

虚拟网络切片中的在线异常检测算法研究

王威丽 陈前斌* 唐 伦

(重庆邮电大学通信与信息工程学院 重庆 400065)

(重庆邮电大学移动通信重点实验室 重庆 400065)

摘 要: 在虚拟化网络切片场景中, 底层物理网络中一个物理节点(PN)或一条物理链路(PL)的异常会造成多个网络切片的性能退化。因网络中每个时刻都会产生新的测量数据, 该文设计了两种在线异常检测算法实时监督物理网络的工作状态。首先, 该文提出了一种基于在线一类支持向量机(OCSVM)的PN异常检测算法, 该算法可根据每个时刻虚拟节点(VNs)的新测量数据进行模型参数的更新而不需要任何标签数据; 其次, 基于虚拟链路两端点间测量数据的自然相关性, 该文提出基于在线典型相关分析(CCA)的PL异常检测算法, 该算法只需要少量标签数据就可以准确分析出PL的异常情况。仿真结果验证了该文所提在线异常检测算法的有效性和鲁棒性。

关键词: 虚拟网络切片; 异常检测; 在线一类支持向量机; 在线典型相关分析

中图分类号: TN929.5

文献标识码: A

文章编号: 1009-5896(2020)06-1460-08

DOI: 10.11999/JEIT190531

Online Anomaly Detection for Virtualized Network Slicing

WANG Weili CHEN Qianbin TANG Lun

(School of Communication and Information Engineering, Chongqing University of

Posts and Telecommunications, Chongqing 400065, China)

(Key Laboratory of Mobile Communications, Chongqing University of Posts

and Telecommunications, Chongqing 400065, China)

Abstract: In virtualized network slicing scenario, one anomaly Physical Node (PN) or Physical Link (PL) in substrate networks will cause performance degradation of multiple network slices. For new measurements are achieved in each period, two online anomaly detection algorithms to monitor the working states of substrate networks in real time are designed. An online One-Class Support Vector Machine (OCSVM) algorithm is first proposed in this paper to detect the working states of PNs. Without requiring any labeled data, the model parameters of OCSVM can be updated based on the new measurements of Virtual Nodes (VNs) in each iteration. Then, an online Canonical Correlation Analysis (CCA) based PL anomaly detection algorithm is proposed according to the natural correlation of measurements between neighboring VNs of virtual links. With a small amount of labeled data, the algorithm can accurately analyze the working states of PLs. The simulation results verify the effectiveness and robustness of the proposed online anomaly detection algorithms for the virtualized network slicing.

Key words: Virtualized network slicing; Anomaly detection; Online One-Class Support Vector Machine (OCSVM); Online Canonical Correlation Analysis (CCA)

1 引言

网络切片是为无线网络中新兴业务类型提供多

样化需求的关键技术^[1,2]。网络功能虚拟化(Network Function Virtualization, NFV)技术的出现便捷了网络切片的部署, 使得之前需要在专有硬件上实现的网络功能可在通用服务器上执行^[3]。基于NFV技术, 网络切片根据用户需求定制虚拟网络功能(Virtual Network Function, VNF)生成服务功能链(Service Function Chain, SFC)以提供定制化的服务^[4,5]。

和传统网络架构相比, VNF编排的复杂性使其更容易受到物理网络中异常情况的影响, 产生难

收稿日期: 2019-07-15; 改回日期: 2020-02-12; 网络出版: 2020-03-03

*通信作者: 陈前斌 cqb@cqupt.edu.cn

基金项目: 国家自然科学基金(61571073), 重庆市教委科学技术研究项目(KJZD-M201800601)

Foundation Items: The National Natural Science Foundation of China (61571073), The Science and Technology Research Program of Chongqing Municipal Education Commission (KJZD-M201800601)

以预料的故障。为了实现对虚拟网络切片的异常检测, OI等人^[3]提出了一种使用探测数据包估计SFC中故障位置的方法。COTRONEO等人^[6]通过评估两个相邻虚拟节点(Virtual Node, VN)数据的相关程度判定SFC的工作状态。由于虚拟网络切片的共享特性, 物理网络中一个物理节点(Physical Node, PN)或一条物理链路(Physical Link, PL)的异常会造成多个网络切片的性能退化。因此, 实现对物理网络的准确检测是保证切片性能的重要前提。针对PN的异常检测问题, 一类支持向量机(One-Class Support Vector Machine, OCSVM)^[7]是一种较为常用的异常检测算法, 但该算法需要大量标签数据进行离线训练。针对PL的异常检测问题, 因在一条SFC中, 数据流会依次经过每个VN, 则相邻VN间的测量数据是自然相关的^[6], 因此可根据映射到一条PL两端的VN之间的数据相关性判定PL的工作状态。典型相关分析(Canonical Correlation Analysis, CCA)是用于分析两组数据之间相关性的重要方法^[8], 但该方法同样需要大量的标签数据进行离线训练。

在虚拟化网络切片场景中, VN中每个时刻都会产生新的无标签测量数据, 保存每个时间上的数据进行离线训练不仅会占用大量的存储资源, 且需要花费较长的时间^[9]。因此, 怎样充分利用网络每个时刻产生的无标签数据进行在线异常检测是当前面临的重要问题。基于上述分析, 本文的主要工作和创新点总结如下:

首先, 本文提出一种基于在线OCSVM的异常检测算法推断PN的工作状态, 本算法可根据每个时刻VN产生的新测量数据进行模型参数更新, 并

在每次迭代中判定数据的异常情况, 从而在推断PN工作状态的同时丢弃会对最终模型精确度产生影响的异常数据, 在节约存储资源的同时提高算法鲁棒性;

其次, 本文提出一种在线CCA算法分析PL的工作状态, 本算法只需要少量的标签数据就可以准确判定相邻VN在每个时刻产生的新测量数据间的相关性变化, 从而推断出PL的异常情况, 本算法不仅可以节约大量的存储资源, 且和传统的CCA算法相比, 计算复杂度较低, 适应性也较强;

最后, 本文通过仿真验证了在线OCSVM算法和在线CCA算法的有效性和鲁棒性。

2 系统模型

如图1所示, 当网络收到具有特定服务需求的切片请求时, 网络中的管理和编排器(MANagement and Orchestration, MANO)会根据切片需求为其分配相应的虚拟网络功能(Virtual Network Function, VNF)并按照一定顺序连接, 生成一条满足特定性能需求的服务功能链(Service Function Chain, SFC)。在切片实例化过程中, MANO负责将多条SFC部署到共享的底层物理网络中为不同的切片请求提供定制化服务^[10]。

假设 Q 为组成底层物理网络的PN集合, 映射到PN $q(q \in Q)$ 上的VN集合为 J_q , 对于每一个VN $j_q \in J_q$, 其测量数据为 $\mathbf{x}_{j_q}$, 则PN q 的相关数据集可表示为 $\mathbf{x}_q = \bigcup_{j_q \in J_q} \mathbf{x}_{j_q}$, $\mathbf{x}_q \in \mathbb{R}^d$ 。

物理网络中1个PN或1条PL的异常会影响多个网络切片的性能, 如图1所示, PN 2的工作状态会影响切片1和3的性能, 而PL13的工作状态会影响




图1 网络切片管理示意图

切片1和2的性能。因此,准确检测PN和PL的工作状态对保证切片的服务性能来说至关重要。为了实现PN和PL状态的实时检测,PN的管理模块会从网络切片管理器中收集映射到该PN上的所有VN的测量数据以推断该PN的异常情况,而PL的管理模块会收集映射到该PL两端的相邻VN的测量数据利用其相关性变化情况判定PL的工作状态。

3 基于在线OCSVM的PN异常检测

3.1 基于OCSVM的PN异常检测

在底层物理网络中,PN q 的相关数据可表示为 $S_q, S_q = \{(\mathbf{x}_{qn}, y_{qn}), n = 1, 2, \dots, N_q\}$, 其中 N_q 表示节点采样数据的数量, $y_{qn} = +1$ 表明所有的训练数据均为正常数据。通常情况下,训练集的分布较为复杂,且线性不可分。因此,OCSVM算法使用特征映射函数 $\varphi(\cdot): R^d \rightarrow R^{d'}$ 将训练数据从输入空间 R^d 映射到高维特征空间 $R^{d'}$ [11]。映射的目的是为了使数据在新空间里线性可分。将输入数据 $\mathbf{x}_q$ 映射到再生核空间后,根据核函数 $k(\mathbf{x}_{q1}, \mathbf{x}_{q2})$ 计算特征

3.2 基于在线OCSVM的PN异常检测

PN中每个时刻都会产生新的测量数据,若将所有历史数据都存储下来将会造成较大的资源消耗,因此希望数据能够按时间顺序进行处理。基于上述分析,本文提出基于在线OCSVM的PN异常检测算法。

通过引入拉格朗日乘子 K 将式(2)转化为如式(3)的形式

$$\min \left\{ \frac{1}{2} \|\mathbf{w}_q\|^2 + C \sum_{n=1}^{N_q} \xi_{qn} - \rho_q + K \frac{1}{N_q} \sum_{n=1}^{N_q} \eta(\mathbf{w}_q, \rho_q, \xi_{qn}, \varphi(\mathbf{x}_{qn})) + K \xi_{qn} \right\} \quad (3)$$

$$\text{s.t. } \xi_{qn} \geq 0, \quad n = 1, 2, \dots, N_q$$

其中, $\eta(\cdot)$ 为损失函数。为了解决式(3),要求 $\eta(\mathbf{w}_q, \rho_q, \xi_{qn}, \varphi(\mathbf{x}_{qn}))$ 必需为可导函数。鉴于此,选择损失函数为 $\min(0, \mathbf{w}_q^T \cdot \varphi(\mathbf{x}_{qn}) - \rho_q + \xi_{qn})^2$, 显然当训练样本 $\mathbf{x}_{qn}$ 满足 $\mathbf{w}_q^T \cdot \varphi(\mathbf{x}_{qn}) \geq \rho_q - \xi_{qn}$ 时,损失函数为0。

显然,上述问题要求每个PN的所有数据必须是可用的,而这给存储资源带来了巨大的挑战。为了克服之一困难,本文提出在线OCSVM的成本函数如式(4)

$$\min f(t) = \left\{ \frac{1}{2} \|\mathbf{w}_q\|^2 + C \xi_q(t) - \rho_q + K \min(0, \mathbf{w}_q^T \cdot \varphi(\mathbf{x}_q(t)) - \rho_q + \xi_q(t))^2 \right\} \quad (4)$$

$$\text{s.t. } \xi_q(t) \geq 0$$

其中, t 为在线学习的时间点, $\mathbf{x}_q(t)$ 为PN q 在 t 时的采样数据, $\xi_q(t)$ 为 $\mathbf{x}_q(t)$ 的松弛变量。然而,在式(4)中, $\varphi(\mathbf{x}_q(t))$ 是未知的,在OCSVM算法中通常会计算 $k(\mathbf{x}_q(l), \mathbf{x}_q(m)) = \langle \varphi(\mathbf{x}_q(l)), \varphi(\mathbf{x}_q(m)) \rangle$, 而不是 $\varphi(\mathbf{x}_q(t))$ 。因此,为了方便计算,本文选择采用随机近似的方法通过 $\mathbf{z}(\mathbf{x}_q(t))$ 来近似 $\varphi(\mathbf{x}_q(t))$ [12]。

通过引入一个随机近似函数 $\mathbf{z}: R^d \rightarrow R^D$ 可将输入数据映射到一个随机特征空间,其中 D 是映射后随机特征空间的大小且满足 $D > d$ 。通过使用

$$\min f(t) = \left\{ \frac{1}{2} \|\mathbf{w}_q\|^2 + C \xi_q(t) - \rho_q + K \min(0, \mathbf{w}_q^T \cdot \mathbf{z}_q(t) - \rho_q + \xi_q(t))^2 \right\} \quad (6)$$

$$\text{s.t. } \xi_q(t) \geq 0$$

映射函数的内积。最常用的核函数为高斯核函数

$$k(\mathbf{x}_{q1}, \mathbf{x}_{q2}) = \langle \varphi(\mathbf{x}_{q1}), \varphi(\mathbf{x}_{q2}) \rangle$$

$$= \exp[-\|\mathbf{x}_{q1} - \mathbf{x}_{q2}\|^2 / \sigma^2]$$

$$= \|\varphi(\mathbf{x}_{q1})\| \cdot \|\varphi(\mathbf{x}_{q2})\| \cdot \cos\langle \varphi(\mathbf{x}_{q1}), \varphi(\mathbf{x}_{q2}) \rangle \quad (1)$$

若 $\mathbf{x}_{q1}$ 为正常数据而 $\mathbf{x}_{q2}$ 在输入空间中远离 $\mathbf{x}_{q1}$, 则 $k(\mathbf{x}_{q1}, \mathbf{x}_{q2})$ 的值很小,这意味着 $\varphi(\mathbf{x}_{q1})$ 和 $\varphi(\mathbf{x}_{q2})$ 之间的角度很大,这时候通常将 $\mathbf{x}_{q2}$ 视为异常数据。因此可通过找到超平面 $\mathbf{w}_q^T \varphi(\mathbf{x}) - \rho_q = 0$ 将异常数据和正常数据分开。基于上述推理,本文将用于PN q 的异常检测问题建立为如式(2)的优化目标

$$\min \left\{ \frac{1}{2} \|\mathbf{w}_q^T\|^2 + C \sum_{n=1}^{N_q} \xi_{qn} - \rho_q \right. \\ \left. \text{s.t. } \mathbf{w}_q^T \varphi(\mathbf{x}_{qn}) \geq \rho_q - \xi_{qn}, \quad n = 1, 2, \dots, N_q \right. \\ \left. \xi_{qn} \geq 0, \quad n = 1, 2, \dots, N_q \right\} \quad (2)$$

其中, C 为惩罚参数, ξ_{qn} 为松弛变量。设定松弛变量是允许一些样本出现在超平面的边缘。

这种方法, $\varphi(\mathbf{x}_q(t))$ 可通过 $\mathbf{z}(\mathbf{x}_q(t))$ 进行近似。在本文中, $\mathbf{z}(\mathbf{x}_q(t)) = [z_{\omega_1}(\mathbf{x}_q(t)) \dots z_{\omega_D}(\mathbf{x}_q(t))]^T$, 其中 $z_{\omega_i}(\mathbf{x}_q(t))$ 为实值映射函数

$$z_{\omega_i}(\mathbf{x}_q(t)) = \sqrt{\frac{2}{D}} \cos(\omega_i^T \mathbf{x}_{qn} + \vartheta_i), \quad i = 1, 2, \dots, D \quad (5)$$

其中 ϑ_i 均匀地从 $[0, 2\pi]$ 中进行取值, ω_i 从高斯核函数的傅里叶变换 $p(\omega) = (2\pi)^{-(D/2)} e^{-\|\omega\|^2/2}$ 中取值 [12]。

基于上述推理,可得在线OCSVM的最终成本函数如式(6)

其中, $\mathbf{z}_q(t) = \mathbf{z}(\mathbf{x}_q(t)) = [z_{\omega_1}(\mathbf{x}_q(t)) \dots z_{\omega_D}(\mathbf{x}_q(t))]^\top$, $\mathbf{x}_q(t)$ 为PN q 在时间 t 时的训练样本。

现在, 可以采用随机梯度下降(Stochastic Gradient Descent, SGD)解决上述优化目标。使用该方法不仅可在节约存储空间的同时继承到历史信息, 还可以充分利用新的测量数据。通过使用SGD可得

$$\mathbf{w}_q(t+1) = \mathbf{w}_q(t) - \alpha_1(t) \nabla_{\mathbf{w}_q} f_q(t) \quad (7a)$$

$$\rho_q(t+1) = \rho_q(t) - \alpha_2(t) \nabla_{\rho_q} f_q(t) \quad (7b)$$

$$\xi_q(t+1) = (\xi_q(t) - \alpha_3(t) \nabla_{\xi_q} f_q(t))^+ \quad (7c)$$

其中, $\mathbf{w}_q(t)$, $\rho_q(t)$ 和 $\xi_q(t)$ 是 $\mathbf{w}_q$, ρ_q 和 ξ_q 在时间点 t 上的估计。 $\alpha_1(t)$, $\alpha_2(t)$ 和 $\alpha_3(t)$ 是正的步长参数, 用于控制优化过程的收敛速度^[13]。 $\nabla_{\mathbf{w}_q} f_q(t)$, $\nabla_{\rho_q} f_q(t)$ 和 $\nabla_{\xi_q} f_q(t)$ 表示 $\mathbf{w}_q$, ρ_q 和 ξ_q 在时间 t 上的梯度

$$\nabla_{\mathbf{w}_q} f_q(t) = \begin{cases} \mathbf{w}_q(t), & \Psi_q(t) \geq 0 \\ \mathbf{w}_q(t) + 2K\Psi_q(t)\mathbf{z}_q(t), & \Psi_q(t) < 0 \end{cases} \quad (8a)$$

$$\nabla_{\rho_q} f_q(t) = \begin{cases} -1, & \Psi_q(t) \geq 0 \\ -1 - 2K\Psi_q(t), & \Psi_q(t) < 0 \end{cases} \quad (8b)$$

$$\nabla_{\xi_q} f_q(t) = \begin{cases} C - L, & \Psi_q(t) \geq 0 \\ C - L + 2K\Psi_q(t), & \Psi_q(t) < 0 \end{cases} \quad (8c)$$

其中, $\Psi_q(t) = \mathbf{w}_q^\top \cdot \mathbf{z}_q(t) - \rho_q + \xi_q(t)$ 。在线OCSVM算法的详细步骤如表1所示。

4 基于在线CCA的PL异常检测

在一条SFC中, 因数据流会依次经过每个VN, 则相邻VN间的测量数据是自然相关的^[6]。假设 VNF_l 和 VNF_{l+1} 实例化到 PN_m 和 PN_{m+1} , $\text{VL}_{l,l+1}$ 实例化到 $\text{PL}_{m,m+1}$, 若 $\text{PL}_{m,m+1}$ 处于正常状态, 则 VNF_l 和 VNF_{l+1} 测量数据的相关性也会稳定在一定范围内, 若 $\text{PL}_{m,m+1}$ 出现异常, VNF_l 和 VNF_{l+1} 测量数

据的相关性也会发生变化。如图1所示, PL 13的状态会影响切片1和切片2的VNF1和VNF2测量数据的相关性。因此, 可以根据映射至PL两端的VN测量数据的相关性变化情况实现对PL工作状态的检测。

CCA方法是一种广泛使用的多变量分析方法^[14]。给定两组随机变量 $\mathbf{U}$ 和 $\mathbf{Y}$

$$\mathbf{U} = [\mathbf{u}_1, \dots, \mathbf{u}_t]^\top = \begin{bmatrix} u_{11} & \dots & u_{1p} \\ \vdots & \ddots & \vdots \\ u_{t1} & \dots & u_{tp} \end{bmatrix} \quad \mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_t]^\top = \begin{bmatrix} y_{11} & \dots & y_{1q} \\ \vdots & \ddots & \vdots \\ y_{t1} & \dots & y_{tq} \end{bmatrix} \quad (9)$$

CCA算法企图找出典型相关向量 $\mathbf{J}$ 和 $\mathbf{L}$, 使得 $\mathbf{J}^\top \mathbf{U}$ 和 $\mathbf{L}^\top \mathbf{Y}$ 之间的相关性最大。也即是

$$(\mathbf{J}, \mathbf{L}) = \arg \max_{(\mathbf{J}, \mathbf{L})} \rho(\mathbf{J}^\top \mathbf{U})(\mathbf{L}^\top \mathbf{Y}) \\ = \arg \max_{(\mathbf{J}, \mathbf{L})} \frac{\mathbf{J}^\top \boldsymbol{\Sigma}_{\mathbf{U}\mathbf{Y}} \mathbf{L}}{(\mathbf{J}^\top \boldsymbol{\Sigma}_{\mathbf{U}} \mathbf{J})^{1/2} (\mathbf{L}^\top \boldsymbol{\Sigma}_{\mathbf{Y}} \mathbf{L})^{1/2}} \quad (10)$$

其中, $\boldsymbol{\Sigma}_{(\cdot)}$ 代表协方差矩阵。式(10)的解决方案可通过对矩阵 $\mathbf{K}$ 进行奇异值分解获得, 具体公式为

$$\mathbf{K} = \boldsymbol{\Sigma}_{\mathbf{U}}^{-1/2} \boldsymbol{\Sigma}_{\mathbf{U}\mathbf{Y}} \boldsymbol{\Sigma}_{\mathbf{Y}}^{-1/2} = \mathbf{R} \boldsymbol{\Sigma} \mathbf{V}^\top \quad (11)$$

由此可得典型相关向量

$$\mathbf{J} = [\mathbf{J}_1 \dots \mathbf{J}_p] = \boldsymbol{\Sigma}_{\mathbf{U}}^{-1/2} \mathbf{R} \in R^{p \times q} \\ \mathbf{L} = [\mathbf{L}_1 \dots \mathbf{L}_q] = \boldsymbol{\Sigma}_{\mathbf{Y}}^{-1/2} \mathbf{V} \in R^{q \times p} \quad (12)$$

针对一段物理路径 $\text{PN}_m \xrightarrow{\text{PL}_{m,m+1}} \text{PN}_{m+1}$, 为了检测 $\text{PL}_{m,m+1}$ 的状态, 在实例化到这段物理路径的多条SFC中找到一条SFC, 其包含的虚拟路径 $\text{VNF}_l \xrightarrow{\text{VL}_{l,l+1}} \text{VNF}_{l+1}$ 和物理路径一一对应。假设当前 VNF_l 和 VNF_{l+1} 的测量数据分别用 $\mathbf{u}$ 和 $\mathbf{y}$ 表示, 则在进行异常检测时, 关键步骤是生成异常检测残差, 如式(13)所示

表 1 基于在线OCSVM的PN异常检测算法

初始化: 总迭代次数 T , 特征空间维度 D , 随机初始化PN q ($0 \leq q \leq Q$) 的估计值 $\mathbf{w}_q(0)$, $\rho_q(0)$ 和 $\xi_q(0)$

- (1) for $t = 0, 1, 2, \dots, T$ do
- (2) PN q 产生新的训练样本 $\mathbf{x}_q(t)$, 使用随机近似函数计算 $\varphi(\mathbf{x}_q(t))$ 的近似值 $z_q(t)$
- (3) 根据式(8a)、式(8b)和式(8c)计算 $\nabla_{\mathbf{w}_q} f_q(t)$, $\nabla_{\rho_q} f_q(t)$ 和 $\nabla_{\xi_q} f_q(t)$
- (4) 根据式(7a)、式(7b)和式(7c)计算 $\mathbf{w}_q(t)$, $\rho_q(t)$ 和 $\xi_q(t)$
- (5) 计算 $g(\mathbf{x}_q(t)) = \text{sgn}(\mathbf{w}^\top(t) \cdot \mathbf{z}_q(t) - \rho(t))$
- (6) if $g(\mathbf{x}_q(t)) == 1$ then
- (7) 判定当前时刻PN q 为正常节点, 更新参数 $\mathbf{w}_q(t)$, $\rho_q(t)$ 和 $\xi_q(t)$
- (8) else
- (9) 判定当前时刻PN q 为异常节点, 保留 $t-1$ 时刻参数值, 丢弃当前值
- (10) end for

$$\mathbf{r} = \mathbf{J}^T \mathbf{u} - \Sigma \mathbf{L}^T \mathbf{y} \quad (13)$$

生成异常检测残差生成后, T^2 检验可建立为

$$T_r^2 = \mathbf{r}^T \Sigma_r^{-1} \mathbf{r}, \quad \Sigma_r = \mathbf{I}_p - \Sigma \Sigma^T \quad (14)$$

因此, 可根据式(15)的判定逻辑估计PL的工作状态

$$\left. \begin{aligned} T_r^2 \leq T_{r,cl}^2 &\Rightarrow \text{anomaly-free} \\ T_r^2 > T_{r,cl}^2 &\Rightarrow \text{anomaly} \end{aligned} \right\} \quad (15)$$

其中, $T_{r,cl}^2$ 为 T_r^2 的控制门限值。

定理1 因残差矢量 $\mathbf{r} = \mathbf{J}^T \mathbf{u} - \Sigma \mathbf{L}^T \mathbf{y}$ 的协方差值最小, 该残差矢量为 T^2 检验中检测两组矢量 $\mathbf{u}$ 和 $\mathbf{y}$ 相关关系变化的最优残差^[14]。

因PN每个时刻都会产生新的测量数据, 为了得到 t 时刻的典型相关向量 $\mathbf{J}(t)$ 和 $\mathbf{L}(t)$, 在每个时刻都需要所有历史数据计算式(11)中的协方差。随着时间的推移, 计算复杂度会越来越高。为了在节约存储空间的同时降低计算复杂度, 本文设计了一种基于在线CCA的PL异常检测算法, 通过使用该方法, 网络只需要存储当前时刻的协方差矩阵和均值向量, 而不需要将所有历史数据都存储下来。

定理2 已知 t 时刻 $\mathbf{U}(t)$ 的协方差矩阵为 $\Sigma_{\mathbf{U}(t)}$ = $\frac{1}{t-1} \begin{bmatrix} a_{11} & \cdots & a_{1p} \\ \vdots & \ddots & \vdots \\ a_{p1} & \cdots & a_{pp} \end{bmatrix}$, $\mathbf{U}(t)$ 每个维度的均值为 $[c_1(t) \dots c_p(t)]$, $t+1$ 时刻的测量数据为 $\mathbf{u}_{t+1} = (u_{(t+1)1} \dots u_{(t+1)p})$, $\mathbf{U}(t+1)$ 的协方差矩阵可通过式(16)得到

$$\Sigma_{\mathbf{U}(t+1)} = \frac{1}{t} \times \begin{bmatrix} a_{11} + m_{11} & \cdots & a_{1p} + m_{1p} \\ \vdots & \ddots & \vdots \\ a_{p1} + m_{p1} & \cdots & a_{pp} + m_{pp} \end{bmatrix} \quad (16)$$

其中, $m_{i,j} = \frac{t(c_i(t) - u_{(t+1)i})(c_j(t) - u_{(t+1)j})}{t+1}$ ($1 \leq i, j \leq p$)。

同理, 在已知 t 时刻矩阵 $\mathbf{U}(t)$ 和 $\mathbf{Y}(t)$ 的协方差

$$\text{矩阵为} \Sigma_{\mathbf{U}(t)\mathbf{Y}(t)} = \frac{1}{t-1} \begin{bmatrix} e_{11} & \cdots & e_{1q} \\ \vdots & \ddots & \vdots \\ e_{p1} & \cdots & e_{pq} \end{bmatrix}, t \text{时刻矩}$$

阵 $\mathbf{Y}(t)$ 每个维度的均值为 $[d_1(t) \dots d_q(t)]$, $t+1$ 时刻的测量数据为 $\mathbf{y}_{t+1} = (y_{(t+1)1} \dots y_{(t+1)q})$, $\mathbf{U}(t+1)$ 和 $\mathbf{Y}(t+1)$ 的协方差矩阵可通过式(17)计算得到

$$\Sigma_{\mathbf{U}(t+1)\mathbf{Y}(t+1)} = \frac{1}{t} \times \begin{bmatrix} e_{11} + n_{11} & \cdots & e_{1q} + n_{1q} \\ \vdots & \ddots & \vdots \\ e_{p1} + n_{p1} & \cdots & e_{pq} + n_{pq} \end{bmatrix} \quad (17)$$

其中, $n_{i,j} = \frac{t(c_i(t) - u_{(t+1)i})(d_j(t) - y_{(t+1)j})}{t+1}$ ($1 \leq i \leq p, 1 \leq j \leq q$)。

因此只需要保存 t 时刻的协方差矩阵和均值向量就可推导出典型相关向量 $\mathbf{J}(t+1)$ 和 $\mathbf{L}(t+1)$, 而不需要使用所有的历史数据, 从而节约大量的缓存资源和计算资源。在线CCA算法的执行过程如表2所示。

5 数值仿真

为了评估本文所提基于在线OCSVM的PN异常检测算法和基于在线CCA的PL异常检测算法的性能, 本文对模拟数据和真实网络数据分别进行了仿真验证。

5.1 模拟数据

为了产生模拟数据验证本文提出的两种在线异常检测算法的性能, 本文构建了具有10个PN和6条SFC的简单虚拟网络切片场景。本文假设网络中包含3种典型应用, 增强移动宽带(Enhanced Mobile

表 2 基于在线CCA的PL异常检测算法

初始化: 初始标签采样个数 t , 映射到物理路径 $\text{PN}_m \xrightarrow{\text{PL}_{m,m+1}} \text{PN}_{m+1}$ 两端的VNF $_l$ 和VNF $_{l+1}$ 测量数据 $\mathbf{U}(t)$ 和 $\mathbf{Y}(t)$, 控制门限值 $T_{r,cl}^2$, 迭代次数 T
(1) 计算 $\mathbf{U}(t)$ 和 $\mathbf{Y}(t)$ 的协方差矩阵和均值向量: $\Sigma_{\mathbf{U}(t)}$, $\Sigma_{\mathbf{Y}(t)}$, $\Sigma_{\mathbf{U}(t)\mathbf{Y}(t)}$, $[c_1(t) \dots c_p(t)]$ 和 $[d_1(t) \dots d_q(t)]$
(2) for $t = t+1 : T$ do
(3) 根据式(16)、式(17)计算 $\Sigma_{\mathbf{U}(t)}$, $\Sigma_{\mathbf{Y}(t)}$ 和 $\Sigma_{\mathbf{U}(t)\mathbf{Y}(t)}$
(4) 根据式(11)对矩阵 $\mathbf{K}(t)$ 进行奇异值分解
(5) 根据式(12)计算典型相关变量 $\mathbf{J}(t)$ 和 $\mathbf{L}(t)$
(6) 根据式(13)生成最优异常检测残差 $\mathbf{r}(t)$ 并建立 T^2 检验: $T_{r(t)}^2 = \mathbf{r}^T(t) \Sigma_{r(t)}^{-1} \mathbf{r}(t)$
(7) if $T_{r(t)}^2 \leq T_{r,cl}^2$ then
(8) 判定 $\text{PL}_{m,m+1}$ 为正常链路, 更新协方差矩阵和均值向量
(9) else
(10) 判定 $\text{PL}_{m,m+1}$ 为异常链路, 保留上一时刻协方差矩阵和均值向量, 丢弃当前值
(11) end for

BroadBand, EMBB)、高可靠低时延(Ultra-Reliable and Low-Latency, URLLC)以及大规模机器通信(Massive Machine-Type Communication, MMTTC)^[15], 每种应用的数据包到达率和数据包大小根据不同应用的特征进行设定, 如表3所示。在仿真过程中, 将VN和VL随机映射到底层物理网络中, 形成专用的SFC给随机到达的用户提供端到端服务从而得到每个VN的模拟数据, 包括处理速率, 数据流量, 排队时延和处理时延等。

本文使用3个指标评估异常检测算法的性能: (1)检测精确度, 表示网络所处状态被准确检测出来的比例; (2)真正率, 表示正常状态被准确判定的比例; (3)误检率, 表示异常状态被判定为正常状态的比例^[16]。

图2给出了在线OCSVM算法和经典OCSVM算法的性能对比结果。在本次仿真中, 设置参数 $K = 20$, $C = 30$ 。为了验证异常数据对经典OCSVM算法的影响, 仿真中引入了训练数据异常比例(Anomaly Rate in Training Data, ARTD)的概念。由图2可

表3 仿真参数

参数	数值
每条SFC包含的VNF数	4~6个
EMBB(到达率, 数据包大小)	(10 packets/s, 200 kbit/packets)
URLLC(到达率, 数据包大小)	(100 packets/s, 10 kbit/packets)
MMTC(到达率, 数据包大小)	(500 packets/s, 1 kbit/packets)
特征空间维度(D)	100
初始标签采样个数(t)	10

知, 经过500次迭代后, 在线OCSVM算法的性能趋近于ARTD为0时的OCSVM算法。但在迭代过程中, 在线OCSVM算法的真正率有轻微下降, 因在异常检测中通常更关注误检率, 故真正率的轻微下降在可接受范围内。此外, 当OCSVM算法的训练集中含有异常数据时(ARTD=0.1), 其检测性能会大幅度下降。在实际网络中, 获得大量标签数据的成本较高, 而本文所提在线OCSVM算法因可在迭代过程中消除异常数据对检测精确度的影响, 在节约成本的同时具有更好的鲁棒性。





图2 在线OCSVM算法和经典OCSVM算法的性能对比图

图3给出了在线OCSVM在迭代过程中, 参数 w 和 ρ 的收敛情况。因 w 是100维的矢量, 所以很难刻画出所有的分量, 故本文随机选取5维分量进行说明。从图中可以看出, 在经过500次迭代后, 参数 w 和 ρ 基本保持不变, 该结果和图2中检测精确度、真正率和误检率的收敛过程基本趋于一致。

图4给出了在线CCA(online CCA)算法和经典CCA算法在PL状态检测中的检测精确度、真正率和误检率对比结果。为了验证异常数据对经典CCA算法产生的影响, 本次仿真中设置了ARTD=0.1的仿真情况。从图4可以看出, 当时间周期数为400时, 在线CCA的误检率几乎为0, 对于相关性变化的检测精确度非常高, 而随着时间周期的增加, 在线CCA算法的性能有所下降, 这是因为随着时间

图3 在线OCSVM算法中 w 和 ρ 的收敛过程

的推移和历史知识的积压,典型相关变量开始变得不够精确。因此,每经过大约400~600个周期,算法需要重新开始。值得注意的是,当经典CCA算法的训练数据中含有异常数据时(ARTD=0.1),其检测性能会大幅度下降,因本文提出的在线CCA算法因可在迭代过程中消除异常数据的影响,故适应性更好。

5.2 真实网络数据

为了进一步验证提出的在线OCSVM和在线CCA算法的有效性,本文引入了CRAWAD数据集^[17]中的真实网络数据进行仿真验证。因使用的due/packet-delivery子集中的网络性能数据均为正常数据,为了生成异常数据,本文在数据子集中随

机插入了服从 $N(\mu, \sigma^2)$ 高斯分布的干扰因子,其中 $\mu=0.1, \sigma=0.1$ 。

图5给出了在线异常检测算法在真实网络数据集上的性能对比图。由图2和图4可知,在线OCSVM算法在经过500次迭代后趋近于最佳检测性能,而为了保证在线CCA算法的检测性能,每经过400~600个周期,算法需要重新开始。因此,为了方便对比,图5(a)和图5(b)中呈现的在线OCSVM和在线CCA的检测结果均是算法能够到达的最佳检测结果。观察图5可知,两种在线学习算法对于真实数据的检测性能和仿真数据的检测性能基本一致,这进一步证明了本文所提在线异常检测算法的有效性。




图4 在线CCA算法和CCA算法的性能对比图




图5 在线异常检测算法在真实网络数据集上的性能对比图

6 结论

实现对物理网络的精确检测是保证虚拟化网络切片性能的首要前提。为了实现对物理网络的实时异常检测,首先,本文提出一种基于在线OCSVM的PN异常检测算法,本算法可根据每个周期内新产生的测量数据更新模型参数并推测PN的工作状态;其次,本文提出一种基于在线CCA的

PL异常检测算法,本算法可根据映射到PL两端的相邻VN测量数据之间的相关性分析PL的工作状态。最后,本文通过对模拟数据和真实网络数据分别进行仿真验证了在线OCSVM和在线CCA算法的有效性和鲁棒性。

参考文献

- [1] ORDONEZ-LUCENA J, AMEIGEIRAS P, LOPEZ D, et al.

- Network Slicing for 5G with SDN/NFV: Concepts, architectures, and challenges[J]. *IEEE Communications Magazine*, 2017, 55(5): 80–87. doi: [10.1109/MCOM.2017.1600935](https://doi.org/10.1109/MCOM.2017.1600935).
- [2] ELAYOUBI S E, JEMAA S B, ALTMAN Z, *et al.* 5G RAN slicing for verticals: Enablers and challenges[J]. *IEEE Communications Magazine*, 2019, 57(1): 28–34. doi: [10.1109/MCOM.2018.1701319](https://doi.org/10.1109/MCOM.2018.1701319).
- [3] OI A, ENDOU D, MORIYA T, *et al.* Method for estimating locations of service problem causes in service function chaining[C]. 2015 IEEE Global Communications Conference, San Diego, USA, 2016. doi: [10.1109/GLOCOM.2015.7416993](https://doi.org/10.1109/GLOCOM.2015.7416993).
- [4] YOUSAF F Z, BREDEL M, SCHALLER S, *et al.* NFV and SDN - key technology enablers for 5G networks[J]. *IEEE Journal on Selected Areas in Communications*, 2017, 35(11): 2468–2478. doi: [10.1109/JSAC.2017.2760418](https://doi.org/10.1109/JSAC.2017.2760418).
- [5] 陈前斌, 杨友超, 周钰, 等. 基于随机学习的接入网服务功能链部署算法[J]. 电子与信息学报, 2019, 41(2): 417–423. doi: [10.11999/JEIT180310](https://doi.org/10.11999/JEIT180310).
- CHEN Qianbin, YANG Youchao, ZHOU Yu, *et al.* Deployment algorithm of service function chain of access network based on stochastic learning[J]. *Journal of Electronics & Information Technology*, 2019, 41(2): 417–423. doi: [10.11999/JEIT180310](https://doi.org/10.11999/JEIT180310).
- [6] COTRONEO D, NATELLA R, and ROSIELLO S. A fault correlation approach to detect performance anomalies in virtual network function chains[C]. The 2017 IEEE 28th International Symposium on Software Reliability Engineering, Toulouse, France, 2017. doi: [10.1109/ISSRE.2017.12](https://doi.org/10.1109/ISSRE.2017.12).
- [7] SCHÖLKOPF B, PLATT J C, SHAW-TAYLOR J, *et al.* Estimating the support of a high-dimensional distribution[J]. *Neural Computation*, 2001, 13(7): 1443–1471. doi: [10.1162/089976601750264965](https://doi.org/10.1162/089976601750264965).
- [8] JIANG Qingchao and YAN Xuefeng. Multimode process monitoring using variational bayesian inference and canonical correlation analysis[J]. *IEEE Transactions on Automation Science and Engineering*, 2019, 16(4): 1814–1824. doi: [10.1109/TASE.2019.2897477](https://doi.org/10.1109/TASE.2019.2897477).
- [9] LI Xiaocan, XIE Kun, WANG Xin, *et al.* Online internet anomaly detection with high accuracy: A fast tensor factorization solution[C]. IEEE INFOCOM 2019-IEEE Conference on Computer Communications, Paris, France, 2019: 1900–1908. doi: [10.1109/INFOCOM.2019.8737562](https://doi.org/10.1109/INFOCOM.2019.8737562).
- [10] DE LA OLIVA A, LI Xi, COSTA-PEREZ X, *et al.* 5G-TRANSFORMER: Slicing and orchestrating transport networks for industry verticals[J]. *IEEE Communications Magazine*, 2018, 56(8): 78–84. doi: [10.1109/MCOM.2018.1700990](https://doi.org/10.1109/MCOM.2018.1700990).
- [11] MIAO Xuedan, LIU Ying, ZHAO Haiquan, *et al.* Distributed online one-class support vector machine for anomaly detection over networks[J]. *IEEE Transactions on Cybernetics*, 2019, 49(4): 1475–1488. doi: [10.1109/TCYB.2018.2804940](https://doi.org/10.1109/TCYB.2018.2804940).
- [12] RAHIMI A and RECHT B. Random features for large-scale kernel machines[C]. The 20th International Conference on Neural Information Processing Systems, Charlotte, USA, 2007.
- [13] SHALEV-SHWARTZ S, SINGER Y, and SREBRO N. Pegasos: Primal estimated sub-GrAdient sOlver for SVM[C]. The 24th International Conference on Machine learning, Corvallis, USA, 2007. doi: [10.1145/1273496.1273598](https://doi.org/10.1145/1273496.1273598).
- [14] JIANG Qingchao, DING S X, WANG Yang, *et al.* Data-driven distributed local fault detection for large-scale processes based on the GA-regularized canonical correlation analysis[J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(10): 8148–8157. doi: [10.1109/TIE.2017.2698422](https://doi.org/10.1109/TIE.2017.2698422).
- [15] 任驰, 马瑞涛. 网络切片: 构建可定制化的5G网络[J]. 中兴通讯技术, 2018, 24(1): 26–30. doi: [10.3969/j.issn.1009-6868.2018.01.006](https://doi.org/10.3969/j.issn.1009-6868.2018.01.006).
- REN Chi and MA Ruitao. Network slicing: Building customizable 5G network[J]. *ZTE Technology Journal*, 2018, 24(1): 26–30. doi: [10.3969/j.issn.1009-6868.2018.01.006](https://doi.org/10.3969/j.issn.1009-6868.2018.01.006).
- [16] XIE Kun, LI Xiaocan, WANG Xin, *et al.* On-line anomaly detection with high accuracy[J]. *IEEE/ACM transactions on networking*, 2018, 26(3): 1222–1235. doi: [10.1109/TNET.2018.2819507](https://doi.org/10.1109/TNET.2018.2819507).
- [17] FU Songwei and ZHANG Yan. The due/packet-delivery (v. 2015-04-01)[EB/OL]. <https://doi.org/10.15783/C7NP4Z>, 2015.
- 王威丽: 女, 1994年生, 博士生, 研究方向为虚拟化网络切片、人工智能算法等。
- 陈前斌: 男, 1967年生, 教授, 博士生导师, 研究方向为个人通信、多媒体信息处理与传输、下一代移动通信网络。
- 唐 伦: 男, 1973年生, 教授, 博士生导师, 研究方向为新一代无线通信网络、异构蜂窝网络。