

基于 BP 神经网络的 GEO 等离子体 环境参数反演分析*

张海呈 全荣辉 张诚悦

(南京航空航天大学航天学院 南京 211106)

摘要 空间等离子体环境诱发的表面充电效应会对航天器运行产生干扰, 严重时将导致太阳电池等部件失效。通过神经网络反演方法, 以 GEO 环境中介质表面充电电位曲线作为输入, 在双峰麦克斯韦分布假设下, 可以逆向得到高能峰的等离子体参数。分析了 GEO 等离子体环境参数对表面充电电位曲线的影响, 表明高能峰在充电过程中起决定性作用; 其次通过 MATLAB 搭建 BP 神经网络, 采用 COMSOL 计算得到多组充电曲线进行网络训练和反演计算, 得到等离子体密度反演的平均相对误差为 0.42%, 温度反演的平均相对误差为 0.03%, 整体误差在 0.1%~5.6%。结果表明, 采用神经网络对等离子体环境进行反演具有可行性, 该方法可以作为空间等离子体环境探测结果的对比参考和航天器非探测点表面电位计算的输入条件。

关键词 表面充电, 等离子体环境, 双麦克斯韦分布, 神经网络反演

中图分类号 P354

Inversion Analysis of GEO Plasma Environmental Parameters Based on BP Neural Network

ZHANG Haicheng QUAN Ronghui ZHANG Chengyue

(School of Astronautics, Nanjing University of Aeronautics and Astronautics, Nanjing 211106)

Abstract The surface charging effect induced by the space plasma environment may interfere with the operation of spacecraft, which can lead to the failure of solar cells and other components. It is shown that the high-energy plasma environmental parameters can also be obtained by taking the electrical potential curve of the dielectric surface in the GEO environment as input under the assumption of double Maxwell distribution. Firstly, the influence of GEO plasma environment parameters on the surface charging potential curve is analyzed, indicating that the high energy peak plays a decisive role in the charging process. Then, BP neural network is established by MATLAB, and the network training data is

* 国家自然科学基金项目资助 (51877111)

2022-03-11 收到原稿, 2022-10-11 收到修定稿

E-mail: quanrh@nuaa.edu.cn

obtained according to multiple groups of charging curves calculated by COMSOL. Finally, the average relative error of plasma density and temperature inversion is 0.42% and 0.03%, and respectively, and the overall relative error is within 0.1%~5.6%. Results showed that it was feasible to use a neural network to invert the plasma environment, and the method can be used as a reference for comparison of the detection results of the space plasma environment. The inversion results can be used as the input conditions for surface potential calculation of non-detection points of spacecraft.

Key words Surface charging, Plasma environment, Bi-Maxwell distribution, Neural network inversion

0 引言

自 20 世纪中期航天器充电效应被发现以来, 有关充放电效应对航天器的危害、航天器充放电机理及充放电效应防护等的研究不断深入, 目前相关研究多集中于航天器充放电效应与防护的新技术、新平台、新要求及新载荷带来的航天器充放电新机理, 而对表面充电相关的等离子体特征环境的研究还比较少^[1]。现有的空间等离子体环境特征研究主要集中在具体环境参数对表面电位的影响, 以及最恶劣等离子体环境标准的确定等方向。例如 Lai 等^[2]详细研究了不同分布下的等离子体密度对航天器表面充电的影响, 分析认为对于符合单麦克斯韦分布及 Kappa 分布的等离子体, 等离子体密度对充电结果没有影响; 对于双麦克斯韦分布的等离子体, 等离子体密度会对表面充电电位产生影响。Nakamura 等^[3]通过表面充电软件 SPIS 进行循环模拟, 对造成表面充电的最恶劣等离子体环境进行评估。Fang 等^[4,5]对等离子体能量密度及二次电子发射系数对表面电位的影响进行了研究; Cui 等^[6]利用 SPIS 软件对 SMILE 卫星进行仿真, 发现二次电子及光电子对卫星表面充电具有重要影响。这些研究均以等离子体环境参数作为输入对航天器表面电位进行预测, 但是对于如何获取等离子体参数无确切可行的方法, 多依赖于在轨探测结果。空间等离子体在轨探测主要还是通过搭载朗缪尔探针和等离子体分析仪进行的, 为保证探测结果的准确性通常需要多探针协同相互校正^[7]。

本文根据等离子体环境参数与航天器表面充电之间的联系, 提出采用人工神经网络对 GEO 等离子体环境参数进行反演分析的方法, 该方法可以只通过表面电位探测数据得到环境特征信息, 并与环境探测

结果进行对比以得出更精确的等离子体环境参数, 减少校正所用探头设备。该方法同时提供了用于表面充电计算的等离子体参数获取途径, 可以通过对表面充电电位曲线进行提取, 计算对应的环境参数, 进而作为其余非探测部位表面充电电位计算的输入条件, 有利于更好地把握航天器整体表面充电水平, 做出更准确的风险评估。

1 GEO 表面充电模型

1.1 GEO 表面充电机理

航天器的表面充电是指航天器在空间中运行时, 表面材料与空间带电粒子相互作用, 导致电荷累积, 进而在航天器表面形成电位分布的现象。撞击到航天器表面的带电粒子主要有环境等离子体、光电子、二次电子、背散射电子/离子等。

由于 GEO 等离子体环境中既有低能的背景等离子体又有地磁亚暴产生的高能等离子体, 因此通常采用双麦克斯韦分布进行环境描述, 等离子体的双麦克斯韦分布速率为

$$f(v) = \left(\frac{m}{2\pi}\right)^{3/2} \left[\frac{n_1}{(kT_1)^{3/2}} \exp\left(-\frac{mv^2}{2kT_1}\right) + \frac{n_2}{(kT_2)^{3/2}} \exp\left(-\frac{mv^2}{2kT_2}\right) \right]. \quad (1)$$

式中, n 为粒子数密度, T 为粒子温度, m 为粒子质量, k 为玻尔兹曼常数, 下标 1 和 2 分别代表低能峰和高能峰等离子体麦克斯韦分布。

将航天器充电部位视为一电容片, 航天器表面电位为

$$dU(t) = \frac{J_{\text{net}}(t)}{C_0} dt. \quad (2)$$

式中, U 为表面充电电位, J_{net} 为航天器表面电流密度, C_0 为航天器单位面积上的电容。考虑二次电子、光电子的影响, 忽略背散射电子和离子, 并假设在光照区, 光电子电流是电子电流的 δ_p 倍 ($\delta_p=0.3$)^[8], 最终航天器表面的净电流密度 J_{net} 为

$$J_{\text{net}} = -J_e + J_i + J_{\text{sec}} + J_{\text{ph}}. \quad (3)$$

式中, J_e 为电子的电流密度, J_i 为离子的电流密度, J_{sec} 为二次电子的电流密度, J_{ph} 为光电子的电流密度。根据文献 [9] 可知, 航天器充负电时, 双麦克斯韦分布下电子的电流密度为

$$J_e = e \sum_{j=1}^2 n_{e,j} \left(\frac{kT_{e,j}}{2\pi m_e} \right)^{1/2} \exp \left(\frac{eU}{kT_{e,j}} \right). \quad (4)$$

式中, e 为电子电荷量, 下标 e 代表电子。双麦克斯韦分布下离子的电流密度为

$$J_i = q_i \sum_{j=1}^2 n_{i,j} \left(\frac{kT_{i,j}}{2\pi m_i} \right)^{1/2} \left(1 - \frac{q_i U}{kT_{i,j}} \right). \quad (5)$$

式中, q_i 为离子电荷量, 下标 i 代表离子。当 δ_e 分别为二次电子的系数时, 二次电子的电流密度为

$$J_{\text{sec}} = \delta_e J_e. \quad (6)$$

设航天器背面接地, 充电介质上表面与等离子体相互作用, 背面与卫星结构保持欧姆接触, 有

$$C_0 \frac{dU}{dt} = J_{\text{net}} - J_c. \quad (7)$$

式中, J_c 为介质从表面传导到背面的电流密度, 可表示为

$$J_c = \frac{U}{\rho d}. \quad (8)$$

式中, ρ 为材料电阻率, d 为材料厚度。可得表面充电

电位的简化方程为

$$\frac{dU}{dt} = \frac{1}{C_0} \left[a_e e \sum_{j=1}^2 n_{e,j} \left(\frac{kT_{e,j}}{2\pi m_e} \right)^{1/2} \exp \left(\frac{eU}{kT_{e,j}} \right) + q_i \sum_{j=1}^2 n_{i,j} \left(\frac{kT_{i,j}}{2\pi m_i} \right)^{1/2} \left(1 - \frac{q_i U}{kT_{i,j}} \right) - \frac{U}{\rho d} \right]. \quad (9)$$

式中, $a_e = \delta_e + \delta_p - 1$ 。可通过仿真软件对式(9)进行求解。

1.2 GEO 表面充电曲线特性

神经网络反演成立的前提是反演输入量与输出量之间存在明确的物理关联。基于上述表面充电机理通过 COMSOL 多物理场仿真软件搭建表面充电仿真模型。若航天器处于阴影区, 则可忽略其中的光电子影响^[10]。通过模型进行计算分析, 可以更直观了解等离子体环境参数对表面充电曲线的影响。COMSOL 采用的航天器模型是长为 0.04 m、宽 0.025 m、厚度 25 μm 的电容片结构, 航天器背面接地。材料选择航天器常用的 Kapton 聚酰亚胺, 采用文献 [11] GEO 典型等离子体环境(见表 1)中的第一组环境参数进行计算, 时间范围为 0.5~10000 s, 使得航天器表面电位能够达到最终的平衡电位。每次仅改变其中一个环境参数值, 参数变化范围主要参考 NASA 定义的最恶劣等离子体环境能谱(见表 1)^[11] 范围内的数据。

首先改变 $n_{e,1}$ 的参数值, 保持其他环境参数不变, 计算得到的充电曲线如图 1(a)所示。其参数值改变后测得的平衡电位及最终平衡时间均没有变化, 可知 $n_{e,1}$ 的值对表面充电没有影响。同样, 改变其他粒子数密度参数得到如图 1(b)~(d)所示的充电曲线,

表 1 GEO 最恶劣等离子体环境参数

Table 1 GEO worst-case environmental parameters

等离子体分布	$n_{e,1}/\text{cm}^{-3}$	$T_{e,1}/\text{eV}$	$n_{e,2}/\text{cm}^{-3}$	$T_{e,2}/\text{eV}$	$n_{i,1}/\text{cm}^{-3}$	$T_{i,1}/\text{eV}$	$n_{i,2}/\text{cm}^{-3}$	$T_{i,2}/\text{eV}$
SCATHA-Mullen1	0.20	400	2.30	24800	1.60	300	1.30	28200
SCATHA-Mullen2	0.90	600	1.60	25600	1.10	400	1.70	24700
ECSS-E-ST-10-04 C (SCATHA 1979)	0.20	400	1.20	27500	0.60	200	1.30	28000
NASA Worst Case	1.12	12000	—	—	0.236	29500	—	—
ATS-6	2.36	29500	—	—	0.236	29500	—	—
MIL-STD-1809	2.36	3100	0.625	25100	0.60	200	1.20	28000
Galaxy 15	4.58	55600	—	—	0.10	75000	—	—




图 1 不同粒子数密度下的充电曲线

Fig. 1 Charge curves for different particle number densities

其中 $n_{e,2}$, $n_{i,1}$, $n_{i,2}$ 对应的充电电位曲线随着参数变大, 平衡电位绝对值变小, 平衡时间变短, 则离子数密度的影响较小; 改变等离子体温度参数得到如图 2(a)~(d)所示的充电曲线, $T_{e,1}$, $T_{e,2}$, $T_{i,1}$, $T_{i,2}$ 对应的充电电位曲线则随参数变大平衡电位绝对值变大, 平衡时间变化不大, 其中电子温度对表面充电的影响较大。

总体而言, 同一麦克斯韦分布下等离子体温度对电位的影响大于等离子体密度, 电子的影响大于离子, 高能峰等离子体环境参数对表面电位的影响明显大于低能峰。由于低能峰等离子体环境对 GEO 表面充电的影响远小于高能峰, 为提高反演数据的精度, 仅对高能峰等离子体环境参数进行反演。

2 BP 神经网络反演模型

2.1 BP 神经网络基本原理

使用 BP 神经网络对造成 GEO 表面充电的高能峰等离子体环境进行反演, 因为 BP 神经网络应用最为广泛, 且具有很强的识别功能, 特别是对应用问题

的识别。其非线性映射能力非常强, 且具有很好的泛化能力和较强的容错性^[12]。

BP 神经网络是一种多层前馈型神经网络, 基本原理是将一个输入矢量经过隐含层的一系列变换, 最终得到一个输出矢量, 实现输入与输出数据之间的一个映射关系。输入信息的正向传播与输出误差的反向传播构成 BP 算法的信息循环。正向传播时, 输入信号通过隐含层作用于输出节点, 结果非线性变换, 产生输出信号, 若实际输出与期望输出不符, 则转入误差的反向传播, 将输出误差通过隐含层向输入层传递, 并将误差分摊给各层所有单元, 通过各层的误差信号调整各单元权值。此过程一直进行到网络输出的误差逐渐减少到可以接受的程度或者达到设定的训练次数为止^[13]。BP 神经网络结构如图 3 所示。 $X_1, X_2, \dots, X_n$ 为网络输入, $Y_1, Y_2, \dots, Y_m$ 为网络输出, W_{ij} 和 W_{jk} 为网络权值。

2.2 反演模型建立

采用三层典型 BP 神经网络, 利用 MATLAB 中最通常的 Levenberg-Marquardt 算法, 该算法处理




图2 不同等离子体温度下的充电曲线

Fig. 2 Charging curves for different plasma temperatures




图3 BP神经网络结构

Fig. 3 Structure diagram of BP neural network

函数逼近问题的能力较强且网络收敛速度最快^[14], 对应函数为 trainlm。以充电电位(X_n)为输入变量, 高能峰等离子体环境参数中的电子浓度(Y_1)、电子温度(Y_2)、离子浓度(Y_3)、离子温度(Y_4)为输出变量。搭建的神经网络结构如图4所示

2.2.1 数据来源

由于 GEO 等离子体环境构成比较复杂, 包含几乎所有能量的等离子体且在不同太阳活动及地磁条件下等离子体能谱不同, 因此为使反演模型更有实际价值, 选取文献[12]中 NASA 定义的 GEO 最恶劣等




图4 神经网络结构

Fig. 4 Structure of BP neural networks

离子体环境能谱(见表1)范围中的数据, 从低到高共划分 36 组环境参数, 以其中 31 组数据作为训练集, 最后 5 组作为测试集。部分环境参数列于表2。

航天器表面电位数据通过 1.2 节搭建的 COM-SOL 多物理场仿真软件搭建的模型计算得到。航天器模型及材料设定不变, 时间范围为 0.5~50 s, 每隔 0.5 s 取一个电位数据, 共获得 100 个电位数据。部分电位数据列于表3。

2.2.2 数据归一化处理

为避免因输入输出数据数量级差距过大造成的网络误差, 需对 2.1 节获得的数据进行归一化处理。采用的是最大最小法, 其函数形式为

表 2 部分等离子体环境参数
Table 2 Partial plasma environmental parameters

等离子体分布	$n_{e,1}/\text{cm}^{-3}$	$T_{e,1}/\text{eV}$	$n_{e,2}/\text{cm}^{-3}$	$T_{e,2}/\text{eV}$	$n_{i,1}/\text{cm}^{-3}$	$T_{i,1}/\text{eV}$	$n_{i,2}/\text{cm}^{-3}$	$T_{i,2}/\text{eV}$
环境1	0.20	400	2.3	24800	1.60	300	1.30	28200
环境2	0.25	450	2.2	25000	1.50	310	1.32	28000
环境3	0.30	500	2.1	25200	1.40	320	1.34	27800
环境4	0.35	550	2.0	25400	1.30	330	1.36	27600
环境5	0.40	600	1.9	25600	1.20	340	1.38	27400
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

表 3 部分电位数据
Table 3 Partial potential data

时间 /s	0.5	1	1.5	2	2.5	3	3.5	⋯	50
电位1	-7.24	-14.48	-21.72	-28.96	-36.21	-43.44	-50.66	⋯	-702.24
电位2	-6.62	-13.23	-19.85	-26.47	-33.08	-39.69	-46.29	⋯	-642.96
电位3	-5.96	-11.92	-17.89	-23.84	-29.79	-35.75	-41.69	⋯	-580.86
电位4	-5.28	-10.56	-15.85	-21.12	-26.40	-31.68	-36.95	⋯	-515.85
电位5	-4.58	-9.15	-13.72	-18.30	-22.87	-27.44	-32.01	⋯	-447.92
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

$$x'_k = \frac{x_k - x_{\min}}{x_{\max} - x_{\min}}. \tag{10}$$

2.2.3 传递函数选择

BP 神经网络的传递函数包括输入层与隐含层、隐含层与输出层之间的传递函数。输入层与隐含层之间的传递函数通常选择对数 S 型函数(logsig), 隐含层与输出层之间的传递函数通常选择线性函数(purelin)。

2.2.4 神经网络参数设置

将 BP 神经网络的最大训练次数设为 100, 学习率设为 0.01; 选取不同期望误差进行测试, 最终将期望误差最小值设为 10^{-5} ; 神经元数量经过测试, 选择误差最小时的数据设为 12。神经网络反演结果以其相对误差作为评价指标。

2.3 反演结果与分析

将神经网络反演结果反归一化后输出(见表 4), 反演结果与实际值的相对误差在 0.02%~6.99% 内, 其中等离子体密度的平均相对误差为 2.76%, 等离子体温度的误差为 0.93%, 误差较大处为等离子体密度 $n_{i,2}$ 处, 误差产生原因为神经网络自身陷入局部最小。表 4 表明, 所建立的 BP 神经网络反演的高能峰

表 4 BP 神经网络反演结果

Table 4 Inversion results by BP neural network

等离子体分布	$n_{e,2}/\text{cm}^{-3}$	$T_{e,2}/\text{eV}$	$n_{i,2}/\text{cm}^{-3}$	$T_{i,2}/\text{eV}$
反演环境1	2.30	24800	1.30	28200
反演结果1	2.22	25025	1.315	28090
相对误差/(%)	3.48	-0.91	-1.15	0.39
反演环境2	1.50	26400	1.46	26600
反演结果2	1.43	26068	1.3579	27103
相对误差/(%)	4.47	1.26	6.99	-1.89
反演环境3	1.00	27500	1.70	24700
反演结果3	0.997	27459	1.5844	25378
相对误差/(%)	0.30	0.15	6.80	-2.74
反演环境4	0.99	27500	1.70	24700
反演结果4	0.967	27272	1.6663	24972
相对误差/(%)	2.30	0.83	1.98	-1.10
反演环境5	0.73	25600	1.46	26800
反演结果5	0.729	25629	1.4603	26738
相对误差/(%)	0.14	-0.11	-0.02	0.23

麦克斯韦参数与实际较为接近,具有一定反演能力。

因航天器在轨期间遭遇的等离子体环境变化极快,输入的充电电位对输出的环境反演结果影响极大,为得出更准确的当前时间的等离子体环境,另取当前充电电位前 5 s 中的 9 个数据加上当前电位数据搭建新的神经网络,以第 5 s 的电位作为当前电位。隐含层神经元数量调整为 12,其他参数不变。因 BP 神经网络自身具有收敛缓慢,易限于局部极小而无法达到全局最优等问题,采用遗传算法(GA)对 BP 神经网络进行优化,以加快收敛速度实现全局寻优,并与传统 BP 神经网络进行比较^[15]。

遗传算法仿真中的种群规模设置为 30,遗传代数设为 50,交叉概率为 0.7,变异概率设为 0.3。BP 神经网络的初始值设置不变,训练集、测试集数据构成不变。

最终反演结果列于表 5,图 5 和图 6 分别为 BP 和 GA-BP 反演结果的相对误差。传统 BP 神经网络相对误差在 0.1%~9.7% 内,等离子体密度的平均相对误差为 2.1%,等离子体温度的平均相对误差为 0.8%; GA-BP 神经网络的反演结果主要在 0.1%~5.6% 内,等离子体密度的平均相对误差为 0.42%,等离子体温度的平均相对误差为 0.03%,反演结果明显

表 5 GA-BP 神经网络反演结果
Table 5 Inversion results by GA-BP neural network

等离子体分布	$n_{e,2}/\text{cm}^{-3}$	$T_{e,2}/\text{eV}$	$n_{i,2}/\text{cm}^{-3}$	$T_{i,2}/\text{eV}$
反演环境1	2.30	24800	1.30	28200
BP值	2.274	24910	1.327	28088
GA-BP值	2.259	25041	1.319	28071
反演环境2	1.50	26400	1.46	26600
BP值	1.488	26394	1.351	27587
GA-BP值	1.499	26392	1.433	26908
反演环境3	1.00	27500	1.70	24700
BP值	1.018	27467	1.631	25101
GA-BP值	0.998	27511	1.688	24755
反演环境4	0.99	27500	1.70	24700
BP值	1.016	27451	1.658	24920
GA-BP值	0.981	27404	1.705	24792
反演环境5	0.73	25600	1.46	26800
BP值	0.746	25691	1.457	26774
GA-BP值	0.741	25650	1.459	26753

优于传统 BP 神经网络。结果表明,建立的神经网络模型有较好的反演精度,且经过遗传算法优化的神经网络反演能力更强。

3 典型算例分析

为确定神经网络反演在实际应用中的可行性,采用 SCATHA 卫星 1979 年 4 月 24 日实际测量 Kap-ton 材料充电电位后获得的数据(见图 7)进行反演测试。本轮充电从 5 min 左右开始,17 min 到达峰值。初始及峰值电位对应等离子体环境参数列于表 6^[16]。在整个充电过程中,电子参数变化较大, $n_{e,1}$ 从初始的 0.6 cm^{-3} 下降到峰值电位时的 0.2 cm^{-3} , $n_{e,2}$ 从初始的 0.6 cm^{-3} 上升到 1.2 cm^{-3} ,但是离子几乎保持不变^[16]。因此,为对实时环境进行反演,分别选取初始时刻及峰值电位前 5 s 的电位数据作为测试集,所选




图 5 BP 神经网络的误差百分比
Fig. 5 Errors of BP neural network




图 6 GA-BP 神经网络的误差百分比
Fig. 6 Errors of GA-BP neural network

表 6 1979 年 SCATHA 卫星环境参数反演结果

Table 6 Inversion results of environmental parameters of SCATHA satellite in 1979

等离子体分布	$n_{e,1}/\text{cm}^{-3}$	$T_{e,1}/\text{eV}$	$n_{e,2}/\text{cm}^{-3}$	$T_{e,2}/\text{eV}$	$n_{i,1}/\text{cm}^{-3}$	$T_{i,1}/\text{eV}$	$n_{i,2}/\text{cm}^{-3}$	$T_{i,2}/\text{eV}$
初始环境	0.60	100	0.60	26000	0.62	300	1.30	28000
反演结果	—	—	1.03	24885	—	—	1.34	27452
峰值环境	0.20	400	1.20	27500	0.60	200	1.30	28000
反演结果	—	—	1.78	24335	—	—	1.62	25127

表 7 所取电位数据

Table 7 Selected potential data

取点	1	2	3	4	5	6	7	8	9	10
初始电位/V	-4.07	-4.41	-4.89	-5.21	-5.57	-6.01	-6.33	-6.70	-6.95	-7.21
峰值电位/V	-295.90	-299.31	-306.83	-314.27	-322.63	-327.01	-330.44	-335.73	-338.10	-341.52




图 7 1979 年 SCATHA 卫星在轨电位曲线

Fig. 7 Potential curve of SCATHA satellite in 1979

数据点参数见表 7。根据 SCATHA 卫星的探测器材料等参数修改第 1 节中的 COMSOL 仿真模型并进行计算获取训练集,再采用 2.3 节建立的 GA-BP 神经网络进行训练反演,其他神经网络参数不变,最终反演结果见表 6。反演参数的平均绝对百分比误差 (MAPE) 为 0.1378,反演结果与实际测量值比较接近。由于训练采用的数据集均由仿真获得,并且忽略了光照及航天器结构(等效为电容结构)等的影响,对真实环境的反演精度还有较大提升空间,因此采用神经网络模型对表面充电的等离子体环境参数进行反演是可行的。

4 结论

在分析等离子体参数与表面充电电位之间关系

的基础上,提出使用 BP 神经网络对双麦克斯韦分布下高能峰等离子体环境参数进行反演分析的方法。通过 MATLAB 搭建神经网络模型,最终反演的等离子体密度平均相对误差为 0.42%,等离子体温度平均相对误差为 0.03%,仿真反演结果精度较高,而实际 SCATHA 环境参数反演结果由于缺少真实数据作为训练集,采用模型反演的参数误差在 1 个量级以内,MAPE 为 0.1378,这表明通过神经网络对等离子体环境进行反演是可行的。通过神经网络对表面充电的等离子体环境进行反演,可与环境探测器结果进行对比验证,用作其余部位表面充电计算的等离子体输入参数,有助于提高等离子体环境探测和表面充电仿真精度。

这里主要对单一结构与材料下,无光照时表面电位曲线对应的空间等离子体环境参数进行反演分析,后续将以此为基础,进一步对不同材料部位的航天器电位及相应等离子体环境参数进行反演分析,并拓展到光照条件下的等离子体环境参数反演。神经网络的反演精度不仅依赖于反演方法,也取决于训练数据的准确性。如何更好地利用卫星在轨探测数据进一步提高计算精度,是未来需要开展的工作。

参考文献

[1] LIU Shanghe, HU Xiaofeng, YUAN Qingyun, et al. Research progress in charging-discharging effects and protection of spacecraft[J]. *High Voltage Engineering*, 2019, 45(7): 2108-2118 (刘尚合, 胡小锋, 原青云, 等. 航天器充放电效应与防护研究进展[J]. *高电压技术*, 2019, 45(7): 2108-

- 2118)
- [2] LAI S T, MARTINEZ-SANCHEZ M, CAHOY K, *et al.* Does spacecraft potential depend on the ambient electron density[J]. *IEEE Transactions on Plasma Science*, 2017, **45**(10): 2875-2884
 - [3] NAKAMURA M, NAKAMURA S, KAWACHI R, *et al.* Assessment of worst GEO plasma environmental models for spacecraft surface charging by SPIS[J]. *Transactions of the Japan Society for Aeronautical and Space Sciences, Aerospace Technology Japan*, 2018, **16**(6): 556-560
 - [4] FANG Qingyuan, ZHOU Jiangbo, JI Qizheng, *et al.* Evaluation of spacecraft surface potential based on plasma's energy density[J]. *Journal of Microwaves*, 2020, **36**(5): 36-40 (方庆园, 周江波, 季启政, 等. 基于等离子体能量密度的航天器表面电位估计[J]. *微波学报*, 2020, **36**(5): 36-40)
 - [5] FANG Qingyuan, WANG Tong, JI Qizheng, *et al.* Analysis of spacecraft charging onset using secondary electron yield[J]. *High Power Laser and Particle Beams*, 2021, **33**(2): 023007 (方庆园, 王通, 季启政, 等. 基于平均二次电子发射系数的航天器表面起电特征分析[J]. *强激光与粒子束*, 2021, **33**(2): 023007)
 - [6] CUI Yang, YANG Yong, ZHANG Xiaofeng, *et al.* Analysis of surface potential characteristics for SMILE satellite [J]. *Chinese Journal of Vacuum Science and Technology*, 2021, **41**(1): 22-28 (崔阳, 杨勇, 张晓峰, 等. SMILE卫星表面电位特性分析[J]. *真空科学与技术学报*, 2021, **41**(1): 22-28)
 - [7] GUAN Yibing, WANG Shijin, LIANG Jinbao, *et al.* Spacecraft potential control and potential monitor during spacecraft docking[J]. *Science and Technology Review*, 2011, **29**(29): 27-31 (关赓炳, 王世金, 梁金宝, 等. 航天器交汇对接电位控制研究与航天器电位监测[J]. *科技导报*, 2011, **29**(29): 27-31)
 - [8] TIAN Licheng, SHI Hong, LI Juan, *et al.* Simulation of spacecraft surface charging and active control of spacecraft surface potential[J]. *Spacecraft Environment Engineering*, 2012, **29**(2): 144-149 (田立成, 石红, 李娟, 等. 航天器表面充电仿真计算和电位主动控制技术[J]. *航天器环境工程*, 2012, **29**(2): 144-149)
 - [9] ZUO Yinghong, WANG Jianguo, LUO Xudong, *et al.* Spacecraft surface charging effect of plasma in bi-Maxwellian distribution[J]. *High Power Laser and Particle Beams*, 2015, **27**(11): 114003 (左应红, 王建国, 罗旭东, 等. 双麦克斯韦分布等离子体对航天器表面的充电效应[J]. *强激光与粒子束*, 2015, **27**(11): 114003)
 - [10] WU Mingzhi. Analysis and Simulation of Surface Charging and Discharging on Solar Array[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2018 (武明志. 空间等离子体诱发太阳能电池表面充放电效应的仿真分析[D]. 南京: 南京航空航天大学, 2018)
 - [11] ISO. ISO 19923: 2017 Space environment (natural and artificial)—plasma environments for generation of worst case electrical potential differences for spacecraft[S]. ISO, London, 2017
 - [12] MA Xiaomin, WANG Xin. An improved BP neural network algorithm based on genetic algorithm[J]. *Journal of Yunnan University*, 2013, **35**(S2): 34-38 (马晓敏, 王新. 基于遗传算法的BP神经网络改进[J]. *云南大学学报(自然科学版)*, 2013, **35**(S2): 34-38)
 - [13] LIU Jianlin. Application of BP neural network prediction model to the electromagnetic fields[J]. *Electric Power Environmental Protection*, 2017, **33**(4): 5-9 (刘建林. BP神经网络模型在电磁环境预测中的应用[J]. *电力科技与环保*, 2017, **33**(4): 5-9)
 - [14] LIU Tian, YAO Menglei, HUANG Jigui, *et al.* Application of back propagation neural network in prediction of infectious disease time series and its MATLAB implementation[J]. *Journal of Preventive Medicine Information*, 2019, **35**(8): 812-816, 821 (刘天, 姚梦雷, 黄继贵, 等. BP神经网络在传染病时间序列预测中的应用及其MATLAB实现[J]. *预防医学情报杂志*, 2019, **35**(8): 812-816, 821)
 - [15] REN Xienan. Study on Optimization of BP Neural Network Based on Genetic Algorithm and MATLAB Simulation[D]. Tianjin: Tianjin Normal University, 2014 (任谢楠. 基于遗传算法的BP神经网络的优化研究及MATLAB仿真[D]. 天津: 天津师范大学, 2014)
 - [16] GUSSENHOVEN M S, MULLEN E G. Geosynchronous environment for severe spacecraft charging[J]. *Journal of Spacecraft and Rockets*, 1983, **20**(1): 26-34