

基于贝叶斯征兆解释度的链路故障定位算法*

王汝言¹, 吴 晴¹, 熊 余^{1,2}, 赵 莹¹

(1. 重庆邮电大学 重庆市光纤通信技术重点实验室, 重庆 400065; 2. 重庆大学 计算机学院, 重庆 400030)

摘 要: 针对故障和征兆关系不确定的网络中故障定位算法检测率低和误检率高的缺陷, 提出了一种基于贝叶斯征兆解释度的链路故障定位算法。该算法以概率加权的二分图作为故障传播模型, 通过处理贝叶斯后验概率信息, 定义一种新的参数贝叶斯征兆解释度, 并基于该参数对可能链路故障进行判断, 得出最优故障假设集合, 实现链路故障定位。理论分析和仿真实验表明, 该算法具有较低的计算复杂度, 且在小规模不确定网络中具有较高的故障检测率和较低的故障误检率。

关键词: 网络生存性; 故障定位; 故障传播模型; 贝叶斯网络

中图分类号: TP393; TP301.6

文献标志码: A

文章编号: 1001-3695(2013)03-0712-03

doi:10.3969/j.issn.1001-3695.2013.03.017

Link failure localization algorithm based on Bayesian symptom explained degree

WANG Ru-yan¹, WU Qing¹, XIONG Yu^{1,2}, ZHAO Ying¹

(1. Chongqing Key Laboratory of Optical Fiber Communications, Chongqing University of Posts & Telecommunications, Chongqing 400065, China; 2. College of Computer Science, Chongqing University, Chongqing 400030, China)

Abstract: Aiming at the low detection rate and high false positive rate of fault localization algorithm in network of uncertainty relationship between fault and symptoms, this paper proposed a link failure localization algorithm based on Bayesian symptom explained degree. This algorithm took probabilistic weighted bipartite graph as fault propagation model, it defined a novel parameter Bayesian symptom explained degree by handling the Bayesian posterior probability, and dealt with the possible link failure based on the parameter, then obtained the optimal fault hypothesis set and realized link failure localization. The theory analysis and simulation results show that the algorithm has lower complexity, and it has higher fault detection rate and lower false positive rate in uncertainty small size network.

Key words: network survivability; fault localization; fault propagation model; Bayesian network (BN)

0 引言

快速准确的故障监测和定位是网络业务恢复的前提, 对提升网络生存能力具有重要意义。因此, 近年来网络的链路故障定位算法成为网络生存性研究的热点^[1-5]。网络中链路发生故障时, 监测模块会收集到链路中业务产生的大量告警信息, 这些告警信息可视为该故障的征兆。然而多个故障可能会同时引发同一征兆, 即故障与征兆之间的关系是不确定的, 所以需要建立反映这种不确定性关系的故障传播模型。基于故障传播模型, 可以得到与所得征兆相关的可能故障集合。定义判别参数对其中的可能故障进行判定, 找出解释所得征兆的最优故障假设集合, 可以实现链路故障的定位。与传统的故障定位算法相比, 此类算法不需要专门的探测信号来获取链路的征兆, 大大节约了网络资源, 具有很重要的研究意义。其中, 选择精确的故障传播模型和合理的判别参数是此类算法研究的关键。

二分图模型是贝叶斯网络的简化模型, 可以简单准确地表达出故障与征兆的不确定性关系, 被广泛地用来作为故障传播模型。二分图模型下的故障定位算法主要分为两类: 基于增量

征兆事件更新的故障定位算法和基于征兆集合的故障定位算法。第一类定位算法^[6,7]能即时处理到达的征兆, 逐步更新故障假设, 计算复杂度较低, 但定位性能不稳定; 第二类算法集中分析获得的征兆集合, 得出产生所有征兆的根源故障集合, 具有较高的定位准确度, 但计算复杂度较高。因此, 此类算法的主要研究方向是降低算法复杂度。最简单的穷举法^[8]计算复杂度很高, 于是引入确定性二分图模型, 并对代码簿进行处理得到根源故障^[9], 但这种算法可移植性不高, 且不适合故障征兆不确定场合。为此建立贝叶斯网络模型, 依据近似推理算法实现网络的链路故障定位^[10,11], 但其计算复杂度较高。因此文献[12,13]将二分图作为故障传播模型, 依据故障对应的征兆数目选择根源故障, 但该算法不能描述故障与征兆间的不确定性关系; 文献[14]引入概率, 增加了二分图模型的建模能力, 基于参数贝叶斯疑似度进行定位, 以最大限度降低计算复杂度和实现准确判定故障, 但该算法在小规模网络中性能较差, 存在较高的误检率。

为了进一步改善基于征兆集合的故障定位算法的性能, 在概率加权的二分图模型下, 定义一种更合理的判别参数贝叶斯

收稿日期: 2012-06-18; **修回日期:** 2012-07-26 **基金项目:** 国家自然科学基金资助项目(60972069, 61001105); 重庆市自然科学基金重点项目(2011BA2041); 重庆市教委科学技术研究项目(KJ110531); 重庆市高校优秀人才支持计划资助项目(2011-29)

作者简介: 王汝言(1969-), 男, 湖北浠水人, 教授, 博导, 博士, 主要研究方向为全光网络理论与技术、下一代光网络故障管理机制、多媒体信息处理等; 吴晴(1989-), 男, 安徽安庆人, 硕士研究生, 主要研究方向为光通信与网络(chongqingwuqing@163.com); 熊余(1982-), 男, 四川资中人, 讲师, 博士研究生, 主要研究方向为宽带网络可靠性理论及抗毁技术; 赵莹(1988-), 女, 四川泸州人, 硕士研究生, 主要研究方向为光通信与网络。

征兆解释度 α , 在该参数的基础上提出了一种基于贝叶斯征兆解释度的链路故障定位算法 (Bayesian symptom explained degree link failure localization algorithm, BSED)。该算法计算复杂度较低, 定位性能得到改善。

1 故障定位模型与算法

1.1 故障传播模型

概率加权的二分图 (probabilistic weighted bipartite graph, PWBG) 模型 (图 1) 可以简单准确地表达出链路故障与征兆之间的关系, 主要由三个部分组成: 故障和征兆组成的二分节点集合 $V, V = F \cup S$, 其中 F 为故障集, S 为征兆集; 故障指向征兆的有向边集合 $E, E = F \times S$; 所有边权重 $p(s|f)$ 组成的集合 $P_{F \times S}, P_{F \times S} = \{p(s|f) | f \in F, s \in S\}$, 其中 $p(s|f)$ 指在故障 f 发生的条件下, 征兆 s 发生的概率值。确定性模型中, $P_{F \times S} = \{0, 1\}$; 非确定性模型中, $P_{F \times S} = (0, 1)$ 。




图1 概率加权的二分图PWBG

为了更好地对 PWBG 进行研究, 定义参数 $F(s_i)$ 、 $S(f_i)$ 和 S_o , 其中 $F(s_i)$ 表示与征兆 s_i 关联的所有故障的集合, $S(f_i)$ 表示与故障 f_i 关联的所有征兆的集合, $S_o (S_o \subset S)$ 表示系统中能够观察到的征兆集。

1.2 参数定义

目前相关文献中定义参数都表达出了故障发生的可能性大小, 但是也存在一定的缺陷。最大覆盖范围算法 MCA (max covering algorithm) [12] 采用参数覆盖范围作为故障选择标准。覆盖范围是指故障对应征兆的数目, 在不确定网络中, 覆盖范围最大的故障很可能并不是实际发生的故障, 当多个故障同时具有最大覆盖范围时, 容易出现故障误判。基于贝叶斯疑似度的故障定位算法 BSD (Bayesian suspected degree) [14] 采用参数贝叶斯疑似度作为可能故障的选择标准。比值形式的定义更精确地表达了故障发生的可能性, 但是也使得参数的精确度与故障对应的征兆数目相关。故障对应征兆数目越少, 参数的值越粗糙, 与实际故障发生的概率值相差越大; 故障对应征兆数目越多, 参数的值越精确, 与实际故障发生的概率值相差越小。当与同一征兆相关的多个可能故障对应的征兆数目相差较大时, 参数对不同故障的可能性推测的准确度相差较大, 此时, 容易出现故障误判。小规模网络中更容易出现这种情况。

本文在概率加权的二分图模型下, 对获得的贝叶斯后验概率进行分步处理, 定义参数贝叶斯征兆解释度 α 。贝叶斯征兆解释度不仅体现了一个征兆对多个相关故障反馈信息的差异性, 而且体现了多个征兆对同一相关故障提供信息的差异性, 更精确地表达出了故障发生的可能性。贝叶斯征兆解释度 α 的定义过程分为以下三步:

a) 求取贝叶斯后验概率信息。根据式 (1), 即贝叶斯公式, 依次求出后验概率 $p(f_j | s_i)$, $s_i \in S_N, f_j \in F(s_i)$ 。其中: $p(f_j |$

$s_i)$ 表示征兆 s_i 出现的条件下, 故障 f_j 发生的概率, $p(f_j | s_i)$ 值越大, 故障 f_j 解释征兆 s_i 的可能性越大。

$$p(f_j | s_i) = \frac{p(f_j)p(s_i | f_j)}{\sum_{f \in F(s_i)} p(f)p(s_i | f)} \quad (1)$$

b) 归一化处理贝叶斯概率信息。对于不同的故障 $f_j \in F(s_i)$, $p(f_j | s_i)$ 值是不同的, 具有差异性, 所以不同的 $f_j \in F(s_i)$ 对征兆 $s_i (s_i \in S_N)$ 的解释程度是不同的。经过归一化计算得到故障 f_j 对征兆 s_i 的解释度 $\alpha(f_j, s_i)$, 不仅能够保证征兆 s_i 能被故障集合 $F(s_i)$ 中至少一个故障解释, 而且可以表达出选择故障 f_j 来解释征兆 s_i 的可能性大小。对每一个征兆 $s_i (s_i \in S_N)$, 根据式 (2) 对其提供的后验概率 $p(f_j | s_i)$ 进行归一化计算, 定义故障 $f_j (f_j \in F(s_i))$ 对征兆 s_i 的解释度 $\alpha(f_j, s_i)$ 。从统计学角度看, $\alpha(f_j, s_i)$ 的值可以定义为故障 f_j 可以解释征兆 s_i 的个数。

$$\alpha(f_j, s_i) = \frac{p(f_j | s_i)}{\sum_{f \in F(s_i)} p(f | s_i)} \quad (2)$$

c) 计算故障的贝叶斯征兆解释度 α 。对 $f \in F$, 根据式 (3) 逐一计算可能故障 f 对征兆集合 S_N 的贝叶斯征兆解释度 $\alpha(f, S_N)$ 。 $\alpha(f, S_N)$ 值的大小表示故障 f 解释征兆集合 S_N 中征兆的个数。 $\alpha(f, S_N)$ 值越大, 故障发生的可能性越大。

$$\alpha(f, S_N) = \sum_{s_i \in S(f)} \alpha(f, s_i) \quad (3)$$

1.3 算法步骤

BSED 算法使用参数贝叶斯征兆解释度 α 来度量故障发生的可能性。其算法主要思想是依据发生的可能性对可能故障进行排序, 然后通过启发式方法对排序后的集合进行求解, 找出最有可能解释观察到的征兆集合 $S_N (S_N \subset S_o)$ 的故障假设集合 H 。也就是说, 对每一个征兆进行处理得到相关故障对此征兆的解释度 $\alpha(f, s_i)$, 求和可得每个可能故障对征兆集合 S_N 的解释度 $\alpha(f, S_N)$, 依据 $\alpha(f, S_N)$ 的大小对可能故障进行排列, 依次取出对应的可能故障对获得的征兆集合进行解释, 将可以更新解释征兆集合的故障加入故障假设集合 H 中, 直至所有征兆都被解释完为止。

求取 $F(S_N)$ 中每个故障 f 的贝叶斯征兆解释度 $\alpha(f, S_N)$, 构成集合 F_α , 并对 F_α 中元素从大到小排序。当 F_α 中最有可能的前 m 个故障完全覆盖了所有观测到的征兆集合 S_N 时, 则认为找到了最优的故障假设集合。

假设: Noisy-OR 模型, 即引起某个征兆的多个故障相互独立, 任何一个故障都可以引起该征兆发生; 故障独立假设, 即不同故障相互独立。输入为: 故障传播模型 $FPM = (F, S, P_F, P_{F \times S})$; 可观察征兆集合 S_o ; 在单个时间窗口中观察到的征兆集合 $S_N \subset S_o$; 征兆可观察率 $OR (OR = |S_o|/|S|)$; 征兆丢失率 $LR (s) (s \in S_o)$; 征兆虚假率 $SSR (s) (s \in S_o)$ 。输出为: 能够对 S_N 作出解释的最优故障假设集 H 。 S_N 中每个征兆被 H 中的至少一个故障解释, H 中包含的故障最有可能产生征兆集合 S_N 。

Algorithm BSED 算法:

a) 设 $H = \emptyset$ 。

b) 对每一个征兆 $s_j (s_j \in S_N)$, 找出其可能故障集合, 构成待选故障子集 $F(S_N)$, $F(S_N) = \{f | f \in F, s \in S(f) \cap S_N\}$ 。

c) 对应 $F(S_N)$ 中每一个故障 f_i , 计算 $\alpha(f_i, S_N)$, 加入集合 F_α 中。

d) 初始化征兆集合 S_α 为空。

e) 对集合 F_α 中的征兆解释度由高向低进行排序, 依次取

出 $a \in F_a$ 循环执行,直至 $|S_a \cap S_N|/|S_N|=1$ 。

- 获得 a 对应的 f_i ;
- 获得 f_i 对应的 $S_i, S_i = S(f_i) \cap S_N$;
- 如果 $S_a \cup S_i - S_a \neq \emptyset$, 则 $S_a = S_a \cup S_i, H = H \cup \{f_i\}$ 。
- 输出故障假设集合 H 。

1.4 算法复杂度分析

基于增量征兆事件更新的故障定位算法计算复杂度较低, IHU (incremental hypothesis updating) 算法^[6]和 IBSD (incremental Bayesian suspected degree) 算法^[7]的复杂度均为 $O(|F|^2 \times |S|)$, 其中 $|F|$ 为故障数目, $|S|$ 为征兆数目。基于征兆集合的故障定位算法的算法复杂度相对较高。文献^[10,11]中引入三种近似推理算法, 计算复杂度较高, 依次为 $O(|F|^2 \times \exp|F|)$ 、 $O(|F|^5)$ 和 $O(|F|^6)$ 。基于二分图模型的最大覆盖范围算法 MCA/MCA+^[12,13]的计算复杂度得到降低, 为 $O(|F| \times |S|^2)$ 。BSD 算法^[14]引入概率, 算法的计算复杂度得到进一步降低, 仅为 $O(|F| \times |S|)$ 。本文算法对每一个故障只求取一次贝叶斯征兆解释度, 并将能更新征兆解释集合的故障加入故障假设集合中, 算法计算复杂度与 BSD 算法相同, 仅为 $O(|F| \times |S|)$ 。

2 仿真结果和分析

2.1 仿真实验

与文献^[14]类似, 本文仿真环境由四个模块组成: 网络生成模块、故障征兆关系生成模块、故障用例生成模块和根源故障定位模块。仿真过程具体如下:

a) 网络生成模块随机生成 N 个节点的任意形状的网络。将网络中直接相连的两点之间的链路定义为链接 (link), 通过一跳或多跳形成的两点之间的通路定义为路径 (path)。每个链接对应一个链路故障, 每个路径对应一个征兆, 一个故障可能会导致多个征兆发生。找出所有链接组成的故障集 F 和所有路径组成的征兆集 S 。生成故障集和征兆集及两个集合间的对应关系。

b) 故障征兆关系生成模块生成故障集 F 和征兆集 S 之间定量的非确定性关系 P_F 和 $P_{F \times S}$ 。其中, P_F 服从 $(0.001, 0.1)$ 的均匀分布; $P_{F \times S}$ 服从 $(0, 1)$ 的均匀分布。

c) 故障用例生成模块生成 CASENUM 个用例集。按照 P_F 生成故障, 每个故障 f 按照 $P_{F \times S}$ 生成征兆 $S(f)$ 。 $S(f)$ 中的征兆信息按照参数 $LR(s)$ 的概率丢失; 按照 OR 生成可观察征兆集合 $S_o, S_o - S(f)$ 中的征兆信息按照参数 $SSR(s)$ 的概率生成虚假征兆。在 6~30 节点的网络中, 对应相应的参数, 生成 100 个随机的有效单故障案例。

d) 根源故障定位模块根据算法进行故障定位和输出定位结果与性能。 S_i 定义为观察到的 i 个征兆形成的集合 $S_i = \{s_1, s_2, \dots, s_i\}$, F_C 为产生这些征兆的实际故障集合。

本文算法为 BSED, 对比算法为 MCA 和 BSD, 其中 MCA 算法是一种定义参数表达故障可能性的经典算法, BSD 算法是目前相关算法中一种计算复杂度较低且算法性能很高的算法。

单个窗口中, 算法输入均为 S_{Ni} , 输出为故障假设集合 H , 故障检测率 (detection rate) $DR(S_{Ni}), DR(S_{Ni}) = |H \cap F_C|/|F_C|$, 故障误检率 (false positive rate) $FPR(S_{Ni}), FPR(S_{Ni}) = |H - F_C|/|H|$ 。

设窗口数为 m , 最后输出为: 故障检测率 $DR = \sum_{i=1}^m DR(S_{Ni})/m$, 故障误检率 $FPR = \sum_{i=1}^m FPR(S_{Ni})/m$ 。

2.2 结果分析

图 2 为三种算法的故障检测率比较。网络规模为 6~24 节点时, BSED 算法的故障检测率在 94.20%~98.57% 之间, 平均为 96.57%; BSD 算法的故障检测率在 94.00%~96.82% 之间, 平均为 94.96%; MCA 算法的故障检测率在 75.4%~84.1% 之间, 平均为 78.14%。网络规模较小时, BSED 算法具有较高的故障检测率, 相比性能较好的 BSD 算法, 最大可高出 3.61%。当网络规模大于 25 节点时, BSED 算法的故障检测率比 BSD 算法低, 但仍能保持在 90% 以上。

图 3 为三种算法的故障误检率比较。网络规模为 6~24 节点时, BSED 算法的故障误检率在 3.47%~8.98% 之间, 平均为 5.89%; BSD 算法的故障误检率在 4.57%~10.18% 之间, 平均为 7.19%; MCA 算法的故障误检率在 15.9%~24.6% 之间, 平均为 21.86%。网络规模较小时, BSED 算法的故障误检率较小, 相比性能较好的 BSD 算法, 最高可低 1.93%。




图2 故障检测率($OR=100\%$, $LR=0, SSR=0$)




图3 故障误检率($OR=100\%$, $LR=0, SSR=0$)

下面对仿真结果的原因作简要分析。当多个故障同时具有最大覆盖范围时, MCA 算法中可能会出现故障误判。由于多个故障同时具有最大覆盖范围的情况与网络大小无关, 所以 MCA 算法的故障检测率和故障误检率基本保持在平均水平。随着网络规模的增大, 网络中的每个业务的平均跳数也会随之增加, 导致观察到的业务征兆集合对应的可能故障集合包含的可能故障数量增加。可能故障数量越大, 对故障判断的干扰也越大, 所以, BSED 算法的故障检测率呈逐步下降的趋势, 故障误检率呈逐步上升的趋势。在网络规模小于 21 节点时, 随着网络规模的增大, 与故障征兆相关的不同故障对应的征兆数目相差越来越大, 导致 BSD 算法的故障检测率逐步下降, 故障误检率逐步上升; 而当网络规模大于 21 节点时, 随着网络规模的增大, 与故障征兆相关的不同故障对应的征兆数目相差越来越小, 使得算法的故障检测率逐步上升, 故障误检率逐步下降。

3 结束语

在概率加权的二分图模型的基础上, 对贝叶斯概率进行合理的处理, 定义了一种新的判别参数贝叶斯征兆解释度, 并在此参数的基础上提出了一种基于贝叶斯征兆解释度的链路故障定位算法 BSED。与目前性能较好的算法比较, 该算法在低计算复杂度的情况下, 在小规模不确定网络中具有更好的性能。由于可能故障数量的增加会导致算法性能的下降, 所以 BSED 算法在较大规模的网络中性能相对较差。为了进一步完善算法, 需要对可能故障集合进行初步筛选, 减少集合中可能故障数量。因此, 如何有效地对可能故障集合进行筛选, 将作为进一步研究的工作。

(下转第 719 页)

二阶段相似度学习的协同过滤推荐算法具有较高的计算效率。

5 结束语

针对传统的基于最近邻协同过滤推荐算法在相似度计算中的缺陷,本文提出了基于二阶段相似度学习的协同过滤推荐算法,该算法通过邻居海选和精选两个阶段实现了相似度的学习。实验表明,在海选邻居数选取适当时,本文提出的二阶段相似度学习推荐算法在 MAE 和 RMSE 性能指标上都明显优于传统的基于 K-NN 的协同过滤推荐算法,具有较高的推荐准确度,而且算法无须进行深度迭代,具有收敛速度快、可分布式计算等优点,这使得相似度随评分数据的更新能够在线动态调整,提高了算法的灵活性。另外,在实验中还发现了当训练数据极度稀疏时,由于整个训练数据集稀疏到无法表征整个评分矩阵的数据关系,这会导致基于二阶段相似度学习算法的误差性能改善空间减小甚至不再改善。因此,如何提高算法在数据极度稀疏下的性能是进一步研究的重点内容。

参考文献:

- [1] MICHAEL J, ANDREAS T, ROBERT L. Combining predictions for accurate recommender systems[C]//Proc of the 16th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2010: 693-702.
- [2] 吴金龙. Netflix Prize 中的协同过滤算法[D]. 北京: 北京大学, 2010.
- [3] ROBERT B, YEHUDA K, CHRIS V. Modeling relationships at multiple scales to improve accuracy of large recommender systems[C]//Proc of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2007: 95-104.
- [4] SU Xiao-yuan. Collaborative filtering recommendation using machine learning and statistical techniques [D]. Boca Raton: Florida Atlantic University, 2008.
- [5] 查文琴, 梁昌勇, 曹镭. 基于用户聚类的协同过滤推荐方法[J]. 计算机技术与发展, 2009, 19(6): 69-75.
- [6] 项亮. 动态推荐系统关键技术研究[D]. 北京: 中国科学院研究生院, 2011.
- [7] DAVID P, ERIC H, STEVE L, *et al.* Collaborative filtering by personality diagnosis: a hybrid memory and model based approach[C]//Proc of National Conference on Artificial Intelligence. San Francisco: Morgan Kaufmann Publishers Inc, 2000: 473-480.
- [8] RASHID A M, LAM S K, KARYPIS G, *et al.* ClustK-NN: a highly scalable hybrid model & memory-based CF algorithm [C]//Proc of the 12th ACM SIGKDD International Conference on KDD and Data Mining. New York: ACM Press, 2006.
- [9] CHEN Zhi-min, JIANG Yi, ZHAO Yao. A collaborative filtering recommendation algorithm based on user interest change and trust evaluation[J]. International Journal of Digital Content Technology and its Applications, 2010, 4(9): 106-113.
- [10] PAUL R, NEOPHYTOS L, MITESH S, *et al.* GroupLens: an open architecture for collaborative filtering of netnews [C]//Proc of ACM Conference on Computer Supported Cooperative Work. New York: ACM Press, 1994: 175-186.
- [11] SUN Duo, ZHOU Tao, LIU Jian-guo, *et al.* Information filtering based on transferring similarity[J]. Physical Review E, 2009, 80(1): 017101.
- [12] 陈宝林. 最优化理论与算法[M]. 北京: 清华大学出版社, 2005: 254-392.
- [13] 张学胜. 面向数据稀疏的协同过滤推荐算法研究[D]. 合肥: 中国科学技术大学, 2011.
- [14] 熊忠阳, 刘芹, 张玉芳, 等. 基于项目分类的协同过滤改进算法[J]. 计算机应用研究, 2012, 29(2): 493-496.
- [15] PANG Yan-wei, MA Zhao, PAN Jing, *et al.* Robust sparse tensor decomposition by probabilistic latent semantic analysis [C]//Proc of the 6th International Conference on Image and Graphics. 2011: 893-896.
- [16] HERLOCKER J, KONSTAN J, BORCHERS A, *et al.* An algorithmic framework for performing collaborative filtering [C]//Proc of Conference on Research and Development in Information Retrieval. New York: ACM Press, 1999: 230-237.
- [1] STANIC S, SUBRAMANIAM S, SAHIN G, *et al.* Active monitoring and alarm management for fault localization in transparent all-optical networks [J]. IEEE Trans on Network and Service Management, 2010, 7(2): 118-131.
- [2] ZENG Hong-qing, HUANG Chang-cheng, VUKOVIC A. Spanning-tree based monitoring-cycle construction for fault detection and localization in mesh AONs [C]//Proc of IEEE International Conference on Communications. 2005: 1726-1730.
- [3] TAPOLCAI J, PINHAN H O, RONYAI L, *et al.* Failure localization for shared risk link groups in all-optical mesh networks using monitoring trails [J]. Journal of Lightwave Technology, 2011, 29(10): 1597-1606.
- [4] SOLE-PARETA J, SUBRAMANIAM S, CAREGLIO D, *et al.* Cross-layer approaches for planning and operating impairment-aware optical networks [J]. Proceedings of the IEEE, 2012, 100(5): 1118-1129.
- [5] WU Bin, HAN Ho-pin, YEUNG K L, *et al.* Optical layer monitoring schemes for fast link failure localization in all-optical networks [J]. IEEE Communications Surveys & Tutorials, 2011, 13(1): 114-125.
- [6] STEINDER M, SETHI A S. End-to-end service failure diagnosis using belief networks [C]//Proc of IEEE/IFIP Network Operations and Management Symposium. 2002: 375-390.
- [7] 张成, 廖建新, 朱晓民. 一种基于增量贝叶斯疑似度的事件驱动故障定位算法[J]. 电子与信息学报, 2009, 31(6): 1501-1504.
- [8] KATZELA I, SCHWARTZ M. Schemes for fault identification in communication networks [J]. IEEE/ACM Trans on Networking, 1995, 3(6): 733-764.
- [9] YEMINI S, KLIGER A, MOZES S, *et al.* High speed and robust event correlation [J]. Communications Magazine, 1996, 34(5): 82-90.
- [10] STEINDER M, SETHI A S. Probabilistic fault localization in communication systems using belief networks [J]. IEEE/ACM Trans on Networking, 2004, 12(5): 809-822.
- [11] STEINDER M, SETHI A S. Probabilistic event-driven fault diagnosis through incremental hypothesis updating [C]//Proc of IFIP/IEEE International Symposium on Integrated Network Management. 2003: 635-648.
- [12] HUANG Xiao-hui, ZOU Shi-hong, WANG Wen-dong, *et al.* Fault management for Internet service: modeling and algorithms [C]//Proc of IEEE International Conference on Communications. 2006: 854-859.
- [13] 黄晓慧, 邹仕洪, 王文东, 等. Internet 服务故障管理: 分层模型和算法 [J]. 软件学报, 2007, 18(10): 2584-2594.
- [14] 张成, 廖建新, 朱晓民. 基于贝叶斯疑似度的启发式故障定位算法 [J]. 软件学报, 2010, 21(10): 2610-2621.

(上接第 714 页)

参考文献: