DOI:10.3969/j.issn.1674-7135.2022.03.017

基于深度网络的太赫兹波束预判方法研究

白浪涛,朱忠博,李小军

(中国空间技术研究院西安分院,西安710000)

摘 要:针对太赫兹波波束较窄引起的伺服天线被动跟踪无法达到空间太赫兹通信链路性能要求 的问题,提出了一种基于优化深度网络的太赫兹波束预判方法。首先通过分析方位、俯仰角误差 大小随运行周期、外推初始时刻的变化,得到高轨对低轨卫星指向误差呈周期性发散的特征;然后 采用粒子群算法优化长短时记忆网络参数,对未来时刻指向误差进行预测并修正,针对粒子群算 法易陷入局部最优、全局搜索能力较差的问题,通过动态调整粒子群算法的惯性权重,以达到优化 长短时记忆网络的目的。仿真结果表明:基于改进后粒子群算法优化的长短时记忆网络能够有效 预测未来时刻指向误差,在同一链路场景中相比未改进网络平均绝对百分比误差降低13.08%。 关键词:深度网络:太赫兹:粒子群算法

中图分类号:V443 文献标志码:A 文章编号:1674-7135(2022)03-0099-05

Research on terahertz beam prediction method based on deep network

BAI Langtao, ZHU Zhongbo, LI Xiaojun

(China Academy of Space Technology (Xi'an), Xi'an 710000, China)

Abstract: Aiming at the problem that passive tracking of servo antennas cannot meet the performance requirements of spatial terahertz communication links caused by narrow terahertz beams, a pre-judgment method of terahertz beams based on optimized deep networks is proposed. Firstly, by analyzing the variation of the azimuth and pitch angle errors with the operation period and the initial time of extrapolation, the characteristic of the periodic divergence of the pointing errors of high-orbit satellites to low-orbit satellites is obtained. Then, the long-short-term memory network parameters are optimized by particle swarm optimization, the pointing error of the future time is predicted and corrected. In view of the poor global search ability of the particle swarm optimization and easy to fall into the local optimum, the inertia weight of the particle swarm optimization is dynamically adjusted to achieve the purpose of optimizing the long-short-term memory network optimized by the improved particle swarm optimization can effectively predict the pointing error in the future, and the average absolute percentage error is reduced by 13.08% compared with the unimproved network in the same scenario.

Key words: deep network; terahertz; particle swarm optimization

0 引言

太赫兹(Terahertz,1 THz = 10¹⁰ Hz)波通常指频 率在 0.1~10 THz 波段范围内的电磁波,它介于微 波与红外光之间的特殊位置,因此具有特殊的物理 属性,其在生物医学、6G 通信、雷达等诸多领域^[1]具 有广阔的市场前景。由于太赫兹技术所具有的大容量、高速率优点及其大气特性^[2]与星间链路通信场景的特点相匹配,该技术目前已成为星间通信领域研究的聚焦点之一^[3]。但是目前报道的太赫兹通信系统都是静态节点的点对点通信,由于空间飞

收稿日期:2022-02-14; 修回日期:2022-02-26

引用格式:白浪涛,朱忠博,李小军.基于深度网络的太赫兹波束预判方法研究[J].空间电子技术,2022,19(3):99-103. BAI L T, ZHU Z B, LI X J. Research on terahertz beam prediction method based on deep network[J]. Space Electronic Technology, 2022,19(3):99-103.

行器自身的运动以及地球轨道的摄动影响,使得空 间通信信道为非平稳信道,故目前静态节点的点对 点通信系统无法适用于空间通信,在未来应用中, 存在许多需要克服的问题,太赫兹波束控制便是其 中之一。由于太赫兹波的波束较窄,卫星间通信距 离较远,加之机械伺服天线机构负载大、转动惯量 大,在采用传统的被动跟踪方式时,在链路噪声及 波动误差的影响下,易造成捕获跟踪性能无法达到 空间太赫兹通信要求的情况,故需要提前获知下一 时刻所需指向角度,提前调整指向机构(即超前 瞄),使之克服轨道摄动力影响所带来的角度误差, 以实现太赫兹星间高速通信。

目前,国内外主要通过外推经典力学模型对卫 星轨道进行预报^[4],并通过上注导航星历上传至卫 星,卫星通过坐标转换调整指向以达到星间通信, 由于轨道预报精度受到任务要求、定轨精度、轨道 高度及空间动态环境等因素的影响,导致动力学轨 道外推的预报精度误差较大。随着神经网络的发 展,近年来出现了一些利用神经网络进行轨道预报 的相关研究。文献[5]利用 BP 神经网络作为建模 工具,对卫星的轨道位置与速度进行预测,然而由 于将卫星位置直接作为神经网络的输出,导致网络 状态量动态范围大,限制了预报精度的提高;文献 [6]利用长短时记忆神经网络与卷积神经网络相结 合对卫星轨道的 TLE 数据进行预报,在一定程度上 提高了中长期预报精度,但该方法针对特定的卫星 位置有效,不具有普适性。

文章针对高低轨卫星太赫兹通信应用场景,利 用长短时记忆网络(long short-term memory networks,LSTM)建立预测模型,并通过改进粒子群算 法(particle swarm optimization, PSO)对预测模型参 数进行优化,通过对历史时刻指向误差的分析,掌 握其变化规律,再预测未来时刻方位角与俯仰角误 差并修正,达到提高链路余量的目的。文中首先对 高轨对低轨卫星指向误差特征进行详细分析,利用 这些特征制定了一种基于 PSO-LSTM 深度网络的太 赫兹波束预判方法,实时预测下一时刻的指向误差 并修正,并对特定应用场景进行仿真分析。

1 指向误差特征分析

由于星间通信存在摄动力影响,卫星轨道模型 并非理想的开普勒运动模型,误差矢量始终存在, 本文旨在通过分析误差数据从而预估下一时刻所 需修正量,提前控制天线机构调整指向角,故在对 指向误差矢量分析时,重点在于误差数据为未来预 测的影响。通过对摄动力、轨道外推模型的研究, 可以发现误差矢量主要取决本体星与目标星的位 置与速度,其次外推时间也对误差矢量有影响。因 此有必要对误差矢量关于时间和卫星位置的关系 特征进行分析,主要讨论方位、俯仰角误差随时间 的变化以及外推初始时刻对误差大小的影响。

文章通过 STK 软件选用 BEIDOU-3 与 IRIDI-UM-16 仿真搭建高轨对低轨通信场景,通过选择不 同的轨道外推模型得到两组卫星之间的位置误差, 并通过坐标转换算法将误差矢量转换到实际 GEO 的本体坐标系中,图1(a)~图1(d)表示了方位、俯 仰角误差和距离误差随时间变化的趋势。由图 1 (a)、图1(b)可知在65d的外推弧段内,误差呈周 期性变化,周期约为36d;方位角误差在[-12°, 12°]之间,俯仰角误差在[-11°,11°]之间。在1d 的外推弧段内,误差呈周期性发散变化,周期约为4 200 s。以 2021 年 1 月 1 日至 2021 年 5 月 4 日的零 点作为初始时刻,在卫星参数不变的情况下分别进 行外推40d,从图1(e)、图1(f)可以看出,虽然选择 同一卫星参数,在同一动力学模型下,由于各种原 因不同初始时刻下的误差数据各不相同,40d的方 位、俯仰角误差最大值约为[10°,20°];不过误差大 小随初始时刻的分布还是有一定规律的,通过图像 可以大致确定这种分布具有一定的连续性、周期 性:相邻初始时刻之间关系比较确定,间隔一定时 间误差最大值大小相近,经过观察,初始时刻相差 14.5d左右时,误差大小最为接近。综上所述,高轨 对低轨卫星的波束指向误差数据具有一定的周期 性与连续性,故可以采用长短时记忆网络以14d为 周期进行序列预测。

2 改进 PSO-LSTM 预测模型

2.1 长短时记忆神经网络

长短时记忆神经网络是对循环网络进行改进 后的深度网络,它有效地回避了循环网络存在梯 度消失或梯度爆炸的问题,LSTM 网络能够长期记 忆信息的关键就是引入输入门(input gate)、输出 门(output gate)、遗忘门(forget gate)三个门结构^[7] 对单元状态 *c* 进行管理控制。LSTM 主要算法过 程为:



图 1 指向误差特征曲线 Fig. 1 Pointing error characteristic curve

1)

$$f_{t} = \boldsymbol{\sigma}(\boldsymbol{W}_{f} \cdot [\boldsymbol{s}_{t-1}, \boldsymbol{x}_{t}] + \boldsymbol{b}_{f}) \tag{(4)}$$

$$i_{t} = \sigma(\boldsymbol{W}_{i} \cdot [\boldsymbol{s}_{t-1}, \boldsymbol{x}_{t}] + \boldsymbol{b}_{i})$$

$$(2)$$

$$\tilde{c}_{t} = \tanh(W_{c} \cdot [s_{t-1}, x_{t}] + b_{c})$$
(3)

$$c_i = f_i * c_{i-1} + i_i * \tilde{c}_i$$

 $o_{t} = \sigma(\boldsymbol{W}_{o} \cdot [\boldsymbol{s}_{t-1}, \boldsymbol{x}_{t}] + \boldsymbol{b}_{o})$ (4)

$$s_t = o_t * \tanh(c_t) \tag{5}$$

其中, s_{t-1} 是t-1时刻的单元状态, x_i 是t时刻 的输入, W是权重矩阵,b是偏置, σ 、tanh是激活函 数。式(1)中 f_i 表示遗忘门控制将t-1时刻的单元 状态 c_{t-1} 中需要保存的信息保存到t时刻单元状态 c_i 中;式(2)中 i_i 表示输入门控制t时刻的输入 x_i 有多少信息保存到t时刻单元状态 c_i 中;式(3)中 \hat{c}_i 表示遗忘门控制单元状态c内历史状态的存储;式 (4)、(5)中 o_i 、 s_i 表示输出门控制单元状态的输出 信息。根据式(1)~式(5)可知,LSTM 网络的参数 选取对网络性能影响较大,如何选择最优参数集成 为LSTM 网络的重难点问题,本文提出改进的粒子 群算法,不断迭代寻找LSTM 的最优参数集。

2.2 改进的粒子群算法

粒子群算法是一种进化计算方法,源于对鸟群 捕食行为的研究,目前已被广泛应用于各类优化问 题^[8],其基本思想是寻找最优解。该算法的形式化 描述为:群体由 m 个粒子组成,并在 d 维空间中进 行搜索对问题求解。即群体 $\mathbf{x} = \{x_1^{(k)}, x_2^{(k)}, \cdots, x_m^{(k)}\}$, 其中 k 指当前时刻,第 i 个粒子在 d 维空间中的位 置可以描述为 $\mathbf{x}_i^{(k)} = (x_{i1}^{(k)}, x_{i2}^{(k)}, \cdots, x_{id}^{(k)})(i=1,2,\cdots,$ m),这是其中一个粒子在 k 时的位置,同时也是问 题的一个可能解^[7]。粒子通过不断运动寻找解决 问题的最优位置,其速度向量为 $\mathbf{v}_i^{(k)} = (v_{i1}^{(k)}, v_{i2}^{(k)}, \cdots$ $v_{id}^{(k)})(i=1,2,\cdots,m), \mathbf{v}_i^{(k)}$ 可以描述粒子在空间中 每一维度的运动情况。通过粒子的当前位置以及 其速度矢量可以计算其下一时刻(k + 1)的d 维空 间位置与速度矢量的函数计算公式:

$$\mathbf{v}_{id}^{(k+1)} = \boldsymbol{\omega} \cdot \mathbf{v}_{id}^{(k)} + c_1 \cdot r_1 \cdot (\mathbf{p}_{id}^{(k)} - \mathbf{x}_{id}^{(k)}) + c_2 \cdot r_2 \cdot (\mathbf{p}_{id}^{(k)} - \mathbf{x}_{id}^{(k)})$$
(6)

$$\mathbf{x}_{id}^{(k+1)} = \mathbf{x}_{id}^{(k)} + \mathbf{v}_{id}^{(k+1)}$$
(7)

其中, ω 表示惯性权重, c_1 、 c_2 表示粒子的学习 因子, r_1 、 r_2 是(0,1)间的随机值, $\mathbf{x}_{id}^{(k)}$ 是d维空间粒 子k时刻的位置向量, $\mathbf{v}_{id}^{(k)}$ 是d维空间粒子k时刻运 动的速度向量, $\mathbf{p}_{id}^{(k)}$ 表示粒子个体的位置最优值。 在式(6)、式(7)中,最关键的影响因素为 ω 惯性权 重,它的幅值直接影响着 PSO 的收敛效率。算法的 全局收敛能力会随 ω 的增大而提高,但同时也减弱 了算法的局部收敛能力^[9]。原 PSO 算法的 ω 为常 量并不会随着迭代次数的增加而变化,会削弱算法 的全局寻优能力,降低算法的收敛速度。

故本文提出由大变小,呈非线性变化的惯性权 重ω计算公式,在迭代初期,全局收敛能力较好,提 高收敛速度;迭代的后期,适当减小ω,提高算法的 局部收敛能力^[9],从而提高算法的精确度。ω的形 式如式(8)所示:

$$\omega = a \cdot \sin\left[\frac{\pi}{2} \cdot \left(1 - \frac{k}{k_{\max}}\right)\eta\right] + b \tag{8}$$

式中,k 为当前迭代次数, k_{max} 为算法迭代次数 的最大值, η 为曲率调节参数,a、b 为调节参数,k制 ω 幅值范围。 ω 随着k 与 η 的增大由逐渐增大到 逐渐减小,为了使迭代周期内 ω 变化比较平缓,确 定使 $\omega(k\approx30) = \max[\omega(k,\eta)]$ 的 η ,经过计算可得 $\eta = 1.74$ 。

2.3 改进 PSO-LSTM 预测算法流程

改进 PSO-LSTM 预测模型中关键的参数包含 LSTM 网络的隐含层层数、隐含层神经元个数和学 习率。通过改进的 PSO 算法对这 3 项重要参数不 断进行优化,以达到最优预测性能。该算法关键步 骤如下:

1)初始化参数。设置 PSO 最大迭代次数、种群数、学习因子、曲率调节参数、定义区间和 LSTM 网络初始参数。

2)构建 LSTM 网络预测模型。对训练集样本进行归一化处理,随机初始化粒子位置和速度。

3)确定粒子适应度值。在步骤2)中得到初始 LSTM 网络参数,对多组14d为周期的指向误差训 练集序列数据进行学习并得到预测集,验证集为 14d后0.05s时刻的实际指向误差值,将预测集拟 合误差的均方根误差作为适应度值。

4)更新粒子群状态。规定粒子与种群当前时 刻的最优位置,并根据式(6)、式(7)、式(8)更新粒 子位置与速度,计算粒子群适应度值,并保留更好 的粒子状态。 5)重复执行步骤3)、步骤4),判断是否达到终止条件,当满足终止条件时,跳出循环,得到一组最 优粒子群状态。

6)使用最优粒子群状态设置 LSTM 网络参数并进行预测,网络的输出即为模型的预测值。本文所述网络模型流程图如图2所示。



图 2 网络模型流程图 Fig. 2 The flow chart of the network model

3 实例分析

文章选用 BEIDOU-3 与 IRIDIUM-16 仿真搭建 GEO-LEO 通信场景,以 2021 年 1 月 1 日至 1 月 30 日作为运行周期,对运行周期 1 d 内进行采样,采样 周期 0.05 s,其中 90% 用于训练集,10% 用于验证 集,BEIDOU-3 与 IRIDIUM-16 卫星每 0.05 s 在 J2000 坐标系下的位置速度信息作为训练集输入, 下一时刻的方位、俯仰、距离误差大小为训练集理 想输出;设置 PSO 初始数据为 5 个初始种群,总迭 代次数为 10, $c_1 = c_2 = 1.5$,曲率调节参数 $\eta = 1.74$, 空间维数 d = 4;分别对 LSTM 网络的隐含层层数、 隐含层单元个数和学习率进行优化,最终优化结果 为:设置 LSTM 网络结构为 11 个输入层,3 个隐含 层,隐含层含 30 个隐含单元,20 个全连接层,1 个输 出层,学习率为 0.01。

分别使用 PSO-LSTM 网络、LSTM 网络、BP 网络 与改进后 PSO-LSTM 对同一实验数据的方位误差、 俯仰误差进行预测对比。结果如图 3 所示,由图 3 可知改进后 PSO-LSTM 网络对方位角、俯仰角的误 差预测较为准确,与实际值误差最大为 0.037 3°。



图 3 改进后 PSO-LSTM 网络对误差角预测



为了确定该网络的准确性、稳定性,选用均方 根误差(RMSE)、平均绝对误差(MAE)、平均绝对百 分比误差(MAPE)3个统计指标^[10],分别使用本文 所述模型与未经 PSO 算法优化的 LSTM 网络模 型^[7]对同一数据参数进行预测仿真,并对比两者的 误差指标,如表1所列。

表1 各网络模型预测性能对比

 Tab. 1
 Comparison of prediction performance of each network model

网络模型	RMSE	MAE	MAPE
LSTM	4.31	0.45	13.21%
本文模型	0.07	0.02	0.13%

通过对比可以判断出:经过改进,网络预测性 能有较为明显的提高,尤其是平均绝对百分比误差 相比改进前提高了 13.08%,由此可见基于改进后 PSO-LSTM 网络的太赫兹波束预判方法可以稳定提 高链路余量。

4 结论

针对当前机械伺服机构难以满足太赫兹波束 较窄特性的问题,提出了一种基于改进PSO-LSTM 深度网络的太赫兹波束预判方法,该方法通过建立 深度网络模型,以历史指向误差数据为训练集,实 时预测未来时刻的指向误差并进行修正,从而达到 准确预测未来指向的目的。在建立深度网络模型 中,本文改进了粒子群算法的惯性权重更新模式, 提高算法的局部收敛能力,使深度网络的预测更加 准确,通过实例分析,本文提出的网络预测性能优 于 LSTM 网络模型。

参考文献:

- [1] RANGAN S, RAPPAPORT T S, ERKIP E. Millimeterwave cellular wireless networks: Potentials and challenges
 [J]. Proceedings of the IEEE, 2014, 102(3):366-385.
- [2] 周忆鑫,齐涛,杨晓帆,等.沙尘环境下太赫兹波衰减
 特性[J].太赫兹科学与电子信息学报,2021,19(1):
 18-23.
- [3] 雷红文, 王虎, 杨旭, 等. 太赫兹技术空间应用进展分 析与展望[J]. 空间电子技术, 2017, 14(2):1-7+12.
- [4] 白东炜,杨慧,翟君武,等.导航卫星在轨管理与服务 系统[J].空间电子技术,2021,18(2):16-22.
- [5] 黄金,张宇喆,张正强,等.高轨卫星轨道预报中神经 网络模型优化设计[J].测绘科学技术学报,2015,32
 (6):559-564.
- [6] 罗飞,任昊利,赵冰.基于神经网络算法的卫星轨道预报[J].舰船科学技术,2020,42(19):146-151.
- [7] 刘博. 基于 PSO-LSTM 算法的短期电力负荷预测应用 研究[D]. 长春:吉林大学,2020.
- [8] 李燕斌,万亚宁,肖俊明,等.基于 PSO 优化 BP 神经网络的光伏发电量预测[J].中原工学院学报,2019,30 (4):75-79.
- [9] 宋思远,朱武,王光东,等. 基于 IPSO-LSTM 神经网络 的短期负荷预测[J]. 计算机仿真,2021,38(8):92-96.
- [10] KAMINSKIY R, SHAKHOVSKA N, KAJANOVá J, et al. Method of distinguishing styles by fractal and statistical indicators of the text as a sequence of the number of letters in its words[J]. Mathematics, 2021,9(19):2410.

作者简介:白浪涛(1998-),硕士研究生,主要研究方向为空间太赫兹通信。E-mail:bailt1998@163.com 通讯作者:李小军(1971-),研究员,博士,主要研究方向为空间前沿通信与信息处理。E-mail:lixj@cast504.com