

基于空中目标特征模的 RCS 序列预测方法研究



谷继红,石家敏,王照源,康婕,丁大志
南京理工大学,江苏 南京 210094

摘要:随着现在雷达技术的快速发展,对目标隐身性能和雷达探测精度的要求日益提高,快速准确地预测目标的雷达截面(RCS)序列成为航空航天等领域的重要课题。本文利用目标固有的特征模实现对空中目标 RCS 序列的快速准确预测。将目标固有的特征模线性重构可以快速获得其在任意激励下的电磁响应,并保证计算所得 RCS 序列的精度。利用特征模线性重构目标的 RCS 序列需要目标飞行的位置和姿态角等参数信息,因此,对空中目标某一时段的 RCS 序列预测可转换为对其在该时段的位置和姿态等运动参数的预测。针对时间序列的运动参数预测,本文探讨了双向长短期记忆神经网络(LSTM)和单向 LSTM 以及反向传播神经网络(BP)在预测中的应用效果。试验结果表明,双向 LSTM 在时间序列预测任务中预测精度优于另外两种模型。然后基于预测和实际的运动参数进行目标特征模线性重构感应电流和散射场的方式高效准确地计算目标的 RCS 序列。空中目标 RCS 序列的快速预测可为空间目标识别和监测提供大量有效的数据库,对基于 RCS 序列的空间目标识别具有重要的现实意义。

关键词:RCS; 特征模; 线性重构; LSTM; 特征电流

中图分类号:TN820

文献标识码:A

DOI: 10.19452/j.issn1007-5453.2025.06.005

空中目标的雷达截面积(RCS)作为表征目标在雷达波照射下散射特性的关键参数,其精确计算对于预警雷达系统、导航雷达系统、跟踪雷达系统、目标探测和识别、隐身技术评估等方面具有重要意义。

随着计算电磁学领域的不断发展,针对空中目标 RCS 序列的计算已经发展出多种成熟且各具特色的方法,适用于不同的应用场景和计算需求。首先是基于电磁波的波动方程在高频条件下的近似解,通过追踪射线路径和计算反射、绕射等效应来估算 RCS 序列的高频渐近方法,其中包括物理光学法和几何光学法。物理光学法和几何光学法^[1]虽计算效率高,但是在处理复杂目标时计算结果不够精确。其次是依赖于麦克斯韦方程组或其等效形式以获取目标在电磁波照射下散射场的全波仿真法。其包括微分方程法和积分方程法。积分方程法以矩量法^[2]为主,需要对目标进行离散,通过矩阵求逆得出目标的电流分布和远近场特征信息,其计算精度很高,但是计算复杂度较高;微分方程法

则包括有限元法和有限差分法,该方法将整个计算域离散化,以空间中的场为未知量,对存储和计算能力的需求极高。更有基于矩量法的多层快速多极子法来计算目标的 RCS 序列,其存储量和计算时间分别为 $O(M \lg(N))$ 和 $O(N^2 \lg(N))$,用于分析单一目标时难度不大,但是对于集群目标来说,计算成本会显著提高。

特征模方法作为一种新兴的电磁分析方法,不仅可以充分反映天线的谐振频率、辐射电流等关键特性,广泛应用于单极子^[3-4]和超表面^[5-6]等天线的设计和优化,特别是平台天线一体化和电小天线设计,还可以用于分析目标电磁散射特性和雷达方向图综合等方面。将特征模作为全域基函数^[7]来展开表面电流,从而分析无人机编队的散射特性,与传统矩量(MoM)方法计算的无人机编队 RCS 对比发现,引入特征模(CM)对 RCS 计算的精度影响较小且显著缩短了时间,在计算无人机 RCS 方面精度高、效率高,具备广泛的适用性。Wang Zhonggen 等^[8]将特征模理论与压缩感知结

收稿日期:2024-10-17; 退修日期:2024-12-27; 录用日期:2025-02-28

基金项目:国家自然科学基金(62301258);航空科学基金(20230027059001);江苏省基础研究计划自然科学基金(BK20230918)

引用格式: Gu Jihong, Shi Jiamin, Wang Zhaoyuan, et al. Research on RCS sequence prediction method based on air target's characteristic mode[J]. Aeronautical Science & Technology, 2025, 36(6):40-48. 谷继红,石家敏,王照源,等. 基于空中目标特征模的 RCS 序列预测方法研究[J]. 航空科学技术, 2025, 36(6):40-48.

合计算三维导体目标的双站 RCS 序列,但是生成的基函数个数多,测量矩阵的维数大。本文通过空中目标的特征模线性重构感应电流和电场来高效计算目标的 RCS 序列。由于特征模式的正交性,在计算 RCS 序列时利用正交特征模可以避免计算过程中不必要的重复计算,且一个特征模的误差不会影响其他特征模的计算,提高计算的效率和精度。

通过空中目标特征模计算 RCS 序列时,需要目标飞行过程中与雷达的相对位置和姿态角信息,即需要对目标飞行过程中航迹进行准确预测。深度学习是一种自动从大量数据中学习和预测的算法^[9],通过挖掘目标飞行过程中航迹特征随时间变化的关系进行航迹预测。严皓^[10]构建了 CNN-LSTM、Stacked LSTM 多种模型均是以 LSTM 网络为基础的变体优化的模型,对飞机飞行的经度、纬度、高度进行预测对比。马兰等^[11]提出了一种基于深度挖掘 ADS-B 数据的 CURE 聚类算法来预测当日航班的实际航迹、过点时间及过点高度等航迹数据,其预测结果表明,该方法在预测结果和实际航迹有较强的拟合性。Liu Chaoyue 等^[12]通过对 4D 航迹预测方法进行概述总结,将航迹预测技术进行分类研究,表明机器学习的预测方法在处理历史数据方面有很大优势。根据研究对比可知,传统的神经网络对所提航迹参数预测的方法往往受限于数据精度和模型泛化能力,难以满足对航迹预测的高精度要求,变体的 LSTM 模型对时间序列的预测精度更高。本文对目标飞行过程时中心位置和姿态角的预测使用了双向 LSTM 模型,并将其与单向 LSTM 和 BP 进行误差对比,体现双向 LSTM 对于时间序列的目标位置和姿态角数据预测精度更高。

本文根据神经网络预测出目标运动过程中的位置和姿态角变化,利用特征模的线性重构,结合电磁散射理论,高效预测目标飞行过程中的 RCS 序列。本文首先介绍提取空中目标特征模的过程,基于提取的特征模式实现空中目标的 RCS 重构;其次介绍利用单双向 LSTM 模型预测目标 RCS 所需的目标中心位置和姿态角的方法原理;最后分析构建的预测网络和特征模重构结合实现对目标 RCS 序列快速预测的精度。

1 空中目标 RCS 序列重构

通过目标的特征模线性重构出空中目标表面的电流分布和电场可以高效计算无人机飞行过程中的 RCS 序列。

1.1 空中目标的特征模提取

由等效原理可知,目标散射场可等效为由理想导体表面上的等效源在自由空间中产生的场。根据麦克斯韦方程

组和辅助位函数可得到散射电场 E^s

$$E^s(r) = -j\omega\mu_0\mathbf{A}(r) + \frac{1}{j\omega\epsilon_0}\nabla\phi(r) \quad (1)$$

式中, r 为场点位置; $E^s(r)$ 为散射电场; j 为虚数单位; $\mathbf{A}(r)$ 和 $\phi(r)$ 分别为矢量磁位和标量电位; μ_0 和 ϵ_0 则分别为自由空间的磁导率和介电常数; ω 为角频率。根据式(1)可通过 $L(\cdot)$ 算子建立电场与表面电流的关系, $L(\cdot)$ 算子的具体形式如下

$$L(J) = j\omega\mu_0 \int_S G(r, r') J(r') dS' - \frac{1}{j\omega\epsilon_0} \nabla \int_S G(r, r') \nabla J(r') dS' \quad (2)$$

式中, J 为电流; $G(r, r')$ 为格林函数; r' 为源点位置。该算子具有阻抗特性,所以为了表示阻抗特性定义阻抗算子 $Z(\cdot)$

$$Z(J) = [L(J)]_{\tan} \quad (3)$$

式中, $Z(\cdot)$ 描述了感应电流 J 引起的电场的切向分量,即 $Z = L_{\tan}$ 。式(3)计算得到的 MoM 矩阵是 $Z(\cdot)$ 算子的离散形式,因此,式(3)也被称为阻抗矩阵 \mathbf{Z} 。

$$\mathbf{Z} = \mathbf{R} + j\mathbf{X} \quad (4)$$

式中, \mathbf{R} 和 \mathbf{X} 均是实对称矩阵,且 \mathbf{R} 为半正定矩阵。

特征模式可以通过其广义本征方程^[13]获得

$$Z(\mathbf{J}_n) = (1 + j\lambda_n)M(\mathbf{J}_n) \quad (5)$$

式中, \mathbf{J}_n 为特征模式矢量; $1 + j\lambda_n$ 为特征值; M 为权重算子。选择 $M = \mathbf{R}$, 不仅能使 Z 对角化,而且与坡印廷定理联系在一起,式(5)可变为以下形式

$$(\mathbf{R} + j\mathbf{X})\mathbf{J}_n = (1 + j\lambda_n)\mathbf{R}(\mathbf{J}_n) \quad (6)$$

消除公共项 $\mathbf{R}(\mathbf{J}_n)$, 可得到简化的加权特征方程

$$\mathbf{X}(\mathbf{J}_n) = \lambda_n \mathbf{R}(\mathbf{J}_n) \quad (7)$$

根据式(7)可求解目标的系数矩阵所对应的特征模和特征模式矢量。将特征电流从物理上进行辐射电流归一化,使其辐射的功率为 1, 即

$$\langle \mathbf{J}_n^*, \mathbf{R}\mathbf{J}_n \rangle = 1 \quad (8)$$

根据辐射归一化后,模式之间的正交性可表示为

$$\langle \mathbf{J}_m^*, \mathbf{R}\mathbf{J}_n \rangle = \delta_{mn} \quad (9)$$

$$\langle \mathbf{J}_n^*, \mathbf{X}\mathbf{J}_n \rangle = \lambda_n \delta_{nn} \quad (10)$$

$$\langle \mathbf{J}_m^*, \mathbf{Z}\mathbf{J}_n \rangle = (1 + j\lambda_n) \delta_{mn} \quad (11)$$

式中,当 $m = n$ 时, $\delta_{mn} = 1$; 当 $m \neq n$ 时, $\delta_{mn} = 0$ 。

1.2 空中目标的 RCS 重构

CMs 是完整的正交模式,用于扩大任何由于特定的外部源而产生的感应电流和远场,即目标表面上的感应电流可以近似表示为有限项特征电流的叠加

$$J \approx \sum_{n=1}^K a_n J_n \quad (12)$$

式中, K 为截断项数, a_n 为每个特征模式对应的模式权重系数。将式(12)代入式(1)的EFIE方程中, 可得

$$\sum_{n=1}^K a_n Z(J_n) = E_{\text{tan}}^i(r) \quad (13)$$

用特征电流 J_m 与式(13)做内积可得

$$\sum_{n=1}^K a_n \langle J_m, Z(J_n) \rangle = \langle J_m, E_{\text{tan}}^i(r) \rangle \quad (14)$$

将式(4)代入式(14)可得

$$a_n = \frac{\langle J_m, E_{\text{tan}}^i(r) \rangle}{(1 + j\lambda_n) \langle J_m, R(J_n) \rangle} \quad (15)$$

根据式(9)所表达的特征模式正交性, 只有当 $m=n$ 时, 式(15)才有值, 即

$$a_n = \frac{\langle J_n, E_{\text{tan}}^i(r) \rangle}{1 + j\lambda_n} \quad (16)$$

由特征电流 J_n 产生的特征电场 E_n 为

$$E_n(r, r', \theta, \varphi) = -j\omega\mu \left[\frac{e^{-jkr}}{4\pi r} \int J_n(r') e^{jkr' \cdot r'} dS' \right] \quad (17)$$

同感应电流原理一致, 即目标表面的远场可以近似表示为有限项特征电场的叠加

$$E^s(r, r', \theta, \varphi) \approx \sum_{n=1}^K a_n E_n(r, r', \theta, \varphi) \quad (18)$$

由已知的电场可以求得目标的RCS序列

$$\sigma = \lim_{r \rightarrow \infty} 4\pi r^2 \frac{|E^s(r, r', \theta, \varphi)|^2}{|E^i(r, r', \theta, \varphi)|^2} = 4\pi r^2 |E^s(r, r', \theta, \varphi)|^2 \quad (19)$$

根据式(19)可以发现, RCS的求解与目标的位置、姿态角信息有关。因此, 使用特征模线性重构求解RCS, 首先需要目标运动过程中的中心位置和姿态角进行预测。

2 空中目标运动参数预测

根据特征模方式线性重构目标RCS原理可以发现, 计算RCS值时, 对 r, r' 的需求, 需要实时了解目标飞行过程中与雷达的相对位置关系; 而对 θ, φ 的需求, 需要实时了解目标飞行过程中的姿态角。因此, 需要使用神经网络对时间序列的目标位置和姿态进行预测。

2.1 单向LSTM网络原理

针对传统的机器学习方法在处理参数的历史数据时, 难以捕捉数据间错综复杂的关联性和时序性, 因而忽视历史数据中蕴含的潜在规律, 导致预测精度受限, LSTM^[14]是对循环神经网络(RNN)的改进, 是专门为了解决“长期依赖”问题而诞生的, 改善了RNN的梯度消失和梯度爆炸问

题。与标准RNN相比, LSTM最主要的改进就是引入了门控机制(输入门、遗忘门和输出门), 用来控制神经网络中的信息传输。LSTM隐藏层神经元的基本结构如图1所示。

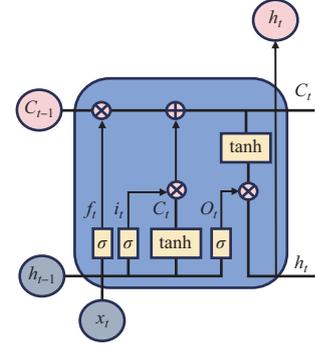


图1 LSTM神经元结构图

Fig.1 LSTM neuronal structure diagram

本文将运动参数作为模型的输入, 定义运动参数表示为: $f=[x, y, z, \text{俯仰角}, \text{方位角}, \text{滚转角}]$ 。为了实现该模型多变量时序序列的预测, 首先将处理好的包含 n 个时刻的运动参数 $X_t = \{x_1, x_2, \dots, x_n\}$ 数据输入模型中。 h_t 和 C_t 分别被记为隐藏层状态和细胞状态; $t-1$ 时的隐藏层状态和细胞状态则分别表示为 h_{t-1}, C_{t-1} ; 模型引入了三个关键的门控机制: 输入门为 i_t , 输出门为 O_t 和遗忘门为 f_t ; 输入门、输出门、遗忘门以及细胞状态的权重矩阵分别是 W_i, W_o, W_f, W_c , b_i, b_o, b_f, b_c 是与之——对应的偏移量; σ 和 \tanh 均是激活函数。LSTM的学习训练过程计算方法见式(20)~式(25)。

首先, 遗忘门用于决定是否遗忘上一时刻隐藏层的输出信息。该遗忘门读取 $t-1$ 时隐藏层状态 h_{t-1} 与 t 时运动参数 x_t , 经过 sigmoid 层输出 0~1 之间的数 f_t 与 $t-1$ 时刻的细胞状态 C_{t-1} 中数字逐点相乘, f_t 为 0 表示完全丢弃, 1 表示完全保留。

$$f_t = \sigma(W_f[x_t, h_{t-1}] + b_f) \quad (20)$$

其次, 输入门控制新输入信息的流动。在每个时间步, LSTM模型会接收一个新的输入, 并根据当前的状态和前一个时间步的输出计算一个新的候选状态。这个候选状态表示新的信息, 需要通过输入门来控制它的流动。通过输入门和遗忘门将网络预测运动参数过程中的细胞状态从 C_{t-1} 更新到 C_t 。

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (21)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (22)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (23)$$

最后, 基于细胞状态保存的内容通过 sigmoid 激活函数

来确定输出内容 O_t ,再使用 \tanh 激活函数对细胞状态的内容进行处理,得到真正希望的输出。

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (24)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (25)$$

将图 1 的 LSTM 神经元模块记为 A ,使用单向 LSTM 网络进行运动参数预测的具体结构如图 2 所示。

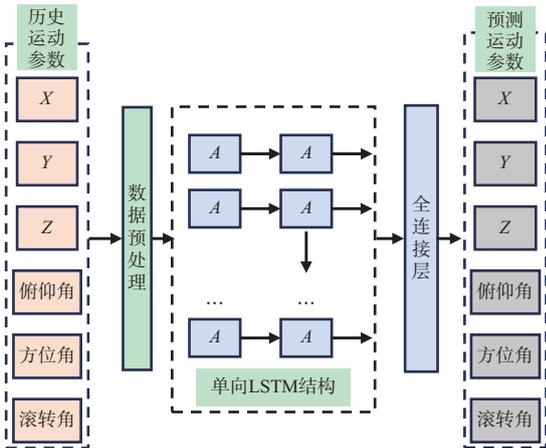


图2 LSTM结构图

Fig.2 LSTM structure diagram

根据单向 LSTM 原理,对运动参数预测模型进行搭建,中心位置和姿态角分开训练,中心位置模型是 12 个隐藏层神经元节点、3 层 LSTM、学习率为 0.001,姿态角模型是 15 个隐藏层神经元节点、2 层 LSTM、学习率为 0.0005,训练轮次均为 200。

对于网络模型的参数,本文使用自适应动量的随机优化方法(Adam)对该模型的参数进行更新修正^[15],模型使用 sigmoid 作为神经元的激活函数

$$\text{sigmoid}(x) = \frac{1}{1 + \exp(-x)} \quad (26)$$

从激活函数的定义可以看出,该函数将输入特征值压缩到 0~1 之间,使得在深层网络中可以保持数据幅度不会出现较大的变化,损失函数使用 MSE 来表示。

模型训练首先将输入的 6 维航迹数据传入 LSTM 层,利用神经网络的学习原理,通过对传入的数据进行前向传播和反向传播两个过程,对各时间序列点的隐藏层状态相对应的门权重和偏置矩阵进行传播,通过计算预测值与实际值之间的误差不断调整优化^[16],通过误差更新门权重值和偏置值,最终学习到适合及稳定的神经网络模型。

2.2 双向 LSTM 网络原理

相比于单向 LSTM,双向 LSTM 展现出其独特的优势,

通过一种创新的方式融合了目标运动参数序列数据的过去和未来信息,实现对时间序列数据的双向洞察,其具体的原理结构如图 3 所示。其中 $A_0 \sim A_i$ 、 $A'_0 \sim A'_i$ 均表示图 1 的 LSTM 隐藏层神经元, x_t 则表示输入的历史运动参数。

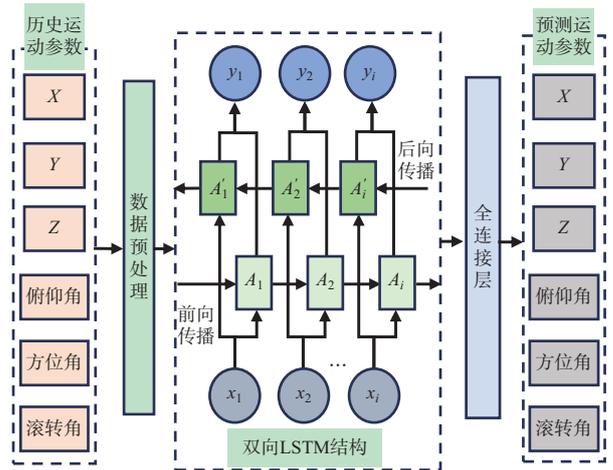


图3 双向 LSTM 结构图

Fig.3 Bidirectional LSTM structure diagram

使用双向 LSTM 能够同时利用序列之前和之后的信息来预测,在 Forward 层从 1 到 i 时刻,正向计算一遍。得到并保存每个时刻向前隐含层的输出。在 Backward 层中,沿着 i 和时刻 1 反向计算一遍,得到并保存每个时刻向后隐含层的输出。最后在每个时刻,结合 Forward 层和 Backward 层的相应时刻输出的结果得到最终的输出。双向 LSTM^[17] 能够更好地捕捉数据的时序特征和上下文信息,适应更复杂的数据结构和模式,从而提高了模型的预测准确性。这种特性使其在预测任务中能够更准确地识别特征,更好地预测结果。该双向 LSTM 网络模型搭建的层数、学习率与单向 LSTM 一致,且使用 Adam 对模型参数进行更新修正, sigmoid 作为神经元的激活函数。

3 试验结果与分析

本文对空中目标的运动参数进行预测,通过特征模线性重构感应电流和电场的方式计算模型单站 RCS。对目标 RCS 预测的整体流程如图 4 所示。

3.1 数据预处理

自定义空中目标飞行过程中路径变化的航迹样本 150 条,每条样本航迹有 200 个航迹点,目标飞行的位置和姿态随时间变化而采集,具有时序性。通过前 80% 的输入预测后 20% 的输出,即每条样本的预测点为 40 个。模型的输入为多变量输入,不同的输入对目标的雷达截面积的影响程

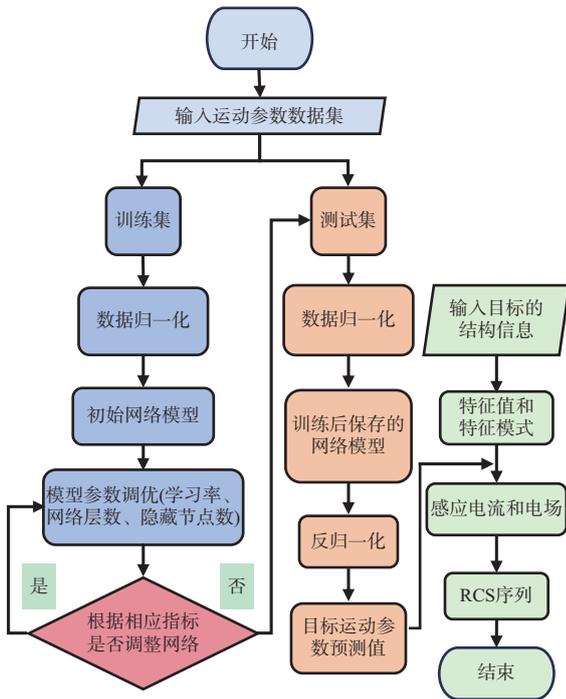


图4 RCS预测的整体流程

Fig.4 Overall flowchart of RCS forecasting

度不同,因此,在训练时需要考虑输入的多维性。其中,110条样本航迹用于训练,40条样本航迹用于测试。

采用min-max标准化对原始中心位置和姿态数据进行归一化处理^[18],使数据映射到[0,1]区间,同时保存了数据中的时序关系。

$$R_i^* = \frac{R_i - R_{\min}}{R_{\max} - R_{\min}} \quad (27)$$

式中, R_i 为空中目标*i*时刻的运动参数值; R_i^* 为归一化后的结果; R_{\max} 和 R_{\min} 分别为每条运动参数数据的最大值和最小值。

此时模型训练预测输出的结果是归一化之后的数据,通过反归一化对数据赋予实际意义,得到最终预测的目标中心位置和姿态信息,反归一化公式如下所示

$$R_i = (R_{\max} - R_{\min}) \cdot R_i^* + R_{\min} \quad (28)$$

3.2 模型评价指标

本文将平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方根误差(RMSE)作为模型预测精度评价指标, RMSE是预测值与真实值之差平方的期望值,再开平方根; MAE是预测值和观测值之间绝对误差的平均值;而MAPE是一个和原始数据相比较的过程,体现了误差与真实值之间的比例,表达式分别如式(29)~式(31)所示

$$\text{RMSE} = \left[\frac{1}{m} \sum_{i=1}^m (|P_i - R_i|)^2 \right]^{\frac{1}{2}} \quad (29)$$

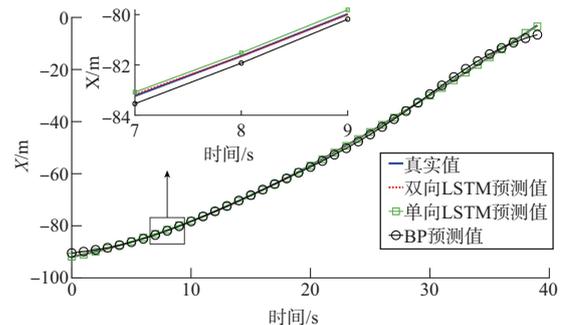
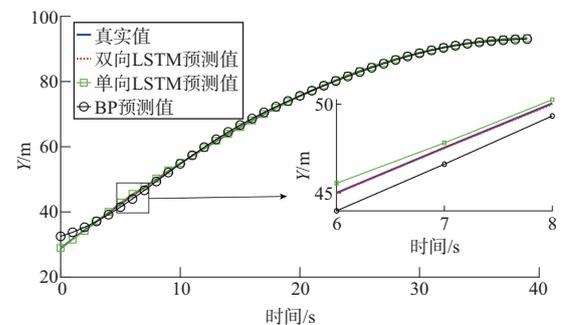
$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |P_i - R_i| \quad (30)$$

$$\text{MAPE} = \frac{1}{m} \sum_{i=1}^m \left| \frac{P_i - R_i}{P_i} \right| \times 100\% \quad (31)$$

式中, N 为样本个数; P_i 表示在*i*时刻的预测运动参数; R_i 表示在*i*时刻的实际运动参数。

3.3 单目标RCS预测

为了验证双向LSTM模型的有效性和可行性,将变体双向LSTM模型与传统LSTM模型以及BP模型进行对比验证。该试验过程中无人机平缓飞行,滚转角不随时间变化。所有的模型都采用相同的训练集和测试集进行学习训练,预测结果如图5~图9所示,分别是无人机*X*方向、*Y*方向、*Z*方向、俯仰角、方位角的预测结果。

图5 预测轨迹*X*方向投影图Fig.5 Projection plot of the *X*-direction of the prediction trajectory图6 预测轨迹*Y*方向投影图Fig.6 Projection plot of the *Y*-direction of the prediction trajectory

从图5~图9的运动参数预测拟合图可以发现,上述三种模型的预测趋势大致相同,其中局部放大结果图可以看出双向LSTM具有较好的预测效果,预测值和真实值拟合

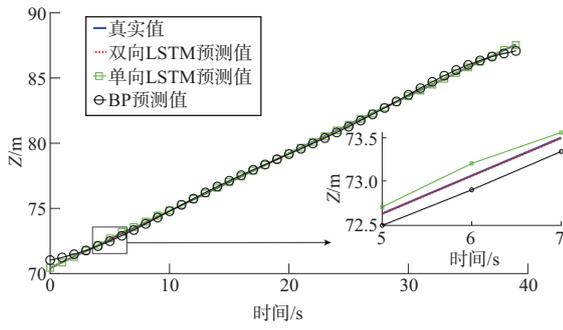


图7 预测轨迹Z方向投影图

Fig.7 Projection plot of the Z-direction of the prediction trajectory

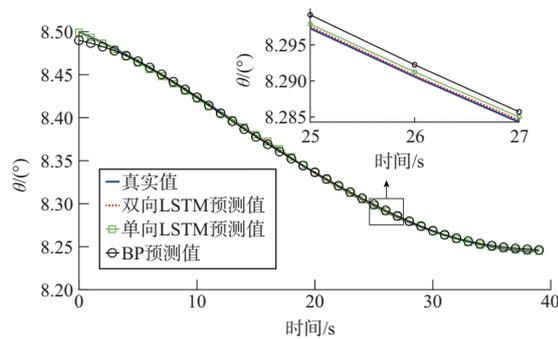


图8 θ 预测拟合图

Fig.8 θ prediction fitting plot

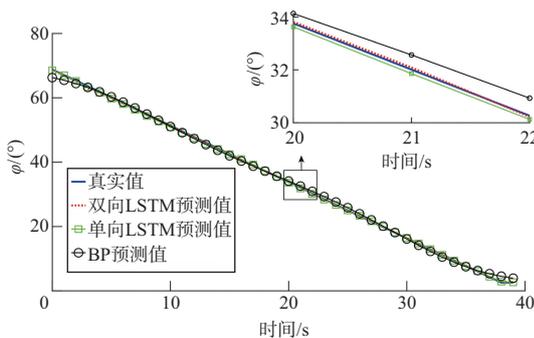


图9 φ 预测拟合图

Fig.9 φ prediction fitting plot

度更高,而BP网络拟合的效果最差。表1~表3给出了不同模型在MAE、MAPE和RMSE下的预测误差,对比分析各个模型预测的优劣情况。

从表1~表3的预测误差指标可以看出,LSTM模型对时间序列预测的精度远比BP模型预测的高,且双向LSTM模型预测的误差最小。

基于矩量法构建目标的阻抗矩阵,构建并求解特征方程,以获取目标的特征值和特征模式矢量。由于特征模式

表1 运动参数预测误差MAE性能分析

Table 1 Performance analysis of motion parameter prediction error MAE

| 评价指标 模型 | MAE | | |
|--------------------|--------|---------|---------|
| | BP | 单向 LSTM | 双向 LSTM |
| X/m | 0.6563 | 0.1049 | 0.0373 |
| Y/m | 0.4850 | 0.0939 | 0.0281 |
| Z/m | 0.1376 | 0.0231 | 0.0078 |
| $\theta/(^\circ)$ | 0.0017 | 0.0009 | 0.0005 |
| $\varphi/(^\circ)$ | 0.5772 | 0.1910 | 0.1206 |

表2 运动参数预测误差MAPE性能分析

Table 2 Performance analysis of motion parameter prediction error MAPE

| 评价指标 模型 | MAPE/% | | |
|--------------------|--------|---------|---------|
| | BP | 单向 LSTM | 双向 LSTM |
| X/m | 5.3346 | 0.6000 | 0.1957 |
| Y/m | 1.0713 | 0.1951 | 0.0497 |
| Z/m | 0.1751 | 0.0300 | 0.0097 |
| $\theta/(^\circ)$ | 0.0199 | 0.0111 | 0.0055 |
| $\varphi/(^\circ)$ | 5.5477 | 0.9455 | 0.7774 |

表3 运动参数预测误差RMSE性能分析

Table 3 Performance analysis of motion parameter prediction error RMSE

| 评价指标 模型 | RMSE | | |
|--------------------|--------|---------|---------|
| | BP | 单向 LSTM | 双向 LSTM |
| X/m | 0.9370 | 0.1216 | 0.0459 |
| Y/m | 0.7932 | 0.1533 | 0.0358 |
| Z/m | 0.1843 | 0.0345 | 0.0112 |
| $\theta/(^\circ)$ | 0.0024 | 0.0011 | 0.0006 |
| $\varphi/(^\circ)$ | 0.7723 | 0.2414 | 0.1667 |

的正交性,在计算RCS序列时利用正交特征模可以避免计算过程中不必要的重复计算。通过特征电流线性重构出目标表面的感应电流分布和远场,从而计算不同位置和姿态下目标的RCS序列,图10为根据航迹进行解算的单站RCS对比图,其中蓝线为根据实际运动参数通过特征模方式计算的RCS序列,红色虚线是根据双向LSTM预测运动参数通过特征模方式计算的RCS序列。

对真实与预测的RCS值进行误差计算可得两者的均方根误差为0.1070dBsm。

3.4 多目标RCS预测

为了进一步验证该模型在多变量时序输入的航迹预测的稳定性和泛化能力,对多个无人机航迹同时进行训练预测,预测结果如图11所示,其中蓝色虚线为真实运动参数

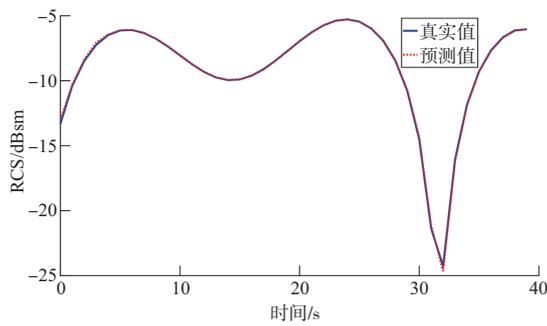


图10 真实与预测RCS对比曲线

Fig.10 Comparison curves of real and predicted RCS

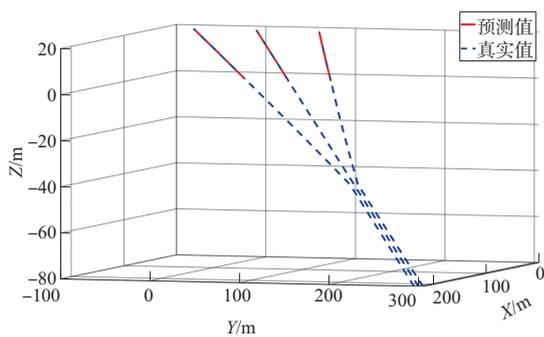


图11 三架无人机航迹

Fig.11 Three UAV tracks

曲线,红色为预测运动参数曲线。

由预测运动参数和实际运动参数通过特征模线性重构感应电流和电场的方式快速准确计算飞行过程中的RCS序列。由于飞行过程中之间的距离较远,因此,可忽略耦合作用。图12为三架目标实际RCS序列与预测RCS序列的对比曲线图,蓝线为真实RCS序列值,红色虚线为预测RCS序列值。

对真实与预测的RCS序列进行误差计算可得两者的均方根误差为2.6145dBsm。图12中,虚线左边预测的三架目标 X 、 Y 、 Z 方向的RMSE分别为0.0137m、0.0354m、0.0054m, θ

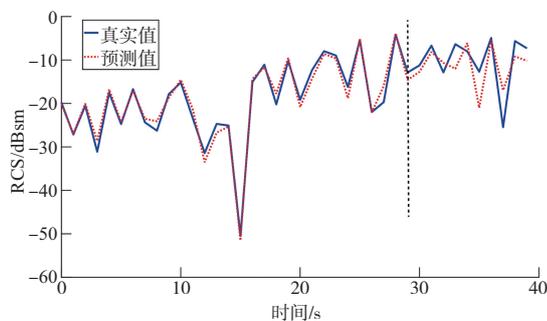


图12 真实与预测RCS对比曲线

Fig.12 Comparison curves of real and predicted RCS

和 φ 的RMSE分别为 0.0008° 、 0.0029° ;虚线右边预测的三架目标 X 、 Y 、 Z 方向的RMSE分别为0.0198m、0.0288m、0.0101m, θ 和 φ 的RMSE分别为 0.0013° 和 0.0036° 。总体而言,虚线左侧除了 Y 方向之外其他各维度预测误差均小于右侧,预测的RCS精确度更高。

进行多目标RCS预测时,每一架目标的位置姿态均会存在误差,造成整体的误差累积,因此,多目标的RCS预测对于目标的位置和姿态角的要求精度会更高。

为了进一步验证本文所述的特征模方法预测目标的RCS序列的高效性,分别统计传统的全波快速计算方法矩量法-多层快速多极子算法(MoM-MLFMA)和特征模方法计算目标RCS序列的时间和内存开销,见表4。

表4 预测RCS的效率统计

Table 4 Statistics on the efficiency of predicting RCS

| 方法 计算效率 | MoM-MLFMA | 特征模 |
|------------|-----------|--------|
| 时间/s | 1097.36 | 86.55 |
| 内存开销/M | 696.86 | 144.34 |

根据表4的对比可以看出,使用特征模方法预测目标RCS序列在时间和内存开销方面效率都有一定的提升,可以快速预测目标的RCS序列。

4 结论

本文通过对空中目标RCS的关键运动参数进行预测研究,提出基于双向LSTM预测模型的预测运动参数方法,并通过特征模线性重构感应电流和电场的方式提高计算RCS的效率。针对运动参数的多维性和时序性特征问题,采用双向LSTM,利用序列前后信息来进行预测,提高预测精度。通过研究,得出以下结论:

(1)针对多变量时序输入的预测,双向LSTM模型预测精度高于其他预测模型。

(2)对于目标的RCS序列计算,由于特征模的正交性,利用特征模重构的方式可以迅速描述目标在任意激励下的电磁响应,并保证计算所得RCS的精度。

AST

参考文献

- [1] 王宁辉.多旋翼无人机目标特性及测试天线设计[D].西安:西安工业大学,2024.
Wang Ninghui. Multi-rotor UAV target characteristics and test antenna design[D]. Xi'an: Xi'an University of Technology,

2024. (in Chinese)
- [2] 董安博. 基于海情的掠海无人机综合隐身性能分析[D]. 西安: 西安电子科技大学, 2022.
- Dong Anbo. Comprehensive stealth performance analysis of sea-skimming UAV based on sea conditions[D]. Xi'an: Xidian University, 2022. (in Chinese)
- [3] Tran H H, Nguyen-Trong N, Abbosh A M. Simple design procedure of a broadband circularly polarized slot monopole antenna assisted by characteristic mode analysis[J]. IEEE Access, 2018, 6: 78386-78393.
- [4] Jiang Shu, Xu Hengfei, Dou Jiangling, et al. Dual-layer microstrip monopolar patch antenna with characteristic mode analysis[J]. Frequenz, 2023, 77(9-10):485-491.
- [5] Zhang Qianyun, Ma Runbo, Su Wei, et al. Design of a Multimode UWB Antenna Using Characteristic Mode Analysis [J]. IEEE Transactions on Antennas and Propagation, 2018, 66(7): 3712-3717.
- [6] 王晓. 特征模理论及其在 UWB MIMO 天线设计中的应用 [D]. 成都: 电子科技大学, 2017.
- Wang Xiao. Eigenmode theory and its application in UWB MIMO antenna design[D]. Chengdu: University of Electronic Science and Technology of China, 2017. (in Chinese)
- [7] 朱晨曦. 具有重复结构电磁问题的特征模快速分析方法[D]. 南京: 南京理工大学, 2020.
- Zhu Chenxi. Eigenmode rapid analysis method for electromagnetic problems with repetitive structures[D]. Nanjing: Nanjing University of Science and Technology, 2020. (in Chinese)
- [8] Wang Zhonggen, Wang Pan, Sun Yufa, et al. Fast analysis of bi-static scattering problems for three-dimensional objects using compressive sensing and characteristic modes[J]. IEEE Antennas and Wireless Propagation Letters, 2018, 17(1): 118-121.
- [9] 韩仁坤, 杜焦喜, 刘子扬, 等. 基于深度神经网络的含运动边界非定常流场预测方法研究[J]. 航空科学技术, 2023, 34(12): 37-42.
- Han Renkun, Du Jiaoxi, Liu Ziyang, et al. Research on unsteady flow field prediction method with moving boundary based on deep neural network[J]. Aeronautical Science & Technology, 2023, 34(12):37-42. (in Chinese)
- [10] 严皓. 基于改进 LSTM 的终端区进港航班 4D 航迹预测研究 [D]. 广汉: 中国民用航空飞行学院, 2023.
- Yan Hao. Research on 4D track prediction of inbound flights in terminal area based on improved LSTM[D]. Guanghan: Civil Aviation Flight University of China, 2023. (in Chinese)
- [11] 马兰, 高永胜. 基于 ADS-B 数据挖掘的 4D 航迹预测方法[J]. 中国民航大学学报, 2019, 37(4):1-4.
- Ma Lan, Gao Yongsheng. 4D track prediction method based on ADS-B data mining [J]. Journal of Civil Aviation University of China, 2019, 37(4):1-4. (in Chinese)
- [12] Liu Chaoyue, Zheng Qi, Chang Jincai, et al. Summary and Outlook of 4D Track Prediction Methods[J]. Journal of Mechanical Engineering, Automation and Control Systems, 2020(1): 1.
- [13] 贾春来. 薄介质涂敷结构的高效特征模电磁分析方法研究 [D]. 南京: 南京理工大学, 2023.
- Jia Chunlai. Research on efficient eigenmode electromagnetic analysis method for thin dielectric coating structure[D]. Nanjing: Nanjing University of Science and Technology, 2023. (in Chinese)
- [14] 何昆鹏, 赵瑾玥, 周琪, 等. 基于 LSTM 神经网络的机载光纤陀螺温度冲击误差补偿技术[J]. 航空科学技术, 2024, 35(2): 31-38.
- He Kunpeng, Zhao Jinyue, Zhou Qi, et al. Temperature shock error compensation technology of airborne fiber optic gyroscope based on LSTM neural network[J]. Aeronautical Science & Technology, 2024, 35(2): 31-38. (in Chinese)
- [15] 胡玉可, 夏维, 胡笑旋, 等. 基于循环神经网络的船舶航迹预测[J]. 系统工程与电子技术, 2020, 42(4): 871-877.
- Hu Yuke, Xia Wei, Hu Xiaoxuan, et al. Ship track prediction based on recurrent neural network [J]. Systems Engineering and Electronics, 2020, 42(4): 871-877. (in Chinese)
- [16] 李旭娟, 皮建勇, 黄飞翔, 等. 基于自生成深度神经网络的 4D 航迹预测[J]. 计算机应用, 2021, 41(5): 1492-1499.
- Li Xujuan, Pi Jianyong, Huang Feixiang, et al. 4D track prediction based on self-generated deep neural network[J]. Journal of Computer Applications, 2021, 41(5): 1492-1499. (in Chinese)
- [17] 宋岩. 基于深度学习的 4D 航迹预测方法研究[D]. 广汉: 中国民用航空飞行学院, 2024.
- Song Yan. Research on 4D track prediction method based on deep learning[D]. Guanghan: Civil Aviation Flight University

- of China, 2024. (in Chinese)
- [18] 孔建国,李亚彬,张时雨,等.基于CNN- LSTM-attention模型航迹预测研究[J].航空计算技术,2023,53(1):1-5.
- Kong Jianguo, Li Yabin, Zhang Shiyu, et al. Research on trajectory prediction based on CNN- LSTM-attention model[J]. Aeronautical Computing Technology, 2023, 53(1): 1-5. (in Chinese)

Research on RCS Sequence Prediction Method Based on Air Target's Characteristic Mode

Gu Jihong, Shi Jiamin, Wang Zhaoyuan, Kang Jie, Ding Dazhi

Nanjing University of Science and Technology, Nanjing 210094, China

Abstract: With the rapid advancement of radar technology, there is an increasing demand for enhanced target stealth performance and precise radar detection. Consequently, the accurate and swift prediction of radar cross section (RCS) sequences has emerged as a critical focus in aerospace and civil applications. This paper presents a method for efficiently predicting the RCS sequence of airborne targets using their intrinsic characteristic modes. By reconstructing the intrinsic characteristic mode, this paper rapidly derive the electromagnetic response of the target under arbitrary excitation, ensuring the accuracy of the calculated RCS sequences. The linear reconstruction of the RCS sequence relies on parameters such as the target's flight position and attitude angle, allowing us to transform the prediction of the RCS over a specified period into a prediction of its positional and motion parameters during that interval. This paper evaluate the predictive capabilities of bidirectional long short-term memory (LSTM), unidirectional LSTM, and backpropagation (BP) neural networks. Experimental results indicate that the bidirectional LSTM outperforms the other two models in time series prediction tasks. Finally, utilizing both predicted and actual motion parameters, this paper efficiently and accurately calculate the target's RCS sequences through linear reconstruction of the modal current and electric field derived from the target's characteristic mode. The rapid prediction of aerial target RCS sequences can establish an extensive and reliable database for space object identification and surveillance, demonstrating substantial practical significance for RCS sequence-based space target recognition.

Key Words: RCS; characteristic mode; linear reconstruction; LSTM; modal current

Received: 2024-09-26; **Revised:** 2024-12-27; **Accepted:** 2025-02-28

Foundation item: National Natural Science Foundation of China (62301258); Aeronautical Science Foundation of China (20230027059001); Jiangsu Provincial Basic Research Program Natural Science Foundation (BK20230918)