

基于 GAN 的异构无线网络故障检测与诊断算法

朱晓荣, 张佩佩

(南京邮电大学江苏省无线通信重点实验室, 江苏 南京 210003)

摘要: 针对异构无线网络故障检测与诊断过程中, 如何基于小数据量样本进行准确的故障检测与诊断模型的训练的问题, 提出了基于生成对抗网络的异构无线网络故障检测与诊断算法。首先, 分析了异构无线网络环境下的常见网络故障来源, 通过 GAN 算法, 在小数据量的网络故障样本的基础上, 得到大量可靠数据集。然后, 基于这些数据, 利用极端梯度提升算法选择故障检测阶段输入参数的最优特征组合, 并完成故障检测与诊断。仿真结果表明, 所提算法可以实现对异构无线网络更加准确而高效的故障检测与诊断, 准确率可达 98.18%。

关键词: 异构无线网络; 生成对抗网络; 极端梯度提升; 故障检测; 故障诊断

中图分类号: TN915.81

文献标识码: A

doi: 10.11959/j.issn.1000-436x.2020165

Fault detection and diagnosis method for heterogeneous wireless network based on GAN

ZHU Xiaorong, ZHANG Peipei

Jiangsu Key Laboratory of Wireless Communications, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract: Aiming at the problem that in the process of network fault detection and diagnosis, how to train the precise fault diagnosis and detection model based on small data volume, a fault diagnosis and detection algorithm based on generative adversarial networks (GAN) for heterogeneous wireless networks was proposed. Firstly, the common network fault sources in heterogeneous wireless network environment was analyzed, and a large number of reliable data sets was obtained based on a small amount of network fault samples through GAN algorithm. Then, the extreme gradient boosting (XGBoost) algorithm was used to select the optimal feature combination of input parameters in the fault detection stage and completed fault diagnosis and detection based on these data. Simulation results show that the algorithm can achieve more accurate and efficient fault detection and diagnosis for heterogeneous wireless networks, with an accuracy of 98.18%.

Key words: heterogeneous wireless network, GAN, XGBoost, fault detection, fault diagnosis

1 引言

未来移动网络的发展不再是某一技术或某一网络的单一存在, 而是各种无线接入技术的共存、互补和共同发展, 从而更好地满足用户的需求。在这种网络异构化、密集化的发展趋势下, 如何对网

络故障进行高效的诊断和预测成为一个巨大挑战^[1], 很多学者对这一方面进行了研究。

Szilagy 等^[2]提出了一个完整的故障诊断框架, 故障检测过程主要是监视无线电测量数据, 并与配置文件捕获的正常行为进行比较。该框架对根本原因的诊断依赖于先前记录的故障案例, 并了解其对

收稿日期: 2020-01-14; 修回日期: 2020-04-13

基金项目: 国家自然科学基金资助项目 (No.61871237); 江苏省高校“青蓝工程”和江苏省重点研发计划基金资助项目 (No.BE2019017)

Foundation Items: The National Natural Science Foundation of China (No.61871237), Program to Cultivate Middle-aged and Young Science Leaders of Universities of Jiangsu Province and Key Research and Development Plan of Jiangsu Province (No.BE2019017)

关键性能指标 (KPI, key performance indicator) 的影响, 考虑了信道质量、通话中断和切换时间提前 3 个 KPI。在监督学习的背景下, 文献[3-5]考虑贝叶斯分类, 建立了 GSM (global system for mobile communication) 和 UMTS (universal mobile telecommunication system) 网络故障和根本原因之间的关系。Barco 等^[3]通过对故障诊断的关键性能指标的连续分析, 确定在故障历史数据和故障根源充足的情况下, 采用连续的 KPI 进行故障诊断是有益的。事实上, 只有当训练数据集足够大时, 才可以获得更好的性能。Khanfer 等^[4]和 Barco 等^[5]使用离散的 KPI, 文献[4]综合使用了模拟数据和实际数据进行验证, 但错误小区的识别仅依赖于一个 KPI, 即掉话率; 文献[5]侧重于数据驱动模型参数学习, 避免了典型的依赖专家意见的贝叶斯方法。Khatib 等^[6]提出了一种基于监督遗传模糊算法的诊断方法, 基于一个模拟数据集和一个包含 72 条记录的真实数据集, 故障诊断过程中考虑了 4 个 KPI 和 4 个故障原因, 利用遗传算法学习模糊规则库, 其准确率依赖于标记训练集。

目前, 很多专家对 5G 异构无线网络中网络故障的诊断和预测进行了研究。网络切片技术被认为是电信运营商即将采用的 5G 中的一项关键技术, 大多数网络切片方法都遵循下一代移动网络 (NGMN, next generation mobile network)^[7]所描述的概念, ETSI (European telecommunications standard institute) 网络功能虚拟化 (NFV, network function virtualization) 框架^[8]是网络切片的关键推动者。Kukliński 等^[9]针对与网络切片技术相关的 KPI 仍然没有定义的问题, 定义了 5G 网络切片的 KPI, 为后续的 5G 网络的研究提供了参考。Mfula 等^[10]针对 5G 复杂的网络环境, 提出了一种自适应根源分析 (ARCA, adaptive root cause analysis) 自动故障检测和诊断解决方案, 该方案使用测量数据和其他网络数据, 并结合贝叶斯网络理论进行自适应根源分析, 只需要更少人力或不需要人工操作, 并通过自适应学习期间的知识来提高效率。

由上述对网络故障诊断方法的研究可知, 传统的网络故障诊断方法需要大量的人工标注的训练数据集, 十分耗时耗力。另外, 上述文献仅考虑了几类故障, 并且故障识别过程仅依赖少量 KPI 指标, 但在复杂的异构无线网络环境下, 一方面, 网络故障更加多样化, 网络故障的识别也会依赖更多的

KPI; 另一方面, 需要考虑在这种复杂的网络环境下, 如何获得大量可靠的数据集, 该数据集可通过监督学习获得故障诊断策略。目前常见做法是从已令人满意地解决的且已知故障的已存储案例 (即标记案例) 中提取信息。然而, 由于专家不倾向于收集 KPI 和与它们解决的故障相关的标签, 所以可用的历史记录很少。特别是, 实际网络中没有太多的故障, 对于每个特定的故障, 没有很多标记的案例。因此, 从真实网络获得的历史数据不够丰富, 利用监督技术来构建诊断系统所达到的效果并不理想。而利用生成对抗网络 (GAN, generative adversarial network) 的思想可以解决历史数据不丰富的问题。

近几年来, GAN 作为实现人工智能的典型方法, 在计算机视觉、图像识别和自然语言处理领域取得了广泛的成功, 在处理复杂问题方面表现出很好的能力。GAN 包括 2 个独立的深层网络^[11], 即生成器和判别器。生成器接收一个服从 p_g 分布的随机变量, 用来捕捉数据的分布。判别器分别输出 1 和 0 来区分真实样本和生成的样本。GAN 在训练过程中, 利用生成器和判别器分别对样本进行生成和分类, 对抗性地提高样本的性能。文献[11]利用 GAN 方法对 *minist* 手写数据集进行识别, 实验结果证明了 GAN 方法的潜力。但文献[11]在实际训练过程中还存在一些问题, 如训练困难、生成样本缺乏多样性等。文献[12-13]针对文献[11]存在的问题, 提出了 WGAN (Wasserstein GAN), 仿真结果表明, 其能够解决 GAN 训练不稳定的问题, 而且确保了生成样本的多样性。Arjovsky 等^[12]从理论上解释了 GAN 训练不稳定的原因。文献[13]引入 Wasserstein 距离代替 JS (Jensen-Shannon) 散度和 KL (Kullback-Leibler) 散度, 并将其作为优化目标。与原始 GAN 中的 KL 散度与 JS 散度相比, WGAN 解决了原始 GAN 存在的梯度消失问题。

本文创新性地提出了将 GAN 思想应用到网络故障诊断与预测领域中, 将 GAN 思想与典型的网络故障诊断方法结合。利用 GAN 思想, 基于少量带有标签的数据集, 获得了大量可靠的带有标签的数据集用于网络故障诊断模型的训练, 这样做不仅大大节省了人工标注训练数据的时间, 而且提高了故障诊断模型的精度。仿真结果表明, 所提方法能够达到准确和高效的网络故障诊断与预测效果。

2 系统模型

本文考虑图 1 所示的宏小区、微小区和毫微微小区交叉重叠覆盖的 4G 异构无线网络场景。在这种场景下，由于网络的多样性，系统更加复杂，网络管理也更加困难。本文考虑此场景下的网络故障诊断与预测，首先分析衡量网络性能的 KPI 以及常见的网络故障，并对其进行简单的关联，这部分是构建网络故障诊断模型的前期工作。

2.1 关键性能指标

本文所选 KPI 涵盖了 4G 异构网络的主要方面，与移动网络中的主要类别相关联，主要如下：质量指标，如参考信号接收功率、参考信号接收质量、分组丢失率；接入性指标，如无线资源控制连接建立成功率、演进的无线接入承载建立成功率；保持性指标，如掉话率；移动性指标，如切换成功率、切换时延；业务量指标，如平均吞吐量。本文所选 KPI 具体如表 1 所示。

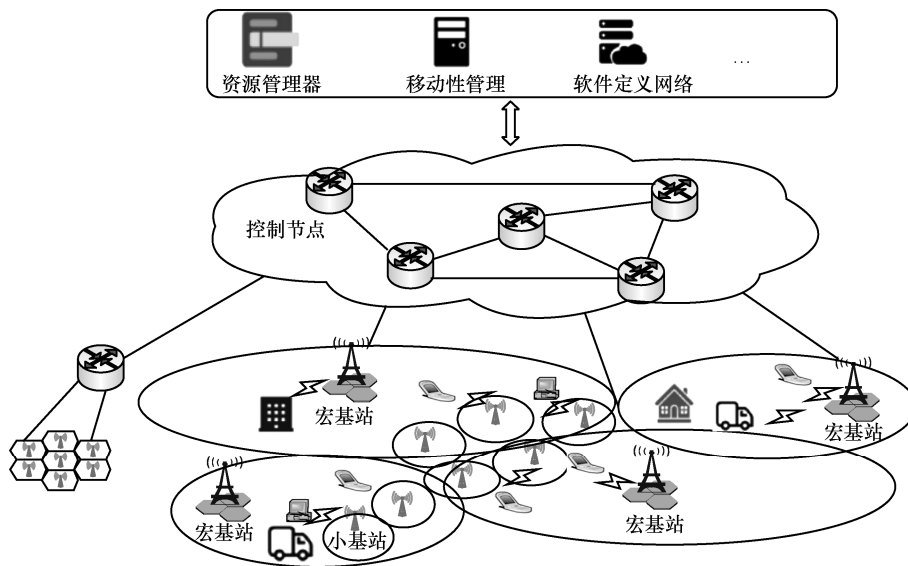


图 1 4G 异构无线网络场景

表 1

本文所选 KPI

KPI	简称
参考信号接收功率	RSRP (reference signal receiving power)
参考信号接收质量	RSRQ (reference signal receiving quality)
上行链路分组丢失率	PD_UL (packet drop_up link)
下行链路分组丢失率	PD_DL (packet drop_down link)
上行链路信噪比	SNR_UL (sigal noise ratio_up link)
下行链路信噪比	SNR_DL (sigal noise ratio_down link)
无线资源控制连接建立成功率	RRC (radio resource control)
演进无线接入承载建立成功率	E-RAB (evolved radio access bearer)
掉话率	DCR (dropped call rate)
切换成功率	HO (handover success rate)
上行平均吞吐量	Throughput_UL (throughput_up link)
下行平均吞吐量	Throughput_DL (throughput_down link)
节点传出平均吞吐量	LT(out) (link throughput(out))
节点传入平均吞吐量	LT(in) (link throughput(in))
切换时延	HO_d (handoff delay)
链路误码率	LER (link bit error rate)

1) 参考信号接收功率, 描述下行链路中接收的导频信号的强度。其定义为在考虑的带宽内承载来自服务小区的小区特定参考信号的资源元素上的平均下行链路接收功率。

2) 参考信号接收质量, 描述下行链路中接收的导频信号的质量, 以 dB 为单位。其定义为 RSRP 与载波带宽加上热噪声时所有基站的宽带接收信号之间的比例。

3) 分组丢失率, 指丢失分组的数量与发送的分组总数的比例。这个度量对于确定网络的状态非常重要。本文分别考虑上行链路分组丢失率 (PD_UL) 和下行链路分组丢失率 (PD_DL)。

4) 信噪比, 是衡量网络性能好坏的重要指标, 信噪比越高, 信号中杂波越少, 网络性能越好; 反之, 网络性能越差。本文分别考虑上行链路的信噪比 (SNR_UL) 和下行链路的信噪比 (SNR_DL)。

5) 无线资源控制连接建立成功率, RRC 连接建立成功次数与 RRC 连接建立尝试次数的比值。只有当 RRC 连接建立成功, 才可以进行通信业务, 若连接建立失败, 则用户与网络不能建立正常连接, 网络业务中断。

6) 演进无线接入承载建立成功率, 指 E-RAB 连接建立成功次数与 E-RAB 连接建立尝试次数的比值。如果连接建立失败, 则用户与网络不能正常连接, 影响网络服务的质量。

7) 掉话率, 是衡量网络性能的重要指标, 也称通话中断率, 是指移动通信过程中通信意外中断的概率。小区存在弱覆盖区域或者网络间存在干扰等原因都会导致呼叫掉线。

8) 切换成功率, 是指成功切换次数与切换尝试总数的比值, 描述了网络使用户能够继续接收服务并在移动过程中保持连接的能力。

9) 平均吞吐量, 指单位时间下载或者上传的数据量。平均吞吐量 = $\frac{\sum \text{吞吐量}}{\text{统计时长}}$, 对于运营商而言是重要的性能指标。本文考虑上行、下行平均吞吐量 Throughput_UL、Throughput_DL, 以及节点传出、传入平均吞吐量 LT(out)、LT(in)。

10) 时延, 通常指发送到接收之间的时间间隔, 网络出现时延的情况时, 可以从网络拓扑、网络中的业务模型、传输资源等方面考虑问题出现的原因。本文考虑切换时延 HO_d。

11) 误码率, 在一段特定时间内数据传输的准

确率的度量, 如果有误码就会有误码率。误码的产生是由于网络传输质量低导致的。本文考虑链路误码率 LER。

2.2 网络故障

训练网络故障诊断模型所需要的数据集由不同的网络故障组成, 每个故障代表一个单元小区出现的问题, 邻居小区也会受到这个问题的影响。本文分析了网络运营过程中的常见网络故障^[14-15], 具体如下。

1) 干扰, 一般指进入信道或通信系统影响合法信道正常运行的信号, 移动通信系统的干扰是影响无线网络出现掉线、接通失败等原因的重要因素之一, 严重影响了网络正常运行和服务质量。本文从频段角度考虑, 将干扰分为上行干扰和下行干扰。当上行链路出现干扰时, 所需的用户信号必须比干扰信号强, 这样基站才能与用户通信, 因此, 用户必须更靠近基站, 从而减少了基站的覆盖范围。下行干扰是指干扰源在移动网络下行频段内所发出的干扰信号。当用户接收到干扰信号时, 无法分辨正常的基站信号, 使用户与基站的联系中断, 导致通话掉线或无法注册。

2) 覆盖, 常见的故障为覆盖漏洞, 表示服务单元与邻近单元的信号电平平均低于维持服务所需的强制电平区域, 常由物体障碍造成, 例如城市地区的新建筑和农村地区的丘陵等。在某些情况下, 不合适的天线参数和无线电频率规划也可能造成覆盖漏洞。该故障的典型表现包括服务区域某部分用户的 RSRP 较低, 导致频繁掉线和无线链路故障。

3) 硬件故障, 通常指基站设备部件故障, 比如基站中部分组件反应不灵敏。硬件出现较为严重的故障时会导致小区服务中断, 掉话率急剧上升。

4) 链路故障, 通常指网络运行中链路出现堵塞或者由于其他原因导致链路不能正常传输数据, 网络无法正常运行。

5) 配置参数故障, 在无线接入端, 若仅考虑基站, 其自身有很多参数调整, 如果某些重要的参数配置错误或者更新时出现问题, 可能会导致网络性能下降。

针对上述的 KPI 以及网络故障, 依照故障排除专家经验进行关联, 如表 2 所示。

3 网络故障检测与诊断

本文提出了基于 GAN 的网络故障诊断与预测

模型, 如图 2 所示。首先, 从异构无线网络环境中采集不同网络状态下的少量 KPI 数据, 将不同网络状态与 KPI 数据相关联。为方便分析, 本文将收集到的小样本数据进行归一化处理, 输入 GAN 进行不同网络状态下的数据拟合, 从而得到不同网络状态下大量带有标记的模拟数据。然后, 对 GAN 产生的模拟数据集与原始数据集同时进行数据处理。本文选择极端梯度提升 (XGBoost, extreme gradient boosting) 算法首先对数据进行降维, 去除冗余数据, 选择故障检测阶段输入参数的最优特征组合。最后, 把处理后的数据分为训练集和测试集, 进行 XGBoost 故障检测模型的训练, 从而得到最优的诊断结果。

表 2 故障原因与 KPI 的关联

故障	原因	KPI
干扰	上行干扰	RSRP
		RSRQ
		PD_UL
		SNR_UL
		DCR
	下行干扰	RSRP
		RSRQ
		PD_DL
		SNR_DL
		DCR
覆盖故障	缺少覆盖	RSRP
		RSRQ
		PD_UL
		PD_DL
		RRC
		ERAB
		DCR
硬件故障	基站故障	HO
		Throughput_UL
		Throughput_DL
		LER
		LT(out)
		LT(in)
		PD_UL
传输故障	链路故障	PD_DL
		RRC
		ERAB
		DCR
		LER
		LT(out)
		ERAB
其他故障	配置参数错误	HO
		HO_d

3.1 输入阶段

不同的网络状态有不同的特征, 网络故障诊断与预测模型必须确定不同的网络状态对应的症状, 以便对多个故障进行识别。本文定义 $\mathbf{S}=[KPI_1, KPI_2, KPI_3, \dots, KPI_m]$ 表示不同网络状态的输入向量, \mathbf{S} 是含有 m 个 KPI 的向量; 定义 $C=\{FC_1, FC_2, FC_3, \dots, FC_n\}$ 表示网络的状态, 如网络正常工作或者出现某种故障。

从异构无线网络环境中采集的小样本数据组成的输入数据向量由被研究小区的所有相关的 KPI 组成。根据诊断流程所需的粒度, 可以使用不同的时间聚合级别 (如小时、日、周、月等) 收集 KPI。

若在某段时间 T 出现网络故障 FC_i , 则这段时间的网络状态表示为

$$\mathbf{S}_{FC_i} = \begin{bmatrix} KPI_1^{t-T+1} & KPI_2^{t-T+1} & \dots & KPI_m^{t-T+1} \\ KPI_1^{t-T+2} & KPI_2^{t-T+2} & \dots & KPI_m^{t-T+2} \\ \vdots & \vdots & \ddots & \vdots \\ KPI_1^t & KPI_2^t & \dots & KPI_m^t \end{bmatrix} \quad (1)$$

其中, KPI_m^t 指在 t 时刻, 第 m 个 KPI 的数值。

在输入阶段, 选择特定的 KPI_i 并进行归一化。确保它们的动态范围是相似的。在本文系统中, 基于每个 KPI 的最大值分别进行归一化处理, 即

$$KPI_i = \frac{KPI_i}{\max(KPI_i)} \quad (2)$$

其中, KPI_i 指归一化的第 i 个 KPI, $\max(KPI_i)$ 指收集的数据中第 i 个 KPI 出现的最大值。式(2)用于转换特定指标 KPI_i 的动态范围, 仅考虑不在区间[0,1]的 KPI_i , 其目标是确保所有的变量都在期望的区间内。

归一化后的网络状态为

$$\hat{\mathbf{S}}_{FC_i} = \begin{bmatrix} \widehat{KPI}_1^{t-T+1} & \widehat{KPI}_2^{t-T+1} & \dots & \widehat{KPI}_m^{t-T+1} \\ \widehat{KPI}_1^{t-T+2} & \widehat{KPI}_2^{t-T+2} & \dots & \widehat{KPI}_m^{t-T+2} \\ \vdots & \vdots & \ddots & \vdots \\ \widehat{KPI}_1^t & \widehat{KPI}_2^t & \dots & \widehat{KPI}_m^t \end{bmatrix} \quad (3)$$

3.2 GAN 框架

GAN 框架如图 3 所示, 主要基于博弈论中的零和博弈。该框架必须具有 2 个相互竞争的网络, 并同时优化其目标。第一个网络为生成器 G , 它在给定高斯噪声或均匀噪声的情况下输出模拟样本。第二个网络为判别器 D , 将来自真实分布的样本或由

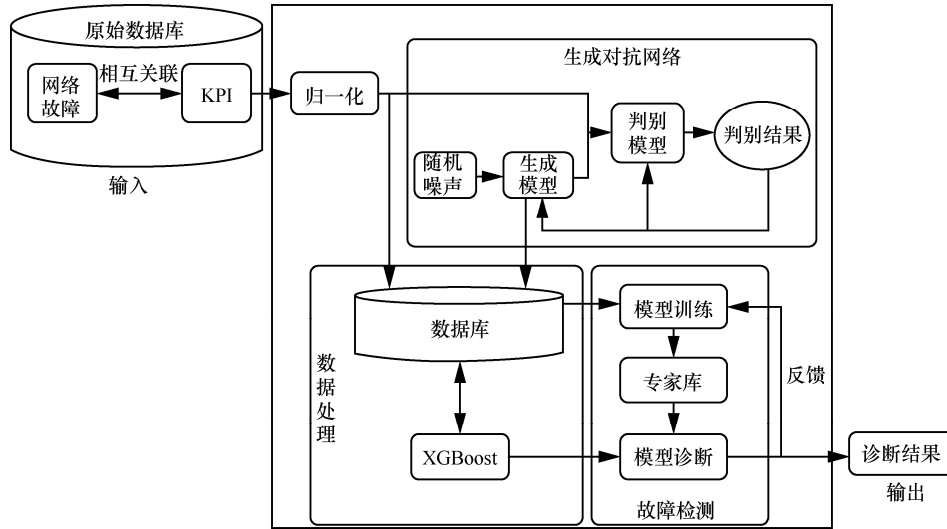


图 2 基于 GAN 的网络故障诊断与预测模型

G 生成的样本输入判别器 D , D 尝试将给定样本标记为 0 (样本来自生成器分布) 或 1 (样本来自真实数据分布)。迭代后, 这种竞争将使 2 个网络都更好地完成任务。特别是生成器 G , 能够产生可以欺骗人类的真实样本。优化的目标函数为

$$\min_G \max_D V(D, G) = E_{\hat{s} \sim p_r} [\log D(\hat{s})] + E_{z \sim p_z} [\log(1 - D(G(z)))] \quad (4)$$

其中, p_r 表示异构无线网络收集的归一化的真实数据 \hat{s} 的分布; p_z 表示输入噪声服从的分布; $G(z)$ 表示数据空间的映射; G 表示一个由多层感知机表示的可微函数; $D(\hat{s})$ 为标量, 表示 \hat{s} 来自真实数据分布而不是 p_z 的概率。

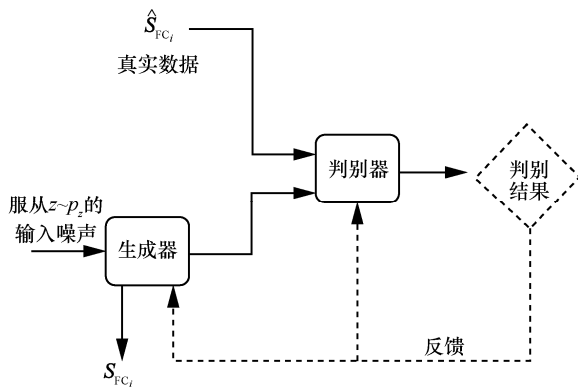


图 3 GAN 框架

通过上述分析可知, GAN 中的 G 作为生成模型, 不像传统模型那样需要十分严格的生成数据的表达式, 避免了数据非常复杂导致的不可计算; 同时, G 本身也不需要计算量庞大的求和计算。

GAN 仅需要输入一个服从一定规律的噪声、一些真实数据、2 个可以逼近函数的网络。通过生成器与判别器之间的不断博弈, 当判别器趋于稳定时, 生成器获得趋于真实数据分布的不同网络状态 \hat{S}'_{FC_i} 。

$$\hat{S}'_{FC_i} = \begin{bmatrix} \widehat{KPI}_1^{t-T+1'} & \widehat{KPI}_2^{t-T+1'} & \dots & \widehat{KPI}_m^{t-T+1'} \\ \widehat{KPI}_1^{t-T+2'} & \widehat{KPI}_2^{t-T+2'} & \dots & \widehat{KPI}_m^{t-T+2'} \\ \vdots & \vdots & \ddots & \vdots \\ \widehat{KPI}_1^{t'} & \widehat{KPI}_2^{t'} & \dots & \widehat{KPI}_m^{t'} \end{bmatrix} \quad (5)$$

经典的 GAN 算法使真实分布和近似分布之间的 JS 散度最小化。然而, JS 散度是不连续的, 梯度在某些地方不可用。为了克服这个缺点, Liu 等^[13] 提出用 Wasserstein 距离代替 JS 散度, WGAN 保证了梯度的可用性。鉴于 Wasserstein 距离方程求解十分困难, WGAN 利用 Kantorovich-Rubinstein 对偶性来简化计算, 同时为判别器引入一个基本约束来寻找 1-Lipschitz 函数。在超参数控制的范围内对判别器的权值进行裁剪以满足约束条件。此外, Gulrajani 等^[16] 提出具有梯度惩罚的 WGAN 算法, 即 WGAN-GP (WGAN with gradient penalty), 它采用梯度惩罚来执行 1-Lipschitz 约束, 而不是采用权值裁剪。本文采用 WGAN-GP 产生模拟数据。优化目标如下

$$L = E_{\hat{s}' \sim p_z} [D(\hat{s}')] - E_{\hat{s} \sim p_r} [D(\hat{s})] + u E_{\hat{s} \sim p_z} [\|\nabla_{\hat{s}} D_w(\hat{s})\| - 1]^2 \quad (6)$$

其中, $\hat{s}' \sim p_z$ 表示生成器产生的数据服从的分布; $\hat{s} \sim p_r$ 表示真实数据服从的分布, 这里指异构无线网络环境下收集的不同网络状态下归一化的小样

本数据的分布； \tilde{s} 是对真实数据与生成数据组成的数据集采样得到的，本文利用 $\varepsilon \sim \text{uniform}[0,1]$ ，在 \hat{s}' 和 \hat{s} 的连线上随机插值采样，得到 $\tilde{s} = \varepsilon\hat{s} + (1-\varepsilon)\hat{s}'$ ； $E_{\tilde{s} \sim p_{\tilde{s}}} [(\|\nabla_{\tilde{s}} D_w(\tilde{s})\| - 1)^2]$ 为惩罚项， $\|\nabla_{\tilde{s}} D_w(\tilde{s})\|_2$ 越接近 1，惩罚就越少； u 为惩罚参数。WGAN-GP 具体实现过程如算法 1 所示。在固定生成器时判别迭代次数为 n_{critic} ，批次大小为 m 。用于判别器以及生成器训练的 Adam 算法的超参数定义如下： α 为学习率，用于控制步幅； β_1 为一阶矩估计的指数衰减率； β_2 为二阶矩估计的指数衰减率。本文中 $u = 10$ ， $n_{\text{critic}} = 100$ ， $\alpha = 0.001$ ， $\beta_1 = 0.9$ ， $\beta_2 = 0.999$ ， $\sigma = 10^{-8}$ 。

算法 1 WGAN-GP

初始化 判别器参数 w_0 ，生成器参数 θ_0

- 1) while 生成器参数 θ 未收敛 do
- 2) for $t = 1, \dots, n_{\text{critic}}$
- 3) for $i = 1, \dots, m$
- 4) 获取真实数据 $\hat{s} \sim p_r$ ，噪声 $z \sim p_z$ ，以及一个随机数 $\varepsilon \sim \text{uniform}[0,1]$
- 5) $\hat{s}' \leftarrow G_{\theta}(z)$
- 6) $\tilde{s} = \varepsilon\hat{s} + (1-\varepsilon)\hat{s}'$
- 7) $L^{(i)} \leftarrow D_w(\hat{s}') - D_w(\hat{s}) + uE_{\tilde{s} \sim p_{\tilde{s}}} [(\|\nabla_{\tilde{s}} D_w(\tilde{s})\| - 1)^2]$
- 8) end for
- 9) 使用 Adam 训练判别器
- 10) $w \leftarrow \text{Adam}\left(\nabla_w \frac{1}{m} \sum_{i=1}^m L^{(i)}, w, \alpha, \beta_1, \beta_2\right)$
- 11) end for
- 12) 从前置随机采样 $z^{(i)}_{i=1}^m \sim p_z$
- 13) 使用 Adam 训练生成器
- 14) $\theta \leftarrow \text{Adam}\left(\nabla_{\theta} \frac{1}{m} \sum_{i=1}^m -D_w(G_{\theta}(z)), \theta, \alpha, \beta_1, \beta_2\right)$
- 15) end while

Adam 算法主要思想是利用梯度的一阶矩估计和二阶矩估计动态调整各参数的学习率，从而达到参数更新的目的。Adam 算法的优点是经过偏差校正后，每次迭代的学习率都固定在一定范围，使参数相对稳定。Adam 算法具体实现过程如算法 2 所示，其中， t 为更新的步数 (step)； θ 为要求解的参数； f_{θ} 为带有参数 θ 的随机目标函数，一般指损失函数； g_t 为目标函数 f_{θ} 对 θ 求导所得梯度； m_t 为梯度 g_t 的期望； v_t 为梯度 g_t 的期望； \hat{m}_t 为 m_t 的偏置矫正； \hat{v}_t 为 v_t 的偏置矫正。

算法 2 Adam 算法

初始化 参数 θ_0 ，期望 m_0 ，期望 v_0 ，更新步数

- $t = 0$
- 1) while θ_0 未收敛 do
- 2) 更新步数， $t \leftarrow t + 1$
- 3) 计算原目标函数 f_{θ} 对参数 θ 的梯度 g_t ， $g_t \leftarrow \nabla_{\theta} f_t(\theta_{t-1})$
- 4) 计算梯度的一阶矩， $m_t \leftarrow \beta_1 m_{t-1} + (1-\beta_1)g_t$
- 5) 计算梯度的二阶矩， $v_t \leftarrow \beta_2 v_{t-1} + (1-\beta_2)g_t^2$
- 6) 对一阶矩 m_t 进行校正， $\hat{m}_t \leftarrow \frac{m_t}{1-\beta_1^t}$
- 7) 对二阶矩 v_t 进行校正， $\hat{v}_t \leftarrow \frac{v_t}{1-\beta_2^t}$
- 8) 更新参数 θ_t ， $\theta_t \leftarrow \theta_{t-1} - \frac{\alpha \hat{m}_t}{\sqrt{\hat{v}_t} + \sigma}$
- 9) end while
- 10) return θ_t

3.3 XGBoost

XGBoost^[17] 是基于梯度增强决策树 (GBDT, gradient boosting decision tree)^[18] 的改进算法，在计算速度、泛化性能和可扩展性等方面都得到了提升。GBDT 算法在训练的每次迭代中，都会在先前模型损失函数的梯度下降方向上建立新的决策树模型，在构造决策树后对其进行修剪。XGBoost 在决策树的构造阶段将正则化项加入损失函数，如式(7)所示。

$$F_{\text{obj}}^{(m)} = \sum_{i=1}^N L(y_i, \hat{y}_i^{(m)}) + \Omega(f_m) \quad (7)$$

其中， $L(y_i, \hat{y}_i^{(m)})$ 为损失函数，用来度量预测值 $\hat{y}_i^{(m)}$ 和目标值 y_i 之间的差异，本文中指预测的网络状态标签与真实的网络状态标签之间的差异，如式(8)所示。

$$L(y_i, \hat{y}_i^{(m)}) = (y_i - \hat{y}_i^{(m)})^2 \quad (8)$$

$\Omega(f_m)$ 为正则化项，定义为

$$\Omega(f_m) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (9)$$

其中， T 指叶节点的数量， λ 为正则化参数， γ 为学习率， w_j 表示第 j 个叶节点的预测值。

令 $\hat{y}_i^{(m-1)}$ 表示现有的 $(m-1)$ 树的最优解，损失函数 $F_{\text{obj}}^{(m)}$ 在 $\hat{y}_i^{(m-1)}$ 处的二阶泰勒展开式为

$$F_{\text{obj}}^{(m)} = \sum_{j=1}^T [G_j w_j + \frac{1}{2} (H_j + \lambda) w_j^2] + \gamma T \quad (10)$$

其中,

$$G_j = \sum_{i \in I_j} \frac{\partial L(y_i, \hat{y}^{(m-1)})}{\partial \hat{y}^{(m-1)}} \quad (11)$$

$$H_j = \sum_{i \in I_j} \frac{\partial^2 L(y_i, \hat{y}^{(m-1)})}{\partial \hat{y}^{(m-1)^2}} \quad (12)$$

I_j 定义为样本的索引集, 其值与叶节点 j 相关。

假设决策树的结构已经确定, 每个叶节点上的预测值可以通过使损失函数的导数为零得到, 即

$$w_j^* = -\frac{G_j}{H_j + \lambda} \quad (13)$$

将预测值代入损失函数, 得到损失函数的最小值。 F_{obj}^* 为最终损失函数, 其值越小, 越接近实际结果, 表示树的结构越好, 如式(14)所示。

$$F_{\text{obj}}^* = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T \quad (14)$$

本文使用 XGBoost 框架训练数据, 然后用训练后的模型预测某时间段的网络状态, 即为收集到的其他未知数据打上标签。此外, 使用 XGBoost 的另一个好处是, 创建提升树之后, 可以为每个属性获得一个重要性评分。一般情况下, 重要性评分衡量模型中某属性的价值, 以增强决策树的构建。属性在模型中用于构建决策树的次数越多, 就越重要。本文利用 XGBoost 框架的特征重要性排序功能进行数据的预处理, 选出影响衡量网络状态的最相关的性能指标。利用此算法可以对测试集的准确性和模型复杂度进行权衡, 从而实现高效而可靠的网络故障的检测。

4 性能分析

4.1 模拟数据集

为了说明本文所提方法的有效性, 采用 OPNET 18.6 搭建仿真实验环境, 其网络仿真参数设置如表 3 所示。

仿真中主要设置了 11 种网络状态类别, 具体可分为正常、干扰、覆盖故障、硬件故障和传输故障五大类, 其中, 正常为 $\{FC_1\}$; 干扰分为上行干扰和下行干扰, 即 $\{FC_2, FC_3\}$; 覆盖故障为 $\{FC_4\}$; 硬件

故障分为 4 种不同基站故障, 即 $\{FC_5, FC_6, FC_7, FC_8\}$; 传输故障分为 3 种不同的链路故障, 即 $\{FC_9, FC_{10}, FC_{11}\}$ 。网络状态类别组成的集合 $C = \{FC_1, FC_2, FC_3, \dots, FC_{11}\}$ 。然后预先设置这些网络状态的发生时间以便人工产生数据标签, 每次仿真时间设置为 2 h, 每种网络状态发生的时间为 20 min。

表 3 网络仿真参数

仿真参数	宏基站	微基站
基站数/个	3	8
每个基站的用户数/个	30	10
传输功率/ dBm	46	30
阴影衰落标准差/dB	8	10
传输损耗模型	自由空间	室内/办公环境
天线增益/dBi	15	8
运行模式	LTE 5 MHz FDD	LTE 10 MHz FDD
接收灵敏度/dBm	-110	-107
基站选择策略	最适合 eNode B	最适合 eNode B
用户分布	随机分布	随机分布

4.2 基于生成对抗网络的故障检测与诊断

利用本文提出的基于生成对抗网络进行网络故障检测与诊断的思想, 在进行数据处理以及故障检测之前, 利用 WGAN-GP 算法对从异构无线网络环境中收集的各个网络状态下服从一定规律的小样本数据进行学习, 从而得到各个网络状态下大量带有标记的模拟数据。对生成对抗网络产生的模拟数据集与原始数据集同时进行数据的处理, 本文选择 XGBoost 算法首先对数据进行降维, 去除冗余数据, 把处理后的数据分为训练集和测试集, 进行 XGBoost 故障检测模型的训练。

实验中分别基于原始小样本数据和扩充后数据集, 利用 XGBoost 算法进行网络故障的检测与诊断, 准确率如图 4 所示。由图 4 可知, 本文方法很大程度上提高了网络故障诊断的准确率, 随着迭代次数的增加, 准确率可达 98.48%。

考虑节省网络故障诊断时间, 本文利用 XGBoost 模型进行特征的筛选, 在保证正确率的基础上, 降低数据的维度, 达到缩短网络故障检测时间的目的。利用 XGBoost 模型对 16 个 KPI 进行重要性排序, 结果如图 5 所示。图 5 反映了 16 个 KPI 在网络故障诊断过程中所占的比重。




图 4 网络故障诊断准确率




图 6 不同特征组合的故障诊断准确率

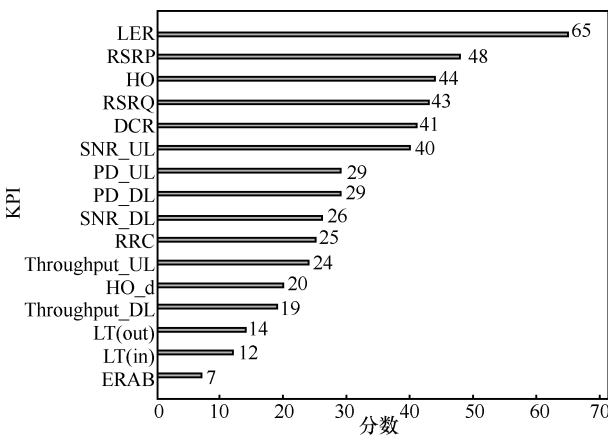


图 5 特征重要性排序

基于特征重要性的排序进行数据筛选，故障诊断准确率如图 6 和表 4 所示。结果表明，训练 200 次后，若特征全部保留，得到的诊断准确率最高，为 98.48%。对应特征分别选取 15 个和 13 个时，诊断准确率分别为 98.22% 和 98.18%。这是由于特征选取个数的减少对诊断准确率造成了影响，但是节省了网络故障诊断时间，并且诊断准确率并未随特征的减少而大幅度降低。对测试集的诊断准确率和模型复杂度进行权衡，选取 13 个特征时性能最好，根据图 5 的特征重要性的排序，最终从所有特征里选取 RSRP、RSRQ、PD_UL、PD_DL、SNR_UL、SNR_DL、RRC、DCR、HO、HO_d、Throughput_UL、LER、Throughput_DL 进行故障检测与诊断，准确率为 98.18%。

从网络故障诊断时间考虑，经特征筛选后，训练模型的输入参数的维度减少，模型的训练时间也相应减少。故障诊断时间如图 7 所示，本文提出的经特征筛选后进行网络故障诊断方法的诊断时间比未经特征筛选的故障诊断方法短。

表 4 训练 200 次时故障诊断准确率

特征数	准确率
16	98.48%
15	98.22%
14	98.11%
13	98.18%
12	97.85%
11	97.58%
10	96.70%




图 7 故障诊断时间

另外，本文基于朴素贝叶斯分类器、K 最近邻 (KNN, K-nearest neighbor)、决策树、随机森林等算法对异构无线网络环境下的网络故障进行诊断，当训练稳定时，与本文算法进行比较，从而验证本文算法的优越性。仿真结果如表 5 所示。当训练稳定时，与其他算法相比，本文算法由于原始小样本数据集得到扩充，网络故障诊断的准确率得到提高，而且诊断时间并没有因为数据量的增加而增加过多，与有些算法相比诊断时间更短。

表 5 仿真结果对比

算法	准确率	诊断时间/s
本文算法	98.18%	0.27
朴素贝叶斯分类器	24.8%	7
KNN	78.9%	0.34
决策树	83.8%	0.27
随机森林	87.9%	0.22

5 结束语

本文提出了一种适用于异构无线网络的基于生成对抗网络的网络故障检测与诊断算法，利用生成对抗网络思想，基于小样本数据获得大量可靠数据用于算法的训练，节省了人工标注训练数据的时间。仿真结果表明，本文算法能够实现高效而可靠的网络故障诊断，但是需要生成对抗网络模型训练得非常好才能实现上述效果，而在训练过程中，误差不可避免。因此，如何获得准确的生成对抗网络模型值得进一步探究。

参考文献：

- [1] STEINDER M, SETHI A. A survey of fault localization techniques in computer networks[J]. *Science of Computer Programming*, 2004, 53(2): 165-194.
- [2] SZILAGYI P, NOVACZKI S. An automatic detection and diagnosis framework for mobile communication systems[J]. *IEEE Transactions on Network and Service Management*, 2012, 9(2): 184-197.
- [3] BARCO R, LAZARO P, DIEZ L, et al. Continuous versus discrete model in autodiagnosis systems for wireless networks[J]. *IEEE Transactions on Mobile Computing*, 2008, 7(2): 673-681.
- [4] KHANAFER R M, SOLANA B, TRIOLA J, et al. Automated diagnosis for UMTS networks using Bayesian network approach[J]. *IEEE Transactions on Vehicular Technology*, 2008, 57(4): 2451-2461.
- [5] BARCO R, WILLE V, DÍEZ V, et al. Learning of model parameters for fault diagnosis in wireless networks[J]. *Wireless Networks*, 2010, 16(1): 255-271.
- [6] KHATIB E J, BARCO R, ANDRADES A G, et al. Diagnosis based on genetic fuzzy algorithms for LTE self-healing[J]. *IEEE Transactions on Vehicular Technology*, 2015, 65(3): 1.
- [7] 5G Alliance. Description of network slicing concept[R]. NGMN, (2016-01)[2020-01-14].
- [8] ETSI. Network functions virtualisation (NFV): architectural framework: ETSI GS NFV 002 V1.2.1[R]. (2014-12)[2020-01-14].
- [9] KUKLIŃSKI S, TOMASZEWSKI L. Key performance indicators for

5G network slicing[C]//2019 IEEE Conference on Network Softwarization. Piscataway: IEEE Press, 2019: 464-471.

- [10] MFULA H, NURMINEN J. Adaptive root cause analysis for self-healing in 5G networks[C]//2017 International Conference on High Performance Computing & Simulation. Piscataway: IEEE Press, 2017: 136-143.
- [11] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//International Conference on Neural Information Processing Systems. Massachusetts: MIT Press, 2014: 2672-2680.
- [12] ARJOVSKY M, BOTTOU L. Towards principled methods for training generative adversarial networks[J]. *arXiv Preprint, arXiv: 1701.04862*, 2017.
- [13] LIU H, GU X, SAMARAS D. Wasserstein GAN with quadratic transport cost[C]//2019 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2019: 4831-4840.
- [14] WILLE V, BRIMER A, DAVIES G, et al. A simple and fast method for identification of missing adjacencies in WCDMA networks[C]//IEEE International Conference on 3G & Beyond. Piscataway: IEEE Press, 2005: 132-139.
- [15] BETTSTETTER C, FITZEK F, HARTENSTEIN H, et al. Special issue on self-organization in mobile networking[J]. *European Transactions on Telecommunications*, 2005, 16(5): 371-373.
- [16] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[C]//Advances in Neural Information Processing Systems. Massachusetts: MIT Press, 2017: 5767-5777.
- [17] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2016: 785-794.
- [18] FRIEDMAN J H. Greedy function approximation: a gradient boosting machine[J]. *Annals of Statistics*, 2001, 29(5): 1189-1232.

[作者简介]



朱晓荣（1977-），女，山东临沂人，博士，南京邮电大学教授、博士生导师，主要研究方向为 5G 通信系统、异构网络、物联网等关键技术及系统研发。



张佩佩（1995-），女，山东菏泽人，南京邮电大学硕士生，主要研究方向为 4G/5G 网络故障诊断、网络故障预测等。