段能够提高水汽的精度,理论上可以 提高整体反演精度。这里精度提高不明显,主要原 因是波段27的地面辐射几乎很难穿透达到传感器, 也就说透过率非常低,星上亮温主要包含的是高空 大气水汽信息,因此对地表温度反演精度贡献不是 非常大,但增加了反演的稳定性。

表 4 是 MODIS 波段 27-28-29-31-32-33 作为输 入参数时的反演误差信息表,当隐含层是 8 并且每 表 3 波段 27-28-29-31-32 组合时地表温度的反演误差 Table 3 Retrieval errors of surface temperature for band 27-28-29-31-32 combination

2)-5	1-52	comomation	

隐	隐含节点												
含		600 M/K SD/K R			700			800			900		
层	M/K	SD/K	R	M/K	SD/K	R	M/K	SD/K	R	M/K	SD/K	R	
7	0.64	0.68	0.993	0.58	0.59	0.995	0.61	0.69	0.995	0.76	0.88	0.979	
8	0.61	0.67	0.995	0.62	0.93	0.993	0.66	0.85	0.978	0.48	0.54	0.998	
9	0.62	0.68	0.994	0.65	1.02	0.991	0.73	0.97	0.965	0.44	0.52	0.999	
10	0.65	0.88	0.978	0.64	1.12	0.99	0.48	0.61	0.998	0.56	0.89	0.997	

层隐含节点为900时精度最高。平均精度最高为 0.51 K,标准差为0.55 K,相关系数是0.997。从 表3和表4可以看出,当有汽波段时,添加波段33 时并没有提高反演精度。主要原因是热红外波段33 受CO₂的影响比较大,不是非常适合于反演地表温 度,因此增加热红外波段不一定会增加反演精度, 有时反而会降低反演精度。表3分析说明当增加的 波段与输出参数之间存在强相关性时,可以提高精 度;表4说明当增加的波段与输出参数之间是弱关 系或者是增加了噪声时,会降低反演精度。

同时也可以将发射率反演计算出来,这里主要 列出了波段27-28-29-31-32组合时波段31和32的发 射率误差,如表5和表6所示,反演误差都在0.01

表4 波段27-28-29-31-32-33 组合时地表温度的反演 误差

Table 4 Retrieval errors of surface temperature for band 27-28-29-31-32-33 combination

隐		隐含节点												
含		600			700			800			900			
层	M/K	SD/K	R											
7	0.68	0.69	0.991	0.65	0.67	0.991	0.65	0.68	0.996	0.63	1.21	0.957		
8	0.62	0.65	0.992	0.63	0.88	0.992	0.65	0.70	0.995	0.51	0.55	0.997		
9	0.64	0.66	0.991	0.68	0.68	0.995	0.69	0.79	0.992	0.54	0.56	0.996		
10	0.93	1.65	0.912	0.69	0.72	0.994	0.51	0.55	0.998	0.77	1.51	0.935		

以下。发射率在热红外波段相对被动微波受土壤水 分变化的影响较小,能够用来表征地表类型。在微 波波段,发射率受土壤水分的变化影响很大,地表 温度和土壤水分通过发射率纠缠在一起^[10]。

表5	波段27-28-29-31-32组合时波段31的发射率误差	

Table 5 Retrieval emissivity errors in band 31 for band 27-28-29-31-32 combination

						隐含	节点					
隐含层		600			700			800			900	
	M/K	SD/K	R									
7	0.006	0.007	0.971	0.006	0.007	0.976	0.008	0.086	0.926	0.005	0.006	0.981
8	0.007	0.008	0.965	0.005	0.006	0.980	0.005	0.007	0.979	0.007	0.023	0.953
9	0.005	0.007	0.972	0.005	0.007	0.978	0.008	0.021	0.944	0.005	0.006	0.983
10	0.005	0.006	0.976	0.004	0.007	0.981	0.004	0.005	0.991	0.007	0.007	0.961

表6 波段27-28-29-31-32组合时波段32的发射率误差

Table 6 Retrieval emissivity errors in band 32 for band 27-28-29-31-32 combination

	隐含节点												
隐含层	600				700			800		900			
	M/K	SD/K	R										
7	0.005	0.006	0.972	0.005	0.006	0.977	0.005	0.007	0.976	0.006	0.008	0.962	
8	0.005	0.006	0.975	0.004	0.005	0.986	0.004	0.005	0.986	0.004	0.004	0.992	
9	0.004	0.005	0.979	0.005	0.013	0.961	0.008	0.014	0.948	0.005	0.005	0.981	
10	0.004	0.006	0.978	0.004	0.006	0.977	0.007	0.006	0.956	0.005	0.006	0.977	

3.3 近地表空气温度反演

近地表空气温度是天气预报和农业干旱等模型 的关键参数,以往主要是通过气象站点插值获取。 也有一些研究通过统计方法或者神经网络从遥感数 据中反演近地表空气温度,但通常缺乏可解释和物 理意义,而且精度有限。本研究采用深度学习和基 于物理逻辑推理反演近地表空气温度,其推理和分 析过程参考文献 [9] 和 [15]。在热红外遥感窗口 波段,热红外传感器获取的主要信息来自地表,近 地表空气温度的信息量相对较少,因此反演精度受 限。表7是MODIS波段27-28-29-31-32组合时直接 反演近地表空气温度的误差信息表,当隐含层是10 和每层隐含节点是700时精度最高。理论平均精度 最高为1.42 K,标准差为1.46 K,相关系数0.975。

表 8 是 波 段 27-28-29-31-32+LST+LSE31+ LSE32组合时近地表空气温度的反演误差(其中, LSE31为波段31发射率,LSE32为波段32发射率), 最高精度是在隐含层为10和每层隐含节点为800 时,最高平均精度为0.81 K,标准偏差为0.91 K, 相关系数为0.984。当利用地表温度和发射率作为

表7 波段27-28-29-31-32组合时近地表空气温度反演 误差

Table 7 Retrieval errors of near-surface air temperature for

band 27-28-29-31-32 combination

隐	隐含节点											
含		600			700			800			900	
层	M/K	SD/K	R									
7	1.64	1.55	0.958	1.52	1.55	0.962	1.58	1.66	0.963	1.68	1.78	0.966
8	1.58	1.64	0.953	1.56	1.58	0.958	1.56	1.65	0.964	1.60	1.72	0.958
9	1.44	1.51	0.959	1.49	1.54	0.965	1.56	1.63	0.968	1.69	1.77	0.959
10	1.47	1.49	0.961	1.42	1.46	0.975	1.46	1.52	0.967	1.64	1.69	0.969

先验知识时,近地表空气温度的精度明显得到提高,而且反演精度更加稳定。这主要是因为利用地表温度作为先验知识放大了近地表空气温度的信号,而且发射率提供了地表类型,因此反演精度大幅提高,并且算法更具移植性^[9]。因此对于输入变量与输出变量之间是弱相关的参数反演,加入强相关性的变量作为先验知识可以提高弱相关参数的反演精度。

表8 波段27-28-29-31-32+LST+LSE31+LSE32组合时 近地表空气温度反演误差

Table 8 Retrieval errors of near-surface air temperature for

band 27-28-29-31-32+LST+LSE31+LSE32 combination

隐	隐含节点											
含		600 M/K SD/K R			700			800			900	
层	M/K	SD/K	R	M/K	SD/K	R	M/K	SD/K	R	M/K	SD/K	R
7	1.14	1.36	0.976	1.19	1.37	0.975	1.14	1.38	0.981	1.16	1.36	0.978
8	1.25	1.34	0.968	1.18	1.38	0.975	1.19	1.41	0.978	1.03	1.16	0.979
9	1.22	1.32	0.971	1.26	1.41	0.964	0.93	1.05	0.980	1.19	1.37	0.975
10	1.19	1.29	0.976	1.14	1.36	0.977	0.81	0.91	0.984	1.22	1.34	0.973

3.4 大气水汽含量反演

大气水汽含量是天气预报和农业干旱监测等 模型的重要参数,在上面分析的基础上,表9是波 段 27-28-29-31-32 组合时的大气水汽含量反演误 差。最高精度是在隐含层数为9和每层隐含节点为 800时,最高平均精度为0.09 g/cm²,标准偏差为 0.11 g/cm²,相关系数为0.989。

表 10 是波段 27-28-29-31-32+LST+LSE 组合时的大气水汽含量反演误差,最高精度是在隐含层为 9 和每层隐含节点为 900 时,最高平均精度为 0.08 g/cm²,标准偏差为 0.09 g/cm²,相关系数为

表9 波段27-28-29-31-32组合时大气水汽含量反演误差 Table 9 Retrieval errors of atmospheric water vapor content for

band 27-28-29-31-32 combination

隐	隐含节点											
含		600			700			800			900	
层	M/K	SD/K	R									
7	0.18	0.19	0.960	0.15	0.19	0.971	0.18	0.21	0.977	0.15	0.17	0.979
8	0.12	0.15	0.975	0.23	0.27	0.972	0.11	0.13	0.979	0.13	0.15	0.980
9	0.17	0.22	0.963	0.18	0.23	0.973	0.09	0.11	0.989	0.14	0.16	0.976
10	0.87	0.93	0.875	0.35	0.41	0.938	0.13	0.15	0.983	0.40	0.55	0.923

0.992。对比表9和表10,当使用LST和LSE作为先 验知识时,精度略有提高和误差相对比较稳定。如 果当先验知识LST和LSE具有一定误差时,可能精 度不会有太大的改善。因此,当输入参数中有2个 输入波段对输出参数水汽比较敏感时,可以不加入 先验知识。

表 10 波段 27-28-29-31-32+LST+LSE 组合时大气水汽 含量的反演误差

Table 10 Retrieval errors of atmospheric water vapor content

for band 27-28-29-31-32+LST+LSE combination

隐	隐含节点											
含		600			700			800		900		
层	M/K	SD/K	R									
7	0.15	0.17	0.976	0.18	0.21	0.971	0.17	0.18	0.975	0.14	0.16	0.976
8	0.15	0.16	0.976	0.21	0.23	0.969	0.09	0.11	0.991	0.15	0.17	0.977
9	0.14	0.16	0.977	0.23	0.25	0.967	0.11	0.15	0.979	0.08	0.09	0.992
10	0.17	0.19	0.975	0.15	0.19	0.971	0.09	0.11	0.990	0.11	0.12	0.989

4 讨 论

人类认识世界通过观察(取样),然后基于观 察和思考用大脑抽象构造模式,最大程度地形成知 识以达到快速认识世界或者目标的目的,本质上可 以归结为定义规则认识世界。目标只有一个——最 大程度地提高识别(认知)精度,因此不必过于考 虑具体方法的形式(统计方法或物理方法或AI方 法),这些都是认知的手段。根据作者团队多年的 研究经验,统计方法、物理方法和机器学习方法本 质上是一致的,是人们根据不同的情况定义的认识 事物规律的一种方法或手段,特别是目前用得比较 多的深度学习神经网络算法其实是一种更高级的统 计优化计算方法,这种方法的精度和普适范围取决 于构建样本库(训练和测试数据的代表性和精度) 时遵循的规则是否更符合真实情况。

传统遥感地球物理参数反演方法主要适合于地 势平坦,地表类型单一的纯净像元。如图3所示, 对于地球物理遥感参数反演,传统的物理方法无 法解决像元相对入射角问题,也很难解决混合像 元问题,从而导致传统方法反演精度具有瓶颈,公 式(4)中参数的物理意义具体请参考文献[9]和 [15]。AI方法可以将混合像元当成一个新的等效地 物类型,在解决复杂像元反演问题上具有比传统物 理方法非常强的优势。从能量信息流传播的角度 看,深度学习神经网络通过神经元控制传递能量的 方式比统计和物理方法更接近真实情况,甚至更具 有物理意义,这需要人们提高或改变认知思维,并 从信息传播的角度解读^[1,10]。因此只要深度学习耦 合物理和统计方法的模式满足范式条件,理论上可 以无限逼近真实情况。



图3 地球物理参数遥感反演混合像元问题

Fig. 3 Mixed pixel problem in remote sensing retrieval of geo-

physical parameters

另外,从某个角度上讲,AI是一种高级的优化 计算方法,与物理方法和统计方法在本质上是一样 的,都是识别目标的手段。只不过机器学习方法在 硬件技术高速发展的辅助下,显示出更加强大的识 别目标的迭代优化计算能力,深度学习理论上可以 将很多组不同物理方法和统计方法耦合在一起。在 满足反演范式条件下,深度学习的反演和适应范围 理论上远远胜过一个或者几个物理和统计传统方法 的组合。作者团队在2006年和2007年将深度学习 (动态学习神经网络)应用于地表温度和发射率反 演^[1921],但当时由于计算机内存不够,隐含层一般 只设置了3层,而现在算法的隐含层和内存翻到了 几倍甚至几十倍上百倍^[1,12],对计算机要求更高。 由于计算机技术的进步,目前地球物理参数遥感反 演的精度也大幅提升。在满足范式条件下,基于AI 的深度学习耦合物理和统计方法范式是目前利用遥 感数据反演地球物理参数特别是农业气象遥感关键 参数的最佳方法。

本文主要讨论的是地球物理参数反演范式理论 和判定条件,其对于遥感分类或者目标识别也同样 适用^[22,23]。目前卷积神经网络(Convolutional Neural Network, CNN)被认为是较好的分类和目标识 别方法之一,其实CNN是在传统神经网络的基础 上进一步利用不同的卷积核从不同的尺度上提取目 标的信息,目的就是通过不同维度的信息来唯一确 定目标,从而达到提高分类(目标识别)的精 度^[24]。理论上讲,如果这些从不同维度(不同卷 积核)上提取的信息也可以构建数学方程唯一确定 输出参数,也可以形成范式,否则同样也存在不确 定性。

5 结 论

最近几年, AI在许多领域的突破催生了很多新 技术、新产品和新产业,将深刻影响和改变人类生 产生活方式和思维模式,实现生产力的整体跃升。 为了促进AI在地学和农学的应用和培养交叉学科 的人才,本研究提出了基于AI 地球物理参数反演 范式理论及判定条件,即通过物理逻辑推理,目标 信息(问题)在理论或物理逻辑上可以用数学表达 式进行描述,同时可以用物理模型模拟获得物理方 法的解。为了克服物理方法的缺陷,基于物理逻辑 推理构建泛化的统计方法,并且通过多源数据获得 统计方法的解。在此基础上,物理方法和统计方法 的解构成深度学习的训练和测试数据,从而达到深 度学习耦合物理和统计方法的目的。深度学习通过 大数据学习和优化计算将物理方法和统计方法相结 合,从而保证了提出的范式不仅有物理意义和可解 释性,而且还具备通用性。

AI方法反演地球物理参数是否形成范式,即形成具有物理机理和可解释的深度学习范式基本条件有两个:(1)输入与输出变量(参数)之间必须存

在因果关系;(2)输入和输出变量(参数)之间理 论上可以构建闭合的方程组(未知数个数少于或等 于方程组个数),也就是说输出参数可以被输入变 量唯一确定。如果使用深度学习没有证明或不能证 明存在上述两个条件,一般被认定为"黑箱"。如 果能证明:输入和输出参数之间肯定不存在闭合的 关系(未知数大于方程组个数),那么这样的应用 可能主要适合于局部区域,不能通用,很难具备移 植性,不能称为范式。

AI方法的应用不能脱离具体的问题,在解决某 个应用问题时,要先对问题对象进行物理逻辑推 理,从理论上构造方程,确定是输入变量和输出变 量之间的因果关系;然后从方程里面的未知数个数 确定方程组的个数,也就是确定几个输入参数,最 后使用深度学习进行优化求解。进行物理逻辑推理 是使得深度学习具有物理意义和可解释的关键。利 用MODIS遥感数据反演地表温度、发射率、近地 表空气温度和大气水汽含量对范式理论进行了论 证:当输出参数(LST和LSE)与输入变量(BT) 之间具有强相关性时,利用深度学习耦合物理和统 计方法可以获得非常高的精度;当输出参数 (NSAT) 与输入变量(BT) 之间是弱相关性时, 加入先验知识(LST 和 LSE)可以提高输出参数 (NSAT) 反演精度和稳定性; 部分强相关性时 (WVC与BT_i),加入先验知识(LST和LSE)虽然 能稍微提高精度和稳定性,但先验知识(LST和 LSE)的误差可能带来不确定性,因此也可以不加 入先验知识。通过对 MODIS 传感器热红外波段地 球物理参数反演分析可知,波段27、28、29、31 更适合于反演大气水汽含量,波段28、29、31和 32更适合于反演地表温度和发射率及近地表空气温 度。如果要获得4个参数的最高精度,则建议仪器 设计5个波段(27、28、29、31、32)最合适。如 果只设计4个热红波段,可以优先考虑27、28、 31、32。本研究分析结果表明地球物理参数反演范 式理论和判定条件可靠,该理论和判定条件的提出 对利用AI方法反演地表物理参数具有重大意义。

地球物理参数反演范式理论和判定条件也适用 于遥感分类等目标识别,只是需要换一个角度解 读,比如不同卷积核提取的特征信息要能唯一确定 目标。在满足范式条件下,基于AI反演地球物理 参数是最佳选择,因此建议科技部和国家自然基金 委给予支持,打造中国基于AI的地球物理参数反 演范式的"ChatGPT"。

利益冲突声明:本研究不存在研究者以及与公开 研究成果有关的利益冲突。

参考文献:

- DEL FRATE F, FERRAZZOLI P, SCHIAVON G. Retrieving soil moisture and agricultural variables by microwave radiometry using neural networks[J]. Remote sensing of environment, 2003, 84(2): 174-183.
- [2] QIN Z H, DALL'OLMO G, KARNIELI A, et al. Derivation of split window algorithm and its sensitivity analysis for retrieving land surface temperature from NOAA-advanced very high resolution radiometer data[J]. Journal of geophysical research: Atmospheres, 2001, 106(D19): 22655-22670.
- [3] NOTARNICOLA C, ANGIULLI M, POSA F. Soil moisture retrieval from remotely sensed data: Neural network approach versus Bayesian method[J]. IEEE transactions on geoscience and remote sensing, 2008, 46(2): 547-557.
- [4] MAO K B, SHEN X Y, ZUO Z Y, et al. An advanced radiative transfer and neural network scheme and evaluation for estimating water vapor content from MODIS data[J]. Atmosphere, 2017, 8(8): ID 139.
- [5] MAO K B, MA Y, XIA L, et al. A neural network method for monitoring snowstorm: A case study in Southern China[J]. Chinese geographical science, 2014, 24(5): 599-606.
- [6] HAN J Q, MAO K B, XU T R, et al. A soil moisture estimation framework based on the CART algorithm and its application in China[J]. Journal of hydrology, 2018, 563: 65-75.
- [7] TAN J C, NOURELDEEN N, MAO K B, et al. Deep learning convolutional neural network for the retrieval of land surface temperature from AMSR2 data in China[J]. Sensors, 2019, 19(13): ID 2987.
- [8] MAO K B, ZUO Z Y, SHEN X Y, et al. Retrieval of landsurface temperature from AMSR2 data using a deep dynamic learning neural network[J]. Chinese geographical science, 2018, 28(1): 1-11.
- [9] DU B Y, MAO K B, BATENI S M, et al. A novel fully coupled physical – statistical – deep learning method for retrieving near-surface air temperature from multisource data[J]. Remote sensing, 2022, 14(22): ID 5812.
- [10] MAO K B, WANG H, SHI J C, et al. A general paradigm for retrieving soil moisture and surface temperature from passive microwave remote sensing data based on artificial intelligence[J]. Remote sensing, 2023, 15(7): ID 1793.
- [11] MAO K B, LI S M, WANG D L, et al. Retrieval of land surface temperature and emissivity from ASTER1B data

using a dynamic learning neural network[J]. International journal of remote sensing, 2011, 32(19): 5413-5423.

- [12] MAO K B, SHI J C, LI Z L, et al. An RM-NN algorithm for retrieving land surface temperature and emissivity from EOS/MODIS data[J]. Journal of geophysical research: Atmospheres, 2007, 112(D21): ID D21102.
- [13] WANG H, MAO K B, YUAN Z J, et al. A method for land surface temperature retrieval based on model-dataknowledge-driven and deep learning[J]. Remote sensing of environment, 2021, 265: ID 112665.
- [14] 毛克彪,杨军,韩秀珍,等.基于深度动态学习神经网络和辐射传输模型地表温度反演算法研究[J].中国农业信息, 2018, 30(5): 47-57.
 MAO K B, YANG J, HAN X Z, et al. Retrieving land surface temperature based on deep dynamic learning NN algorithm and radiation transmission model[J]. China agricultural informatics, 2018, 30(5): 47-57.
- [15] MAO K B, TANG H J, WANG X F, et al. Near-surface air temperature estimation from *ASTER* data based on neural network algorithm[J]. International journal of remote sensing, 2008, 29(20): 6021-6028.
- [16] MAO K B, MA Y, SHEN X Y, et al. Estimation of broadband emissivity (8-12 um) from *ASTER* data by using RM-NN[J]. Optics express, 2012, 20(18): 20096-20101.
- [17] MAO K B, LI H T, HU D Y, et al. Estimation of water vapor content in near-infrared bands around 1 μm from MO-DIS data by using RM-NN[J]. Optics express, 2010, 18 (9): 9542-9554.
- [18] MAO K B, SHI J C, TANG H J, et al. A neural network technique for separating land surface emissivity and temperature from *ASTER* imagery[J]. IEEE transactions on geoscience and remote sensing, 2008, 46(1): 200-208.

- [19] MAO K, SHI J, LI Z, et al. A multiple-band algorithm for separating land surface emissivity and temperature from *ASTER* imagery[C]// 2006 IEEE International Symposium on Geoscience and Remote Sensing. Piscataway, NJ, USA: IEEE, 2007: 1358-1361.
- [20] 毛克彪, 唐华俊, 李丽英, 等. 一个从 MODIS 数据同时反 演地表温度和发射率的神经网络算法[J]. 遥感信息, 2007, 22(4): 9-15, 8.
 MAO K B, TANG H J, LI L Y, et al. An NN algorithm for retrieving land surface temperature and emissivity from MODIS data[J]. Remote sensing information, 2007, 22 (4): 9-15, 8.
- [21] 毛克彪, 唐华俊, 陈仲新, 等. 一个用神经网络优化的针对ASTER数据反演地表温度和发射率的多波段算法[J]. 国土资源遥感, 2007, 19(3): 18-22.
 MAO K B, TANG H J, CHEN Z X, et al. An optimizaed multiple-band algorithm by using neural network for separating land surface emissivity and temperature from aster imagery[J]. Remote sensing for land & resources, 2007, 19 (3): 18-22.
- [22] MAS J F, FLORES J J. The application of artificial neural networks to the analysis of remotely sensed data[J]. International journal of remote sensing, 2008, 29(3): 617-663.
- [23] CHEN Y S, JIANG H L, LI C Y, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. IEEE transactions on geoscience and remote sensing, 2016, 54(10): 6232-6251.
- [24] 付秀丽,黎玲萍,毛克彪,等.基于卷积神经网络模型的 遥感图像分类[J].高技术通讯,2017,27(3):203-212.
 FU X L, LI L P, MAO K B, et al. Remote sensing image classification based on CNN model[J]. Chinese high technology letters, 2017, 27(3):203-212.

The Paradigm Theory and Judgment Conditions of Geophysical Parameter Retrieval Based on Artificial Intelligence

MAO Kebiao^{1,2,3*}, ZHANG Chenyang⁴, SHI Jiancheng⁵, WANG Xuming², GUO Zhonghua², LI Chunshu², DONG Lixin⁶, WU Menxin⁷, SUN Ruijing⁶, WU Shengli⁶, JI Dabin³, JIANG Lingmei⁸, ZHAO Tianjie³, QIU Yubao³, DU Yongming³, XU Tongren⁸

(1. State Key Laboratory of Efficient Utilization of Arid and Semi-arid Arable Land in Northern China, Institute of Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences, Beijing 100081, China; 2. School of Physics and Electronic-Electrical Engineering, Ningxia University, Yinchuan 750021, China; 3. State Key Laboratory of Remote Sensing Science, Aerospace Information Research Institute, Chinese Academy of Science, Beijing 100094, China; 4. College of Environmental Sciences and Engineering, Peking University, Beijing 100871, China; 5. National Space Science Center, Chinese Academy of Sciences, Beijing 100094, China; 7. National Meteorological Center, Beijing 100081, China; 7. National Meteorological Center, Beijing 100101, China; 8. Department of Geographical Science, Beijing Normal University, Beijing 100875, China)

[Objective] Deep learning is one of the most important technologies in the field of artificial intelligence, which has sparked a research boom in academic and engineering applications. It also shows strong application potential in remote sensing retrieval of geophysical parameters. The cross-disciplinary research is just beginning, and most deep learning applications in geosciences are still

"black boxes", with most applications lacking physical significance, interpretability, and universality. In order to promote the application of artificial intelligence in geosciences and agriculture and cultivate interdisciplinary talents, a paradigm theory for geophysical parameter retrieval based on artificial intelligence coupled physics and statistical methods was proposed in this research.

[Methods] The construction of the retrieval paradigm theory for geophysical parameters mainly included three parts: Firstly, physical logic deduction was performed based on the physical energy balance equation, and the inversion equation system was constructed theoretically which eliminated the ill conditioned problem of insufficient equations. Then, a fuzzy statistical method was constructed based on physical deduction. Representative solutions of physical methods were obtained through physical model simulation, and other representative solutions as the training and testing database for deep learning were obtained using multi-source data. Finally, deep learning achieved the goal of coupling physical and statistical methods through the use of representative solutions from physical and statistical methods as training and testing databases. Deep learning training and testing were aimed at obtaining curves of solutions from physical and statistical methods, thereby making deep learning physically meaningful and interpretable.

[Results and Discussions] The conditions for determining the formation of a universal and physically interpretable paradigm were: (1) There must be a causal relationship between input and output variables (parameters); (2) In theory, a closed system of equations (with unknowns less than or equal to the number of equations) can be constructed between input and output variables (parameters), which means that the output parameters can be uniquely determined by the input parameters. If there is a strong causal relationship between input parameters (variables) and output parameters (variables), deep learning can be directly used for inversion. If there is a weak correlation between the input and output parameters, prior knowledge needs to be added to improve the inversion accuracy of the output parameters. The MODIS thermal infrared remote sensing data were used to retrieve land surface temperature, emissivity, near surface air temperature and atmospheric water vapor content as a case to prove the theory. When there was strong correlation between output parameters (LST and LSE) and input variables (BTi), using deep learning coupled with physical and statistical methods could obtain very high accuracy. When there was a weak correlation between the output parameter (NSAT) and the input variable (BTi), adding prior knowledge (LST and LSE) could improve the inversion accuracy and stability of the output parameter (NSAT). When there was partial strong correlation (WVC and BTi), adding prior knowledge (LST and LSE) could slightly improve accuracy and stability, but the error of prior knowledge (LST and LSE) may bring uncertainty, so prior knowledge could also be omitted. According to the inversion analysis of geophysical parameters of MODIS sensor thermal infrared band, bands 27, 28, 29 and 31 were more suitable for inversion of atmospheric water vapor content, and bands 28, 29, 31 and 32 were more suitable for inversion of surface temperature, Emissivity and near surface air temperature. If someone want to achieve the highest accuracy of four parameters, it was recommended to design the instrument with five bands (27, 28, 29, 31, 32) which were most suitable. If only four thermal infrared bands were designed, bands 27, 28, 31, and 32 should be given priority consideration. From the results of land surface temperature, emissivity, near surface air temperature and atmospheric water vapor content retrieved from MODIS data using this theory, it was not only more accurate than traditional methods, but also could reduce some bands, reduce satellite load and improve satellite life. Especially, this theoretical method overcomes the influence of the MODIS official algorithm (day/night algorithm) on sudden changes in surface types and long-term lack of continuous data, which leads to unstable accuracy of the inversion product. The analysis results showed that the proposed theory and conditions are feasible, and the accuracy and applicability were better than traditional methods. The theory and judgment conditions of geophysical parameter retrieval paradigms were also applicable for target recognition such as remote sensing classification, but it needed to be interpreted from a different perspective. For example, the feature information extracted by different convolutional kernels must be able to uniquely determine the target. Under satisfying with the conditions of paradigm theory, the inversion of geophysical parameters based on artificial intelligence is the best choice.

[Conclusions] The geophysical parameter retrieval paradigm theory based on artificial intelligence proposed in this study can overcome the shortcomings of traditional retrieval methods, especially remote sensing parameter retrieval, which simplify the inversion process and improve the inversion accuracy. At the same time, it can optimize the design of satellite sensors. The proposal of this theory is of milestone significance in the history of geophysical parameter retrieval.

Key words: artificial intelligence; deep learning; retrieval paradigm; physical logic derivation; explainable; agrometeorological remote sensing