

# Web 服务组合的行为推断诊断方法

贾志淳<sup>1</sup> 邢星<sup>1,2</sup>

(渤海大学信息科学与技术学院 锦州 121013)<sup>1</sup> (哈尔滨工业大学航天学院 哈尔滨 150001)<sup>2</sup>

**摘要** 随着 Web 服务以及 Web 服务组合应用软件在分布式网络中的广泛应用, Web 服务的规模和复杂性也在不断地增加, 这使得服务在运行过程中可能产生各种故障, 因此对服务系统进行及时的故障诊断与排除越来越重要。为了解决在故障诊断中系统模型不完备和历史数据中存在噪音数据这一实际问题, 提出一种基于服务行为模型的行为推断诊断方法。该方法通过加权方式结合多种诊断信息构建服务行为模型, 应用隐马尔科夫模型中的解码思想推断出与异常执行序列最匹配的 normal 执行序列, 并与观察序列进行比较, 从而发现差异定位服务故障。实验表明, 该方法应用包含不同噪音比例的诊断信息进行诊断, 其诊断准确性均高于传统的 service 故障诊断方法。

**关键词** Web 服务, 基于模型诊断, 隐马尔科夫模型, 噪音数据, 历史数据, 服务进程

**中图分类号** TP391.5 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.4.010

## Diagnosis Method of Behavior Inference in Web Service Composition

JIA Zhi-chun<sup>1</sup> XING Xing<sup>1,2</sup>

(College of Information Science and Technology, Bohai University, Jinzhou 121013, China)<sup>1</sup>

(School of Astronautics, Harbin Institute of Technology, Harbin 150001, China)<sup>2</sup>

**Abstract** With the wide applications of Web services and composite services in the distributed network, the size and complexity of Web service are increasing continuously. These could cause various faults of service system during the running. In building high-reliable service applications, one of the critical challenges is how to localize faulty service quickly and exactly and help service engine restore the normal process as soon as possible. To perfect the diagnosis model and minimize the impact of noise data on diagnosis accuracy, we presented a service behavior model-based diagnosis method of behavior inference. The method models hidden markov model by combining historical data into service process definition. On the basis of using the decoding algorithms in HMM, the method is able to infer a correct execution trace which has the maximum likelihood with the exception execution trace and localize the service faults by comparing the differences between them. The experimental results show that the method is effective and robust to various noises in diagnosing the faults of Web services.

**Keywords** Web service, Model-based diagnosis, Hidden markov model, Noise data, Historical data, Service process

## 1 引言

作为动态网络环境下一种受欢迎的分布式计算模式, 对 Web 服务组合的研究在商业业务需求的驱动下不断地向前发展。然而, 网络上的 Web 服务数量急剧增加, 组合服务进程规模不断增大, 使得在满足业务需求的同时, 组合进程的复杂性也在不断提高, 且对服务组合的可用性、可靠性以及它的容错能力提出了相当大的挑战<sup>[1]</sup>。除此之外, 网络环境的动态变化、非预期的网络失效以及其它各种外部问题也会使服务在组合过程中受到影响。以上这些不确定因素导致服务组合在运行过程中会出现各种故障, 而由于服务之间的互操作会使得这些故障在服务间不断累积和传播, 这就让服务组合的故障问题更加突出<sup>[2]</sup>。因此, 如何从大规模分布式系统中发现并移除故障, 以保证组合进程的正常运行<sup>[3]</sup>, 已经成为一个亟待解决的重要问题。

目前, 依据服务故障的特性, 研究者们已经提出了许多服务故障的诊断框架和检测、诊断及修复方法<sup>[4-10]</sup>。根据可获取的先验知识, 针对 Web 服务的故障诊断方法主要包括两大类: 基于模型的故障诊断方法<sup>[11-14]</sup>和基于历史数据的故障诊断方法<sup>[15-19]</sup>。基于模型的诊断方法利用已知的 Web 服务描述关于服务结构、功能和行为的信息来构建待诊断的 Web 服务进程模型或故障模型。这种方法提供了一种独立于进程的推理过程, 进而判断组合服务中哪些组件服务的不正确行为解释了给定的观察异常。通过使用这种形式化的模型和进程运行时的观察, 基于模型的诊断方法不仅能够识别故障的组件, 而且能够对故障的传播路径提供一种解释。然而, 传统的基于模型的诊断有一个重要的假设前提, 即系统模型是完备的。从理论上讲, 模型永远是不完备的, 因为它不是系统本身, 总有模型没有定义或无法描述的系统行为。例如, Yan<sup>[13]</sup>等人提出应用同步自动机构建服务故障模型并假设所

到稿日期: 2014-05-16 返修日期: 2014-08-12

贾志淳 (1982-), 女, 博士, 副教授, 主要研究方向为 Web 服务组合、服务故障诊断、云计算等, E-mail: zhichun.jia@bhu.edu.cn; 邢星 (1982-), 男, 博士, 副教授, 主要研究方向为社交网络挖掘、社会计算、推荐系统等。

有的故障都可以通过模型与观测的不一致性来描述,然而在实际当中这种假设往往并不成立。为此,一些研究者使用基于历史数据的诊断方法通过服务历史数据中行为执行情况,预测行为发生故障的概率,从而对服务故障进行诊断。与基于模型的诊断方法相反,基于历史数据的故障诊断方法仅以历史数据作为先验知识,通过分析历史数据构建诊断模型或对故障进行分类。该方法的优点在于它易于执行,不用分析行为间的逻辑关系,降低了诊断算法的复杂性,并且能够有效地处理数据。但此类方法也有其自身的局限性,在实际的服务诊断系统当中,历史数据内往往存在一定数量的噪音数据,这些噪音数据在很大程度上影响了诊断的精确性。例如, Dai<sup>[15]</sup>等人提出的基于错误繁殖度诊断服务故障方法,该方法的诊断精确性受限于历史数据中故障数据的准确性和覆盖范围。因此,在实际应用中我们很难获得完备的系统模型或理想的历史数据来对服务进行故障诊断。从这两种方法的优缺点可见,单一诊断方法已无法满足 Web 服务应用不断发展的诊断需求,因此构建一种混合型诊断方法是服务诊断研究的一个重要发展方向。

针对以上问题,本文扩展了文献[20]中的前期工作,构建了完善的诊断模型,并对相关参数进行了分析与验证。本文通过将 Web 组合服务的 BPEL 规约与历史运行数据转换成相同的行为模型,进而将两种诊断数据相融合,并借鉴隐马尔科夫模型中利用状态转移概率来描述行为间的依赖关系的思想,进一步分析服务行为间的依赖关系,提出一种基于行为模型的服务故障诊断方法。该方法通过系统正常行为和消息转移矩阵推断系统模型中的正常消息转移序列,并将其与观察到的异常行为序列中的消息转移序列进行比较,找到可能是故障的消息并推断出正确的消息转移替代它从而获得一个正确的消息转移序列;再应用解码思想推断出能够与求得的正确消息转移序列具有最大相似性的行为转移序列,将该行为序列与观察序列相比较找到差异,从而定位服务的故障行为,并且通过故障发生位置来分析故障发生的原因。与已有方法相比,本文方法同时使用两种数据类型构建诊断模型,从而提高了模型的精确性,通过概率分析方法可有效清除数据噪音,提高诊断的精确性。

## 2 服务行为模型

服务行为模型利用 BPEL 规约和历史数据构建用于 Web 服务故障诊断的正常行为模型,通过赋予的权重值加权合并两个子行为模型。考虑实际当中服务行为描述的不完备性以及历史数据中包含的噪音数据,将两种诊断信息按比例融合能够弥补通过单类诊断信息进行诊断的不足,完善服务诊断模型,提高诊断的准确性。其主要思想是将服务中的行为执行序列转化为行为转移概率矩阵,将服务中的消息执行序列转化为消息转移概率矩阵,以及将行为与其输出之间的依赖关系转化为观察概率矩阵。

**定义 1** 一个服务行为模型是一个六元组  $SBM = (B, M, \pi, BM, MM, OM)$ ,且:

- ①  $B$  表示一组行为集合,并且  $B = \{b_1, b_2, \dots, b_n\}$ ,其中  $n$  表示在服务中行为的个数;
- ②  $M$  表示一组可观察到的输出的消息集合,并且  $M = \{m_1, m_2, \dots, m_k\}$ ,其中  $k$  表示输出消息的个数;
- ③  $\pi$  表示初始状态分布,并且  $\pi = \{\pi_i, 1 \leq i \leq n\}$ ,  $\pi_i =$

$P(X_1 = b_i)$ ,其中  $X_1$  表示初始执行的行为;

④  $BM$  表示行为转移矩阵,并且  $BM = \{bp_{ij}, 1 \leq i, j \leq n\}$ ,  $bp_{ij} = P(X_{t+1} = b_j | X_t = b_i)$ ,其中  $bp_{ij}$  表示从第  $i$  个行为到第  $j$  个行为的转移概率,  $X_t$  表示  $t$  时刻执行的行为,且  $bp_{ij} > 0$ ,  $\sum_{j=1}^n bp_{ij} = 1$ ;

⑤  $MM$  表示消息转移矩阵,且  $MM = \{mp_{ij}, 1 \leq i, j \leq k\}$ ,  $mp_{ij} = P(Y_{t+1} = m_j | Y_t = m_i)$ ,其中  $mp_{ij}$  表示从第  $i$  个消息到第  $j$  个消息的转移概率,  $Y_t$  表示  $t$  时刻输出的消息,且  $mp_{ij} > 0$ ,  $\sum_{j=1}^k mp_{ij} = 1$ ;

⑥  $OM$  表示观察矩阵,并且  $OM = \{op_{ij}, 1 \leq i \leq n, 1 \leq j \leq k\}$ ,  $op_{ij} = P(Y_t = o_j | X_t = b_i)$ ,其中  $op_{ij}$  表示第  $i$  个行为输出第  $j$  个消息的概率,  $o_j$  表示第  $j$  个消息,  $Y_t$  表示  $t$  时刻输出的消息,  $X_t$  表示  $t$  时刻执行的行为。

### 2.1 建模 BPEL 规约

对于一个组合 Web 服务的 BPEL 规约而言,行为转移矩阵描述的是所有可能的正常的行为执行序列。类似地,消息转移矩阵描述的是所有可能的正常的消息输出序列,而观察矩阵描述的是所有执行行为与其可能的输出消息之间的正常依赖关系。由于 BPEL 规约中所有执行序列都具有相同的发生概率,因此对于行为描述中所有从同一行为转移的行为转移序列具有相同的转移概率;同样地, BPEL 规约中对于所有从同一消息转移的消息转移序列也都具有相同的转移概率;而 BPEL 规约中所有从同一行为输出的观察序列都具有相同的概率。通过下面 3 个定义分别描述了服务行为模型中应用 BPEL 规约构建的定义 1 中的行为转移矩阵、消息转移矩阵和观察矩阵,且每个定义都通过公式给出了 3 个矩阵中的元素值(即转移概率)的计算方法。

**定义 2** 一个 BPEL 规约的行为转移矩阵  $BM_1 = \{bp_{ij}^1, 1 \leq i, j \leq n\}$ ,这里:

① 对于任意的行为  $b_i$  和  $b_j$ ,  $1 \leq i, j \leq n$ ,如果在 BPEL 规约中存在  $(b_i, b_j)$  的行为转移序列,那么  $n(b_i, b_j) = 1$ ,否则  $n(b_i, b_j) = 0$ ;

$$② bp_{ij}^1 = n(b_i, b_j) / \sum_{r=1}^n n(b_i, b_r).$$

**定义 3** 一个 BPEL 规约的消息转移矩阵  $MM_1 = \{mp_{ij}^1, 1 \leq i, j \leq k\}$ ,这里:

① 对于任意的消息  $m_i$  和  $m_j$ ,  $1 \leq i, j \leq k$ ,如果在 BPEL 规约中存在  $(m_i, m_j)$  的消息转移序列,那么  $n(m_i, m_j) = 1$ ,否则  $n(m_i, m_j) = 0$ ;

$$② mp_{ij}^1 = n(m_i, m_j) / \sum_{r=1}^k n(m_i, m_r).$$

**定义 4** 一个 BPEL 规约的观察矩阵  $OM_1 = \{op_{ij}^1, 1 \leq i \leq n, 1 \leq j \leq k\}$ ,这里:

① 对于任意的行为  $b_i$  和任意的消息  $m_j$ ,  $1 \leq i \leq n, 1 \leq j \leq k$ ,如果在 BPEL 规约中的行为  $b_i$  能够输出消息  $m_j$ ,那么  $n(b_i, m_j) = 1$ ,否则  $n(b_i, m_j) = 0$ ;

$$② op_{ij}^1 = n(b_i, m_j) / \sum_{r=1}^k n(b_i, m_r).$$

### 2.2 建模历史数据

与建模 BPEL 规约一样,下面通过 3 个定义分别描述服务行为模型中应用服务运行的历史数据构建的定义 1 中的行为转移矩阵、消息转移矩阵和观察矩阵,且每个定义都通过公式给出了 3 个矩阵中的元素值(即转移概率)的计算方法。对于 Web 服务的历史数据本节做了如下假设:

(1) 历史数据中记录的是正常的执行序列,或可以根据执行结果来判断执行序列是否为正常执行,以便于选取所有正常执行的序列进行建模;

(2) 历史数据中每个执行序列都记录了执行的行为以及行为输出的消息;

(3) 历史数据集用  $hd$  来表示,且  $hd = \{esq_i, 1 \leq i \leq l\}$ ,  $l$  表示数据集  $hd$  中执行序列的个数;

(4) 在历史数据集  $hd$  中的执行序列  $esq_i = \langle o_1, o_2, \dots, o_T \rangle$  中,  $T$  表示执行的行为个数,  $o_t = (b_t, m_t)$  表示执行序列中第  $t$  个执行的行为是  $b_t$  且其输出的消息是  $m_t$ ;

(5) 对于执行序列中的每个观察值  $o_t = (b_t, m_t)$ ,  $1 \leq t \leq T$ ,  $1 \leq i \leq n$ ,  $1 \leq j \leq k$ 。

**定义 5** 一个历史数据集  $hd$  的行为转移矩阵  $BM_2 = \{bp_{ij}^2, 1 \leq i, j \leq n\}$ , 这里:

① 对于任意的  $1 \leq i, j \leq n$ ,  $n(b_i, b_j)$  表示在数据集  $hd$  中从行为  $b_i$  转移到行为  $b_j$  的个数;

$$\textcircled{2} bp_{ij}^2 = n(b_i, b_j) / \sum_{r=1}^n n(b_i, b_r)$$

**定义 6** 一个历史数据集  $hd$  的消息转移矩阵  $MM_2 = \{mp_{ij}^2, 1 \leq i, j \leq k\}$ , 这里:

① 对于任意的  $1 \leq i, j \leq k$ ,  $n(m_i, m_j)$  表示在数据集  $hd$  中从消息  $m_i$  转移到消息  $m_j$  的个数;

$$\textcircled{2} mp_{ij}^2 = n(m_i, m_j) / \sum_{r=1}^k n(m_i, m_r)$$

**定义 7** 一个历史数据集  $hd$  的观察矩阵  $OM_2 = \{op_{ij}^2, 1 \leq i \leq n, 1 \leq j \leq k\}$ , 这里:

① 对于任意  $1 \leq i \leq n, 1 \leq j \leq k$ ,  $n(b_i, m_j)$  表示在数据集  $hd$  中行为  $b_i$  输出消息  $m_j$  的个数;

$$\textcircled{2} op_{ij}^2 = n(b_i, m_j) / \sum_{r=1}^k n(b_i, m_r)$$

### 2.3 构建服务行为模型

对于服务行为模型而言,它的行为转移矩阵、消息转移矩阵以及观察矩阵就是将通过行为描述和历史数据构建的两组相同的矩阵按照一定的权重进行合并。对于 BPEL 规约的权重  $w_1$  和历史数据的权重  $w_2$ , 这里并不做具体说明,可根据实际情况进行确定,但是两个权重值之和必须等于 1, 即  $w_1 + w_2 = 1$ 。如果历史数据量大、噪音小,能够覆盖大部分正常执行情况,且 BPEL 规约相对完备,那么可以设置  $w_1 = w_2 = 0.5$ ; 如果历史数据量大且噪音小,而 BPEL 规约不完备,那么可以设置  $w_1 < w_2$ ; 再如历史数据量小或噪音大,而 BPEL 规约相对完备,那么可以设置  $w_1 > w_2$ 。

**定义 8** 一个服务行为模型的行为转移矩阵  $BM = \{bp_{ij}, 1 \leq i, j \leq n\}$ , 这里:

$$\textcircled{1} bp_{ij} = w_1 bp_{ij}^1 + w_2 bp_{ij}^2;$$

②  $w_1$  表示 BPEL 规约在模型中所占的权重,  $w_2$  表示历史数据在模型中所占的权重。

**定义 9** 一个服务行为模型的消息转移矩阵  $MM = \{mp_{ij}, 1 \leq i, j \leq k\}$ , 这里:

$$\textcircled{1} mp_{ij} = w_1 mp_{ij}^1 + w_2 mp_{ij}^2;$$

②  $w_1$  表示 BPEL 规约在模型中所占的权重,  $w_2$  表示历史数据在模型中所占的权重。

**定义 10** 一个服务行为模型观察矩阵  $OM = \{op_{ij}, 1 \leq i \leq n, 1 \leq j \leq k\}$ , 这里:

$$\textcircled{1} op_{ij} = w_1 op_{ij}^1 + w_2 op_{ij}^2;$$

②  $w_1$  表示 BPEL 规约在模型中所占的权重,  $w_2$  表示历

史数据在模型中所占的权重。

**定义 11** 一个消息观察序列  $\sigma = \{o_1, o_2, \dots, o_T\}$ , 这里:

①  $T$  表示消息观察序列  $\sigma$  中行为及其输出消息的个数;

②  $o_t$  表示观察序列中第  $t$  个执行的行为及其输出的消息,  $1 \leq t \leq T$ 。

这里需要说明的是,对于服务中的并发执行序列,由于观察序列是一个顺序序列,因此并发执行的行为及其输出的消息也是按观察到的顺序进行记录的,在使用行为描述进行建模时,对于并发结构的行为不仅要考虑行为描述中定义的正常行为及消息转移序列,而且还要考虑并发执行序列间的转移情况,即对于包含  $m$  个执行序列的并发结构中的第  $l$  个执行序列中的第  $i$  个行为  $b_i$  及其输出消息  $m_i$ ,  $bp_{i\tau}^l = 1 / (1 + \sum_{j=1}^m nb_j - nb_l)$ ,  $mp_{i\tau}^l = 1 / (1 + \sum_{j=1}^m (nm_j - nm_l))$ 。这里  $\tau$  表示第  $l$  个执行序列中的第  $i+1$  个行为  $b_{i+1}$  或其输出消息  $m_{i+1}$ , 或表示并发结构中除第  $l$  个执行序列以外的其它任何一个执行序列中的任何一个行为或消息;  $nb_j$  表示第  $j$  个执行序列中行为的个数;  $nm_j$  表示第  $j$  个执行序列中消息的个数。

## 3 行为推断诊断方法

### 3.1 消息故障推断算法

应用服务行为模型首先能够判断给定的观察序列  $\sigma$  中消息执行序列中是否存在异常的消息,即消息集中没有包含的消息或消息转移矩阵中概率小于  $\epsilon$  的消息转移序列,如果存在异常消息就寻找一个与该观察序列最匹配的消息来代替异常消息,然后获得一个与观察序列最匹配的正常消息序列。这里的  $\epsilon$  表示一个极小概率值,如果描述规约及历史数据中不包含噪音,那么  $\epsilon = 0$ ; 如果描述规约及历史数据中包含噪音,那么设定  $\epsilon_i = 1 / 2nz_i$ , 这里  $nz_i$  表示消息转移矩阵  $MM$  的第  $i$  行元素  $mp_{i\cdot}$  中概率不为 0 的元素个数。

**算法 1** CorrMS(SBM,  $\sigma$ )

输入: 服务模型 SBM, 观察序列  $\sigma$

输出: 消息序列 MS, 消息诊断解集合 DS<sub>sm</sub>

1. MS(1) =  $\sigma(1).m_1$ ;
2. IF MS(1)  $\notin$  MM
3. MS(1) =  $\max(OM(\sigma(1).b, \cdot))$ ;
4. DS<sub>sm</sub> = DS<sub>sm</sub>  $\cup$   $\sigma(1).m_1$ ;
5. END IF
6. FOR  $i = 2; \sigma.length$
7.  $tp = \sigma(i).m_1$ ;
8. IF  $MM(MS(i-1), tp) < \epsilon(MS(i-1))$
9. DS<sub>sm</sub> = DS<sub>sm</sub>  $\cup$   $\sigma(i).m$
10.  $tp = \max(OM(\sigma(i).b, \cdot)) \wedge$
11.  $MM(MS(i-1), \cdot) \geq \epsilon(MS(i-1))$ ;
12. IF  $tp = \phi$
13.  $tp = \max(MM(MS(i-1), \cdot) \geq \epsilon(MS(i-1)))$ ;
14. END IF
15. END IF
16. END FOR
17. RETURN (MS, DS<sub>sm</sub>);

算法 1 的时间复杂度为  $O((n+2k)T)$ 。

在算法 1 中,  $\max(matrix(\cdot))$  表示矩阵  $matrix$  中满足条件的所有元素中概率值最大元素。算法 1 按观察序列中从前向后的顺序依次进行诊断,首先判断观察序列中前一消息转移到下一个消息在消息转移矩阵的概率是否小于  $\epsilon$ , 如果

小于  $\epsilon$  则推断所转移到的消息发生异常;如果消息异常,则找出满足由行为  $\sigma(i)$  输出的消息且从消息  $MS(i-1)$  出发的转移序列中转移概率最大的消息,用于替换相应的异常消息;如果未找到这样的消息,那么进一步放宽匹配条件,找到从消息  $MS(i-1)$  出发的转移序列中转移概率最大的消息用于替换相应的异常消息。最后,当遍历完观察序列中的所有消息后,得到一个最匹配的正确转移序列  $MS$  和消息诊断解集合  $DS_m$ 。在时间复杂度中,  $T$  表示在消息观察序列  $\sigma$  中行为及其输出消息的个数,  $n$  表示行为转移矩阵  $BM$  中行为的个数,  $k$  表示消息转移矩阵  $MM$  中消息的个数。

### 3.2 行为故障推断算法

在获得与观察序列相匹配的正确消息序列  $MS$  之后,再应用 Viterbi 算法推断出与  $MS$  最匹配的行为序列  $BS$ , 然后通过比较  $BS$  和  $\sigma$  找出它们之间的差异,并将  $\sigma$  中与  $BS$  同一位置但与其不同的行为放入行为诊断解集合  $DS_b$  中。

**算法 2**  $CorrBS(SBM, \sigma, MS)$

输入:服务模型  $SBM$ , 观察序列  $\sigma$ , 正确消息序列  $MS$

输出:行为诊断解集合  $DS_b$

```

1. FOR  $i = 1; n$ 
2.    $\delta(1, i) = \pi(i)OM(i, MS(1));$ 
3.    $\phi(1, i) = 0;$ 
4. END FOR
5. FOR  $i = 2; T$ 
6.   FOR  $j = 1; n$ 
7.      $\delta(i, j) = \max(\delta(i-1, k)BM(k, j)) \cdot OM(j, MS(i));$ 
8.      $\phi(i, j) = \operatorname{argmax}_{1 \leq k \leq n} (\delta(i-1, k)BM(k, j));$ 
9.   END FOR
10. END FOR
11.  $q^*(T) = \operatorname{argmax}_{1 \leq k \leq n} (\delta(T, k));$ 
12. FOR  $i = T-1; 1$ 
13.    $q^*(i) = \phi(i+1, q^*(i+1));$ 
14. END FOR
15.  $BS = q^*;$ 
16. FOR  $i = 1; BS.length$ 
17.   IF  $\sigma(i).b \neq BS(i)$ 
18.      $DS_b = DS_b \cup \sigma(i).b;$ 
19.   END IF
20. END FOR
21. RETURN  $DS_b;$ 

```

算法 2 的时间复杂度为  $O(n^2 T)$ 。

在算法 2 中,  $\pi(i)$  表示行为  $i$  的初始概率, 如果行为  $i$  是开始行为, 那么  $\pi(i) = 1$ , 否则  $\pi(i) = 0$ ;  $\max(\cdot)$  表示给定集合  $\cdot$  中的最大值;  $\operatorname{argmax}_{1 \leq k \leq n}(\cdot)$  表示给定集合  $\cdot$  中有最大值的元素。算法 2 首先根据给定的正确消息序列  $MS$  计算每个行为作为开始行为的概率, 然后依次计算与消息序列  $MS$  中相应位置的消息相匹配的行为执行序列的概率, 选取具有最大概率值的行为作为与该位置消息相匹配的行为, 并将行为序号放入  $\phi$  中, 然后根据整个正确行为序列带有最大概率的最后一个执行行为从后向前推出与  $MS$  最匹配的行为序列  $BM$ , 最后比较  $BM$  与给定观察序列  $\sigma$ , 如果  $\sigma$  中的第  $i$  个行为与  $BM$  中的第  $i$  个行为不同, 那么认为  $\sigma$  中的第  $i$  个行为是故障行为, 并将其放入行为诊断解集合  $DS_b$  中。在时间复杂度中,  $T$  表示在消息观察序列  $\sigma$  中行为及其输出消息的个数,  $n$  表示行为转移矩阵  $BM$  中行为的个数。

通过算法 1 和算法 2, 不仅能够诊断出发生故障的行为以

及错误的输出, 而且可以根据消息诊断解集合和行为诊断解集合分析出故障发生原因, 即数据语义故障或行为逻辑故障。

## 4 仿真实验

### 4.1 实验设置

为了评估诊断方法的有效性, 我们使用 Matlab 实现了一个用于服务故障诊断的仿真实验系统。实验设置了两个评价准则: 准确率和噪音率。准确率是指在所有诊断中诊断正确的次数与总的诊断次数的比例; 而噪音率则是指在行为描述及历史数据中包含噪音的比例。本文定义了 3 种噪音产生操作: (1) 在工作流或执行信息中删除某个行为结点; (2) 从工作流或执行信息中任意选择两个行为结点并交换它们的位置; (3) 使用一个特殊标记替换工作流或执行信息中任意一个行为结点, 使其成为一个未知的行为。如果随着噪音率的提高, 方法的准确性没有下降或受影响很小, 就认为方法的抗噪音能力强; 反之则说明方法的抗噪能力差。

此外, 将本文提出的方法与两种诊断方法进行了比较, 一个是 Yan 等<sup>[13]</sup>提出的一种基于同步自动机模型的诊断方法, 该方法主要考虑进程中两个相关行为间的依赖关系, 并且给出了明确的诊断定义; 另一个是 Dai 等<sup>[15]</sup>提出的基于错误繁殖度的诊断方法, 该方法通过异常发生历史构建模糊异常矩阵, 矩阵使用概率描述了异常与行为间的依赖关系, 根据发生异常的观察序列计算序列中每个行为与异常的相似度, 进而判断是哪个行为发生了故障。

将以上提到的 3 种诊断方法应用于 3 个真实的 BPEL 进程中, 这 3 个 BPEL 进程的部分特征如表 1 所列。对每一个进程注入 3 种故障类型: 1) 数据故障, 即随机改变或删除变量输出的数值; 2) 数据类型不匹配故障, 即随机改变活动输出的变量的类型; 3) 行为逻辑故障, 即随机使用一个活动代替另外一个活动。

表 1 3 个 BPEL 进程的结构特征

进程	活动数	变量数	是否包含 flow	是否包含 switch	是否包含 while
进程 1	13	9	y	y	N/A
进程 2	17	20	y	y	N/A
进程 3	23	26	y	N/A	y

### 4.2 实验对比

实验是通过 3 个真实的 Web 服务, 且在诊断信息中包含不同噪音率的情况下, 比较 3 种方法的诊断准确性, 对每一个进程共注入 100 次故障, 每次注入 2 个故障, 并且在产生相应历史执行数据时给定故障行为执行失败的概率是 0.8, 异常行为抛出异常的概率也是 0.8, 而其它行为一直成功地执行。

图 1 显示的是针对进程 1 在只有历史数据作为诊断信息的情况下,  $shm$  方法与  $yan$  方法在不同噪音率下的诊断准确性的比较。从图中可以看出, 当噪音率在 0~20% 之间时,  $shm$  方法的诊断准确性远远高于  $yan$  的方法, 这是由于  $yan$  的方法在建立诊断模型时仅考虑了前后行为之间的依赖关系, 而本文方法考虑了整个执行序列之间的依赖关系, 通过从全局出发, 全面地分析行为发生故障的可能性以及发生故障的原因, 因此本文方法能够获得更高的准确性。当噪音率在 50% 时, 诊断模型受到噪音的严重干扰, 因此诊断准确性明显下降。

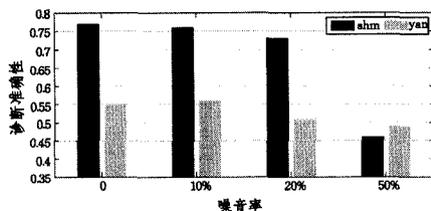


图1 基于行为描述的诊断准确性比较

图2显示的是针对进程1在只有行为描述作为诊断信息的情况下,shm方法与dai方法在不同噪声率下的诊断准确性的比较。从图中可以看出,当噪声率在0~20%之间时,shm方法的诊断准确性远远高于dai的方法,这是由于dai的方法同样仅考虑了行为与发生异常的行为之间的依赖关系,而未考虑整个执行序列与行为之间的关系,因此诊断效果不如本文方法好。另外,dai的方法仅考虑了历史故障,对未知故障的诊断能力,必然比本文方法要弱。同样地,当噪声率在50%时,两个方法的诊断模型都受到噪音的严重干扰,因此诊断准确性都非常低。

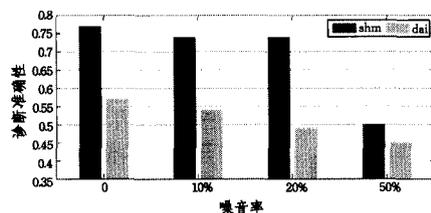


图2 基于历史数据的诊断准确性比较

从以上实验可以看出,本文方法与已有的基于模型的方法yan和基于历史数据的方法dai相比,在诊断的准确性和抗噪音能力方面都优于上述两种方法。实验表明,本文方法对于Web服务的故障诊断是非常有效的,尤其在抗噪音能力上。

**结束语** 本文提出了一个基于服务行为模型的行为推断诊断方法,用于利用多种诊断信息构建更加完备的诊断模型,进而快速准确诊断异常发生的位置及原因。该方法首先通过转移概率来分别描述服务的历史数据和BPEL规约中的行为和消息之间的依赖关系,通过给定的权重将两组概率进行合并,得到最终的服务模型。基于该模型本文方法能够推断出与异常执行最匹配的正确消息执行序列和行为执行序列,通过这两个执行序列不仅可以找到故障的行为,而且能够对故障原因提供解释。与其它诊断方法比较,该方法可以灵活地使用可获得的诊断信息完善系统模型,而且实验对比证明了本文方法的诊断效果要优于其它的诊断方法。

## 参考文献

[1] Bruning S, Weissleder S, Malek M. A Fault Taxonomy for Service-Oriented Architecture[C]//10th IEEE High Assurance Systems Engineering Symposium (HASE'07). Plano, TX, 2007:367-368

[2] 赵童童. Web服务组合中服务的选择和服务质量的研究[D]. 济南:山东师范大学,2012

[3] Armbrust M, Fox A, Griffith R, et al. A View of Cloud Computing[J]. Communications of the ACM, 2010, 53(4):50-58

[4] Peng K-L, Huang C-Y. Reliability Evaluation of Service-oriented Architecture Systems Considering Fault-tolerance Designs[J]. Journal of Applied Mathematics, 2014, 2014:1-11

[5] Carrera A, Iglesias C A, Garcia-Algarra J, et al. A Real-life Application of Multi-agent Systems for Fault Diagnosis in the Provision of An Internet Business Service[J]. Journal of Network and Computer Applications, 2014, 37:146-154

[6] Zheng Z, Lyu M R. Personalized Reliability Prediction of Web Services[J]. ACM Transactions on Software Engineering and Methodology, 2013, 22(2):1-25

[7] Yang Tao, Wei Xin, Yu Liang-wen, et al. MisDis: An Efficient Misbehavior Discovering Method Based on Accountability and State Machine in VANET[C]//The 15th Asia-Pacific Web Conference (APWeb 2013). Sydney, Australia, 2013:583-594

[8] Xue T, Ying S, Wu Q. Exception Handling in Service-oriented Software: A Survey[C]//2013 IEEE International Conference on Green Computing and Communications and IEEE Internet of Things and IEEE Cyber, Physical and Social Computing. Beijing, China, 2013:2048-2052

[9] Wagner S, Kopp O, Leymann F. Consolidation of Interacting BPEL Process Models with Fault Handlers[C]//Proceedings of the 5th Central-European Workshop on Services and their Composition (ZEUS 2013). Rostock, Germany, 2013:9-16

[10] 杜翠兰, 谭建龙, 王晓岩, 等. 基于事件处理的分布式系统故障定位技术[J]. 计算机科学, 2013, 40(Z6):302-306

[11] Ardissono L, Console L, Goy A, et al. Enhancing Web Services with Diagnostic Capabilities[C]//Proceedings of the Third European Conference on Web Services (ECOWS'05). Växjö, Sweden, 2005:182-191

[12] Li Y, Ye L, Dague P, et al. A Decentralized Model-based Diagnosis for BPEL Services[C]//Proceedings of the 2009 21st IEEE International Conference on Tools with Artificial Intelligence (ICTAI'09). Newark, NJ, 2009:609-616

[13] Yan Y, Dague P, Pencole Y, et al. A Model-based Approach for Diagnosing Faults in Web Service Processes[J]. The International Journal of Web Services Research (JWSR), 2009, 6(1):87-110

[14] 赵相福. 离散事件系统基于模型诊断的若干问题研究[D]. 长春:吉林大学, 2009

[15] Dai Y, Yang L, Zhang B, et al. Exception Diagnosis for Composite Service Based on Error Propagation Degree[C]//2011 IEEE International Conference on Services Computing (SCC 2011). Washington, DC, USA, 2011:160-167

[16] Han Xu, Shi Zhong-zhi, Niu Wen-jia, et al. Similarity-based Bayesian Learning from Semi-structured Log Files for Fault Diagnosis of Web Services[C]//2010 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology (WI-IAT). Toronto, Canada, 2010:589-596

[17] Zhu Z, Dou W. QoS-Based Probabilistic Fault-Diagnosis Method for Exception Handling [C] // New Horizons in Web-based Learning: ICWL 2010 Workshops. Shanghai, China, 2011:227-236

[18] 付晓东, 邹平, 尚振宏, 等. 基于贝叶斯网络的 Web 服务组合故障诊断[J]. 计算机应用, 2008, 28(5):1095-1100

[19] 贾志淳, 邢星. 基于贝叶斯与多故障推理的 Web 服务诊断[J]. 计算机科学, 2013, 41(6):225-230

[20] Jia Zhi-chun, Chen Rong. Hybrid Model-based Diagnosis of Web Service Compositions[C]//Proceedings of the Twenty-Seventh AAAI Conference on Artificial Intelligence (AAAI 2013). Bellevue, Washington, USA, 2013:1617-1618