基于自适应阈值的SA雷达发射机故障重构预警方法研究

周薇[1] 赵忠凯[2] 王一萌[1] 沈超[1] 李巍[1] 王大林[3] 李旭[4]

(1 中国气象局气象探测中心,北京 100081;2 黑龙江省气象数据中心,哈尔滨 150001;
3 清华大学工业工程系,北京 100085;4 和尘自仪(嘉兴)科技有限公司,嘉兴 314500)

摘要 新一代天气雷达的故障识别和判定一直是雷达运维面临的技术挑战,部分严重故障的滞后响应会导致雷达相应部件的损坏加剧。本文在结合人工智能技术和雷达数据特点的基础上,提出了基于自适应阈值的SA雷达发射机系统故障预警和判定方法,建立了基于重构模型的发射机故障在线监测的算法框架。该算法框架能够在雷达发射机故障发生早期识别异常并给出预警。采用实际运行记录进行计算分析,并验证了该方法在实际运行中有效可用。

关键词 CINRAD/SA;发射机;自适应;重构模型;故障判定

中图分类号: P415.2 **DOI:** 10.19517/j.1671-6345.20220427 **文献标识码:** A

引言

新一代气象雷达作为复杂电子系统,具备多模块、结构复杂且工作过程多样等特点,使得雷达系统的故障预警和诊断一直面临极大的困难和挑战[1-2]。随着雷达的自动化程度和各项技术指标越来越高,传统的人工故障诊断方法越来越难以满足需求[3-5]。雷达系统一旦发生故障,雷达状态监测信号常会发生异常,导致雷达的探测能力异常而难以发挥作用,同时由于雷达的复杂性,简单组件故障就可能导致整个雷达系统丧失可用性[6]。雷达系统故障在系统运行时以功能失效的形式表现,绝大多数故障为单一故障逐渐演变为严重故障,在故障早期征兆不明显时根据系统的状态信息和故障迹象进行故障识别并给出预警信息,以便开展预测性维修活动,对实现雷达智能维修,提升雷达设备保障水平具有重要意义。

近年来人工智能在气象探测领域越来越受到重视[7]。在故障预警和诊断领域得到广泛探索和应用的人工智能算法为解决雷达的故障预警和诊断问题提供了可能的技术手段[8]。人工智能应用于故障预警和诊断的研究主要分为两类:一类是基于知识的专家系统,如基于D-S证据理论的推理[9]、多信号流图模型[10]、粗糙集理论[11]、基于故障树的知识推理[12]等;另一类是基于数据驱动的方法,如BP神经网络方法[13]、模糊神经网络方法[14]、小波神经网络方法[15]、混沌遗传算法、决策树和支持向量机方法等[16-17]。国内外应用人工智能算法进行雷达故障诊断定位的研究也逐渐增多,如采用隐式半马尔可夫模型进行雷达故障预测建模[18]、采用BP神经网络在军事雷达故障诊断中进行应用[19],采用装备系统分级思想和自组织映射网络SOM对雷达机型健康状态评估和寿命预测[20]等。但在天气雷达故障人工智能预测方面的应用研究尚未广泛开展,且雷达是复杂的电子系统,参数多且运行状态切换频繁,很难通过单次模型训练得到一个应用持续有效的算法模型,因此需要随着雷达的运行不断地训练更新模型来提高故障预测诊断的识别效果。

基于实时数据进行算法模型更新训练的思路,本文提出一种基于自适应阈值的SA雷达发射机系统故障预警方法。该方法通过建立基于重构模型的发射机故障在线监测的算法框架,从预测残差中提

作者简介:周薇,女,1986年生,硕士,高级工程师,主要从事雷达装备保障信息化与智能化关键技术研发工作,Email:zhouwei0427@foxmail.com

收稿日期:2022年10月11日;定稿日期:2023年4月23日

取状态有效性,并在时间区间内计算健康度和故障点率,当健康度和故障点率超过阈值时发出预警,实现雷达发射机故障的早期异常识别并给出相应故障预警。与传统的单次模型训练和测试来说,基于数据更新的重构模型思路,能够更好地识别雷达的近期状态,根据近期运行状态的偏离,提高雷达发射机故障的预测准确率。

1　重构算法框架构建

本文所提出的自适应阈值 SA 雷达发射机故障重构预警判定算法是针对 SA 雷达发射机的基于重构模型的在线监测和故障诊断的算法框架,该故障探测方法基于以下假设构造:当系统故障发生时,重构模型的预测值和实际测量值的残差与正常状态下的残差分布不同。算法框架包括 2 个主要模块:①离线重构模型,用于针对 SA 雷达发射机故障进行特征选择和重构模型训练;②在线监测模型,用于分析残差分布并根据所计算的状态有效值和故障点率来诊断雷达是否处于故障状态。算法框架流程如图 1 所示。

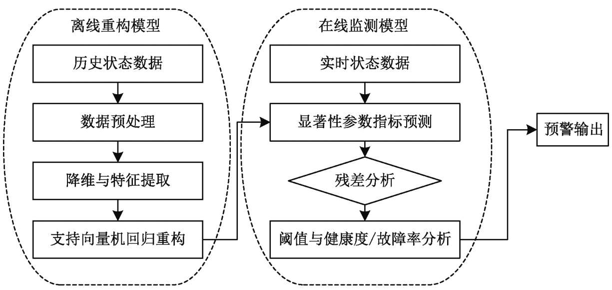

图 1　自适应阈值 SA 雷达发射机故障重构预警判定算法流程

1.1　离线重构模型

离线模块从历史状态数据中提取与故障相关的重要状态参数,并根据所提取的状态数据建立正常状态下的重构模型。重构模型的构建分为 3 个过程,包括数据预处理,特征提取,重构模型训练。

1.1.1　数据预处理

数据预处理用于对原始数据的初步处理,其步骤包括删除不准确的数据、填充丢失的数据、统一时间范围和数据归一化[21]。在雷达状态数据的预处理中,根据设计标准通过监测值的阈值对离群值进行过滤,离群值是统计数据分布中的异常点数据值,同时对数据丢失问题进行处理,采用具有相关特征的完整数据的回归方法填充缺失数据,并通过间隔平均值对数据进行重新采样实现统一时间标度。在完成上述步骤后,对状态数据进行归一化处理,归一化是开展重构模型的必要过程,由于原始状态数据最大值和最小值之间通常会有很大差异,采用 Z 分数标准化进行原始状态数据的范围缩放:

$$v' = \frac{v-\bar{v}}{\sigma} \tag{1}$$

其中,v 为原始值,v' 为归一化值,$\bar{v}$ 为数据均值,σ 为数据标准差。

数据预处理过程中需要对数据的准确性和有效性进行判断。准确性判断方法主要通过正态性校验,对于每个待分析参数,超出$[\bar{v}-3\sigma,\bar{v}+3\sigma]$范围的标记为异常数据,在算法模型构建和训练时进行滤除。有效性判断主要包括 2 个方面:①数据密度;②数据变化程度。本文使用雷达数据的采样率为 6 min 一条记录[22],在进行数据预处理时,优先选择连续 6 min 采样间隔的数据进行分析建模,若某日 24 h 内该组数据点数少于 60%,则该日数据标记为缺失异常,在算法模型构建和训练时进行滤除。数据变化程度通过方差阈值法滤除无波动的参数信号,以本文采用的数据集为例,滤除后的 59 维参数信号进行相关分析结果如图 2 所示,大量信号间存在相关性,验证了数据的波动有效性。

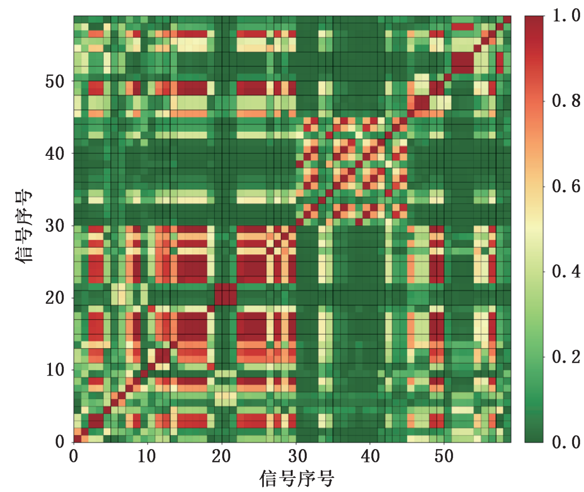

图 2　方差滤除法滤除无波动参数后的相关性

1.1.2　降维、特征提取和目标参数选择

SA 雷达发射机属于复杂机械电子系统,目前信息采集系统已采监测参数达 139 个[23],即使经过预处理筛选后的变量参数仍达 59 维,而监测参数数量太多导致模型构建困难,为分析所关注的故障类

型，须进行特征提取实现参数降维，以减小原始数据的维数，使用特征提取后的相关参数构建模型可以减少干扰并提高模型准确性。

在自适应阈值SA雷达发射机故障重构预警判定算法框架中，采用专家经验和向前逐步回归相互结合的方法来提取雷达发射机关键特征参数。经过机理和经验梳理，总结发射机相关的特征参数，形成待筛选参数集合，再通过向前逐步回归分析方法，筛选出相关有效变量。

向前逐步回归分析可以帮助选择对预测因变量最相关的自变量。前向逐步回归从一个空模型开始，按照各个自变量参数的贡献顺序添加来预测目标因变量。由于SA雷达的报警记录中包含很多虚警，因此报警不能直接用作重构模型的训练目标，而使用状态数据通过特征提取找到与发射机故障的最相关的“目标参数”，进而将此“目标参数”作为重构模型的标签，并将其他参数作为模型的输入参数。

1.1.3 支持向量机回归模型

由于雷达的系统状态随着运行时间持续不规则的变化，如采用单一时刻的参数值作为模型输入会导致时间维度上的信息丢失，因此在本算法框架中使用支持向量机回归（Support Vector Regression，SVR）对目标参数进行拟合重构[24]。

SVR应用核函数将特征从低维向高维进行转换，使用非线性映射的方法将数据投影至特征空间，在特征空间内寻找一个超平面使所有数据到这个超平面的距离之和最小。在本算法框架中使用径向基函数（Radial Basis Function，RBF）作为回归核函数。径向基函数在特征空间中的表现形式为非线性，能够更好拟合非线性决策边界，从而处理非线性问题[25]。

1.2 在线监测模型

离线重构模型的训练数据使用雷达的历史正常状态数据，而在线监测模型的目的是使用近期和实时状态数据预测、识别和判定雷达的异常和故障状态。近年来建设的雷达在线状态参数大数据平台为系统应用和数据积累提供了基础[26-28]。在计算中由历史正常数据训练的重构模型输出的是所关注状态参数的预测值，而残差由预测值和实际测量值之间的偏差确定。在通常情况下可假设预测值和实际测量值服从正态分布，而残差应在零点附近随机分布，这也与状态参数的直观经验相吻合。

在线监测模型对在线实时数据应用重构模型对目标参数值进行预测，并进一步通过计算预测值和测量值之间的残差来检查雷达状态。如果计算所得的残差分布与正常残差分布不同，则可以识别该雷达处于异常状态。在线监测模型中使用标准化高斯函数作为状态有效值来检测潜在异常点，使用时间间隔统计信息来过滤由于状态参数缺失或错误等导致的异常情况，从而提高故障预测的准确性。

对每个在线监测时刻的数据点，状态有效值 μ 计算如下：

$$\mu = \mathrm{e}^{-\frac{(y-\hat{y})^2}{2\sigma_y^{\ 2}}} \tag{2}$$

其中，y 为实际监测值，$\hat{y}$ 为重构模型的预测值，σ_y 为实际监测值的标准差。当状态有效值低于阈值 μ_p（通常取 $\mu_p = 0.95$）时，发射机的状态识别为异常，此时发射机状态与正常状态相比发生明显偏离。

为减少单一时刻监测状态数据的异常干扰，在计算中采用时段计算方法，通过对监测时间长度为 n 的监测时刻点进行状态有效值统计以滤除参数错误或异常干扰，在对 n 个监测时刻点计算后统计出满足状态有效值小于阈值（$\mu < \mu_p$）的点数 n_f，进而由下式计算雷达发射机的故障点率 R（健康度）：

$$R = \frac{n_f}{n} \tag{3}$$

当故障点率 R 大于设定阈值 R_p 时发射机出现了异常故障，在对发射机进行算法调参时分析获得通常 n 取50～500，R_p 取0.2～0.4较为合理，在本文开展的雷达发射机实算中取 $n=100$，$R_p = 0.3$。

2 雷达发射机数据集计算及验证

2.1 数据描述

发射机作为雷达系统的核心模块，其运行可靠性直接影响雷达功能和可用性，易发生故障且难以监测和诊断[29-30]。本文使用上述算法模型对SA雷达的实际运行记录进行计算分析，并与维修记录中的故障记录进行对比以验证算法有效性。

福州气象雷达站2016年1月1日至2017年12月12日有3个数据库：①雷达状态数据，包括243021个具有观察时间的样本以及其他139个以6 min为间隔的状态参数；②故障记录数据，其中包括4条发射机故障记录，包含故障类型、维护时间、故障描述等信息；③报警数据，7492条包含报警时间和报警代码的报警记录。其中报警数据远超过故障记录数

据,意味着目前监测使用阈值方法产生的报警信号大量是虚警。

2.2　故障特征提取

SA 雷达状态数据已采参数维数为 139,高维数会导致直接分析雷达故障十分困难。考虑到降维必要性,按算法框架流程使用逐步回归方法提取与发射机故障相关的特征参数。

基于专家经验梳理得到的待筛选发射机关键参数集合,包括水平通道天线峰值功率、发射机峰值功率、发射机与天线功率比 r、水平通道天线功率调零、发射机功率调零、水平通道相位噪声、垂直通道相位噪声、水平通道滤波前功率、水平通道滤波后功率、垂直通道滤波前功率、垂直通道滤波后功率、KD 标定期望值、KD 标定测量值、反射率期望值 1～8、反射率测量值 1～8、KD 标定期望值 1～6、KD 标定测量值 1～6。

在该雷达站的报警数据中找到与发射机故障相关的共 7492 条报警信号记录,在 6 min 的采样间隔内在状态数据中找到带有报警信号的样本,完成状态样本与报警信号在时间上的对齐,将状态数据中异常状态的这些样本标记为逐步回归的目标量,最后应用向前逐步回归,从专家筛选出来的发射机关键参数中获得与发射机故障相关的参数。

如表 1 所示,由向前逐步回归方法确定出有 27 个参数的回归系数绝对值大于等于 0.01,图 3 中显示了回归系数高于 0.01 的 9 个关键参数,可认为这 27 个参数对发射机故障具有一定的表示性。其中水平通道天线峰值功率的回归系数远大于表 1 中的其他参数,可认为水平通道天线峰值功率是最适合作为发射机故障的重构目标参数,其他 26 个相关参数作为重构模型的输入用于计算获得水平通道天线峰值功率的预测值。

表 1　特征提取得到的 SA 雷达发射机故障相关参数

参数名称	回归系数	参数含义	单位
ANT_PEAK_PWR	−2.03	水平通道天线峰值功率	kW
XMTR_PEAK_PWR	−0.57	发射机峰值功率	kW
POWER_METER_RATIO_DB	0.01	发射机与天线功率比 r	dB
ANT_PWR_MTR_ZERO	0.56	水平通道天线功率调零	
XMTR_PWR_MTR_ZERO	0.01	发射机功率调零	
UNFILTERED_LIN_CHAN_PWR	0.12	水平通道滤波前功率	dBz
FILTERED_LIN_CHAN_PWR	0.01	水平通道滤波后功率	dBz
EXPECTED_REFL_AMP1	0.01	反射率期望值 1	dBz
EXPECTED_REFL_AMP2	0.01	反射率期望值 2	dBz
EXPECTED_REFL_AMP3	0.01	反射率期望值 3	dBz
EXPECTED_REFL_AMP4	0.01	反射率期望值 4	dBz
EXPECTED_REFL_AMP5	0.01	反射率期望值 5	dBz
EXPECTED_REFL_AMP6	0.01	反射率期望值 6	dBz
EXPECTED_REFL_AMP7	0.01	反射率期望值 7	dBz
EXPECTED_REFL_AMP8	0.01	反射率期望值 8	dBz
MEASURED_REFL_AMP1	0.01	反射率测量值 1	dBz
MEASURED_REFL_AMP2	0.01	反射率测量值 2	dBz
MEASURED_REFL_AMP3	0.01	反射率测量值 3	dBz
MEASURED_REFL_AMP4	0.01	反射率测量值 4	dBz
MEASURED_REFL_AMP5	−0.19	反射率测量值 5	dBz
MEASURED_REFL_AMP6	−0.17	反射率测量值 6	dBz
MEASURED_REFL_AMP6	0.15	反射率测量值 7	dBz
MEASURED_REFL_AMP6	0.01	反射率测量值 8	dBz
EXPECTED_RF8_AMP3	0.13	KD 标定期望值 3	dBz
EXPECTED_RF8_AMP5	0.01	KD 标定期望值 5	dBz
MEASURED_RF8_AMP5	0.13	KD 标定测量值 5	dBz
MEASURED_RF8_AMP6	0.01	KD 标定测量值 6	dBz

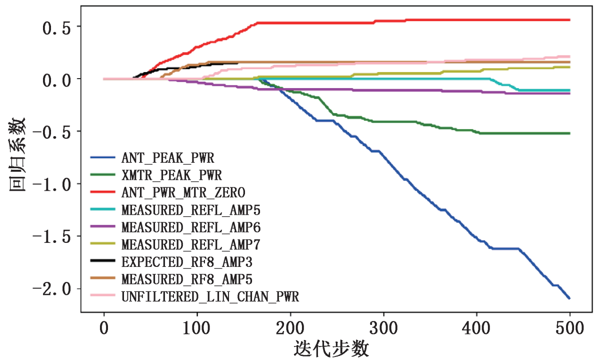

图 3 向前逐步回归法参数筛选结果

（图中参数对应表 1）

2.3 在线监测模型

在本步骤中设计支持向量机回归 SVR 模型对水平通道天线峰值功率的值进行重构以实现发射机的故障监测。以福州雷达站 2017 年 3 月 20 日的一次发射机严重故障为例，该次故障表现为发射机功率偏低。选择 2017 年 3 月 2—18 日的 3840 个正常状态样本作为训练数据。在线监测数据（测试）包含 2017 年 3 月 18—24 日的 1440 个样本，其中包括正常状态和故障状态样本点。训练数据和测试数据在时间上是连续的，每个样本包含特征提取到的 14 个相关参数值和监测时间。

重构模型使用水平通道天线峰值功率的归一化结果作为样本标签，用以消除数据类型不同带来的数据偏差。SVR 模型重构结果如图 4 所示，预测值在 4620 数据点之前基本吻合，在 4620 数据点开始，重构结果与测量值开始产生偏差。

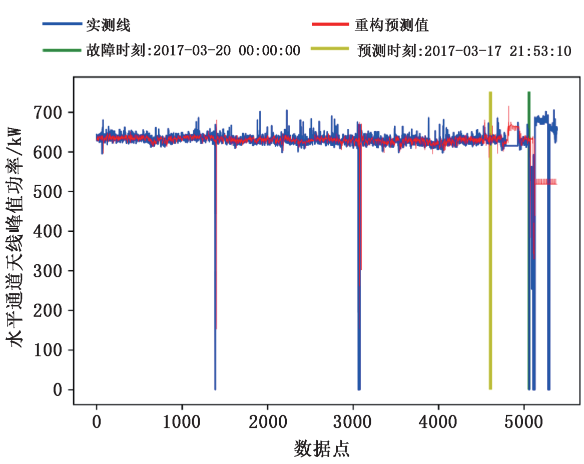

图 4 SVR 重构模型的水平通道天线峰值功率预测结果

2.4 在线监测分析

根据式（2）计算训练数据和测试数据的状态有效值，状态有效值的范围为 0～1 之间的值，1 为正常状态，0 为故障状态。经过计算得到状态有效值后，根据设置的状态有效值阈值 $\mu_p = 0.95$，在时间区间内统计状态有效值小于阈值的点的数量。根据式（3）计算该时间区间的故障点率，故障点率超过设定阈值 R_p 即认为探测到了故障异常，给出预警。

本文取时间区间长度 $n=100$，故障点率阈值 $R_p = 0.3$。故障点率的计算结果如图 5 所示。训练数据集和测试数据集中的正常数据部分计算出的故障点率基本保持在零附近，认为发射机处于正常状态。

数据测试集故障部分中随时间发展其故障点率由 0 上升至 0.80，根据故障点率阈值 $R_p = 0.3$，在第 4620 个监测点发出故障警报。而实际故障记录在 5129 监测点产生，在线监测模型比实际故障记录提前了 509 个监测点发现故障征兆。

监测点之间的时间间隔为 6 min，也就是在线监测模型能够提前 50.9 h 发现发射机的故障异常征兆并给出报警，这使得故障预警得以实现并为发射机维护维修提供了充足时间，从而避免其进一步发生严重事故导致发射机性能丧失至雷达停机。

本案例应用所设计的自适应阈值重构判定算法框架对福州气象雷达站的实际发射机故障进行预测，验证了本文所应用的算法框架在气象雷达故障预警上的有效性。

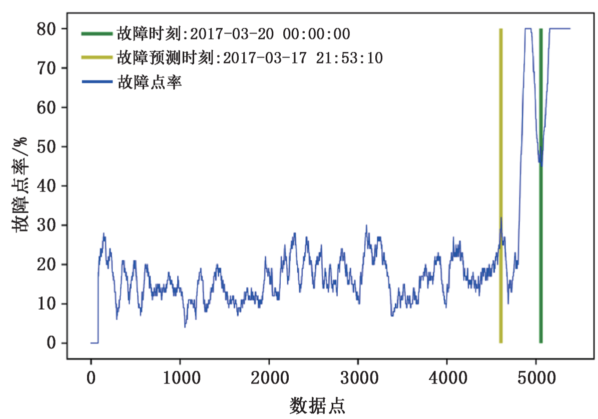

图 5 在线监测模型的故障点率计算结果

2.5 其他雷达发射机故障案例验证

对于本文提出的基于重构模型自适应阈值的

SA 雷达发射机故障检测算法框架，将其应用于多个雷达站的发射机故障案例，验证其算法的有效性和适用性。验证的数据范围包括 2016—2017 年 38 个雷达站的相关数据，发射机相关故障 85 次，能够提前预测或完成当天诊断的共 70 次，未识别出的故障共 15 次，故障识别准确率 82.3%，平均提前预警时间为 10 h 23 min，当前算法故障识别率较高，漏报警情况发生很少，对于当前气象雷达站点的发射机监测有一定的应用性。

图 6 展示了湖州、南京、徐州、长沙、重庆雷达站的成功识别案例和福州雷达站的滞后识别案例。其中福州雷达站该次故障识别结果比真实故障记录滞后，维修前后发射机峰值功率较稳定，但维修后水平通道天线功率调零等参数的波动频率突然上升，且发射机功率调零下降，导致发射机峰值功率预测值的偏离，产生了虚假发射机故障报警信号。

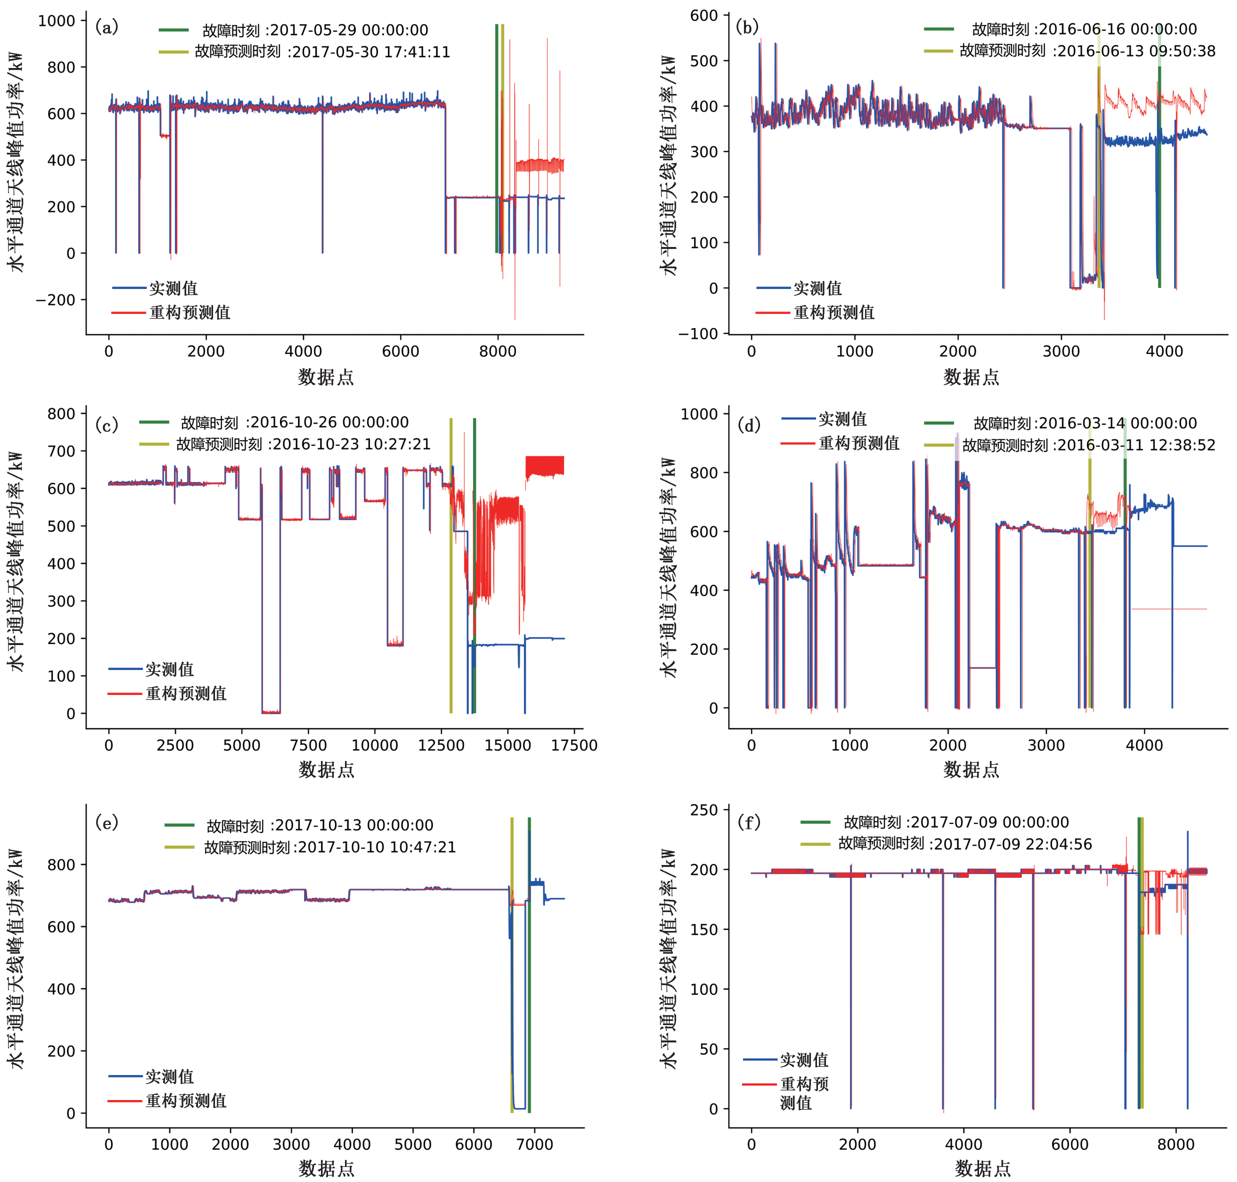

图 6　雷达站发射机故障识别应用案例：(a)福州 2017 年 5 月 29 日，(b)湖州 2016 年 6 月 16 日，(c)南京 2016 年 10 月 26 日，(d)徐州 2016 年 3 月 14 日，(e)长沙 2017 年 10 月 13 日，(f)重庆 2017 年 7 月 9 日

3 结论与讨论

本文提出了一种基于重构模型自适应阈值的SA雷达发射机在线故障诊断算法，通过状态数据监测重构模型的预测值与实际参数值的残差计算运行健康状态，并基于时间序列统计滤除异常参数干扰，实时计算当前雷达运行故障点率。其特点是利用正常状态的数据构建重构模型，模型建立不需要故障数据，从而避免出现数据驱动算法受制于故障样本不足而无法应用的缺陷。实算验证证明该算法能够早于当前雷达系统的故障发生时间给出预警信息，有效实现雷达设备的故障早期预警。

作为复杂机械电子系统的雷达设备因系统复杂、故障样本少、故障类型多等特点而面临智能故障预测诊断技术的应用挑战。本文探索了复杂算法在SA雷达发射机故障预警判定方面的可实现性，并采用实际数据进行了验证。随着数据量的积累和数据质量提升，模型应用的准确性和有效性可进一步提高，为未来SA雷达故障智能预测诊断工程应用提供了一种可行的方法路线。

目前算法框架中参数选取是基于过往10余年积累的状态参数和故障记录通过训练算法选取。受制于数据质量和训练特点，可能出现选取参数相关性弱、特征提取准确度不足等选取不合理情形。采用专家经验、故障树、信号流程等方式对训练获得的参数进行二次筛选，将机理、应用反馈和数据特征进行融合，是下一步提高模型质量和准确度的可行路径。

参考文献

[1] 曾广宇，郭泽勇，杜云东，等. 基于双信号源的双偏振雷达接收机故障诊断技巧[J]. 气象科技，2021，49(1)：139-143.

[2] 杨金红，高玉春，柴秀梅. 新一代天气雷达运行保障能力分析[J]. 气象科技，2014，42(1)：31-37.

[3] 郑元珠，杨德，宋小梅，等. 相控阵雷达基于状态维修技术研究[J]. 现代雷达，2020，42(10)：12-17+21.

[4] 石城，梁海河，孟昭林，等. 新一代天气雷达故障处理和故障标准化平台的研发与应用[J]. 气象科技，2012，40(2)：160-164.

[5] 李冀宁，沈鹿鸣，刘洪林，等. 气象雷达原理及故障维护[J]. 科技创新导报，2019，16(20)：45-46.

[6] 王楠，吴峰峰，丁鹤鸣. CINRAD/SA雷达几个典型机械故障的检修[J]. 气象水文海洋仪器，2015，32(3)：98-100.

[7] 翟玉婷，程占昕，房少军. 智能化雷达故障预测及检测技术综述[J]. 计算机科学，2023，50(5)：217-229.

[8] 杜智涛，姜明波，杜晓勇，等. 机器学习在气象领域的应用现状与展望[J]. 气象科技，2021，49(6)：930-941.

[9] Sun T, Liu B. Health assessment based on DS evidence theory of equipment [J]. International Journal of Advanced Network, Monitoring and Controls, 2020, 5(4): 15-26.

[10] Chen S, Lian K, Wang H. Fault diagnosis method of radar receiver using multi-signal flow graphs model [J]. Journal of University of Electronic Science and Technology of China, 2009, 38(1): 87-91.

[11] Yu J, Wei L H, Leng X M, et al. Research on fault location of distribution network based on Radar principle [C] // IOP Conference Series: Earth and Environmental Science, IOP Publishing, 2020, 431(1): 012013.

[12] 王超，潘佳梁，孙艳. 基于虚拟仪器的雷达电子设备故障诊断系统[J]. 仪器仪表用户，2009，16(4)：24-26.

[13] Yang Z, Baraldi P, Zio E. A comparison between extreme learning machine and artificial neural network for remaining useful life prediction [C] // 2016 Prognostics and System Health Management Conference (PHM-Chengdu), IEEE, 2016: 1-7.

[14] Pan W, Xu J H, Liu S L. Radar fault diagnosis based on adaptive genetic algorithm and neural network [C] // 2011 Chinese Control and Decision Conference (CCDC), IEEE, 2011: 3084-3088.

[15] Wang X W, Li Z H. Fault diagnosis of radar filter based on wavelet transform and neural network [J]. Electronic Design Engineering, 2016, 24(8): 83-85.

[16] Shanableh T, Assaleh K. Feature modeling using polynomial classifiers and stepwise regression [J]. Neurocomputing, 2010, 73(10-12): 1752-1759.

[17] 马溧溧，罗正华，胡德昆. 融合型AR模型在雷达故障预测中的应用[J]. 现代电子技术，2020，43(11)：20-23.

[18] 贾倩茜，杨光，曹阳，等. 一种雷达故障预测模型建模方法研究[J]. 雷达与对抗，2021，41(3)：37-39+42.

[19] 蒋艳艳. BP神经网络在雷达故障诊断中的应用[J]. 通信电源技术，2020，37(6)：119-120.

[20] 吴冬寒. 某型雷达健康状态评估与寿命预测方法研究[D]. 西安：西安电子科技大学，2020.

[21] Kotsiantis S B, Kanellopoulos D, Pintelas P E. Data preprocessing for supervised leaning [J]. International Journal of Computer Science, 2006, 1(2): 111-117.

[22] 李婵，范增禄，韩明稚，等. 地面气象台站元数据质量控制分析[J]. 气象科技，2020，48(3)：342-347.

[23] 刘媛媛，何文春，王妍，等. 气象大数据云平台归档系统设计及实现[J]. 气象科技，2021，49(5)：697-706.

[24] Benkedjouh T, Medjaher K, Zerhouni N, et al. Remaining useful life estimation based on nonlinear feature reduction and support vector regression [J]. Engineering Applications of Artificial Intelligence, 2013, 26(7): 1751-1760.

[25] Ojo S, Sari A, Ojo T P. Path loss modeling: A machine learn-

ing based approach using support vector regression and radial basis function models [J]. Open Journal of Applied Sciences, 2022, 12(6): 990-1010.

[26] 韩同欣,何文春,吴鹏,等.气象基础设施云平台关键设计与实现[J].气象科技,2022,50(2):290-296.

[27] 田辉,王天成,齐涛.基于天气雷达标准输出控制器的雷达远程控制[J].气象水文海洋仪器,2022,39(4):103-106.

[28] 余永城,王笑,魏夏潞.福建气象综合业务平台融入“天擎”技术方案设计及实现[J].气象科技,2022,50(5):653-659.

[29] 杨奇,李传柱.CINRAD/SA-SB 雷达高频放大链前级组件故障诊断系统设计与实施[J].气象科技,2020,48(6):808-815.

[30] 刘洁,陈玉宝,王箫鹏,等.天气雷达移动测试保障平台自动智能化测试设计及实现[J].气象科技,2022,50(4):500-505.

Research on Early Warning of SA Radar Transmitter Fault Based on Reconstruction Method with Adaptive Threshold

ZHOU Wei[1] ZHAO Zhongkai[2] WANG Yimeng[1] SHEN Chao[1] LI Wei[1] WANG Dalin[3] LI Xu[4]

(1 Meteorological Center of China Meteorological Administration, Beijing 100081; 2 Heilongjiang Province Meteorological Data Center, Harbin 150001; 3 Department of Industrial Engineering, Tsinghua University, Beijing 100085; 4 Hechenziyi Jiaxing Tech. Co., Zhejiang, Jiaxing 314500)

Abstract: The fault prediction and diagnosis of the new generation weather radar have always been a technical challenge for radar operation and maintenance. The delayed response to some severe faults will lead to aggravated damage to the corresponding components of the radar. In this paper, based on the combination of artificial intelligence technology and radar data characteristics, a SA radar transmitter system fault warning and determination method based on the adaptive threshold is proposed. An algorithm framework for transmitter fault online monitoring based on a reconstruction model is established. The algorithm framework can identify anomalies and warn early when radar transmitter failures occur. The actual operation records are used for calculation and analysis, verifying the method's effectiveness.

Keywords: CINRAD/SA; transmitter; self-adaptive threshold; data reconstruction model