

深度学习辅助下的蜂窝涂覆目标 RCS 高效预测方法 *

张凡¹⁾ 刘江¹⁾ 何鹏¹⁾ 王者¹⁾ 吴学良¹⁾ 何博琨^{1)†} 王娟¹⁾
武明虎¹⁾ 张云华²⁾

1) (湖北工业大学太阳能高效利用及储能运行控制湖北省重点实验室, 武汉 430068)

2) (武汉大学地球与空间科学技术学院, 武汉 430072)

在隐身应用背景下, 准确预测蜂窝涂覆目标的雷达散射截面对于满足相关工程应用的严格性能要求具有重要意义。针对宽带下蜂窝涂覆目标雷达散射截面预测中计算效率低、传统等效方法精度不足的问题, 本文提出一种基于深度学习辅助的高效预测框架。该框架以结构几何参数与材料参数为输入, 通过电磁建模与散射求解实现雷达散射截面的快速预测。区别于常规的端到端神经网络模型, 本文构建了由双数据集驱动的 BiGT-Net (BiGRU-Transformer) 级联架构。该机制将等效过程分为两阶段: 以宽频反射系数 (S_{11}) 为物理桥梁, 先利用 BiGRU 提取蜂窝结构的频率特征, 再结合 Transformer 捕获谐振特性, 从而突破传统均匀化方法的限制, 高精度地反演出宽频等效电磁参数, 随后再根据精度要求选择对应的 RCS 求解器。该框架可根据具体应用需求灵活选择散射求解器, 从而兼顾计算精度与效率。值得注意的是, 低占空比下蜂窝涂覆材料因其吸波涂覆层薄、材质更为轻盈, 在先进隐身装备中具有极高的应用价值与研究意义, 本文以 X 波段为例开展了实验验证。对比结果表明, 在保持相同仿真精度和硬件环境下与传统等效方法相比, 本文方法不仅成功克服了方法前人方法在低占空比场景下精度锐减的困难, 显著提升了整体预测精度, 还大幅优化了计算资源消耗, 其计算效率提升了约 18 倍, 且内存占用降低了约 8 倍。所提出的方法为蜂窝涂覆目标雷达散射截面的快速分析与工程设计提供了一种高效且可扩展的技术途径。

关键词: 雷达散射截面; 蜂窝结构; 深度学习; 电磁均匀化; RCS 预测框架

1 引言

蜂窝结构因其优异的电磁波吸收性能和轻质特性，在现代雷达隐身技术中得到了极其广泛的应用。在此背景下，准确预测蜂窝涂覆目标的雷达散射截面（Radar Cross Section, RCS）对于满足相关工程应用的严格性能要求具有重要意义^[1-3]。然而，宏观目标尺度与微观蜂窝结构尺度之间存在显著差异，宏观电大尺寸目标本身已对计算资源提出较高要求，而微观蜂窝结构的引入迫使网格剖分尺寸必须远小于微结构特征长度，这双重约束共同导致了网格规模爆炸式增长，使得直接开展多尺度 RCS 计算面临巨大的计算复杂度与资源消耗挑战。

在此背景下，电磁均匀化方法通过将非均匀复合介质等效为均匀介质，从而显著降低电磁计算复杂度，因此在工程分析中得到广泛应用。目前，用于获取蜂窝结构等效电磁参数的方法主要包括反演法和正向等效理论两类。反演法因其易于获取散射参数且适用于复合材料结构而被广泛应用。该方法通过对散射参数（Scattering Parameters, S -parameters）中的反射系数（Reflection Coefficient, S_{11} ）和透射系数（Transmission Coefficient, S_{21} ）进行反演，从而推导出等效材料参数，例如，Nicolson, Ross 和 Weir 等人提出 NRW 反演法^[4,5]。基于上述理论，研究者做出了诸多研究：包括东南大学景莘慧教授团队借助网络分析仪解决了 NRW 多值性问题^[6]，Baker-Jarvis J 等人通过算法优化和方程重构，有效地解决了 NRW 算法中存在的相位模糊问题^[7]。以及 Smith 等^[8]通过数值拟合获得的等效介电常数经验表达式。然而，其应用前提是必须已知待测目标的 S 参数，因此无法直接由材料的结构与相参数出发进行理论推导。正向等效理论则基于电磁理论，从复合材料的结构参数与材料参数出发直接计算其等效电磁参数。典型理论包括 Bruggeman 理论^[8]、Hashin-Shtrikman (HS) 理论^[9]以及强扰动理论（Strong Fluctuation Theory, SFT）^[10]。其中，Bruggeman 适用于几种组分材料体积分数相近的情况。HS 变分理论因其卓越的普适性，能够为具有任意微观几何形态的结构型复合材料等复杂材料体系，提供高精度的等效性能预测。基于正向等效理论。Zhou P. 等^[12]在准静态条件下研究了蜂窝复合材料结构参数与介电常数之间的关系。Hu 等^[13]考虑了 SFT 中的波动项，推导出蜂窝夹层结构的等效电磁参数。He 等^[11]提出的蜂窝结构等效电磁参数与吸波特性的研究。然而，无论是 Bruggeman 理论、HS 变分理论还是强扰动理论，在建立等效模型

† 通信作者. E-mail: hebokun@hbut.edu.cn (何博琨)

第一作者. E-mail: joyce_zhang@hbut.edu.cn (张凡)

* 国家自然科学基金 (基金号: 62301215)、中国国家留学基金委员会资助项目 (China Scholarship Council, CSC)、湖北省科研计划项目 (Science and Technology Project of Hubei Province 基金号: 2022BEC017), 电磁散射重点实验室基金以及湖北工业大学博士科研启动基金 (基金号: BSQD2020015) 资助的课题。

时未充分考虑孔径变化对电磁响应的影响，从而为其均质化过程带来了根本性的困难。

近年来，深度学习（Deep Learning, DL）在计算电磁学复杂建模问题中的潜力逐渐得到验证^[14]，并已成功应用于超表面设计^[15,16]以及等效电磁参数提取^[17]等研究方向，其天线阵列雷达散射截面缩减^[18]等领域的拓展应用，进一步彰显了其作为多功能数据驱动电磁分析工具的潜力。鉴于神经网络在表征复杂非线性映射关系方面具备强大的建模能力，团队前期工作针对蜂窝结构等效电磁参数的快速提取提出了一种基于 FNN-INN 架构的深度学习方法，有效解决了宽频条件下等效电磁参数难以高精度预测的问题。然而，当占空比较低时模型性能明显下降，低占空比蜂窝结构因其吸波涂覆层薄、质量轻盈等特性，在追求极致轻量化的现代先进隐身装备中占据着至关重要的地位。因此，攻克低占空比条件下的等效精度衰减难题，不仅是完善电磁预测模型的理论难点，更是推动轻量化蜂窝吸波材料走向实际工程应用迫切需要解决的核心问题，同时该方法尚未形成从材料参数到 RCS 预测完整的通用预测框架^[19]。

因此，针对低占空比条件下预测精度不足的问题，本文构建了由双数据集驱动的 BiGT-Net（BiGRU-Transformer）级联网络。该核心机制将参数反演过程在物理上为两阶段：首先，利用 BiGRU 在蜂窝结构数据集上学习从几何参数到宽频电磁响应（ S_{11} ）的前向映射；随后，以 S_{11} 为物理桥梁，利用 Transformer 的多头注意力机制在均匀介质板数据集上实现等效电磁参数的高精度逆向反演。针对宽带下蜂窝涂覆目标雷达散射截面预测中计算效率低、传统等效方法精度不足的问题，本文提出一种基于深度学习辅助的高效预测框架，基于所获取的等效参数，该框架可灵活结合相应的 RCS 散射求解器完成宏观目标的快速计算。该方法在避免直接多尺度全波仿真高计算代价的同时，实现了较高预测精度。实验结果表明，均匀等效介质涂覆目标得到的 RCS 预测结果与等效前蜂窝涂覆目标具有良好一致性，同时计算时间约减少 18 倍，内存占用降低约 8 倍，从而为大规模复杂目标的快速 RCS 分析与工程设计提供了一种高效可行的技术途径。

2 蜂窝涂覆目标的 RCS 预测框架与方法

2.1 数据集获取

由于神经网络需要大量数据进行训练，本文采用文献^[19]中提出的数据集构建方法，在进行 RCS 计算之前获取所需的等效电磁参数。本文用 CST studio suite 建模蜂窝涂覆材料和均匀介质板，仿真并获取模型的电磁响应，改变模型的参数并获取 S_{11} 参数，再通过 Visual Basic for application（VBA）脚本全自动修改蜂窝结构参数并导出，典型的蜂窝单元与均匀介质板如图 1(a)(b) 所示，其中 t 、 w 、 r 分别为骨架层厚度，吸波层厚度和蜂窝的孔径，骨架层和吸收层的介电常数和磁导率分别为 ε 和 μ ，数据集由两部

分组成：数据集 1 为蜂窝结构模型数据，用于预测蜂窝结构的 S_{11} 参数；数据集 2 为均匀介质平板模型数据，用于预测等效电磁参数。仿真设置包括材料参数（介电常数与磁导率）、边界条件、激励源以及仿真初始化设置等。




图 1: 数据获取模型：(a) 蜂窝单元；(b) 均匀介质板模型。

Figure 1. Data acquisition model: (a) Honeycomb unit; (b) Homogeneous dielectric plate model.

通过电磁仿真获得数据集 1 和数据集 2。其中包含的参数包括蜂窝结构模型参数（吸波层介电常数实部 ϵ'_a 和虚部 ϵ''_a ，磁导率实部 μ'_a 与虚部 μ''_a 、孔径 r 、吸波材料体积分数 v_a ）以及等效模型参数（等效介电常数 ϵ'_{eff} 和虚部 ϵ''_{eff} 、等效磁导率 μ'_{eff} 和虚部 μ''_{eff} ），分别如表 1 和表 2 所示。随后对获得的数据进行整理与处理，构建特征向量矩阵（Feature Vector Matrix, FVM）^[19]。

表 1: 蜂窝结构模型参数

Table 1. Parameters of the honeycomb structure model

Parameter	f/GHz	ϵ'_a	ϵ''_a	μ'_a	μ''_a	r/mm
Range	8–12	6–12	0.5–2	1–3	0.5–1	1–3
Step	0.5	3	0.5	1	0.5	1

表 2: 等效模型参数

Table 2. Parameters of the equivalent homogeneous model

Parameter	f/GHz	$\varepsilon'_{\text{eff}}$	$\varepsilon''_{\text{eff}}$	μ'_{eff}	μ''_{eff}
Range	8–12	1.7–9.2	0.05–1.55	1–2.7	0.05–0.75
Step	0.1	1	1	0.3	0.1

2.2 蜂窝结构等效电磁参数的获取

蜂窝结构等效电磁参数获取模型如图 2 所示, 本文以孔径、体积分数、填充材料的介电常数与磁导率以及频率作为输入特征, 用于预测对应频点处的 S_{11} 参数。蜂窝材料到 S_{11} 参数的数据是一条 S_{11} 随频率变化的序列曲线, 单一频点的 S_{11} 值受到前后频点的干涉影响, 而双向门控循环单元 (Bidirectional Gated Recurrent Unit, BiGRU) [20] 对时序化, 强前后关联的数据具有天然的适用性。BiGRU 是一种在标准 GRU 基础上扩展而来的序列建模网络, 它通过“前后各一套 GRU”同时对时间序列进行从过去到现在, 以及从未来到过去的双向建模。其中单个 GRU 的计算公式如下:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (1)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) A \quad (2)$$

$$h'_t = \tanh(W_h \cdot [r_t * h_{t-1}, x_t]) \quad (3)$$

$$h_t = (1 - z_t)h_{t-1} + z_t * h'_t \quad (4)$$

其中, x_t 为当前序列的输入值, 如蜂窝的材料参数, 电磁参数, 归一化频率值, z_t 为更新门 (update gate) 的值, 表示多大程度上更新当前频点的新电磁特征, r_t 为重置门 (reset gate) 的值, 在当前频点属于谐振点时遗忘大部分历史电磁特征, h_t 和 h_{t-1} 分别表示当前时刻和前一时刻的隐藏状态, h'_t 为候选隐藏状态。

W_r 、 W_z 和 W_h 为权重矩阵, σ 和 $\tanh$ 为激活函数, 其表达式如下:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

σ 把重置门和更新门的数值限制在 0 到 1 之间, 灵活控制信息保留与舍弃, 贴合 S_{11} 曲线平缓变化和谐振突变的特点, $\tanh$ 映射正负区间适配电磁参数与 S_{11} 数值分布并提升非线性拟合能力。

随后需要完成由 S_{11} 到等效电磁参数的映射，在宽频条件下，需要模型学习到宽频下各频点对于等效电磁参数的特征贡献，Transformer 的自注意力机制能直接计算任意两个频点之间的关联权重，自动聚焦谐振点，相位转折点等高贡献区域，因此本文引入基于 Transformer 的序列建模网络^[21]对等效电磁参数进行预测。该网络通过自注意力机制能够有效学习频谱之间的长距离依赖关系以及非平滑频率特性。随后将提取到的特征进行融合，并通过轻量化回归层映射得到等效电磁参数。多头注意力（Multi-Head Attention）是一种用于提升自注意力机制表达能力的重要结构。在处理整个频点序列数据时，对于某一给定频点的 S_{11} 值，通常希望模型能够同时关注多个相关频点之间的依赖关系。单头自注意力层只能在单一表示空间中进行特征建模，难以在不影响其它重要位置注意力的情况下同时关注多个关键频点。为了解决这一问题，多头注意力通过引入多个独立的注意力头，在不同的表示子空间中并行学习特征表示。

具体而言，每一个注意力头使用独立的查询矩阵、键矩阵和值矩阵，将输入特征映射到不同的特征子空间中。随后，每个注意力头分别执行缩放点积注意力（Scaled Dot-Product Attention）计算：首先，通过输入特征计算查询向量 Q 、键向量 K 和值向量 V 。注意力得分 P 是通过计算 Q 与 K^T 的相似度分数并引入缩放因子 $\sqrt{d_k}$ 进行归一化处理后，再经由 Softmax 函数映射得到。该过程旨在保持梯度稳定性并获取加权特征分布。最后，将注意力权重作用于值向量 V 以实现特征重构，其数学表达如下：

$$\text{head}_i = \text{Attention}(Q_i, K_i, V_i) = \text{softmax}\left(\frac{Q_i K_i^T}{\sqrt{d_k}}\right) V_i \quad (7)$$

其中，输入特征首先被线性映射为三个向量：查询向量 Q （Query）、键向量 K （Key）和值向量 V （Value）。在本文模型中，这三个向量的维度均设定为

$$d_q = d_k = d_v = d_{\text{model}} = 32 \quad (8)$$

此外，为了捕获不同子空间的电磁特征，本文采用多头注意力机制，将各注意力头的输出 head_i 在特征维度进行拼接，并通过线性投影层 W^O 得到最终输出：

$$\text{MultiHead}(Q, K, V) = [\text{head}_1, \text{head}_2, \dots, \text{head}_h] W^O \quad (9)$$

通过多头注意力机制，模型能够在不同特征子空间中同时捕获多个频点 S_{11} 之间的关联模式，例如局部频率响应特征以及全局频谱变化趋势，从而有效提升对频域序列特征的建模能力。相比于单头注意力机制，多头结构显著增强了模型的表达能力和鲁棒性，尤其适用于具有复杂频域相关性的电磁散射数据建模任务。为了评估模型对 S_{11} 参数的预测精度，采用平均绝对误差（mean absolute error, MAE）作为评价指标，该指标用于度量预测值与真实值之间的平均绝对偏差。其中真实 S_{11} 参数对应蜂窝模型的仿真结果，

为验证所提出的反演等效电磁参数检索方法的有效性与其优越性，本文将其与传统卷积神经网络（CNN）模型，门控循环单元（GRU）模型以及文献 [19] 进行了对比。实验结果如表 3 所示，所提出的 Transformer




图 2: 等效电磁参数预测网络结构

Figure 2. Network architecture for equivalent electromagnetic parameter prediction

表 3: 等效电磁参数预测误差比较

Table 3. Comparison of MAE for equivalent electromagnetic parameter prediction

Parameter	CNN	GRU	文献 [19]	本文
ϵ'_{eff}	0.1471	0.1193	0.0999	0.0866
ϵ''_{eff}	0.0957	0.0819	0.0745	0.0694
μ'_{eff}	0.0469	0.0403	0.0364	0.0326
μ''_{eff}	0.0316	0.0287	0.0261	0.0220

模型在等效电磁参数预测任务中整体优于 CNN,GRU 以及文献 [19] 中的参考模型。其性能优势主要来源于两个方面：一方面，Transformer 的并行自注意力结构能够显著提高模型训练效率，尤其适用于本文所采用的大规模数据集；另一方面，其全局注意力机制能够更加有效地捕捉低占空比电磁响应中存在的强非

局域频域相关性。

2.3 RCS 预测与整体流程

RCS 是衡量目标隐身性能的重要指标。用于表征目标对入射电磁波的散射能力，其物理意义是目标在远场条件下将入射电磁波散射回雷达方向的等效面积。RCS 通常用 σ 表示，其计算公式可表示为

$$\sigma = 4\pi R^2 \frac{|E_{\text{sca}}|^2}{|E_{\text{inc}}|^2}. \quad (10)$$

其中， R 为目标与雷达之间的距离， E_{sca} 表示散射场强度， E_{inc} 表示入射场强度。RCS 用于表征目标在远场区域的电磁散射强度，其数值通常可以通过全波电磁仿真、实验测量或高频近似方法进行计算。

如图 3 所示，本文提出的 RCS 预测框架主要包括以下四个步骤。

(1) **数据集构建**。通过在不同几何结构参数与材料参数条件下建立蜂窝结构物理模型（例如 t 、 w 、 r 、 ε 和 μ 等），获取对应的 S_{11} 参数，从而构建用于网络训练的数据集。

(2) **数据预处理**。对原始数据集进行预处理，包括剔除缺失值与异常值、去除无效样本、对数据进行归一化处理，并提取主要特征以构建神经网络输入。

(3) **等效参数预测**。首先，将预处理后的蜂窝材料特征（包含结构参数与材料参数）作为 BiGRU 模型输入，以预测出宽带散射参数 S_{11} ；随后，将预测得到的 S_{11} 参数序列输入至 Transformer 模型中，最终计算并输出蜂窝结构的等效电磁参数。

(4) **RCS 计算**。将获取的等效电磁参数用于构建均匀等效介质涂覆模型，并根据仿真精度与计算效率的要求选择合适的电磁求解器（如全波求解器、混合求解器或高频求解器），从而完成目标的 RCS 分布计算。本文采用 CST Studio Suite 完成上述建模与仿真过程。

3 结果与分析

3.1 等效电磁参数提取精度比较与验证

为了验证本文所提出方法的有效性，从蜂窝结构样本中选取了三个具有代表性的样本进行对比分析。这些样本在结构参数及电磁特性方面存在一定差异。通过对不同占空比条件下的蜂窝结构进行计算与比较，可以进一步评估各方法在不同结构参数条件下的预测性能。所选样本的蜂窝结构参数及填充材料电磁参数如表 4 所示，其中包括孔径 r 、吸波材料体积分数 V_a 以及填充材料的介电常数 ε_a 和磁导率等参数




图 3: RCS 预测整体流程框架

Figure 3. Overall framework of the proposed RCS prediction workflow

μ_a 。由于 S_{11} 参数能够直接表征结构的电磁散射响应，并由等效电磁参数唯一决定，因此本文通过比较不

表 4: 蜂窝结构及填充材料的电磁参数

Table 4. Electromagnetic parameters of the honeycomb structure and its filling material

样本	r/mm	V_a	ε'_a	ε''_a	μ'_a	μ''_a
样本 1	3	0.75	9	0.5	3	0.5
样本 2	3	0.19	12	1	1	1
样本 3	5	0.19	12	1	1	1

同等效方法重构得到的 S_{11} 参数曲线对等效结果进行评估，蜂窝与均质模型的仿真 S_{11} 如图 4 所示。其中，Honeycomb 表示蜂窝结构的真实仿真结果（未进行等效处理），其余结果均为不同方法得到的等效介质模型计算结果。对于样本 1（大占空比情况），本文方法与文献^[19]方法均能够较好地捕捉（8–12）GHz 频段内 S_{11} 曲线的整体变化趋势以及局部特征，相比于 GRU（1.48）和 CNN（1.70），MAE 下降了 58% 和 64%。同时，与传统的 HS 方法和 SFT 方法相比，基于数据驱动的等效方法在预测精度方面表现出明显优势。在低占空比条件下（样本 2 与样本 3），本文方法仍能够较准确地重构蜂窝结构在等效参数提取前的 S_{11} 响应曲线。例如，对于样本 2，本文方法得到的平均绝对误差（MAE）为 0.1764，相比 HS，CNN 方法分别降低了 73.6% 和 87.3%；对于样本 3，MAE 为 2.0308，相比 HS，CNN 方法分别降低了 16.6% 和 67.4%。结果表明，本文方法能够有效反映孔径变化对电磁频率响应特性的影响。相比之下，HS 与 SFT 方法在建立等效模型时未充分考虑孔径变化对电磁响应的影响，因此当蜂窝孔径发生变化时，其等效结果

会出现明显偏差。为了进一步验证本文方法的实用性，用本文方法与文献^[11]表 1 中 $d/(x-t)=0.30$ 作对

表 5: 蜂窝结构涂覆材料的等效电磁参数

Table 5. Equivalent electromagnetic parameters of honeycomb-coated materials

样本	方法	ϵ'_{eff}	ϵ''_{eff}	μ'_{eff}	μ''_{eff}
样本 1	SFT	5.260	0.201	1.979	0.211
	HS	5.548	0.223	1.965	0.200
	GRU	5.800	0.196	2.194	0.329
	CNN	5.713	0.334	2.274	0.207
	文献 ^[19]	5.970	0.276	2.060	0.236
	This paper	5.964	0.277	2.054	0.237
样本 2	SFT	1.746	0.010	1.051	0.129
	HS	2.513	0.093	1.036	0.122
	GRU	2.523	0.030	1.299	0.196
	CNN	2.202	0.152	1.087	0.205
	文献 ^[19]	5.659	0.245	2.320	0.181
	This paper	2.471	0.074	1.223	0.135
样本 3	SFT	1.745	0.010	1.051	0.129
	HS	2.513	0.093	1.036	0.122
	GRU	2.844	0.161	1.305	0.164
	CNN	2.696	0.209	1.197	0.215
	文献 ^[19]	3.218	0.124	1.707	0.204
	This paper	2.585	0.081	1.263	0.148

比，对应的结果如图 5 所示，MAE 误差如表 6 所示，本文方法 MAE 为 0.61，相比于文献^[11]的 0.82，降低了 26%。




图 4: 样本 1-3 S_{11} 参数预测值与真实值对比

Figure 4. Comparison between predicted and actual S_{11} parameters for Samples 1-3




图 5: 文献^[11] S_{11} 参数预测值与真实值对比

Figure 5. Comparison between predicted and actual values of the S_{11} in the literature^[11]

表 6: MAE 误差对比结果

Table 6. MAE results

Method	MAE
Reference ^[13]	0.82
This paper	0.61


3.2 蜂窝涂覆目标的 RCS 计算与验证

在本研究中,选取了两个具有代表性的几何模型——平板和平面二面角——并设置单站 RCS 入射角度为 -180° 到 180° , 频率范围为 (8–12) GHz, 对宽带下蜂窝与均质模型进行仿真。


3.2.1 平板模型

蜂窝涂覆平板如图 6 所示,其尺寸为 (102×114.32) mm, 蜂窝结构的材料参数按照样本 2 进行配置。图 6(a) 为蜂窝结构模型,其仿真结果可视为 MAE 计算中的真实值;图 6(b) 为基于等效均匀介质模型,其仿真结果用于与真实结构进行对比分析。

平板模型在 X 波段的 RCS 预测结果如图 7 所示, Honeycomb 曲线代表真实蜂窝结构的 RCS 结果。可以观察到,本文方法在整个 X 波段内能够较好地拟合真实值的变化趋势,相比 HS、CNN 以及文献^[19]



(a)



(b)

图 6: 平板模型: (a) 涂覆蜂窝的 PEC 平板; (b) 均匀介质涂层

Figure 6. Flat plate model: (a) Honeycomb-coated PEC plate; (b) Homogeneous Dielectric Coating

的方法具有更高的预测精度。该方法通过融合蜂窝结构的几何特征与等效材料参数，提高了等效建模的准确性。在斜入射条件下，由于训练数据基于垂直入射获得，当模型边界处产生明显衍射效应时，预测结果与真实蜂窝结构之间会出现一定偏差，从而导致等效精度略有下降。

表 7: 平板 RCS 预测的 MAE 对比

Table 7. MAE Comparison of RCS Prediction for Flat Plate

方法	8 GHz	10 GHz	12 GHz
HS	0.33	0.41	1.37
CNN	0.42	1.00	2.70
文献 ^[19]	2.76	3.50	4.43
本文方法	0.27	0.36	0.81

为了进一步定量评估不同方法的预测性能，表 7 给出了平板在 8 GHz、10 GHz 和 12 GHz 三个典型频点处的 MAE 对比结果。可以看出，本文方法在三个频点均取得了最低的误差，整体性能优于经典网络 CNN, 传统方法 HS 以及文献 ^[19] 的方法。具体而言，在 8 GHz 时，本文方法的 MAE 为 0.27，相较于 CNN(0.42)、HS (0.33) 和文献 ^[19] (2.76) 分别降低了 33.8%、18.2%、37.1%、99.1%。在 10 GHz 时，MAE 为 1.77，相比分别降低了 64%、12.2%、89.8%。在 12 GHz 时，MAE 为 0.81，相较于其它方法分别降低了 70%、40.9%、81.8%。上述结果进一步验证了本文方法在 RCS 预测中的有效性与优势。




图 7: 平板在 (8-12) GHz 频段的单站 -180° 到 180° RCS 预测结果对比
Figure 7. Comparison of single-station RCS prediction results of the flat plate in the (8 - 12) GHz frequency band from -180° to 180°

3.2.2 二面角模型

二面角模型如图 8 所示，其尺寸为 (114.32×132) mm，夹角为 155° ，蜂窝结构的材料参数按照样本 1 进行配置。图 8(a) 为二面角蜂窝结构模型，其仿真结果可视为 MAE 计算的真实值；图 8(b) 为基于等效均匀介质模型，其结果用于与真实结构进行对比分析。




图 8: 二面角模型: (a) 涂覆蜂窝结构; (b) 等效均匀介质涂层

Figure 8. Dihedral-angle model: (a) honeycomb-coated structure; (b) equivalent homogeneous dielectric coating

二面角 RCS 仿真结果如图 9 所示，其中蜂窝（Honeycomb）表示原始结构的真实 RCS 响应。结果显示，在 8 GHz、10 GHz 和 12 GHz 三个频点下，各方法均能够在一定程度上反映 RCS 曲线的整体变化趋势，但在散射峰值位置及波谷处仍存在明显差异。相比之下，本文方法在全角度范围内与蜂窝全波仿真结果具有更高的一致性，尤其在主散射方向（约 $\pm 60^\circ$ 附近）及多个波谷区域，能够更准确地捕捉 RCS 幅值的变化特征，而 HS 和 SFT 方法在上述区域存在不同程度的偏差或过度平滑现象。

各方法的 MAE 结果如表 8 所示，本文方法在 8 GHz、10 GHz 和 12 GHz 频点分别取得 1.08、1.27 和 1.30 的最低 MAE，整体性能优于其他对比方法。结合图中曲线可以发现，该误差优势主要来源于本文方法对 RCS 局部细节特征（如振荡起伏及波谷处）的精确重构，而其他方法在复杂散射区域难以同时兼顾整体趋势与局部细节。此外，不同频率下 RCS 曲线的角度分布呈现出明显差异，表明散射特性对频率具有较强依赖性。本文方法在多个频点下均保持较高的拟合精度，说明其不仅适用于平板结构，也能够有效推广至二面角等更复杂结构模型，体现出良好的泛化能力。

本文所有仿真实验均在同一硬件平台（NVIDIA GeForce RTX 4060 GPU, Intel Core i5-12490F CPU）






图 9: 二面角模型在 (8–12) GHz 频段单站 -180° 到 180° 的 RCS 预测对比
Figure 9. Comparison of single-station RCS prediction results of the dihedral angle in the (8 - 12) GHz frequency band from -180° to 180°

表 8: 二面角模型 RCS 预测的 MAE 对比

Table 8. MAE Comparison of RCS Prediction for Dihedral Angle Model

方法	8 GHz	10 GHz	12 GHz
HS	2.50	4.35	3.12
CNN	1.32	2.78	1.37
文献 ^[19]	1.09	1.32	1.33
本文方法	1.08	1.27	1.30

表 9: 原始蜂窝模型与等效模型的仿真性能及内存消耗对比

Table 9. Comparison of Simulation Performance and Memory Consumption: Original Honeycomb vs. Equivalent Model

模型类型	内存消耗 (GB)	时间 (h)
Honeycomb	55.37	4.45
本文方法	7.04	0.25

及同一软件环境（CST Studio Suite）下进行。原始细致蜂窝模型与填充了等效电磁参数的等效均匀介质模型进行仿真对比，二面角蜂窝与均匀介质涂覆目标仿真的时间与内存消耗如表 9 所示。结果显示，相较于原始蜂窝结构的直接全波仿真，等效后的均匀介质模型在计算资源消耗方面显著降低，其中仿真时间减少约 18 倍，内存占用降低约 8 倍。上述结果表明，本文的等效方法在保证预测精度的前提下，能够有效降低复杂结构仿真的计算成本。这主要归因于等效模型将细尺度蜂窝结构转化为均匀介质，从而显著减少了网格数量与计算复杂度，体现出优越的计算效率和工程应用潜力。

4 总结与展望

本文提出了一套高效的蜂窝涂覆目标 RCS 预测流程，并构建了一种物理与数据双驱动的蜂窝涂覆目标 RCS 预测。本研究的核心创新在于提出了分步式的 BiGT-Net 电磁参数预测模型，该机制以 S_{11} 为中间媒介重构介质的本构参数，有效解决了前人均匀化方法在低占空比条件下的精度衰减难题。X 波段的实验结果证明了该框架的效能优势：在保障宽频散射特性高精度的前提下，其运算耗时与内存消耗较蜂窝大尺度全波仿真分别降低约 18 倍和 8 倍。未来，我们将致力于拓展该框架的适用边界，重点攻克大角度斜

入射条件下的精度衰减问题, 并尝试实现跨多频带乃至超宽带的宽频材料等效。此外, 针对复杂共形目标的多层蜂窝结构 RCS 预测, 也将是后续研究的重要方向。

参考文献

- [1] Smith D R, Vier D C, Koschny Th, Soukoulis C M 2005 *Phys. Rev. E* **71** 036617
- [2] Yang Z, Yuan X W, Yang M L, Sheng X Q 2021 *Photonics and Electromagnetics Research Symposium (PIERS)* Hangzhou, 21-25 November 2021, p2400
- [3] Wang H, Xiu X, Wang Y, Xue Q, Ju W B, Che W Q, Liao S W, Jiang H Y, Tang M, Long J, Hu J 2020 *Compos. Part B: Eng.* **202** 108378
- [4] Nicolson A M, Ross G F 1970 *IEEE Trans. Instrum. Meas.* **19** 377
- [5] Weir W B 1974 *Proc. IEEE* **62** 33
- [6] Jing X H, Jiang Q X 2005 *J. Astronaut.* **26** 630 (in Chinese) [景莘慧, 蒋全兴 2005 宇航学报 **26** 630]
- [7] Baker-Jarvis J, Vanzura E J, Kissick W A 1990 *IEEE Trans. Microw. Theory Tech.* **38** 1096
- [8] Smith D R, Schultz S, Markos P, Soukoulis C M 2002 *Phys. Rev. B* **65** 195104
- [9] Hashin Z, Shtrikman S 1962 *J. Appl. Phys.* **33** 3125
- [10] Tsang L, Kong J A 1981 *Radio Sci.* **16** 303
- [11] He Y F, Gong R Z, Wang X, Zhao Q 2008 *Acta Phys. Sin.* **57** 5261 (in Chinese) [何燕飞, 龚荣洲, 王鲜, 赵谦 2008 物理学报 **57** 5261]
- [12] Zhou P H, Huang L R, Xie J L, Liang D F, Lu H P, Deng L J 2012 *IEEE Trans. Antennas Propag.* **60** 3679
- [13] Hu J W, He S Y, Rao Z M, Zhu G Q, Yin H C 2013 *Chin. Phys. Lett.* **30** 107702
- [14] Li L L, Wang L G, Teixeira F L, Liu C, Nehorai A, Cui T J 2019 *IEEE Trans. Antennas Propag.* **67** 1819

- [15] Liu C, Ma Q, Luo Z J, Hong Q R, Xiao Q, Zhang H C, Miao L, Yu W M, Cheng Q, Li L L, Cui T
J 2022 *Nat. Electron.* **5** 113
- [16] Zhang X, Wan J X, Liu Z Y, Xu F 2022 *IEEE J. Multiscale Multiphys. Comput. Tech.* **7** 126
- [17] He W J, Zhang Y X, Wu B Y, Sun S, Yang M L, Sheng X Q 2024 *IEEE Antennas Wireless Propag. Lett.* **23** 3982
- [18] Jia Y T, Li S B, Luo J B, Shi G, Liu Z X, Li Z R, Liu Y 2024 *IEEE Trans. Antennas Propag.* **72**
2181
- [19] Zhang F, Chen X, Huang X G, Pan J W, Yu D F, He B K, Wang J, Wu M H, Zhou T, Zhang Y H
2025 *J. Appl. Phys.* **137** 174902
- [20] Lin X, Quan Z, Wang Z J, Huang H, Zeng X X 2020 *Brief. Bioinform.* **21** 2099
- [21] Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, Kaiser L, Polosukhin I 2017
CoRR **30**

An Efficient Deep Learning-Assisted Workflow for RCS Prediction of Coated Honeycomb Structures*

ZHANG Fan¹⁾ LIU Jiang¹⁾ HE Peng¹⁾ WANG Zhe¹⁾ Wu Xueliang¹⁾
HE Bokun^{1)†} WANG Juan¹⁾ WU Minghu¹⁾ ZHANG Yunhua²⁾

1) (*Hubei Key Laboratory for High-efficiency Utilization of Solar Energy and Operation
Control of Energy Storage System, Hubei University of Technology, Wuhan, China*)

2) (*School of Earth and Space Science and Technology, Wuhan University, Wuhan, China*)

Abstract

Aiming at the core challenges in radar cross section (RCS) prediction of broadband honeycomb-coated targets, including insufficient accuracy of traditional equivalent algorithms, degraded prediction performance under low duty cycle conditions, high computational costs of electromagnetic simulation, and the absence of a systematic prediction framework, this paper proposes an efficient deep learning-assisted RCS prediction framework for honeycomb-coated targets. The framework focuses on the structured network design and staged physical mapping mechanism to achieve a favorable trade-off between prediction accuracy and computational efficiency. The primary innovation of this work lies in the construction of a dual-dataset-driven BiGRU-Transformer (BiGT-Net) cascade neural network. In the first stage, the bidirectional gated recurrent unit (BiGRU) is adopted to extract temporal sequence features, which

* This work was supported in part by the National Natural Science Foundation of China under Grant 62301215, the China Scholarship Council (CSC), the Science and Technology Project of Hubei Province under Grant 2022BEC017, the Electromagnetic Scattering Key Laboratory Fund, and the Doctoral Research Foundation of Hubei University of Technology under Grant BSQD2020015.)

These authors contributed equally.

† Corresponding author. E-mail: hebokun@hbut.edu.cn (HE Bokun)

The First Author. E-mail: joyce_zhang@hbut.edu.cn (ZHANG Fan)

fully explores the broadband electromagnetic frequency response characteristics of honeycomb structures in the X-band and establishes accurate forward mapping between structural/material parameters and electromagnetic responses. In the second stage, the multi-head attention mechanism of Transformer is introduced to precisely capture the electromagnetic resonance and aperture sensitivity characteristics of honeycomb structures. This method effectively compensates for the defects of conventional inversion theories (including the NRW inversion method, Bruggeman theory, Hashin-Shtrikman variational theory, and strong perturbation theory) that ignore aperture electromagnetic response differences, and resolves the accuracy degradation problem of equivalent electromagnetic parameter inversion for low-duty-cycle honeycomb structures faced by existing deep learning methods. Furthermore, the proposed framework exhibits superior flexible adaptability, which can dynamically match diverse RCS solvers according to practical engineering accuracy requirements. To fully validate the versatility and superiority of the proposed method, comparative RCS prediction experiments are conducted on two typical honeycomb-coated targets (flat plate and dihedral angle) in the X-band, a widely adopted frequency band for stealth technology research. Traditional Hashin-Shtrikman (HS) equivalent method, convolutional neural network (CNN), and state-of-the-art deep learning models are employed for quantitative comparison. Experimental results demonstrate that the proposed method achieves the lowest average absolute prediction error for both flat plate and dihedral angle models across all comparison algorithms in the X-band broadband range. It significantly reduces prediction errors and effectively suppresses prediction deviations under low duty cycle conditions, delivering superior adaptability and generalization performance for both simple and complex curved honeycomb-coated targets. Unified hardware-based simulation validation shows that the predicted results are highly consistent with high-precision full-wave simulation data. Meanwhile, compared with traditional equivalent methods, the proposed framework improves computational efficiency by approximately 18 times and reduces memory occupancy by 8 times, substantially lowering the computational overhead and time cost of multi-scale electromagnetic simulation. This work provides a reliable and extensible technical solution for the rapid electromagnetic characteristic analysis, parameter optimization, and engineering application of honeycomb-coated stealth structures.

Keywords: Radar Cross Section (RCS), Honeycomb Structures, Deep Learning, Electromagnetic Homogenization, RCS Prediction Workflow.

输入：蜂窝结构参数&材料参数

核心创新：BiGT-Net模型与RCS高效预测框架

