

基于 CNN-BiGRU 的空间目标 RCS 异常检测方法

亓铭瑞, 蒋李兵, 王 壮

(国防科技大学 自动目标识别重点实验室, 长沙 410073)

摘 要:针对相控阵雷达获取单个空间目标 RCS 数据率低、传统姿态异常检测方法提取短 RCS 序列有效特征困难、检测准确率低的问题,提出了一种基于 CNN-BiGRU 网络的 RCS 异常检测方法。首先利用滑动窗口对一段时间空间目标 RCS 实时数据进行积累;之后采用一维 CNN 提取不同检测窗口 RCS 序列的多尺度高维特征向量,采用 BiGRU 提取特征向量的时序依赖特征。通过将两个网络级联,实现对 RCS 随目标姿态变化的多元特征信息的有效提取;最后基于全连接层实现对目标异常 RCS 序列的分类与识别。仿真实验结果表明:相较于传统方法,所提方法检测准确率更高,抗噪声干扰能力更强。实测实验结果表明:利用仿真数据训练的模型针对不同源的实测数据,在低数据率条件下能够保持较高的检测准确度,所提方法具有较好的泛化性,更适用于相控阵雷达体制下 RCS 的异常检测。

关键词:相控阵雷达;雷达散射截面;CNN-BiGRU;异常检测

中图分类号:TN95

文献标志码:A

文章编号:1674-7135(2022)01-0082-07

Space target RCS anomaly detection method based on CNN-BiGRU

QI Mingrui, JIANG Libing, WANG Zhuang

(National Key Laboratory of Science and Technology on Automatic Target Recognition, National University of Defense Technology, Changsha 410073, China)

Abstract: In accordance with the difficulties of extracting the effective features of short RCS sequence and the low detection accuracy by traditional attitude anomaly detection method, which caused by the low data rate of RCS under the phased array radar system, an RCS anomaly detection method based on a convolutional neural network (CNN) and bidirectional gated recurrent units (BiGRU) is proposed in this paper. First, the sliding window is adopted to accumulate the real-time RCS data of space targets. Then, the one-dimensional CNN is adopted to extract high-dimensional features of the RCS sequence, while the BiGRU helps to extract time-series dependency features of the high-dimensional feature vectors. Multivariate feature information of RCS varying with target attitude is extracted effectively by cascading two networks. Finally, the fully connected layer is used for the classification and recognition of anomaly targets' RCS. The simulation experimental results indicate that the proposed method presents higher detection accuracy and stronger noise robustness than traditional methods. Moreover, the real test experimental results indicate that the model trained by simulation data has high detection performance under the condition of low data rate for the measured data of different sources, demonstrating that the model has strong generalization ability, which means that our method is more applicable for RCS anomaly detection under phased array radar system.

Key words: phased array radar; radar cross section; CNN-BiGRU; anomaly detection

收稿日期:2021-10-30; 修回日期:2022-01-15

基金项目:国家重点实验室基金(编号:61404130316)

作者简介:亓铭瑞(1997-), 硕士, 主要研究方向为微波成像与自动目标识别。E-mail:zyqmr77@163.com

通讯作者:王 壮(1973-), 教授, 主要研究方向为空间目标监视、自动目标识别。E-mail:zhuang_wang@sina.com

0 引言

利用空间目标雷达散射截面 (radar cross section, RCS) 对目标状态信息进行推断反演,对空间监视具有重要意义^[1],其中基于 RCS 的姿态异常检测能够为航天器在轨状态分析与后续抢修或应急补发提供依据。航天器正常工作时受控制系统作用一般保持三轴稳定姿态,当发生异常时,其在扰动里的作用下表现为绕主惯量轴的翻滚运动^[2]。RCS 具有姿态敏感性,利用目标 RCS 的时变特征,可以实现对空间目标的异常检测。传统基于 RCS 序列的空间目标异常检测方法主要可以归为两类:一类为利用目标 RCS 序列的时域变化特征(周期性,随机性)进行姿态稳定性判断,如周期图法^[3],通过对 RCS 序列对应频谱响应曲线进行峰值检测,判断 RCS 序列周期性,进而判断目标是否失控翻滚。游程检验法^[4-5]将目标 RCS 序列转换为游程序列,通过随机性检验判断目标姿态稳定性。另一类首先将 RCS 序列进行域变换,基于变换域特征对不同姿态下的 RCS 序列进行分类与识别,进而判断目标姿态稳定性,如小波分解法^[6]。这类方法对于单脉冲体制雷达,短时间就能获得目标较长 RCS 观测序列的情况下,具有较好的检测效果。然而,相控阵雷达在实际任务中往往要对多个目标进行跟踪监视,作用于单个目标的观测资源会受到限制,导致获取单个目标 RCS 数据率一般比较低,相同观测时间内获得 RCS 序列较短。传统方法在提取 RCS 序列特征时主要对其整段数据的全局特征进行提取,未考虑不同时间尺度的局部特征及这些特征间的时序依赖关系,因此当数据量不足以有效反映序列全局属性时,检测准确率就会降低。

神经网络通过各个网络层对数据本质特征进行非线性抽象,能够实现对数据深层特征的提取,简化了复杂的特征工程,针对少量数据也能实现有效的特征提取。此外,空间监视任务中会积累大量目标 RCS 观测数据,这些长期积累的历史数据隐含了目标丰富的特征信息。传统方法在提取 RCS 序列特征时,人的主观经验起主导作用,而忽略了历史数据所包含的对目标 RCS 特征的客观描述,造成了对这些宝贵历史数据的浪费。鉴于神经网络具备从数据中抽象高层次共性特征描述的能力,可以利用其在数据表征上的优势,将深度学习与姿态异常检测进行有机结合,有助于建立鲁棒性更强的判别模型。基于此,本文提出了基于

卷积神经网络(convolutional neural networks, CNN)与门控单元循环网络(bidirectional gated recurrent unit, BiGRU)的空间目标 RCS 异常检测方法,通过级联 CNN 和 BiGRU,获取 RCS 序列高层次特征在时序上的相关关系,实现对异常 RCS 的分类与识别。

1 空间目标不同姿态 RCS 散射特性

不同目标,不同构件的 RCS 散射特性一般不同。大部分在轨航天器尺寸较大,一般处于高频区,故目标整体散射场可以视为各个构件独立散射场的叠加。设雷达的发射信号为:

$$E_i = E_0 \exp(j\omega t) \quad (1)$$

若目标上某构件散射中心 $P(x_i, y_i)$ 与目标中心的距离为 $R_{\Delta i}$,雷达视线方向目标与雷达距离为 $R_0(t)$,雷达 LOS 方向与目标主轴夹角为 θ ,则雷达与该散射中心的距离为:

$$R(t) = R_0(t) + R_{\Delta i} = R_0(t) + y_i \cos \theta - x_i \sin \theta \quad (2)$$

目标反射回波可以表示为:

$$\begin{aligned} F(\omega, \theta) &= \int_{-L}^L \int_{-L}^L \delta(x_i, y_i) \exp(j\omega t - j4\pi R(t)/\lambda) dx dy \\ &= \int_{-L}^L \int_{-L}^L \delta(x_i, y_i) \exp(j\omega t - j4\pi(R_0(t) + \\ &\quad y_i \cos \theta - x_i \sin \theta)/\lambda) dx dy \end{aligned} \quad (3)$$

其中 $\delta(x_i, y_i)$ 为散射系数, λ 为雷达发射信号波长, $2L$ 为目标尺寸, ω 为目标转速,相位补偿后回波可以表示为:

$$\begin{aligned} F(\omega, \theta) &= \int_{-L}^L \int_{-L}^L \delta(x_i, y_i) \exp(-j4\pi(y_i \cos \theta - \\ &\quad x_i \sin \theta)/\lambda) dx dy \end{aligned} \quad (4)$$

由式可以看出,空间目标 RCS 会随姿态角的变化而发生变化。正常工作的卫星在轨运行姿态一般为三轴稳定姿态,卫星的姿态角变化较小,对应 RCS 变化幅度小,但卫星目标上构件的微动会引起整体 RCS 值的变化,如太阳能帆板的转动、天线的旋转等,因此三轴稳定姿态下的空间目标其 RCS 测量值为一个确定常量与一个随机量的叠加。当卫星发生异常时,进行翻滚运动,其 RCS 序列呈周期性变化,虽然和三轴稳定姿态一样会有随机量的叠加,但序列的周期分量趋势一般不会被掩盖^[7]。

2 神经网络 RCS 特征提取

2.1 基于一维 CNN 的 RCS 特征提取

本文采用一维 CNN 对 RCS 序列不同时间尺度

的特征进行提取,如图 1 所示,每进行一次卷积,特征向量相应增加一个特征值,完成一次卷积后,卷积核按照指定步长沿序列滑动,继续执行卷积操作,进而实现对 RCS 序列不同时间尺度的局部特征进行提取。一维卷积的数学表示为:

$$y(m) = f\left(\sum_k^{K-1} w(k) * x(m+k) + b\right) \quad (5)$$

其中 $w(k)$ 为第 k 个卷积核参数, $x(m+k)$ 为输入 RCS 序列第 $(m+k)$ 元素的值, $y(m)$ 为输出特征向量第 m 元素的数值, b 为偏置项, f 为激活函数。对于多层一维卷积网络,若卷积层输入为上一层提取的特征向量,则本层卷积可以实现特征向量间的非线性映射。




图 1 一维卷积原理图

Fig. 1 Schematic diagram of one-dimensional convolution

2.2 基于 BiGRU 的时序特征提取

长短期记忆网络 (long short term memory, LSTM) 作为循环神经网络 (recurrent neural network, RNN) 的变体,解决了 RNN 随着递归量的增加出现的梯度消失或梯度爆炸问题^[7]。门控循环单元 (gated recurrent unit, GRU) 为 LSTM 的简化网络模型,其内部核心结构为更新门与重置门。GRU 在保持 LSTM 性能的同时简化了网络结构,减少了网络参数,显著提高网络的收敛速度。单向 GRU 网络中,节点状态均为从前至后单向传递,对于时间序列当前状态只能利用过去历史信息获得,使得网络难以学习序列前后完整特征,因此本文拟采用 BiGRU 提取特征向量的时域特征。BiGRU 网络由沿时序正反两个方向的循环网络构成,其结构如图 2 所示,设输入特征向量为 $X = [x_1, x_2, \dots, x_{t-1}, x_t, \dots, x_T]$, 则更新门 u_t 、重置门 r_t 在 t 时刻的状态可以表示为:

$$u_t = \sigma(W_u[h_{t-1}, x_t]) \quad (6)$$

$$r_t = \sigma(W_r[h_{t-1}, x_t]) \quad (7)$$

隐藏状态 h_t 与候选隐藏状态 $\tilde{h}_t$ 在 t 时刻可以表示为:

$$h_t = (1 - u_t) * h_{t-1} + u_t * \tilde{h}_t \quad (8)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t * h_{t-1}, x_t]) \quad (9)$$

正向 GRU 的隐藏层状态 $\tilde{h}_t$ 与反向 GRU 的隐

藏层状态 $\tilde{h}_t$ 在当前时间进行线性融合得:

$$y_t = W_{hy}\tilde{h}_t + W_{h\tilde{y}}\tilde{h}_t + b_y \quad (10)$$

这种结构使得网络既能够获得正向长短期的信息,也能获得反向未来的依赖信息。




图 2 BiGRU 结构图

Fig. 2 Network structural diagram of BiGRU

3 RCS 异常检测方法

3.1 异常检测流程

基于空间目标 RCS 的姿态异常检测处理流程如图 3 所示,整个处理流程分为:(1)网络训练;(2)数据划分;(3)异常检测 3 个部分。首先仿真目标 RCS 数据,通过时间窗对整个观测弧段数据进行采样,得到分段 RCS 序列,进而构建训练数据集,之后进行多轮训练对网络进行迭代优化,得到网络模型参数。对于 RCS 测量数据,同样采用滑动时间窗进行积累,时间窗长度为 M ,滑动步长为 N ,即初始积累 RCS 数据长度为 M ,之后每新增 N 个数据,进行一次姿态判别,相邻时间窗姿态判别结果发生改变时,则判断状态发生异常。




图 3 异常检测流程图

Fig. 3 Flow diagram of anomaly detection

3.2 CNN-BiGRU 网络结构设计

本文采用网络结构如图 4 所示,CNN 网络采用 3 层结构(超过 3 层检测准确率没有明显提升,网络

收敛速度反而变慢),每层由卷积层,批归一化(batch normalization, BN)层以及线性修正单元(rectified linear unit, ReLU)激活函数组成,用于提取 RCS 序列各时段的局部特征向量。卷积核数量为 $\{128, 256, 128\}$,适当增加网络卷积核数量有助于提升网络最大性能,网络性能达到最大后,卷积核数量越多,网络需要学习的超参数大幅增加,网络将变的难以收敛,导致网络最大性能下降。不同目标 RCS 分布的差异性会随着网络的迭代不断累积放大,造成网络难以收敛,故加入 BN 层对数据进行规范化以加快网络的收敛速度,提高网络的泛化能力^[8]。ReLU 函数是一种非线性激活函数,能够增强网络对复杂非线性特征的拟合能力;BiGRU 用于提取特征向量沿时序正、反两个方向的关联特征,GRU 单元的数量从文献^[1,2,4,6]中搜索,找到最佳的数量,隐藏层特征维度为 128,隐藏层后设置 0.2 比重的随机丢失机制以防止训练过拟合;最后通过全连接层与 Sigmoid 函数进行特征整合,输出分类结果。




图4 CNN-BiGRU 级联网络结构图

Fig.4 Cascaded network structural diagram of CNN-BiGRU

3.3 数据集构建

利用 FEKO 电磁模拟软件,仿真 3 种卫星目标 RCS 数据。在轨目标位于远场,故雷达信号波形采用平面波,信号载频分别采用 500 MHz、2 GHz、3 GHz 3 种频段,模拟方法为物理光学法。仿真目标三轴稳定姿态 RCS 数据时,固定雷达视角,使目标的三维姿态进行小范围变化;仿真目标翻滚姿态时,使目标绕主轴按照一定的角速度进行旋转,并加入姿态扰动。如图 5 所示为 3 个卫星目标的三维模型以及不同姿态下部分时间窗 RCS 仿真序列。获得目标雷达 RCS 序列数据后,将数据按照如图 6 所示的滑动窗口进行划分,窗长 $M=100$,步长 $N=20$ 。




图5 3类卫星 FEKO 仿真结果

Fig.5 FEKO simulation results of three satellites




图 6 滑动窗口数据划分

Fig. 6 Data partition by sliding-window

4 实验结果与分析


4.1 实验环境与参数

为了满足训练对数据样本的需求,共仿真了 6 000 组窗口 RCS 数据,按照 5:1 划分为训练集与验证集。实验硬件环境基于 Intel Core i9-10900 2.8 GHz CPU、NVIDIA 3080ti GPU 12 GB、32 GB 内存,软件环境基于 Pytorch 深度学习框架与 Matlab2019a 数学分析软件。训练采用自适应矩估计 (adaptive moment estimation, Adam) 优化器,批样本数为 50。训练共迭代 1 000 轮,学习率为 0.000 1,总训练时长为 3 小时。损失函数采用二值交叉熵 (binary cross entropy, BCE) 损失函数。


4.2 仿真实验结果与分析

对网络进行 1 000 轮次的迭代优化,训练集与验证集的损失函数随迭代轮次的变化曲线而变化,如图 7(a) 所示,验证集的预测准确度迭代轮次的变化曲线如图 7(b) 所示,训练集在 600 轮之后损失函数变化趋于稳定,并逐渐收敛趋于 0;验证集在 200 轮后损失函数收敛并趋于 0,准确度趋于 1,表明网

络在训练过程中没有发生欠拟合或过拟合的情况,训练效果较好。



(a) 损失函数曲线



(b) 准确度曲线

图 7 网络训练过程曲线

Fig. 7 Process curve of network training

测试数据为卫星 10 圈次的 RCS 仿真数据,每圈次有 30 个时间窗口观测数据,一圈次的观测数据为一个测试样本。为了测试网络对不同姿态下目标 RCS 序列特征的学习能力,采用 T 分布随机近邻嵌入算法 (T-stochastic neighbor embedding, T-SNE) 对测试数据的高维特征输出进行可视化降维^[9],如图 8 所示。




图 8 RCS 测试数据二维特征分布图

Fig. 8 Two-dimensional characteristic distribution diagram of RCS test data

为了验证本方法相比于传统算法对目标异常状态检测的有效性,与游程检验法、周期图法以及小波变换方法的各圈次的检测准确率进行了对比,实验结果如表 1 所列。可以看出,游程检验与小波分解模糊分类的检测方法准确率相对较低。小波

分解法的准确率主要在 50% 上下波动,整体检测效果较差;游程检验的方法准确率最高能达到 100%,最低仅为 56.67%,稳定性较差;周期图法检测准确率相对较高,平均为 82%,表明目标翻滚在 RCS 序列上表现出一定周期性的时候,该方法比较有效;

本文所提方法相较于其他方法准确率最高且波动较小,平均检测准确率相较周期图法提高了 17%,表明本方法具有较强的检测性能与稳定性,反映出神经网络在提取目标 RCS 序列不同尺度的深层次特征以及基于特征进行识别检测方面具有较大优势,一定程度上突破了传统特征提取方法的局限性。

表 1 各方法检测准确率

Tab.1 Detection accuracies of various methods

检测 方法	游程 检验法	周期 图法	小波 变换法	CNN- BiGRU
圈次 1	60.00	46.67	50.00	96.67
圈次 2	70.00	80.00	50.00	100.00
圈次 3	96.67	93.33	50.00	100.00
圈次 4	100.00	83.33	53.33	100.00
圈次 5	63.33	70.00	43.33	100.00
圈次 6	56.67	93.33	56.67	96.67
圈次 7	66.67	90.00	50.00	96.67
圈次 8	63.33	86.67	53.33	100.00
圈次 9	66.67	83.33	73.33	100.00
圈次 10	60.00	93.33	60.00	100.00
平均	70.33	82.00	54.00	99.00

实际应用中,受雷达系统热噪声、环境扰动、标校精度等因素的影响,RCS 序列会叠加不同程度的噪声,为了验证所提方法在不同噪声条件下的性能,在测试数据加入 5 dB – 25 dB 信噪比范围的高斯噪声的情况下,各方法检测平均准确度随信噪比而变化,如图 9 所示,所提方法准确率整体上高于传统方法,当信噪比达到 15 dB 时,检测准确率能够在 90% 以上,表明所提方法相较于传统方法具有更强的噪声鲁棒性。




图 9 不同信噪比条件下各方法性能曲线图

Fig.9 Capability diagram of various methods under different signal to noise ratios

4.3 实测实验结果与分析

利用两个典型三轴稳定与翻滚目标的雷达实测 RCS 数据,对所提方法的实际检测性能进行分析。为了验证模型的泛化性,采用 4.2 节 FEKO 仿

真数据训练的模型对实测数据进行检测。实测数据共有 200 个时间窗口的 RCS 数据测试样本,每个样本 RCS 序列长度为 100。三轴稳定目标共 140 个样本,翻滚目标共 60 个样本,设置时间窗长范围为 20 – 100,对各方法针对不同窗长 RCS 数据的检测性能进行对比分析,结果如表 2 所列。检测准确率随窗长的变化而变化,如图 10 所示可知,随着窗长的缩短,各方法检测性能均有不同程度的下降,但所提方法的检测准确率均超过了 90%,整体高于传统方法。

表 2 不同窗长条件下各方法检测准确率

Tab.2 Detection accuracies of various methods under different window lengths

检测 方法	游程 检验	周期 图法	小波 变换法	CNN- BiGRU
窗长 20	72.0	62.5	58.5	94.0
窗长 40	79.5	73.0	65.5	96.0
窗长 60	88.0	76.0	67	98.0
窗长 80	90.0	76.5	68	99.5
窗长 100	90.5	75.5	66.5	98.0




图 10 不同窗长条件下各方法性能曲线图

Fig.10 Capability diagram of various methods under different window lengths

进一步验证所提方法在实际应用中的计算效率,对各方法的运算复杂度进行对比分析。不同窗长条件下各方法耗时如表 3 所列,内存使用情况 (Matlab 软件) 如表 4 所列。

表 3 不同窗长条件下各方法检测耗时

Tab.3 Detection time-consuming of various methods under different window lengths

检测 方法	游程 检验	周期 图法	小波 变换法	CNN- BiGRU
窗长 20	0.066	0.060	0.281	0.012
窗长 40	0.067	0.061	0.286	0.012
窗长 60	0.068	0.061	0.287	0.013
窗长 80	0.069	0.062	0.298	0.013
窗长 100	0.069	0.063	0.306	0.016

表 4 不同窗长条件下各方法内存占用
Tab.4 Memory occupancy of various methods under different window lengths

检测 方法	游程 检验	周期 图法	小波 变换法	CNN- BiGRU
内存 占用 /MB	窗长 20	2 613	2 652	2 614
	窗长 40	2 613	2 654	2 614
	窗长 60	2 615	2 655	2 616
	窗长 80	2 617	2 657	2 616
	窗长 100	2 617	2 659	2 643

可以看出,随着窗长的增加,各方法检测耗时与内存占用均有不同程度的增加。所提方法整体上相较于其他方法在不同窗长条件下耗时更低,占用内存更少,表明该方法在提升检测性能的同时,有效降低了运算复杂度,更适用于工程应用。

5 结论

针对相控阵雷达体制下 RCS 数据率低对目标在轨状态检测的影响,本文提出了基于 CNN-BiGRU 级联网络的 RCS 异常检测方法,通过结合 CNN、BiGRU 提取时间序列特征各自的优势,使网络能够学习三轴稳定、翻滚目标 RCS 序列的时变特征,实现了对目标异常状态的有效检测,避免了复杂的数据预处理与人工特征提取过程。实验结果表明,与传统方法相比,所提方法具有更高的检测准确率及更强的噪声鲁棒性。网络针对非同源的实测数据也具有较高的检测精度,在低数据率条件下检测性

能与计算效率明显优于传统方法,表明所提方法更适用于相控阵雷达体制下低数据率 RCS 的异常检测,具有较大的实际应用价值。

参考文献:

- [1] 胡盟霄,来嘉哲,徐灿. 一种空间目标 RCS 序列的姿态异常检测方法[J]. 中国空间科学技术,2019,39(6): 72-79.
- [2] HUANG J, WANG D Y, XIA S Z. An optimal beam alignment method for large-scale distributed space surveillance radar system[J]. Advances in Space Research, 2018, 61(11): 2777-2786.
- [3] 姬伟杰,钟卫军. 应用 RCS 序列估计卫星自旋周期[J]. 电讯技术,2017,57(9): 1004-1010.
- [4] 全备,戴征坚,胡卫东,等. 两类空间目标的非参数姿态判别方法[J]. 中国空间科学技术,2000,20(3): 1-4.
- [5] 秦记东,彭华峰,党同心,等. 融合光度序列和雷达散射截面序列的目标运动特征反演方法[J]. 信息工程大学学报,2018,19(5): 562-567.
- [6] 李鑫. 基于 RCS 序列的雷达目标特征辨识方法研究[D]. 北京:北京交通大学,2018.
- [7] 徐彬,陈渤,刘家麒,等. 采用双向 LSTM 模型的雷达 HRRP 目标识别[J]. 西安电子科技大学学报,2019,46(2): 29-34.
- [8] 冉欢欢,蒙顺开,李毅捷,等. 一种基于忆阻器的深度神经网络:CN112308223A[P]. 2021-02-02.
- [9] 徐秀芳,徐森,花小朋,等. 一种基于 t-分布随机近邻嵌入的文本聚类方法[J]. 南京大学学报(自然科学), 2019,55(2): 264-271.