



(12) 发明专利

(10) 授权公告号 CN 102882703 B

(45) 授权公告日 2015.08.19

(21) 申请号 201210320169.6

(22) 申请日 2012.08.31

(73) 专利权人 赛尔网络有限公司

地址 100084 北京市海淀区中关村东路 1 号
院清华科技园 8 号楼 B 座赛尔大厦

(72) 发明人 何旭 李威 黄友俊 李星
吴建平

(74) 专利代理机构 中科专利商标代理有限责任
公司 11021

代理人 宋焰琴

(51) Int. Cl.

H04L 12/24(2006.01)

H04L 12/26(2006.01)

H04L 29/08(2006.01)

(56) 对比文件

CN 101453424 A, 2009.06.10, 第 6 页第 1 段
至第 7 页第 26 行, 第 8 页第 14 至第 18 行, 第 9 页

13 行至 16 行 .

CN 102055620 A, 2011.05.11, 说明书第
[0111] 段至第 [0116] 段, 第 [0119] 段至第
[0123] 段, 附图 1-3.

CN 101453424 A, 2009.06.10, 第 6 页第 1 段
至第 7 页第 26 行, 第 8 页第 14 至第 18 行, 第 9 页
13 行至 16 行 .

WO 02/099688 A1, 2002.12.12, 全文 .

WO 2006/077454 A1, 2006.07.27, 全文 .

CN 102394885 A, 2011.03.28, 全文 .

US 2008/0059508 A1, 2008.04.06, 全文 .

CN 101872347 A, 2010.10.27, 全文 .

审查员 杜宇坤

权利要求书3页 说明书8页 附图4页

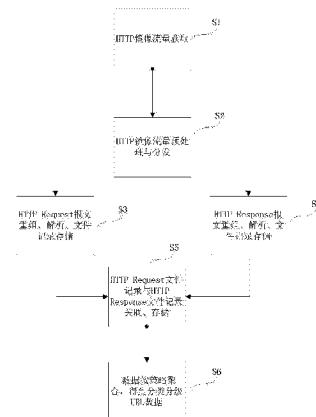
(54) 发明名称

一种基于 HTTP 分析的 URL 自动分类分级的系
统及方法

(57) 摘要

本发明公开了一种基于 HTTP 分析的 URL 自
动分类分级的系统和方法, 该系统包括用于分发
HTTP 请求 / 响应报文镜像数据流的 HTTP 请求 /
响应报文预处理器、用于对 HTTP 请求报文镜像数
据流进行重组的 HTTP 请求报文解析服务器、用于
对 HTTP 响应报文镜像数据流进行重组的 HTTP 响
应报文解析服务器、交换机、用于存储报文信息的
HTTP 存储关联服务器和用于对 URL 进行自动分类
分级的 HTTP 分级分类服务器。该方法包括以下步
骤 : 预处理 HTTP 报文镜像数据流得到 HTTP 请求 /
响应报文镜像数据流, 并对其进行分发 ; 对请求 /
响应报文镜像数据流进行重组, 将从重组数据中
提取到的报文信息存储起来 ; 对存储的信息进行
关联 ; 根据关联信息对 URL 分类分级。本发明能够
实现对 URL 的高效的分类分级。

CN 102882703



1. 一种基于 HTTP 分析的 URL 自动分类分级系统, 其特征在于, 该系统包括 HTTP 请求 / 响应报文预处理器、HTTP 请求报文解析服务器、HTTP 响应报文解析服务器、交换机、HTTP 存储关联服务器和 HTTP 分级分类服务器, 其中 :

所述 HTTP 请求 / 响应报文预处理器用于接收 HTTP 报文镜像数据流并对其进行预处理得到 HTTP 请求报文镜像数据流和 HTTP 响应报文镜像数据流, 并将所述 HTTP 请求报文镜像数据流发给所述 HTTP 请求报文解析服务器, 将 HTTP 响应报文镜像数据流发给所述 HTTP 响应报文解析服务器, 其中, 所述预处理为 : 根据 TCP 层的端口号, 将目的端口号为 80、8080、443 的 HTTP 报文镜像数据流标识为 HTTP 请求报文镜像数据流, 将源端口号为 80、8080、443 的 HTTP 报文镜像数据流标识为 HTTP 响应报文镜像数据流 ;

所述 HTTP 请求报文解析服务器与所述 HTTP 请求 / 响应报文预处理器连接, 用于对所接收的 HTTP 请求报文镜像数据流进行重组处理, 从重组后的数据流中提取报文信息, 并将所述报文信息以 HTTP 请求文件记录的形式存储到所述 HTTP 存储关联服务器上 ;

所述 HTTP 响应报文解析服务器与所述 HTTP 请求 / 响应报文预处理器连接, 用于对所接收的 HTTP 响应报文镜像数据流进行重组处理, 从重组后的数据流中提取报文信息, 并将所述报文信息以 HTTP 响应文件记录的形式存储到所述 HTTP 存储关联服务器上 ;

所述交换机与 HTTP 请求 / 响应报文预处理器、HTTP 请求报文解析服务器、HTTP 响应报文解析服务器、HTTP 存储关联服务器、HTTP 分类分级服务器相连, 用于对 HTTP 请求 / 响应报文预处理器、HTTP 请求报文解析服务器、HTTP 响应报文解析服务器及运行其上的程序进行远程配置管理, 同时也作为 HTTP 请求报文解析服务器、HTTP 响应报文解析服务器、HTTP 存储关联服务器、HTTP 分类分级服务器之间的数据传输通道 ;

所述 HTTP 存储关联服务器与所述交换机相连, 用于根据所述报文信息中的五元组信息, 将所述 HTTP 请求文件记录与所述 HTTP 响应文件记录进行关联, 并将关联上的数据以记录格式按行存入存储文件 ;

所述 HTTP 分类分级服务器与所述交换机相连, 用于根据用户定制的策略, 通过所述交换机访问所述 HTTP 关联存储服务器中的记录信息, 对 URL 进行分类分级。

2. 根据权利要求 1 所述的系统, 其特征在于, 所述五元组信息包括 : 客户端 IP 地址 client_ip、服务器 IP 地址 server_ip、客户端端口号 client_port、服务器端口号 server_port 和关联序列号 rel_seqno。

3. 一种基于 HTTP 分析的 URL 自动分类分级方法, 其特征在于, 该方法包括以下步骤 :

步骤 S1, 在骨干网的路由器上获取 HTTP 报文镜像数据流 ;

步骤 S2, HTTP Request/Response 报文预处理器对所述 HTTP 报文镜像数据流进行预处理得到 HTTP 请求报文镜像数据流和 HTTP 响应报文镜像数据流, 并将所述 HTTP 请求报文镜像数据流发给 HTTP 请求报文解析服务器, 将 HTTP 响应报文镜像数据流发给 HTTP 响应报文解析服务器, 其中, 所述预处理为 : 根据 TCP 层的端口号, 将目的端口号为 80、8080、443 的 HTTP 报文镜像数据流标识为 HTTP 请求报文镜像数据流, 将源端口号为 80、8080、443 的 HTTP 报文镜像数据流标识为 HTTP 响应报文镜像数据流 ;

步骤 S3, 所述 HTTP 请求报文解析服务器对所接收的 HTTP 请求报文镜像数据流进行重组处理, 并将从重组后的数据流中提取到的报文信息以 HTTP 请求文件记录的形式存储到所述 HTTP 存储关联服务器上 ;

步骤 S4, 所述 HTTP 响应报文解析服务器对所接收的 HTTP 响应报文镜像数据流进行重组处理, 并将从重组后的数据流中提取到的报文信息以 HTTP 响应文件记录的形式存储到所述 HTTP 存储关联服务器上;

步骤 S5, HTTP 存储关联服务器根据由 client_ip、server_ip、client_port、server_port、rel_seqno 组成的五元组信息, 将所述 HTTP 请求文件记录与所述 HTTP 响应文件记录进行关联, 并将关联上的数据以记录格式按行存入存储文件;

步骤 S6, HTTP 分类分级服务器根据用户定制的策略, 访问所述 HTTP 关联存储服务器中的记录信息, 将 URL 进行分类分级。

4. 根据权利要求 3 所述的方法, 其特征在于, 所述步骤 S3 中提取的报文信息包括: 客户端 IP 地址 client_ip、服务器 IP 地址 server_ip、客户端端口号 client_port、服务器端口号 server_port、关联序列号 rel_seqno、主机 Host、请求 URL 请求 -URL; 所述步骤 S4 中提取的报文信息包括: 客户端 IP 地址 client_ip、服务器 IP 地址 server_ip、客户端端口号 client_port、服务器端口号 server_port、关联序列号 rel_seqno、内容类型 Content-Type、内容编码 Content-Encoding、内容语言 Content-Language、内容长度 Content-Length。

5. 根据权利要求 3 所述的方法, 其特征在于, 所述步骤 S3 中, 所述 HTTP 请求报文解析服务器对所述 HTTP 请求报文镜像数据流进行重组处理进一步包括以下步骤:

步骤 S300, 获取所述 HTTP 请求报文镜像数据流的当前 TCP 分片;

步骤 S310, 解析所述 HTTP 请求报文的 IP/TCP 报首, 从中获取客户端 IP 地址 client_ip, 服务器 IP 地址 server_ip, 客户端端口号 client_port, 服务器端口号 server_port, ack 序列号 ack_seqno, 根据获取的这些信息计算出下一报文序列号 next_seqno 和关联序列号 rel_seqno; 根据 HTTP 请求报文的报首特征, 判断该 TCP 分片是否为 HTTP 请求报文报首的第一个 TCP 分片, 若是, 则继续判断 HTTP 请求报文的报首是否完整, 如果完整则进入步骤 S320, 否则进入步骤 S330; 如果该 TCP 分片不是 HTTP 请求报文报首的第一个 TCP 分片, 则以 client_ip, server_ip, client_port, server_port, ack_seqno 为索引查找预先存储的 HTTP 流表, 判断所述 HTTP 流表中是否有与所述索引匹配的流表表项, 如果是则进入步骤 S340, 否则结束本次流程, 回到步骤 S300 进入下一次流程;

步骤 S320, 解析所述 HTTP 请求报文的报首, 从中提取出 HTTP 版本号 HTTP Version, 请求 URI Request-URI, 主机 Host; 将所述步骤 S310 得到的 client_ip, server_ip, client_port, server_port, rel_seqno, Host, Request-URI 以 HTTP 请求文件记录的形式写入 HTTP 关联存储服务器, 并删除所述匹配的 HTTP 流表表项, 结束本次流程, 回到步骤 S300 进入下一次流程;

步骤 S330, 以 client_ip, server_ip, client_port, server_port, ack_seqno 为索引, 新建一个 HTTP 流表表项, 结束本次流程, 回到步骤 S300 进入下一次流程;

步骤 S340, 对与所述索引匹配的 HTTP 流表表项进行 TCP 重组, 然后再判断所述 HTTP 请求报文的报首是否完整, 若完整则返回步骤 S320, 否则结束本次流程, 回到步骤 S300 进入下一次流程。

6. 根据权利要求 3 所述的方法, 其特征在于, 所述步骤 S4 中, 所述 HTTP 响应报文解析服务器对所述 HTTP 响应报文镜像流进行重组处理进一步包括以下步骤:

步骤 S400, 获取所述 HTTP 响应报文镜像数据流的当前 TCP 分片, 进入步骤 S410 ;

步骤 S410, 解析所述 HTTP 响应报文镜像数据流的 IP/TCP 报首, 从中获取客户端 IP 地址 client_ip, 服务器 IP 地址 server_ip, 客户端端口号 client_port, 服务器端端口号 server_port, ack 序列号 ack_seqno, 根据获取的这些信息计算下一报文序列号 next_seqno 和关联序列号 rel_seqno ; 根据 HTTP 响应报文的报首特征, 判断该 TCP 分片是否为 HTTP 响应报文报首的第一个 TCP 分片, 若是, 则继续判断 HTTP 响应报文的报首是否完整, 如果完整则进入步骤 S420, 否则进入步骤 S430 ; 如果该 TCP 分片不是 HTTP 响应报文报首的第一个 TCP 分片, 则以 client_ip, server_ip, client_port, server_port, ack_seqno 为索引查找预先存储的 HTTP 流表, 判断所述 HTTP 流表中是否有与所述索引匹配的流表表项, 如果是则进入步骤 S440, 否则结束本次流程, 回到步骤 S400 进入下一次流程 ;

步骤 S420, 解析所述 HTTP 响应报文的报首, 从中提取出状态码 Status-Code, 内容类型 Content-Type, 内容长度 Content-Length, 内容编码 Content-Encoding, 内容语言 Content-Language, 并将所述步骤 S410 得到的 client_ip, server_ip, client_port, server_port, rel_seqno, Status-Code, Content-Type, Content-Length, Content-Encoding, Content-Language 以 HTTP 响应文件记录的形式写入 HTTP 关联存储服务器, 并删除所述匹配的 HTTP 流表表项, 结束本次流程, 回到步骤 S400 进入下一次流程 ;

步骤 S430, 以 client_ip, server_ip, client_port, server_port, ack_seqno 为索引, 新建一个 HTTP 流表表项, 结束本次流程, 回到步骤 S400 进入下一次流程 ;

步骤 S440, 对与所述索引匹配的 HTTP 流表表项进行 TCP 重组, 然后再判断所述 HTTP 响应报文的报首是否完整, 若完整则返回步骤 S420, 否则结束本次流程, 回到步骤 S400 进入下一次流程。

7. 根据权利要求 3 所述的方法, 其特征在于, 所述记录格式包含如下字段 :client_ip, server_ip, Host, URL, Content-Type, Content-Length, Content-Encoding, Content-Language。

8. 根据权利要求 4 所述的方法, 其特征在于, 所述步骤 S6 进一步包括以下步骤 :

步骤 S61, 从 HTTP 请求文件记录中提取出属性信息 URL、Host ;

步骤 S62, 从 HTTP 响应文件记录中提取出属性信息 Content-Type、Content-Encoding、Content-Language、Content-Length ;

步骤 S63, 根据属性信息 Content-Type、Content-Encoding、Content-Language、Content-Length、Host 对 URL 进行分级和分类。

一种基于 HTTP 分析的 URL 自动分类分级的系统及方法

技术领域

[0001] 本发明涉及网络行为监控与网络行为管理技术领域,更具体地,涉及一种基于 HTTP 分析的 URL 自动分类分级的系统及方法。

背景技术

[0002] 据互联网追踪机构 Netcraft 在 2011 年 10 月 9 日的统计报告显示:全球网站总量约 5 亿,其中真正处于活动状态的仅为 1.5 亿。根据数据分析:目前全球网站总数庞大,“垃圾网站”超过 50%,并且处于增长态势,互联网环境有待于清理及净化。在中国社会科学院 2011 年发布的《新媒体蓝皮书》中显示:2010 年中国互联网站总数达 191 万,网页数量 600 亿。

[0003] 众所周知,互联网上的网页和所有其他资源都是通过 URL 标识的,而网络资源访问的一半以上是通过 HTTP 协议承载的。面对如此众多的 URL,仅凭人工标识达到分类分级的目的显然是不现实的。

[0004] 现有常用的 HTTP 报文的 TCP 分片重组算法是:将 HTTP 协议的 TCP 分片按照 src_ip、dst_ip、src_port、server_ip 四元组匹配,并且以 SYN 报文的 seqno 作为起始序号,以 FIN 报文的 seqno 作为结束序号,进行 TCP 流的跟踪和重组,得到一个完整的 TCP 流后,再对上层的 HTTP 协议进行解析。这样做的缺点是:(1)HTTP/1.1 标准中,一个 TCP 流中可以包含多次的 HTTP 的 Request 与 Response,对 HTTP 解析提取增加的判断复杂性。(2)HTTP Response 报文可能承载着音视频数据,造成 TCP 流的持续时间很长,增加了系统的时间与空间的开销。

发明内容

[0005] 为了解决上述现有技术存在的缺陷,本发明提出一种基于 HTTP 分析的 URL 自动分类分级的系统及方法。该方法可以独立对 URL 进行分类分级,也可以结合人工标识对 URL 进行分类分级,并且还可以作为预处理阶段的方法。

[0006] 根据本发明的一方面,提出一种基于 HTTP 分析的 URL 自动分类分级系统,其特征在于,该系统包括 HTTP 请求 / 响应报文预处理器、HTTP 请求报文解析服务器、HTTP 响应报文解析服务器、交换机、HTTP 存储关联服务器和 HTTP 分级分类服务器,其中:

[0007] 所述 HTTP 请求 / 响应报文预处理器用于接收 HTTP 报文镜像数据流并对其进行预处理得到 HTTP 请求报文镜像数据流和 HTTP 响应报文镜像数据流,并将所述 HTTP 请求报文镜像数据流发给所述 HTTP 请求报文解析服务器,将 HTTP 响应报文镜像数据流发给所述 HTTP 响应报文解析服务器;

[0008] 所述 HTTP 请求报文解析服务器与所述 HTTP 请求 / 响应报文预处理器连接,用于对所接收的 HTTP 请求报文镜像数据流进行重组处理,从重组后的数据流中提取报文信息,并将所述报文信息以 HTTP 请求文件记录的形式存储到所述 HTTP 存储关联服务器上;

[0009] 所述 HTTP 响应报文解析服务器与所述 HTTP 请求 / 响应报文预处理器连接,用于

对所接收的 HTTP 响应报文镜像数据流进行重组处理,从重组后的数据流中提取报文信息,并将所述报文信息以 HTTP 响应文件记录的形式存储到所述 HTTP 存储关联服务器上;

[0010] 所述交换机与 HTTP 请求 / 响应报文预处理器、HTTP 请求报文解析服务器、HTTP 响应报文解析服务器、HTTP 存储关联服务器、HTTP 分类分级服务器相连,用于对 HTTP 请求 / 响应报文预处理器、HTTP 请求报文解析服务器、HTTP 响应报文解析服务器及运行其上的程序进行远程配置管理,同时也作为 HTTP 请求报文解析服务器、HTTP 响应报文解析服务器、HTTP 存储关联服务器、HTTP 分类分级服务器之间的数据传输通道;

[0011] 所述 HTTP 存储关联服务器与所述交换机相连,用于根据所述报文信息中的五元组信息,将所述 HTTP 请求文件记录与所述 HTTP 响应文件记录进行关联,并将关联上的数据以记录格式按行存入存储文件;

[0012] 所述 HTTP 分类分级服务器与所述交换机相连,用于根据用户定制的策略,通过所述交换机访问所述 HTTP 关联存储服务器中的记录信息,对 URL 进行分类分级。

[0013] 根据本发明的另一方面,提出一种基于 HTTP 分析的 URL 自动分类分级方法,其特征在于,该方法包括以下步骤:

[0014] 步骤 S1,在骨干网的路由器上获取 HTTP 报文镜像数据流;

[0015] 步骤 S2,HTTP Request/Response 报文预处理器对所述 HTTP 报文镜像数据流进行预处理得到 HTTP 请求报文镜像数据流和 HTTP 响应报文镜像数据流,并将所述 HTTP 请求报文镜像数据流发送给 HTTP 请求报文解析服务器,将 HTTP 响应报文镜像数据流发送给 HTTP 响应报文解析服务器;

[0016] 步骤 S3,所述 HTTP 请求报文解析服务器对所接收的 HTTP 请求报文镜像数据流进行重组处理,并将从重组后的数据流中提取到的报文信息以 HTTP 请求文件记录的形式存储到所述 HTTP 存储关联服务器上;

[0017] 步骤 S4,所述 HTTP 响应报文解析服务器对所接收的 HTTP 响应报文镜像数据流进行重组处理,并将从重组后的数据流中提取到的报文信息以 HTTP 响应文件记录的形式存储到所述 HTTP 存储关联服务器上;

[0018] 步骤 S5,HTTP 存储关联服务器根据由 client_ip、server_ip、client_port、server_port、rel_seqno 组成的五元组信息,将所述 HTTP 请求文件记录与所述 HTTP 响应文件记录进行关联,并将关联上的数据以记录格式按行存入存储文件;

[0019] 步骤 S6,HTTP 分类分级服务器根据用户定制的策略,访问所述 HTTP 关联存储服务器中的记录信息,将 URL 进行分类分级。

[0020] 根据上述本发明的技术方案,本发明的有益效果为:(1)只针对已识别的 HTTP 报文的第一个 TCP 分片建立流表表项,以 client_ip、server_ip、client_port、server_ip、ack_seqno 为索引,后续 TCP 分片根据索引查找对应的表项,并根据 seqno 进行排列重组;(2)以 HTTP 报首和数据的分隔符为重组结束标志,对于 HTTP Response 报文,由于只关注报首的重组,从而对于持续时间长的 TCP 流,大大地节省了系统时间与空间的开销。

附图说明

[0021] 图 1 为本发明基于 HTTP 分析的 URL 自动分类分级系统结构图。

[0022] 图 2 为本发明基于 HTTP 分析的 URL 自动分类分级方法流程图。

[0023] 图 3 为本发明 HTTP Request 报文报首重组解析逻辑图。

[0024] 图 4 为本发明 HTTP Response 报文报首重组解析逻辑图。

具体实施方式

[0025] 为使本发明的目的、技术方案和优点更加清楚明白,以下结合具体实施例,并参照附图,对本发明进一步详细说明。在描述过程中省略了对于本发明来说是不必要的细节和功能,以防止对本发明的理解造成混淆。

[0026] 图 1 为本发明基于 HTTP 分析的 URL 自动分类分级系统结构图,如图 1 所示,根据本发明的一方面,提出一种基于 HTTP 分析的 URL 自动分类分级系统,该系统包括 :HTTP 请求 / 响应 Request/Response 报文预处理器、HTTP 请求 Request 报文解析服务器、HTTP 响应 Response 报文解析服务器、交换机、HTTP 存储关联服务器和 HTTP 分级分类服务器,其中 :

[0027] 所述 HTTP Request/Response 报文预处理器用于接收所述 HTTP 报文镜像数据流并对其进行预处理得到 HTTP Request 报文镜像数据流和 HTTPResponse 报文镜像数据流,并将所述 HTTP Request 报文镜像数据流发给 HTTP Request 报文解析服务器,将 HTTP Response 报文镜像数据流发给 HTTP Response 报文解析服务器。具体地,所述 HTTP Request/Response 报文预处理器具有 4 个网络接口,网络接口 1 用于接收 HTTP 报文镜像数据流,并对其进行预处理 :根据 TCP 层的端口号,将目的端口号为 80、8080、443 的 HTTP 报文镜像数据流标识为 HTTP Request 报文镜像数据流,将源端口号为 80、8080、443 的 HTTP 报文镜像数据流标识为 HTTP Response 报文镜像数据流 ; 网络接口 2 用于将所述 HTTP Request 报文镜像数据流发送给所述 HTTP Request 报文解析服务器 ; 网络接口 3 用于将所述 HTTP Response 报文镜像数据流发送给所述 HTTP Response 报文解析服务器 ; 网络接口 4 与所述交换机连接,用于对 HTTP Request/Response 报文预处理器及运行其上的程序进行配置管理。

[0028] 所述 HTTP Request 报文解析服务器与所述 HTTP Request/Response 报文预处理器连接,用于对所接收的 HTTP Request 报文镜像数据流进行重组处理,从重组后的数据流中提取报文信息,并将所述报文信息以 HTTP 请求文件记录的形式存储到所述 HTTP 存储关联服务器上 ; 所述 HTTP Request 报文解析服务器具有 2 个网络接口,网络接口 1 与 HTTP Request/Response 报文预处理器的网络接口 2 相连,用于接收所述 HTTP Request 报文镜像数据流,并对其进行重组处理,然后将重组处理后的所述 HTTP Request 报文进行解析,提取出客户端 IP 地址 (client_ip)、服务器 IP 地址 (server_ip)、客户端端口号 (client_port)、服务器端口号 (server_port)、关联序列号 (rel_seqno)、主机 (Host)、请求 URL (Request-URL) 等报文信息,并将提取出的上述报文信息以 HTTP Request 文件记录的形式通过与所述交换机相连的网络接口 2 存储到所述 HTTP 存储关联服务器上,另外,还可通过所述网络接口 2 对 HTTP Request 报文解析服务器及运行其上的程序进行远程配置管理 ;

[0029] 所述 HTTP Response 报文解析服务器与所述 HTTP Request/Response 报文预处理器连接,用于对所接收的 HTTP Response 报文镜像数据流进行重组处理,从重组后的数据流中提取报文信息,并将所述报文信息以 HTTP 响应文件记录的形式存储到所述 HTTP 存储关联服务器上 ; 所述 HTTP Response 报文解析服务器具有 2 个网络接口,网络接口 1 与

HTTP Request/Response 报文预处理器的网络接口 3 相连, 用于接收所述 HTTPResponse 报文镜像数据流, 并对其进行重组处理, 然后将重组处理后的所述 HTTP Response 报文进行解析, 提取出客户端 IP 地址 (client_ip)、服务器 IP 地址 (server_ip)、客户端端口号 (client_port)、服务器端口号 (server_port)、关联序列号 (rel_seqno)、内容类型 (Content-Type)、内容编码 (Content-Encoding)、内容语言 (Content-Language)、内容长度 (Content-Length) 等报文信息, 并将提取出的上述报文信息以 HTTP Response 文件记录的形式通过与所述交换机相连的网络接口 2 存储到所述 HTTP 存储关联服务器上, 另外, 还可通过所述网络接口 2 对 HTTP Response 报文解析服务器及运行其上的程序进行远程配置管理;

[0030] 所述交换机进一步为通讯千兆交换机, 所述通讯千兆交换机与 HTTPRequest/Response 报文预处理器、HTTP Request 报文解析服务器、HTTPResponse 报文解析服务器、HTTP 存储关联服务器、HTTP 分类分级服务器的配置管理网络接口相连, 用于使系统维护人员对 HTTP Request/Response 报文预处理器、HTTP Request 报文解析服务器、HTTP Response 报文解析服务器及运行其上的程序进行远程配置管理, 另外也作为 HTTP Request 报文解析服务器、HTTP Response 报文解析服务器、HTTP 存储关联服务器、HTTP 分类分级服务器之间的数据传输通道。

[0031] 所述 HTTP 存储关联服务器与所述交换机相连, 用于根据所述报文信息中的 client_ip、server_ip、client_port、server_port、rel_seqno 五元组信息, 将所述 HTTP Request 文件记录与所述 HTTP Response 文件记录进行关联, 并将关联上的数据以记录格式按行存入存储文件。所述 HTTP 存储关联服务器具有 1 个网络接口, 所述 HTTP 存储关联服务器通过该网络接口与所述交换机连接, 用于与 HTTP Request 报文解析服务器、HTTPResponse 报文解析服务器、HTTP 分类分级服务器之间进行数据传输, 并可通过该网络接口对 HTTP 存储关联服务器及运行其上的程序进行远程配置管理。

[0032] 所述 HTTP 分类分级服务器与所述交换机相连, 用于根据用户定制的策略, 通过所述交换机访问所述 HTTP 关联存储服务器中的记录信息, 对 URL 进行分类分级, HTTP 分类分级服务器具有 1 个网络接口, 所述 HTTP 分类分级服务器通过该网络接口与所述交换机连接, 用于与 HTTP 存储关联服务器之间进行数据传输, 并可通过该网络接口对 HTTP 分类分级服务器及运行其上的程序进行远程配置管理。

[0033] 图 2 为本发明基于 HTTP 分析的 URL 自动分类分级方法流程图, 如图 2 所示, 根据本发明的另一方面, 还提出一种基于 HTTP 分析的 URL 自动分类分级方法, 该方法包括以下步骤:

[0034] 步骤 S1, 在骨干网的路由器上获取 HTTP 报文镜像数据流;

[0035] 步骤 S2, HTTP Request/Response 报文预处理器对所述 HTTP 报文镜像数据流进行预处理得到 HTTP Request 报文镜像数据流和 HTTPResponse 报文镜像数据流, 并将所述 HTTP Request 报文镜像数据流发送给 HTTP Request 报文解析服务器, 将 HTTP Response 报文镜像数据流发送给 HTTP Response 报文解析服务器;

[0036] 所述预处理进一步为: 根据 TCP 层的端口号, 将目的端口号为 80、8080、443 的 HTTP 报文镜像数据流标识为 HTTP Request 报文镜像数据流, 将源端口号为 80、8080、443 的 HTTP 报文镜像数据流标识为 HTTP Response 报文镜像数据流。

[0037] 步骤 S3, 所述 HTTP Request 报文解析服务器对所接收的 HTTP Request 报文镜像数据流进行重组处理, 然后将重组处理后的所述 HTTP Request 报文进行解析, 提取出 client_ip、server_ip、client_port、server_port、rel_seqno、Host、Request-URI 等报文信息, 并将提取出的上述报文信息以 HTTP Request 文件记录的形式存储到 HTTP 存储关联服务器中;

[0038] 该步骤中, 所述 HTTP Request 报文解析服务器对所述 HTTP Request 报文镜像数据流进行重组处理进一步包括以下步骤(如图 3 所示):

[0039] 步骤 S300, 获取所述 HTTP Request 报文镜像数据流的当前 TCP 分片, 进入步骤 S310;

[0040] 步骤 S310, 解析所述 HTTP Request 报文镜像数据流的 IP/TCP 报首, 从中获取客户端 IP 地址 client_ip, 服务器 IP 地址 server_ip, 客户端口号 client_port, 服务器口号 server_port, ack 序列号 ack_seqno 等信息, 根据获取的这些信息计算出下一报文序列号 next_seqno 和关联序列号 rel_seqno; 根据 HTTP Request 报文的报首特征, 判断该 TCP 分片是否为 HTTP Request 报文报首的第一个 TCP 分片, 若是, 则继续判断 HTTPRequest 报文的报首是否完整, 如果完整则进入步骤 S320, 否则进入步骤 S330; 如果该 TCP 分片不是 HTTP Request 报文报首的第一个 TCP 分片, 则以 client_ip, server_ip, client_port, server_port, ack_seqno 为索引查找预先存储的 HTTP 流表, 判断所述 HTTP 流表中是否有与所述索引匹配的流表表项, 如果是则进入步骤 S340, 否则结束本次流程, 回到步骤 S300 进入下一次流程;

[0041] 对于 HTTP 报首的开始与结束的判断方法, 可参考 RFC2068 标准文档。

[0042] 其中, 采用如下公式根据获取的 client_ip, server_ip, client_port, server_port, ack_seqno 等信息计算出 next_seqno, rel_seqno:

[0043] $next_seqno = seqno + payload_length$, $rel_seqno = next_seqno$,

[0044] 其中, seqno 为 TCP 分片报首中的序列号, payload_length 为 TCP 有效载荷长度。

[0045] 所述根据 HTTP Request 报文的报首特征, 判断该 TCP 分片是否为 HTTP Request 报文报首的第一个 TCP 分片进一步为: 以“ \r\n” 为行结束符, 从 TCP 分片的数据段中提取首行数据, 将其与 HTTP Request 报文的请求行的正则表达式“ GET.*HTTP./.” 进行匹配, 若匹配成功, 则判断该 TCP 分片是 HTTP Request 报文报首的第一个 TCP 分片; 若否, 则不是。

[0046] 步骤 S320, 解析所述 HTTP Request 报文的报首, 从中提取出 HTTP 版本号 HTTP Version, 请求 URI Request-URI, 主机 Host 等信息; 将所述步骤 S310 得到的 client_ip, server_ip, client_port, server_port, rel_seqno 以及主机 Host、Request-URI 等信息以 HTTP Request 文件记录的形式写入 HTTP 关联存储服务器, 并删除所述步骤 S310 中匹配的 HTTP 流表表项, 结束本次流程, 回到步骤 S300 进入下一次流程;

[0047] 步骤 S330, 以 client_ip, server_ip, client_port, server_port, ack_seqno 为索引, 新建一个 HTTP 流表表项, 结束本次流程, 回到步骤 S300 进入下一次流程;

[0048] 每个 HTTP 流表表项包含两个数据结构: 一个链表 List<TcpSegment> 和一个搜索二叉树 Tree<seqno, TcpSegment>。所述链表用于存放已重组好的 TCP 分片; 所述搜索二叉树用于存放未重组的 TCP 分片, 并且以 TCP 分片的 seqno 作为搜索二叉树的键值 key。

[0049] 在步骤 S330 中,新建一个 HTTP 流表表项时,链表 List<TcpSegment> 和搜索二叉树 Tree<seqno, TcpSegmet> 均为空,将该 TCP 分片放入链表 List<TcpSegment> 的首部,并回到步骤 S300。

[0050] 步骤 S340,对与所述索引匹配的 HTTP 流表表项进行 TCP 重组,重组后再判断所述 HTTP Request 报文的报首是否完整,若完整则返回步骤 S320,否则结束本次流程,回到步骤 S300 进入下一次流程。

[0051] 步骤 S340 中,对与索引匹配的 HTTP 流表表项进行 TCP 重组进一步为:

[0052] 如果找到一个与该 TCP 分片的索引匹配的 HTTP 流表表项,则判断该 TCP 分片的 seqno 是否等于 List<TcpSegment> 链表尾部的 TCP 分片的下一报文序列号 next_seqno :如果二者相等,那么就将该 TCP 分片加入 List<TcpSegment> 链表的尾部,并且遍历 Tree<seqno, TcpSegmet> 搜索二叉树,对搜索二叉树中的每一个 TCP 分片重复上述比较,直至遍历完整个 Tree<seqno, TcpSegmet> 搜索二叉树或者在相应的 TCP 分片的数据段中匹配到字符串 “ \r\n\r\n ” ,如果是匹配到字符串 “ \r\n\r\n ” ,那么就将链表中存储的 TCP 分片的数据段重组为完整的 HTTP Request 报文,并删除相应的 HTTP 流表表项,返回步骤 S320 ;如果直至遍历完整个 Tree<seqno, TcpSegmet> 搜索二叉树也没有匹配到字符串 “ \r\n\r\n ” ,则直接回到步骤 S300 ;如果二者不等,则直接回到步骤 S300。

[0053] 所述从重组处理后的数据流中提取出 client_ip、server_ip、client_port、server_port、rel_seqno、Host、Request-URI 等信息进一步为:

[0054] 从重组处理后的数据流中提取出源 IP 地址 src_ip,并进一步从 src_ip 中得到 client_ip,提取出目的 IP 地址 dst_ip,并进一步从 dst_ip 中得到 server_ip,提取出源端口号 src_port,并进一步从 src_port 中得到 client_port,提取出目的端口号 dst_port,并进一步从 dst_port 中得到 server_port,将最后一个 TCP 分片的序列号 seqno 加上 TCP 有效载荷长度 payload_length 得到 rel_seqno。

[0055] 步骤 S4,所述 HTTP Response 报文解析服务器对所接收的 HTTP Response 报文镜像数据流进行重组处理,然后将重组处理后的所述 HTTP Response 报文进行解析,并提取出 client_ip、server_ip、client_port、server_port、rel_seqno、Content-Type、Content-Encoding、Content-Language、Content-Length 等信息,将提取出的信息以 HTTP Response 文件记录的形式存储到所述 HTTP 存储关联服务器中;

[0056] 该步骤中,所述 HTTP Response 报文解析服务器对所述 HTTP Response 报文镜像流进行重组处理进一步包括以下步骤(如图 4 所示):

[0057] 步骤 S400,获取所述 HTTP Response 报文镜像数据流的当前 TCP 分片,进入步骤 S410;

[0058] 步骤 S410,解析所述 HTTP Response 报文镜像数据流的 IP/TCP 报首,从中获取客户端 IP 地址 client_ip,服务器 IP 地址 server_ip,客户端端口号 client_port,服务器端口号 server_port,ack 序列号 ack_seqno 等信息,根据获取的这些信息计算下一报文序列号 next_seqno 和关联序列号 rel_seqno ;根据 HTTP Response 报文的报首特征,判断该 TCP 分片是否为 HTTP Response 报文报首的第一个 TCP 分片,若是,则继续判断 HTTP Response 报文的报首是否完整,如果完整则进入步骤 S420,否则进入步骤 S430 ;如果该 TCP 分片不是 HTTP Response 报文报首的第一个 TCP 分片,则以 client_ip,server_ip,client_port,

server_port, ack_seqno 为索引查找预先存储的 HTTP 流表, 判断所述 HTTP 流表中是否有与所述索引匹配的流表表项, 如果是则进入步骤 S440, 否则结束本次流程, 回到步骤 S400 进入下一次流程;

[0059] 其中, 计算下一报文序列号 next_seqno 和关联序列号 rel_seqno 的公式、对于第一个 TCP 分片的判断方法均与步骤 S310 类似, 在此不做赘述。

[0060] 步骤 S420, 解析所述 HTTP Response 报文的报首, 从中提取出状态码 Status-Code, 内容类型 Content-Type, 内容长度 Content-Length, 内容编码 Content-Encoding, 内容语言 Content-Language 等信息, 并将所述步骤 S410 得到的 client_ip, server_ip, client_port, server_port, rel_seqno 以及状态码 Status-Code, 内容类型 Content-Type, 内容长度 Content-Length, 内容编码 Content-Encoding, 内容语言 Content-Language 等信息以 HTTPResponse 文件记录的形式写入 HTTP 关联存储服务器, 并删除所述步骤 S410 中匹配的 HTTP 流表表项, 结束本次流程, 回到步骤 S400 进入下一次流程;

[0061] 步骤 S430, 以 client_ip, server_ip, client_port, server_port, ack_seqno 为索引, 新建一个 HTTP 流表表项, 结束本次流程, 回到步骤 S400 进入下一次流程;

[0062] 在步骤 S430 中, 新建一个 HTTP 流表表项时, 链表 List<TcpSegment> 和搜索二叉树 Tree<seqno, TcpSegmet> 均为空, 将该 TCP 分片放入链表 List<TcpSegment> 的首部, 并回到步骤 S400。

[0063] 步骤 S440, 对与所述索引匹配的 HTTP 流表表项进行 TCP 重组, 重组后再判断所述 HTTP Response 报文的报首是否完整, 若完整则返回步骤 S420, 否则结束本次流程, 并回到步骤 S400 进入下一次流程。

[0064] 步骤 S440 中, 对与索引匹配的 HTTP 流表表项进行 TCP 重组进一步为:

[0065] 如果找到一个与该 TCP 分片的索引匹配的 HTTP 流表表项, 则判断该 TCP 分片的 seqno 是否等于 List<TcpSegment> 链表尾部的 TCP 分片的下一报文序列号 next_seqno: 如果二者相等, 那么就将该 TCP 分片加入 List<TcpSegment> 链表的尾部, 并且遍历 Tree<seqno, TcpSegmet> 搜索二叉树, 对搜索二叉树中的每一个 TCP 分片重复上述比较, 直至遍历完整个 Tree<seqno, TcpSegmet> 搜索二叉树或者在相应的 TCP 分片的数据段中匹配到字符串 "\r\n\r\n", 如果是匹配到字符串 "\r\n\r\n", 那么就将链表中存储的 TCP 分片的数据段重组为完整的 HTTPResponse 报文, 并删除相应的 HTTP 流表表项, 返回步骤 S420; 如果直至遍历完整个 Tree<seqno, TcpSegmet> 搜索二叉树也没有匹配到字符串 "\r\n\r\n", 则直接回到步骤 S400; 如果二者不等, 则直接回到步骤 S400。

[0066] 所述从重组处理后的数据流中提取出 client_ip、server_ip、client_port、server_port、rel_seqno、Content-Type、Content-Encoding、Content-Language、Content-Length 等信息进一步为:

[0067] 从重组处理后的数据流中提取出目的 IP 地址 dst_ip, 并进一步从 dst_ip 中得到 client_ip, 提取出源 IP 地址 src_ip, 并进一步从 src_ip 中得到 server_ip, 提取出目的端口号 dst_port, 并进一步从 dst_port 中得到 client_port, 提取出源端口号 src_port, 并进一步从 src_port 中得到 server_port, 提取出确认序列号 ack_seqno, 并进一步从 ack_seqno 中得到 rel_seqno。

[0068] 步骤 S5, HTTP 存储关联服务器根据由 client_ip、server_ip、client_port、server_port、rel_seqno 组成的五元组信息, 将所述 HTTP Request 文件记录与所述 HTTP Response 文件记录进行关联, 并将关联上的数据以记录格式按行存入存储文件;

[0069] 该步骤中, 在将 HTTP Request 文件记录与 HTTP Response 文件记录进行关联时, 首先过滤掉状态码 Status-Code 不等于 200 的数据, 然后再将 Host, Request-URI 拼接成完整的 URL, 并将关联上的数据以记录格式按行存入存储文件, 记录格式包含如下字段: client_ip, server_ip, Host, URL, Content-Type, Content-Length, Content-Encoding, Content-Language。

[0070] 步骤 S6, HTTP 分类分级服务器根据用户定制的策略, 访问所述 HTTP 关联存储服务器中的记录信息, 将 URL 进行分类分级。

[0071] 匹配成功的 HTTP Request 文件记录和 HTTP Response 文件记录对应一次完整的 HTTP 交互。从 HTTP Request 文件记录中可以提取出 URL、Host 等属性信息, 从 HTTP Response 文件记录中可以提取出 Content-Type、Content-Encoding、Content-Language、Content-Length 等属性信息, 通过根据 Content-Type、Content-Encoding、Content-Language、Content-Length、Host 等属性信息可以对 URL 进行分级、分类。而 HTTP 报文报首的解析与文件记录关联、属性提取、根据属性分级分类都可以在人为制定策略后由计算机程序完成, 从而达到自动化的目的。

[0072] 根据对一段时间内 HTTP 报文报首的解析与关联结果的数据分析, 可以得到不同纬度的 URL 分级与分类, 并对 URL 打上相应的标签: 比如, 可以根据 Host 将 URL 按照所在网站分类; 根据 Content-Type 将 URL 按照内容类型分类; 根据 Content-Encoding 将 URL 按压缩类型分类; 根据 Content-Language 将 URL 按照语言类型分类; 根据 server_ip 将 URL 按照所处网段分类; 根据 Content-Length 将 URL 按照内容大小分级; 根据单位时间内 URL 被访问次数, 将 URL 按照热点程度分级; 或结合以上的一种或多种进行多维度的分类分级。

[0073] 比如 URL 按照网站分类的标签可能有 sina.com、google.com、bupt.edu.cn 等, URL 按 Content-Type 分类的标签可能有 text、video、audio、image 等, URL 按 Content-Language 分类的标签可能有 English、Chinese、Japanese 等, URL 按照访问次数分级的标签可能有每天被访问 10 次以下、10-100 次、100-1000 次、1000-10000 次、10000 次以上, 当用户希望搜索热点为每天被访问 10000 次以上的语言为中文的热点帖子时, 就可以通过定制 Content-Type 标签为 text、Content-Language 标签为 Chinese、访问次数在 10000 次以上, HTTP 分类分级服务器就会根据这些标签条件从存储文件中搜索出符合的 URL 及相关信息的记录。

[0074] 以上所述的具体实施例, 对本发明的目的、技术方案和有益效果进行了进一步详细说明, 所应理解的是, 以上所述仅为本发明的具体实施例而已, 并不用于限制本发明, 凡在本发明的精神和原则之内, 所做的任何修改、等同替换、改进等, 均应包含在本发明的保护范围之内。

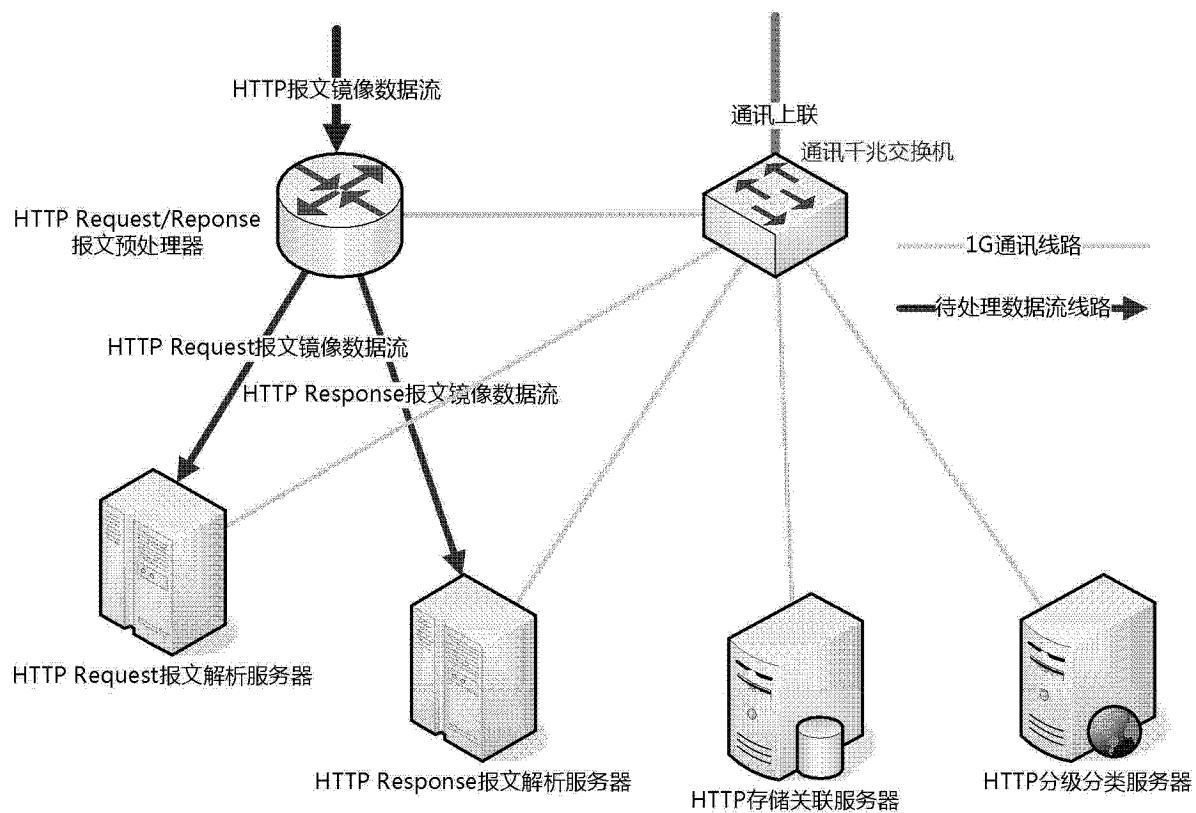


图 1

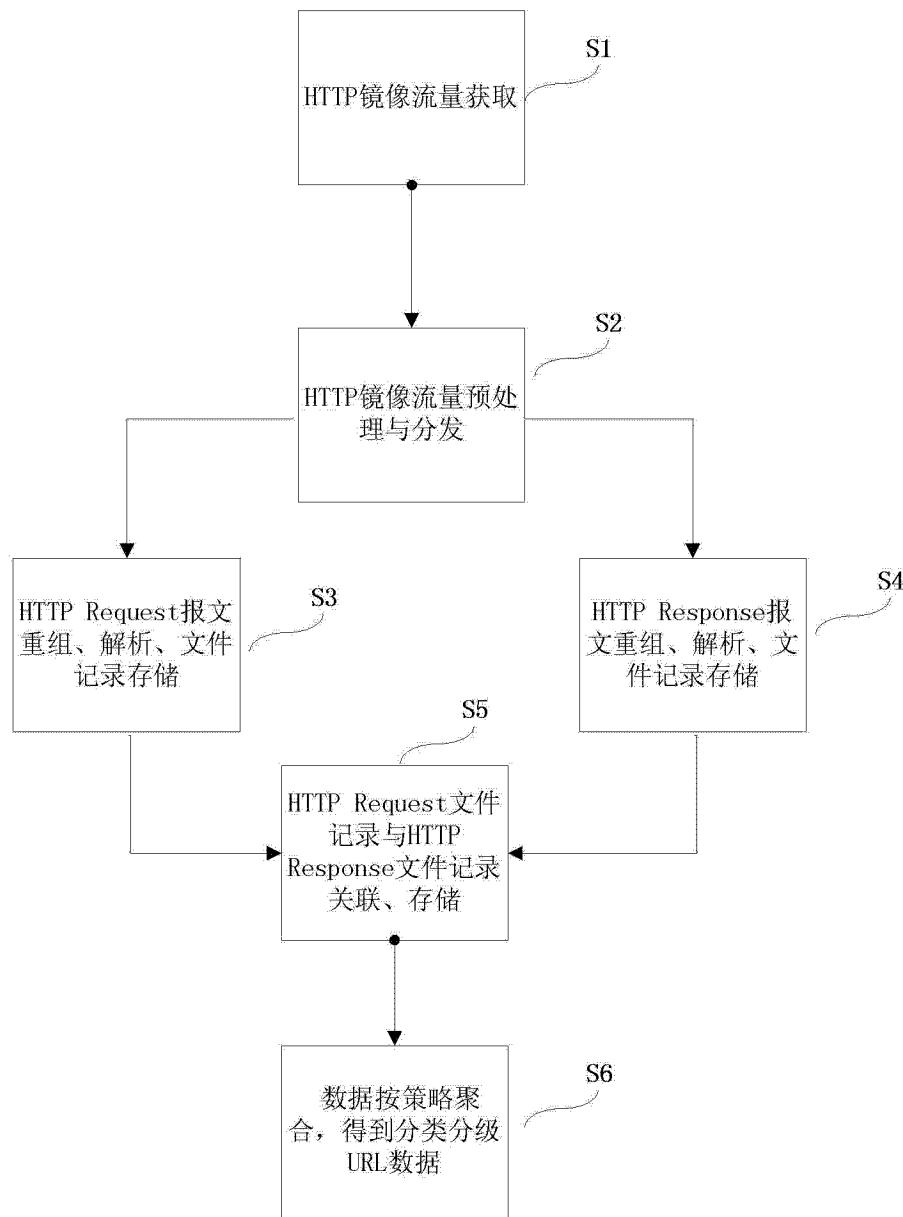


图 2

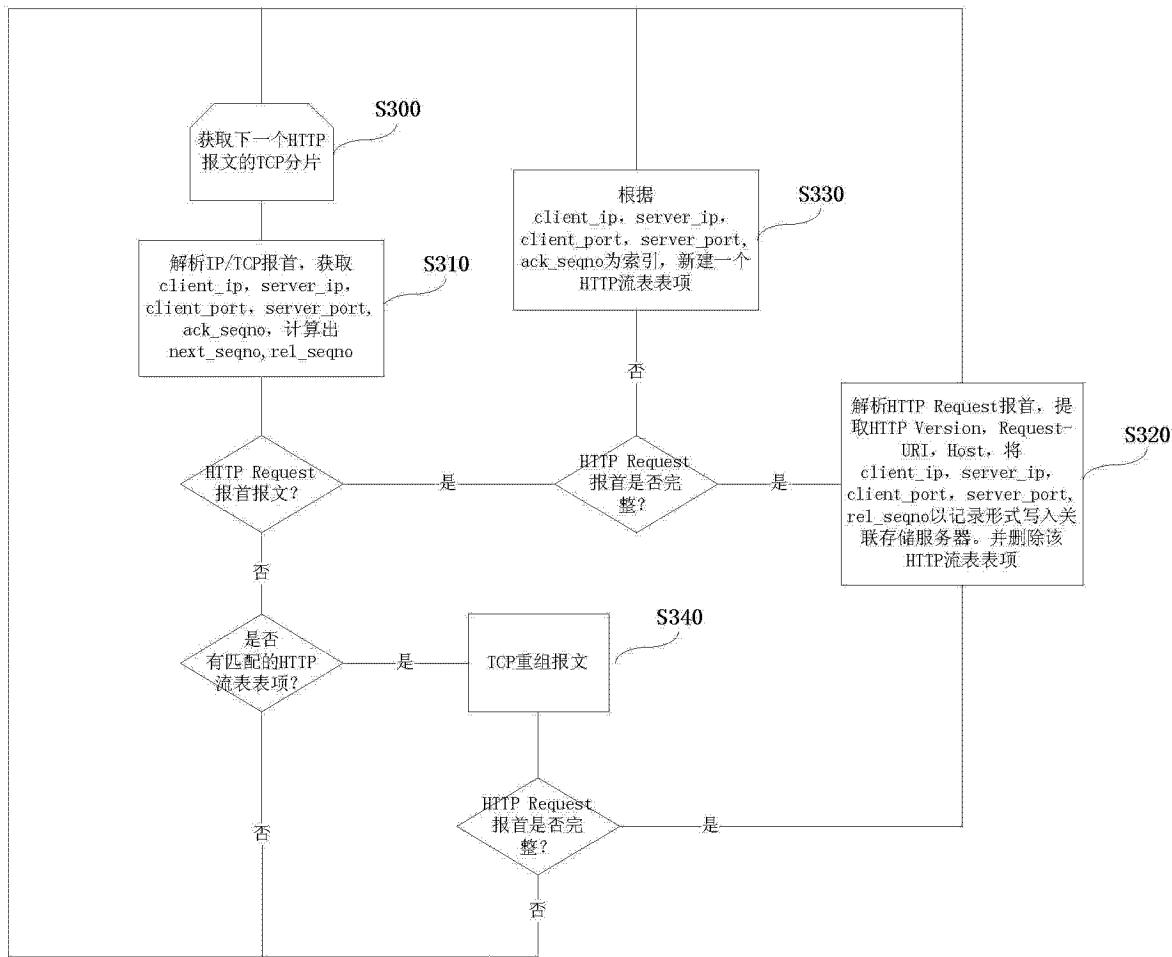


图 3

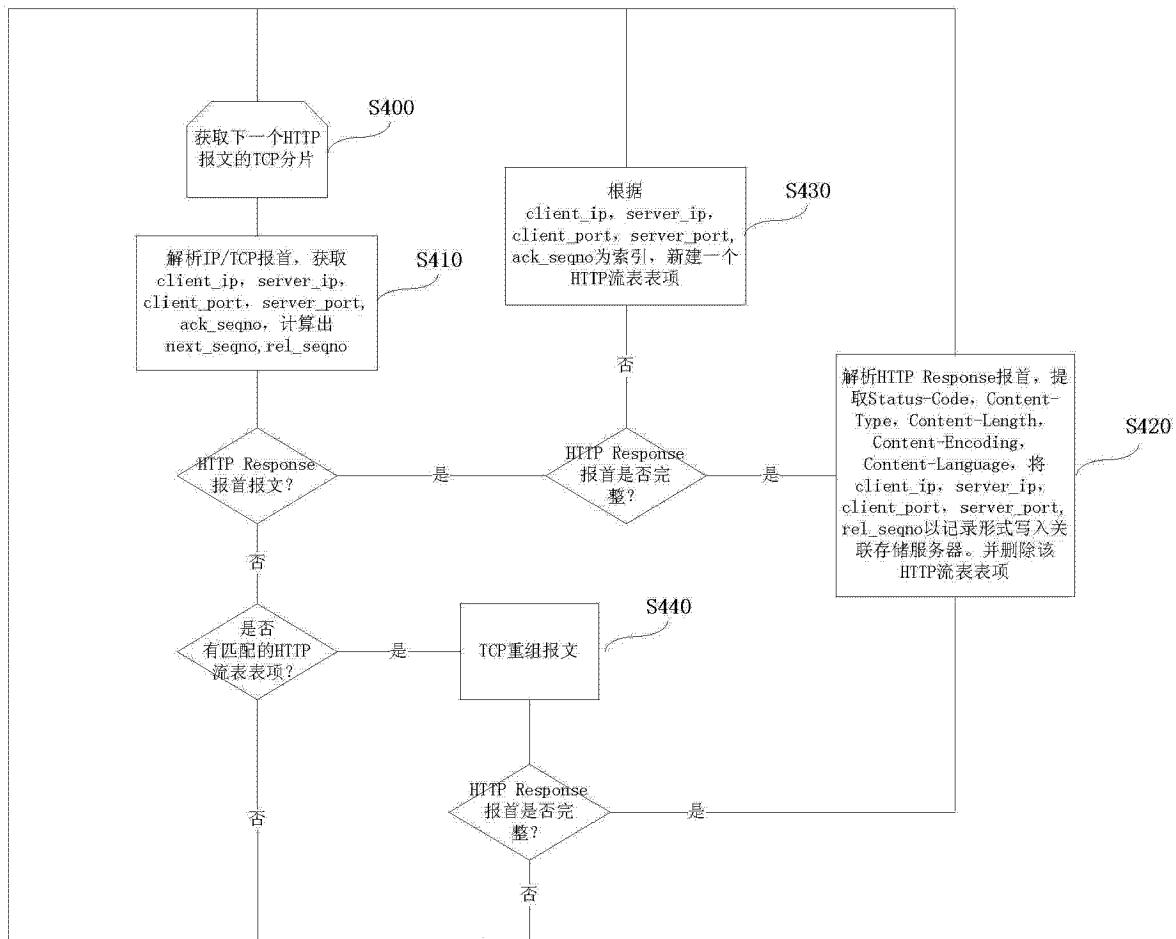


图 4