

文章编号: 2096-1618(2019)03-0257-06

基于天气雷达标准输出控制器的故障诊断方法研究

徐颂捷¹, 何建新¹, 黎志波², 张福贵¹

(1. 成都信息工程大学电子工程学院, 四川 成都 610225; 2. 江西省大气探测技术中心, 江西 南昌 330096)

摘要:根据天气雷达标准输出控制器采集的雷达关键指标数据,提出了一种具有自学习且半监督作用的异常检测与支持向量机(SVM)的联合故障诊断方法,实现天气雷达运行状态评估与故障检测定位。针对采集数据,首先使用异常检测算法建立概率模型,计算样本落入正常范围的概率,实现非正常样本的识别;其次,以所得样本的概率值作为支持向量机模型的新增特征,建立 SVM 分类器,对故障进行诊断。经实验表明与传统的逻辑回归、神经网络的分类方法相比,在小样本且各类别训练数据正负偏离过大的情况下,此方法能够更准确、高效地诊断雷达故障。

关键词:雷达系统;故障诊断;异常检测;支持向量机

中图分类号: TN956

文献标志码: A

doi: 10.16836/j.cnki.jcui.2019.03.009

0 引言

目前中国已基本建成 7 种型号、216 部天气雷达观测网,在临近天气预报、气象防灾减灾中发挥了巨大作用,经济效益显著。然而雷达的各项指标随着科学的进步不断提升,结构上呈现逐渐复杂的趋势,修复普通雷达平均时间为 1.5 h 左右,大量时间浪费在查找故障源上,使雷达的使用效率受到大幅限制^[1]。为提高雷达长期运行稳定性、提高产品数据质量,需建立统一的在线监测方法,由此根据雷达的关键性参数确定雷达的运行状态并完成故障分析与定位。

天气雷达标准输出控制器(WRSOC)主要用于监测天气雷达关键技术参数,同时具备对雷达运行环境参数、附属设备运行状态参数及适配参数变更痕迹等信息采集、在线监测、统计分析和传输等功能。此监测平台虽能监控运行状态,但雷达系统故障呈现出传播性、相关性和不确定性新特点,传统的依靠人工推理、树形诊断模式及专家系统的诊断方法存在一定局限性,同时难以更新知识库、保持高效的学习能力和泛化能力。

近年来,各种智能诊断技术蓬勃发展,为装备的故障诊断开辟了一条新的途径,将智能诊断技术应用于现代雷达装备故障诊断,成为当前雷达装备维修保障研究的重点和热点问题^[2]。文献[3]将支持向量机(SVM)引入雷达故障预诊断,首先对数据预处理,然后构建训练集样本,最后利用训练的 SVM 进行预测,

实现了雷达进入潜伏性故障时就提前诊断;文献[4]对比孤立森林、Robust Covariance、One-Class SVM、局部异常因子 4 种异常检测算法,同时结合大量的数据统计分析得到的过滤规则,实现电机故障预测;文献[5]建立了基于神经网络的雷达故障诊断系统,使用三层 BP 模型,以某型雷达接收机中放板为例来验证结果。这些方法具有模型较为简单且诊断精度有较大幅度提高的优点,但多针对单一或局部故障,未能有效应用在天气雷达整机系统中。

在采用基于天气雷达标准输出控制器的状态监测数据的前提下,融合两种机器学习技术,采用支持向量机浅层分类模型完成具体的故障诊断,通过异常检测方法不断加强异常数据的识别能力,在提高故障诊断可靠性和精确度的同时尽可能实现故障预警,帮助雷达技术人员更高效完成维护维修工作。

1 异常检测

异常检测算法能够检测不符合期望的数据、行为,在故障检测、欺诈检测、入侵检测领域有着广泛应用。通过训练,算法建立起的概率模型能够判断样本落入正常范围的概率,从而具备识别非正常情况的能力。异常检测的核心在于确定一个概率模型,计算出一个样本落入正常样本中的概率,由阈值 ϵ 区分正常和异常样本或大概率运行状态不佳的样本,以便后续重点关注。高斯分布模型就是异常检测算法最常使用的概率分布模型。

得到训练集 $m \times n$ 的二维数组, m 为样本个数, n 为特征个数,首先选择一些足够反映异常样本特征的

数据集 x , 对其各个特征进行参数估计。(若某特征不服从高斯分布则对此特征进行函数组合运算使其符合高斯分布, 如取对数 $x' = \log x$, 平方根变换 $x' = \sqrt{x}$, 倒数变换 $x' = 1/x$)

高斯分布模型第 j 个特征的参数 μ 和参数 δ 的极大似然估计表达式为

$$\mu_j = \frac{1}{m} \sum_{i=1}^m x_j^{(i)}, \delta_j^2 = \frac{1}{m} \sum_{i=1}^m (x_j^{(i)} - \mu_j)^2 \quad (1)$$

x_j 为数据集 x 中每个样本的第 j 个特征值, 参数 μ 和参数 δ 是高斯分布函数的两个重要参数, 刻画函数形状。

概率模型函数由样本的每个特征的高斯函数相乘而来:

$$p(x) = \prod_{j=1}^n p(x_j; \mu_j, \delta_j^2) = \prod_{j=1}^n \frac{2}{\sqrt{2\pi}\delta_j} \exp\left(-\frac{(x_j - \mu_j)^2}{2\delta_j^2}\right) \quad (2)$$

参数 μ 和参数 δ 由公式(1)得出, x_j 为数据集中 x 每个样本数据的第 j 个特征值。

确定阈值 ϵ , 若样本 x 的概率模型值 $p(x) < \epsilon$, 则认为样本 x 是异常样本, 由于异常样本数量差异大, 整个数据集非常偏斜, 不能单纯用预测准确率来评估算法优劣, 因而考虑用加权调和平均数 F_1 、查准率 prec 与召回率 rec 来评估, 选择使 F_1 值最大的即为最佳阈值, 计算公式为

$$F_1 = \frac{2 \cdot \text{prec} \cdot \text{rec}}{\text{prec} + \text{rec}}, \text{prec} = \frac{\text{tp}}{\text{tp} + \text{fp}}, \text{rec} = \frac{\text{tp}}{\text{tp} + \text{fn}} \quad (3)$$

tp 即真阳性是真实标签为异常且被算法诊断为异常的样本数, fp 即假阳性是真实标签为正常但被算法诊断为异常的样本数, fn 即假阴性是真实标签为异常但被算法诊断为正常的样本数。

2 支持向量机

支持向量机是监督学习中最有影响力的方法之一, 在对非线性、小样本、高维数的问题解决上有较大优势, 是一种二分类模型, 对于多分类问题则需要训练多个分类器。得到训练集 $m \times n$ 的已标注数组, m 为样本个数, n 为特征个数。

2.1 最大间隔分类器

支持向量机以逻辑回归为基础, 对假设函数进行改进, 支持向量机假设函数在预测时是以 $z = \theta^T x$ 与 0 的大小关系作为依据的, 然而在训练函数时, 是以 ± 1 为依据的, 这是支持向量机与逻辑回归的一个关键区别, 且导致了支持向量机的最大间隔分类特性。

假设函数为

$$h_{\theta}(x) = \begin{cases} 1, \theta^T x \geq 0 \\ 0, \theta^T x < 0 \end{cases} \quad (4)$$

矩阵 θ 为支持向量机模型参数矩阵, x 为样本数据。

误差函数

$$J = C \sum_{i=1}^m [y^{(i)} \text{cost}_1(\theta^T x^{(i)}) + (1 - y^{(i)}) \text{cost}_0(\theta^T x^{(i)})] + \frac{1}{2} \sum_{j=1}^n \theta_j^2 \quad (5)$$

其中 $y^{(i)}$ 为第 i 个样本的实际标签, $y=1$ 为正常样本, $y=0$ 为故障样本, x^i 为第 i 个样本的特征数据, C 为误差函数的惩罚因子, 矩阵 θ 为支持向量机预测模型参数, $\text{cost}_1(z)$ 与 $\text{cost}_0(z)$ 为实际标签为 1 与 0 的成本函数。

最终希望误差代价最小, 假设选择的 C (惩罚因子) 是个极大的值, 则在代价函数最小化的过程中, 期望找出在 $y=1$ 正常和 $y=0$ 异常两种情况下都使得代价函数中左边的这项尽量为零的参数。若找到此参数, 则最小化问题便转变成如下问题: 若 $y^{(i)} = 1, \theta^T x^{(i)} > 1$, 则误差函数(式 5) 仅需要计算 $\min \frac{1}{2} \sum_{j=1}^n \theta_j^2$ 即可, 现引入向量 $p^{(i)} \cdot \|\theta\|$, 即为 $\theta^T x$ 的向量表示形式, p 为 x 在 θ 上的投影, 由于算法要求 θ 越小则 J 越小, 同时 $\theta^T x > 1$, 即 $p^{(i)} \cdot \|\theta\| > 1$, 则 p 越大越好, 使得判定边界与样本数据之间间隔最大; 同理 $y^{(i)} = 0$ 时, $\theta^T x < -1, p$ 越大, 间隔越大。

最后计算梯度, J 对 θ 求导, 计算使误差函数 J 最小的 θ , 即得到预测模型 $h_{\theta}(X)$ 。

2.2 核函数

SVM 使用核技巧有效地进行非线性分类, 将其输入隐式映射到高维特征空间中, 使得在新的空间里样本线性可分, 进而可用线性样本的分类理论解决此类问题。核函数(此处为高斯核函数, RBF)的目标是根据训练集和地标 l 之间的距离来构建新特征代替旧特征, 这些核函数需要满足 Mercer's 定理, f_1 即为 x 与第一个地标 $l^{(1)}$ 之间的相似度函数, 即核函数

$$f_1 = \text{similarity}(x, l^{(1)}) = e^{\left(-\frac{\|x - l^{(1)}\|^2}{2\sigma^2}\right)} \quad (6)$$

其中: $\|x - l^{(1)}\|^2 = \sum_{j=1}^n (x_j - l_j^{(1)})^2, \sigma > 0$, 为实例 x 中所有特征与地标 $l^{(1)}$ 之间的距离的和, 在预测时, 采用的特征不是训练实例本身的特征, 而是通过核函数计算出的新特征 f_1, f_2, f_3 由此转化为高纬度的计算。若一个训练实例 x 与地标 l 之间的距离近似于 0, 则新特征 f 近似于 e^0 约为 1, 若训练实例 x 与地标 l 之间距离很远, 则 f 近似于 $e^{-\infty}$ 约为 0。

3 模型实现

构建一个基于异常检测与支持向量机的联合天气雷达故障诊断模型,其系统流程如图1所示。在该模型中,首先通过对数据进行异常检测算法的诊断,计算其正态分布的估计参数,计算其样本概率值与阈值,对雷达运行状态评估同时判断是否有从未出现过的故障情况,然后再以所得样本的概率值作为支持向量机模型的新增特征,使用高斯核函数建模,采用梯度下降法训练模型求得训练参数最优值,再对模型进行交叉验证。

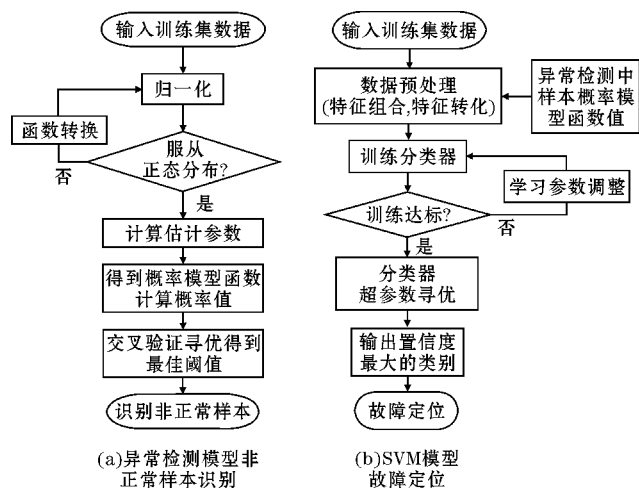


图1 联合算法模型诊断流程图

3.1 异常检测模型实现

由于异常检测的特殊性,仅作为判断样本是否正常的识别算法,不具有多分类功能,其数据标签仅有雷达运行正常、雷达发生故障两种情况。模型实现过程主要分为数据预处理与训练过程。训练过程主要通过训练集样本特征的估计参数值建立高斯概率模型并确定最优阈值,具体步骤如下:

步骤1 对雷达样本数据预处理:将数据归一化,使样本特征 α 缩放至 $[0,1]$,这里使用线性变换方法,令 $a' = (a - a_{\min}) / (a_{\max} - a_{\min})$ 。

步骤2 使训练集样本数据特征服从正态分布。若某个特征不服从正态分布,则对此特征进行对数转换,取 $x' = \log x$ 。

步骤3 计算训练集样本每个特征的高斯模型极大似然估计参数 μ 和参数 δ ,利用高斯模型得到每个样本 $x^{(i)}$ 的概率模型函数值 $p(x^{(i)})$ 。

步骤4 使用加权调和平均数 F_1 通过交叉验证集,寻找使 F_1 值最大的最优阈值 ϵ 。

此时异常检测模型建立,雷达某样本数据 $x^{(i)}$ 的概率模型函数值 $p(x^{(i)})$ 小于阈值 ϵ ,即被诊断为异常样本。

3.2 支持向量机分类器模型实现

支持向量机算法是一种二分类模型,对于多分类问题,基于二分类模型的实现基础,若多分类共有 k 类,则令第 i 个 $(1 \leq i \leq k)$ 二分类器将第 i 个分类类别作为正类,其余皆作反类,每个二分类器的实现过程与以下方法相似,最后取 k 个分类器中输出置信度最大的类别即可。其模型实现具体步骤如下:

步骤1 数据预处理:加入异常检测步骤3中得到的样本概率模型函数值 $p(x^{(i)})$ 为额外特征,对样本数据归一化处理。

步骤2 生成多项式特征:常用于核方法中,通过输入 $m \times n$ 的训练集样本数据的非线性特征组合来增加模型的复杂度,得到特征的高阶和相互作用项,得到 s 个特征且 $s > n$ 。

步骤3 使用高斯核函数对训练集数据特征进行转化,进行特征低维到高维的映射:首先,根据训练集 $m \times s$ 的样本数量选择地标的数量,令: $l^{(1)} = x^{(1)}, l^{(2)} = x^{(2)}, \dots, l^{(m)} = x^{(m)}$,如式(6)计算核函数新特征 f_i 。

步骤4 训练模型:通过使用带标签的新特征训练集样本计算误差函数 J ,然后对 θ 求导,自适应调整学习参数得到使误差函数最小的 θ 值。

$$J = C \sum_{i=1}^m [y^{(i)} \text{cost}_1(\theta)^T f^{(i)}] + (1 - y^{(i)}) \text{cost}_0(\theta^T f^{(i)})] + \frac{1}{2} \sum_{i=1}^m \theta_i^2 \quad (7)$$

步骤5 超参数寻优:使用交叉验证集从多个超参数模型中寻优得到使交叉验证误差最小的惩罚因子 C 值与高斯核函数参数 σ 值。

步骤6 得到二分类支持向量机模型预测函数 $h_\theta(x)$,预测时默认取雷达样本预测函数 $h_\theta(x)$ 中 $\theta^T x \geq 0$ 的即为正类,反之则为负类。

4 仿真与验证

基于天气雷达标准输出控制器监控平台,现采用文中提出的异常检测与支持向量机联合诊断模型对天气雷达整机进行故障诊断仿真来验证本方法的高效性。实验数据来源于2018年9-12月江西省吉安市气象局雷达站天气雷达标准输出控制器,此监测平台能够记录天线伺服系统、发射机系统、接收机系统与系统各标定参数4个部分共66项雷达状态参数,每5 min记录1次,并且实时生成故障报警信息。假设传感器不存在虚警和漏警(理想传感器状态),通过对十余条采集数据根据其报警信息与特征分析,选取3个未知其特征相关特性及与7个故障类别因果关系的前提下,对14422组样本数据进行分析、整理(具体故障分

类见表 1),3 个特征分别为雷达发射机峰值功率 F_1 、系统标定常数变化 F_2 与水平噪声系数 F_3 ,采集的故障样本数据样例及数量分布见表 2、表 3。数据的分类展示图如图 2 所示。

表 1 天气雷达故障数据标签分类表

故障标签	故障具体情况	告警级别	分系统
E1	方位电流故障	严重	天线
E2	线性通道射频激励测试信号变坏	严重	整机
E3	反峰电流故障	严重	发射机
E4	脉冲宽度异常	严重	发射机
E5	水平通道噪声系数超出阈值范围	一般	接收机
E6	俯仰电流故障	一般	天线
E7	线性通道速调管输出测试信号变坏	严重	整机

表 3 样本数量分布情况

分类	正常	E1	E2	E3	E4	E5	E6	E7	总类别
建模用样本个数	2350	3475	996	69	3014	270	1022	19	11215
测试用样本个数	895	999	242	18	759	78	208	8	3207
样本总个数	3245	4474	1238	87	3773	348	1230	27	14422




图 2 雷达原始故障数据的分类展示图

上述模型实现过程:首先使用训练集与交叉验证集数据,通过异常检测作为诊断天气雷达运行状态的半监督算法对各个特征参数偏离正常情况的程度有较为准确的评估,能够排除未曾遇到或与正常情况偏离较大的天气雷达异常情况;然后,以所得样本的概率值作为支持向量机模型的新增特征,分别训练 8 个支持向量机分类器,最终选择 8 个分类器中的置信度最大的作为故障诊断的类别。完成天气雷达故障诊断模型的建立与训练,得到训练准确率 76.8 (训练准确率=训练正确样本个数/训练样本总数),各类别训练结果如图 3(a)所示。

使测试集雷达故障数据通过训练好的模型诊断得出分类结果,与实际标签对比,验证算法效果。异常检测诊断结果如图 4 所示,基本能够识别偏离正常情况的样本,最终故障诊断验证结果混淆矩阵如图 3(b)所示。

表 2 天气雷达标准输出控制器故障样例

样本编号	F_1/kW	F_2/dB	F_3/dB
1	682.3	0	2.4
2	687	0.01	2.54
3	671.39	-0.07	2.47
4	674.19	-0.08	2.44
5	648.6	-0.02	2.45
6	682.3	0	2.47
7	687	0.03	2.4
8	653.1	0.04	2.37
9	685	0	2.44
10	682.3	-0.02	2.47

真实标签	E1	E2	E3	E4	E5	E6	E7	正常
E1	2657.0	37.0	0.0	685.0	0.0	10.0	0.0	86.0
E2	34.0	841.0	3.0	1.0	2.0	19.0	0.0	96.0
E3	0.0	0.0	69.0	0.0	0.0	0.0	0.0	0.0
E4	325.0	0.0	0.0	2689.0	0.0	0.0	0.0	0.0
E5	7.0	1.0	0.0	0.0	43.0	209.0	0.0	10.0
E6	163.0	25.0	0.0	3.0	25.0	726.0	0.0	80.0
E7	0.0	0.0	1.0	0.0	0.0	0.0	18.0	0.0
正常	409.0	290.0	0.0	0.0	2.0	79.0	0.0	1570.0
模型预测类别	E1	E2	E3	E4	E5	E6	E7	正常

(a) 训练结果混淆矩阵图

真实标签	E1	E2	E3	E4	E5	E6	E7	正常
E1	84.0	823.0	0.0	0.0	0.0	5.0	0.0	87.0
E2	6.0	185.0	0.0	0.0	0.0	1.0	0.0	50.0
E3	0.0	0.0	18.0	0.0	0.0	0.0	0.0	0.0
E4	81.0	0.0	0.0	678.0	0.0	0.0	0.0	0.0
E5	9.0	3.0	0.0	0.0	41.0	23.0	0.0	2.0
E6	0.0	13.0	0.0	0.0	1.0	165.0	0.0	29.0
E7	0.0	2.0	2.0	0.0	1.0	2.0	1.0	0.0
正常	0.0	115.0	0.0	0.0	17.0	2.0	0.0	761.0
模型预测类别	E1	E2	E3	E4	E5	E6	E7	正常

(b) 测试集数据验证结果混淆矩阵图

图 3 真实标签分类与预测结果分类数量的混淆矩阵图

示。由混淆矩阵呈现本算法性能的可视化效果,其每 1 列代表雷达故障诊断模型对于样本的故障类别预测,每 1 行代表版本所属的雷达故障真实类别,所有正

确的预测结果都在其正对角线上,高值是渐黑色的,低值是渐白的。雷达不同分系统的故障类别与分布情况均不相同,且故障类别之间有较大的数据量差异,分析数据得知,故障 E1、E2、E4 与正常样本数据相互之间有较多重叠,难以区分,训练准确率未达理想,诊断结果易出现偏差。




图 4 测试集数据异常检测模型诊断结果图

通过测试集数据将本文的 SVM 分类器模型与逻辑回归、神经网络模型进行验证对比,同样使用异常检测的样本概率值作为新特征进行故障分类,如表 4 所示。SVM 作为分类算法,使诊断准确率(诊断/测试准确率=诊断正确样本个数/测试集样本总数)有较大提高。高斯径向基核函数对数据中存在的噪声有着较好的抗干扰能力,由于其很强的局部性,其参数决定了函数作用范围,随着参数 σ 的增大而减弱,使高维中每个特征都能达到较好的区分度,解决样本数据线性不可分的情况。

表 4 3 种诊断方法验证结果比较

算法名称	测试准确率/%
逻辑回归	54.05
神经网络	53.04
SVM	60.27

5 结束语

天气雷达故障诊断技术是雷达运行状态、维护、维修的重要保障,故障诊断能力会直接影响雷达系统的运行效率。为了保证雷达故障诊断的高效性,本文基于天气雷达标准输出控制器提供的数据,对天气雷达故障诊断方法进行研究。构建了一种联合异常检测与支持向量机的天气雷达故障诊断模型,通过对雷达发射机峰值功率、系统标定常数变化与水平噪声系数 3 个特征样本数据的分析、处理,实现雷达运行状态的监控与故障定位。

通过上述的研究工作,得到结论相较于逻辑回归、

神经网络,该方法能够在数据严重不平衡的情况下达到较高的分类准确度,使综合天气雷达故障诊断率达到60.27%,而在故障线性通道射频激励测试信号变坏、俯仰电流故障(E2、E6)中,通过 3 个特征的样本数据输入,引入模型进行故障诊断,分别得到76.45%和79.33%的诊断率,证明该方法的可行性与高效性。

天气雷达故障诊断中难以获取大量标记精确的故障样本,江西省吉安市天气雷达标准输出控制器不能较好地反映雷达故障情况,出现了故障警报混叠的情况,同时由于数据采集周期过长、雷达运行状态不稳定等各种非控制因素,使诊断结果未达到预期,但通过对比试验仍能验证本算法的优越性,具有一定指导意义。

参考文献:

[1] 冯乾. 分析雷达故障检测与诊断技术及新发展[J]. 电子元器件与信息技术,2018,2(8):18-20.

[2] 王晗中,杨江平,张爱元. 现代雷达装备综合智能故障诊断系统设计[J]. 现代雷达,2008,30(11):22-25.

[3] 王玉松. 基于 SVM 的雷达故障预诊断技术研究[J]. 舰船电子工程,2011,31(8):149-151.

[4] 顾佳,安帅,张杜玮. 基于异常检测算法的动车组牵引电机故障预测[J]. 设备管理与维修,2018,422(8):184-185.

[5] 尚朝轩,韩壮志,胡文华. 基于状态监测与信息融合的雷达装备故障趋势预测[J]. 火力与指挥控制,2011,36(2):152-155.

[6] 庄夏. 一种基于增强学习神经网络的雷达故障诊断方法[J]. 现代雷达,2017(12):15-19.

[7] 陈世杰,连可,王厚军. 采用多信号流图模型的雷达接收机故障诊断方法[J]. 电子科技大学学报,2009,38(1):87-91.

[8] Chen Y W, Lin C J. Combining SVMs with Various Feature Selection Strategies[J]. Feature Extraction,2006,207.

[9] Liao W, Rosenhahn B, Yang M Y. Gaussian Process for Activity Modeling and Anomaly Detection[J]. ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Informa,2015,II-3/W5:467-474.

[10] Chandola V, Banerjee A, Kumar V. Anomaly Detection: A Survey[J]. ACM Computing Surveys, 2009,41(3).

[11] 李鹏. 测量雷达智能诊断技术研究[D]. 沈阳: 东北大学,2009.

[12] 王杰,何建新.故障树分析法在新一代天气雷达故障诊断中的应用[J].南京信息工程大学学报(自然科学版),2013,5(2):147-153.

[13] 曾涛,刘伟,龚熙.省级气象装备保障一体化系统设计[J].成都信息工程大学学报,2018,33(5):544-547.

[14] 刘昉,丁明星,张先俊,等.新一代天气雷达方位旋转关节电弧引起无源限幅器故障分析[J].成都信息工程大学学报,2017,32(2):141-146.

Research on Fault Diagnosis Method based on
Weather Radar Standard Output Controller

XU Songjie¹, HE Jianxin¹, LI Zhibo², ZHANG Fugui¹

(1. Electronic Engineering College, Chengdu University of Information Technology, Chengdu 610225, China; 2. Technical Center for Atmospheric Sounding of Jiangxi Province, Nanchang 330096, China)

Abstract:Based on the Weather Radar data Standard Output Controller(WRSOC), acombination fault detection algorithm is proposed in this paper ,which is anomaly detection and support vector machine (SVM) with self-learning and semi-supervisory function, andit realizes the operation state evaluation and fault detection of weather radar. Firstly, building probability model with anomaly detection algorithm, calculate the probability of samples falling into the normal range, and realize the recognition of abnormal samples. Secondly, using the probability value of samples as the new feature of support vector machine model, the SVM classifier model is established to diagnose faults. Experiments show that this method can diagnose radar faults more accurately and efficiently than traditional logistic regression and neural network in the case of small samples and large deviation of training data.

Keywords:radar system; fault diagnosis; anomaly detection; support vector machine