

(12) 发明专利申请

(10) 申请公布号 CN 102118400 A

(43) 申请公布日 2011.07.06

(21) 申请号 200910206791.2

(22) 申请日 2009.12.31

(71) 申请人 北京四维图新科技股份有限公司

地址 100028 北京市朝阳区曙光西里甲 5 号
凤凰置地广场 A 座写字楼 16 层

(72) 发明人 罗丽俊 陈文斌 汪洋 程鹏

(74) 专利代理机构 北京银龙知识产权代理有限公司 11243

代理人 许静

(51) Int. Cl.

H04L 29/08 (2006.01)

G06F 17/30 (2006.01)

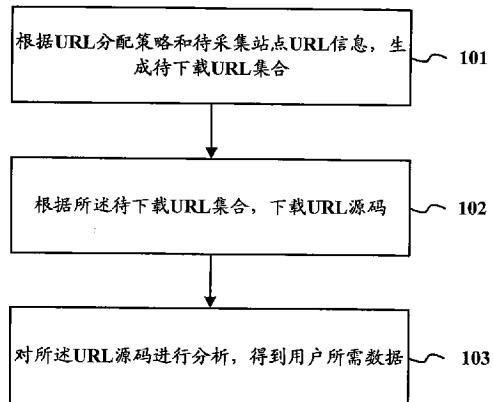
权利要求书 2 页 说明书 7 页 附图 6 页

(54) 发明名称

数据采集方法和数据采集系统

(57) 摘要

本发明提供一种数据采集方法和数据采集系统，所述数据采集方法包括以下步骤：根据 URL 分配策略和待采集站点 URL 信息，生成待下载 URL 集合；根据所述待下载 URL 集合，下载 URL 源码；对所述 URL 源码进行分析，得到用户所需数据。本发明能够自动从互联网上采集用户所需数据。



1. 一种数据采集方法,其特征在于,包括以下步骤:

根据统一资源定位符 URL 分配策略和待采集站点 URL 信息,生成待下载 URL 集合;

根据所述待下载 URL 集合,下载 URL 源码;

对所述 URL 源码进行分析,得到用户所需数据。

2. 根据权利要求 1 所述的数据采集方法,其特征在于,所述 URL 分配策略为:

预设待采集站点的 URL 在所述待下载 URL 集合中所占的条数;和 / 或

预设 URL 级别的 URL 在所述待下载 URL 集合中所占的条数。

3. 根据权利要求 2 所述的数据采集方法,其特征在于,所述对所述 URL 源码进行分析,得到用户所需数据,具体包括:

抽取所述 URL 源码中的情报数据;

从所述情报数据中,获取满足预设过滤规则的第一数据;

采用机器学习算法,将所述第一数据与语料库中的预设语料文件进行匹配,获取所述第一数据的信息价值;

将信息价值超过第一预设阈值的第一数据作为所述用户所需数据。

4. 根据权利要求 3 所述的数据采集方法,其特征在于,所述得到用户所需数据,之后还包括:

从所述用户所需数据中提取属于特定时间范围,且信息价值超过第二预设阈值的第二数据,所述第二预设阈值大于所述第一预设阈值;

将所述第二数据作为新的语料文件,更新所述语料库。

5. 根据权利要求 3 所述的数据采集方法,其特征在于,所述得到用户所需数据,之后还包括:

获取所述用户所需数据对应的 URL,作为有效 URL;

统计所述待采集站点中包含的有效 URL 的条数;

根据所述待采集站点中包含的有效 URL 的条数,更新所述待采集站点的 URL 在所述待下载 URL 集合中所占的条数。

6. 根据权利要求 1 所述的数据采集方法,其特征在于,所述根据所述待下载 URL 集合,下载 URL 源码,之后还包括:

从所述 URL 源码中,获取满足预设条件的 URL,所述预设条件为:所述 URL 不属于特定类型,且为所述待采集站点的 URL,且不属于所述待采集站点的站内 URL 黑名单;

根据所述满足预设条件的 URL,更新所述待采集站点 URL 信息。

7. 根据权利要求 6 所述的数据采集方法,其特征在于,所述从所述 URL 源码中,获取满足预设条件的 URL,之后还包括:

将所述满足预设条件的 URL 存储于内存映射文件中,且采用双层哈希表记录所述满足预设条件的 URL 的存储位置。

8. 根据权利要求 1 至 7 任一项所述的数据采集方法,其特征在于,所述用户所需数据为地理信息数据。

9. 一种数据采集系统,其特征在于,包括:

生成模块,用于根据 URL 分配策略和待采集站点 URL 信息,生成待下载 URL 集合;

下载模块,用于根据所述待下载 URL 集合,下载 URL 源码;

分析模块,用于对所述 URL 源码进行分析,得到用户所需数据。

10. 根据权利要求 9 所述的数据采集系统,其特征在于,所述生成模块、所述下载模块和所述分析模块设置于一台或多台计算机上。

数据采集方法和数据采集系统

技术领域

[0001] 本发明涉及互联网技术领域，尤其涉及一种数据采集方法和数据采集系统。

背景技术

[0002] 在现阶段的电子地图的地理信息数据的生产过程中，均是通过人工的方式进行地理信息数据的采集。在需要采集的地理信息数据规模较大时，通过人工方式采集的效率较低。另外，目前地理信息数据的更新速度也急剧加快，通过人工方式也无法做到地理信息数据的及时更新，难以满足大规模地理信息数据生产的需求。

发明内容

[0003] 有鉴于此，本发明提供一种数据采集方法和数据采集系统，能够自动从互联网上采集用户所需数据。

[0004] 为解决上述问题，本发明提供一种数据采集方法，包括以下步骤：

[0005] 根据 URL 分配策略和待采集站点 URL 信息，生成待下载 URL 集合；

[0006] 根据所述待下载 URL 集合，下载 URL 源码；

[0007] 对所述 URL 源码进行分析，得到用户所需数据。

[0008] 所述 URL 分配策略为：

[0009] 预设待采集站点的 URL 在所述待下载 URL 集合中所占的条数；和 / 或

[0010] 预设 URL 级别的 URL 在所述待下载 URL 集合中所占的条数。

[0011] 所述对所述 URL 源码进行分析，得到用户所需数据，具体包括：

[0012] 抽取所述 URL 源码中的情报数据；

[0013] 从所述情报数据中，获取满足预设过滤规则的第一数据；

[0014] 采用机器学习算法，将所述第一数据与语料库中的预设语料文件进行匹配，获取所述第一数据的信息价值；

[0015] 将信息价值超过第一预设阈值的第一数据作为所述用户所需数据。

[0016] 所述得到用户所需数据，之后还包括：

[0017] 从所述用户所需数据中提取属于特定时间范围，且信息价值超过第二预设阈值的第二数据，所述第二预设阈值大于所述第一预设阈值；

[0018] 将所述第二数据作为新的语料文件，更新所述语料库。

[0019] 所述得到用户所需数据，之后还包括：

[0020] 获取所述用户所需数据对应的 URL，作为有效 URL；

[0021] 统计所述待采集站点中包含的有效 URL 的条数；

[0022] 根据所述待采集站点中包含的有效 URL 的条数，更新所述待采集站点的 URL 在所述待下载 URL 集合中所占的条数。

[0023] 所述根据所述待下载 URL 集合，下载 URL 源码，之后还包括：

[0024] 从所述 URL 源码中，获取满足预设条件的 URL，所述预设条件为：所述 URL 不属于

特定类型,且为所述待采集站点的 URL,且不属于所述待采集站点的站内 URL 黑名单;

[0025] 根据所述满足预设条件的 URL,更新所述待采集站点 URL 信息。

[0026] 所述从所述 URL 源码中,获取满足预设条件的 URL,之后还包括:

[0027] 将所述满足预设条件的 URL 存储于内存映射文件中,且采用双层哈希表记录所述满足预设条件的 URL 的存储位置。

[0028] 所述用户所需数据为地理信息数据。

[0029] 本发明还提供一种数据采集系统,包括:

[0030] 生成模块,用于根据 URL 分配策略和待采集站点 URL 信息,生成待下载在 URL 集合;

[0031] 下载模块,用于根据所述待下载在 URL 集合,下载 URL 源码;

[0032] 分析模块,用于对所述 URL 源码进行分析,得到用户所需数据。

[0033] 所述生成模块、所述下载模块和所述分析模块设置于一台或多台计算机上。

[0034] 本发明具有以下有益效果:

[0035] 系统的自动化程度高。能够自动从互联网上获取用户所需数据,有效提高了数据采集速度,从而能够快速增加数据采集总量,满足大规模数据生产的需求,相对人工方式采集数据来说,既极大地提高了数据生产效率,又节省了人力成本;

[0036] 系统学习能力强。通过对得到的用户所需数据进行分析,能够自动调整 URL 分配策略和语料库,从而能够满足数据更新速度急剧加快的需求。

[0037] 系统并发性高。系统各模块之间互相对立,能够分布式部署,从而提高了系统的并发能力。

[0038] 系统处理能力高。采用内存映射机制,能够支持大批量的 URL 分析处理,同时采用自动修复映射文件机制,能够有效避免服务器突然中断带来的损失。

附图说明

[0039] 图 1 为本发明实施例的数据采集方法的一流程示意图;

[0040] 图 2 为本发明实施例的数据采集方法的另一流程示意图;

[0041] 图 3 为本发明实施例的数据采集系统的一结构示意图;

[0042] 图 4 为本发明实施例的数据采集系统的另一结构示意图;

[0043] 图 5 为本发明实施例的 URL 下载模块的示意图;

[0044] 图 6 为本发明实施例的信息价值分析模块的示意图;

[0045] 图 7 为本发明实施例的 URL 分析模块的示意图;

[0046] 图 8 为本发明实施例的日志分析模块的示意图;

[0047] 图 9 为本发明实施例的 URL 分配策略模块的示意图。

具体实施方式

[0048] 下面结合附图和实施例,对本发明的具体实施方式作进一步详细描述。

[0049] 如图 1 所示为本发明实施例的数据采集方法的一流程示意图,所述数据采集方法包括以下步骤:

[0050] 步骤 101,根据 URL(Uniform/Universal Resource Locator,统一资源定位符)分

配策略和待采集站点 URL 信息,生成待下载 URL 集合。

[0051] 所谓 URL 也称成网页地址,是因特网 (Internet) 上标准的资源地址 (Address)。所述 URL 分配策略可以为包括:预设待采集站点的 URL 在所述待下载 URL 集合中所占的条数。预设待采集站点的 URL 在所述待下载 URL 集合中所占的条数,也称为预设待采集站点的下载权重,例如,URL 分配策略可以设置为:待采集站点 A 的下载权重为 30%,即每 100 条待下载 URL 集合中属于待采集站点 A 的 URL 占 30 条。所述 URL 分配策略还可以为包括:预设 URL 级别的 URL 在所述待下载 URL 集合中所占的条数。本发明实施例中,可以将 URL 划分为四个级别,其中,级别 1:通常需要快速下载,例如,下载期限为 2 天(即需要在 2 天内下载完成),级别 2:一般为列表页,其下载期限略长于级别 1 的下载期限,例如,下载期限为 5 天,级别 3:一般为详细页,其下载期限略长于级别 2 的下载期限,例如,下载期限为一周,级别 4:其下载期限最长,例如,下载期限为一个月。此时,URL 分配策略可以设置为:级别 1 的 URL 的下载权重为 50%,即每 100 条待下载 URL 集合中级别 1 的 URL 占 50 条。

[0052] 所述待采集站点 URL 信息包括:待采集站点的 URL 和待采集站点的站内 URL 黑名单(即不需要访问的站内 URL)。所述待采集站点的 URL 可以为待采集站点的首页 URL(也称为站点种子),也可以为待采集站点的子页面 URL。

[0053] 在系统初始化时,通常设定 URL 分配策略为空,且将所述待采集站点的首页 URL 作为最初的待下载 URL,生成待下载 URL 集合。另外,为了获取大量的用户所需数据,在系统初始化时,待采集站点的个数通常设置的较多,例如为 1000 个。

[0054] 步骤 102,根据所述待下载 URL 集合,下载 URL 源码;

[0055] 所述待下载 URL 集合可以存储于一“URL 下载队列”中,并按照先进先出的顺序从所述“URL 下载队列”中获取待下载 URL,根据所述待下载 URL 下载 URL 源码。

[0056] 具体的,系统通过域名服务器解析所述待下载 URL,将所述待下载 URL 转换成待 IP 地址,从而根据 IP 地址,下载 URL 源码。

[0057] 步骤 103,对所述 URL 源码进行分析,得到用户所需数据。

[0058] 所述用户所需数据可以为地理信息数据、图书数据、产品数据等。

[0059] 通过上述实施例提供的数据采集方法,能够自动从互联网上获取用户所需数据,有效提高了数据采集速度,从而能够快速增加数据采集总量,满足大规模数据生产的需求,相对人工方式采集数据来说,既极大地提高了数据生产效率,又节省了人力成本。

[0060] 下面对 URL 源码的分析过程进行详细描述。

[0061] 如图 2 所示为本发明实施例的数据采集方法的另一流程示意图,所述数据采集方法包括以下步骤:

[0062] 步骤 201,根据 URL 分配策略和待采集站点 URL 信息,获取待下载 URL 集合;

[0063] 步骤 202,根据所述待下载 URL 集合,下载 URL 源码;

[0064] 步骤 203,抽取所述 URL 源码中的情报数据;

[0065] 所述情报数据可以包括:当前页面的 URL、页面标题、页面内容、页面创建时间、所属站内 URL 目录等。

[0066] 步骤 204,从所述情报数据中,获取满足预设过滤规则的第一数据;

[0067] 所述预设过滤规则可以为时间过滤规则,例如,如果只需获取某一时间段内待采集站点的更新数据,则可以通过时间过滤规则以及情报数据中的页面创建时间,仅获取某

一时间段内创建的情报数据。

[0068] 步骤 205,采用机器学习算法,将所述第一数据与语料库中的预设语料文件进行匹配,获取所述第一数据的信息价值;

[0069] 所述语料库中记载有与用户所需数据相关的多个语料文件,所述语料文件中记载有用户所需数据的数据格式、字符编码或文本描述等信息。假设用户所需数据为交通类数据,则所述语料库中则存储有多个交通类数据相关的语料文件,所述语料文件中记载有交通类数据的特定规则。可以通过机器学习算法,将所述第一数据与语料库中的预设语料文件进行匹配,判断所述第一数据与所述预设语料文件的匹配度,从而得到所述第一数据的信息价值。

[0070] 步骤 206,将信息价值超过第一预设阈值的第一数据作为所述用户所需数据。

[0071] 所述信息价值可以设定为 0 至 100 分,例如,通过与预设语料文件匹配,得到所述第一数据的信息价值为 70 分。假设所述第一预设阈值为 80 分,则所述第一数据则不是用户所需数据。

[0072] 步骤 207,从所述用户所需数据中提取属于特定时间范围,且信息价值超过第二预设阈值的第二数据,所述第二预设阈值大于所述第一预设阈值;

[0073] 为了使得语料库中的语料文件的信息价值较高,因此,设定的第二预设阈值要远大于第一预设阈值,例如,所述第一预设阈值可以设定为 80 分,所述第二预设阈值可以设定为 95 分。

[0074] 步骤 208,将所述第二数据作为新的语料文件,更新所述语料库。

[0075] 另外,还可以对得到的用户所需数据进行分析,自动调整 URL 分配策略,从而能够满足数据更新速度急剧加快的需求。此时,上述方法还包括:

[0076] 步骤 209,获取所述用户所需数据对应的 URL,作为有效 URL;

[0077] 步骤 210,统计所述待采集站点中包含的有效 URL 的条数;

[0078] 步骤 211,根据所述待采集站点中包含的有效 URL 的条数,更新所述待采集站点的 URL 在所述待下载 URL 中所占的条数(即所述待采集站点的下载权重)。

[0079] 另外,还可以统计待采集站点与数据类别的比重,调整数据类别在待采集站点中的阀值。

[0080] 以及,统计预设 URL 目录中包含的有效 URL 的条数,将不包含有效 URL 或者包含很少个有效 URL 的 URL 目录列入 URL 黑名单。

[0081] 上述实施例中,在抽取所述 URL 源码中的情报数据时,还可以从所述 URL 源码中抽出 URL,从而更新所述待采集站点 URL 信息。因此,上述方法还包括:

[0082] 步骤 212,从所述 URL 源码中,抽取 URL;

[0083] 步骤 213,从所述抽取的 URL 中,获取满足预设条件的 URL,所述预设条件为:所述 URL 不属于特定类型(例如:图片类型(URL 的后缀为 *. jpg 等)、特定文档类型(URL 后缀为 *. ppt 等)),且属于所述待采集站点(本发明实施例中也将待采集站点称为白名单)的 URL,且不属于所述待采集站点的站内 URL 黑名单。

[0084] 步骤 214,根据所述满足预设条件的 URL,更新所述待采集站点 URL 信息。

[0085] 另外,为了防止随着 URL 的增加而使得系统负担增大,可以将满足预设条件的 URL 存储于内存映射文件中,通过内存映射机制,在单个服务器(4G 内存)能够支持一亿个 URL

的分析处理。另外,为了方便查找,可以采用双层哈希表(hash)记录所述满足预设条件的 URL 的存储位置。采用双层哈希表可以确定 URL 的唯一存储位置,其中,第一层 hash 为固定值(例如 1 ~ 500),可用于分布式扩展,第二层可自动扩展(即大小不限)。另外,由于内存映射文件时时变动,为了防止由于服务器突然中断而带来的影响,需对具有一定机制对内存映射文件进行还原。例如,可以每隔一定时间将内存映射文件保存一次,然而由于内存映射文件通常较大(1 千万 URL 的信息大概有 2G 大小),因此,每次使用拷贝将占用了大量的时间与空间。本发明实施例中,可以仅保存内存 hash 的信息(最多为 500M)为 hash 文件,通过 hash 文件,可快速还原内存映射文件,通常情况下,在 3 分钟之内可还原 1 千万的 URL 信息。

[0086] 对应于上述数据采集方法,本发明实施例还提供一种数据采集系统,如图 3 所示,所述数据采集系统包括:

[0087] 生成模块 301,用于根据 URL 分配策略和待采集站点 URL 信息,生成待下载 URL 集合;

[0088] 下载模块 302,用于根据所述待下载 URL 集合,下载 URL 源码;

[0089] 分析模块 303,用于对所述 URL 源码进行分析,得到用户所需数据。

[0090] 所述生成模块 301、所述下载模块 302 和所述分析模块 304 可以设置于一台计算机上,当然,为了提高系统的并发能力,所述生成模块 301、所述下载模块 302 和所述分析模块 304 还可以设置于多台计算机上。

[0091] 下面举例对上述实施例的数据采集系统进行详细说明。

[0092] 如图 4 所示为本发明实施例的数据采集系统的另一结构示意图,所述数据采集系统包括:WEB 管理系统模块、URL 下载模块、信息抽取模块、信息价值分析模块、URL 分析模块、日志分析模块和 URL 分配策略模块,上述各模块可以分布于一台或多台计算机上,由于每台计算机的处理能力有限,通常将上述模块设置于多台计算机上,各模块通过指定类型的信息包与管道进行通信。管道是一种通信机制,由计算机的操作系统提供。信息包可以采用轮寻的方式或广播的方式在管道中传送,每个模块只处理(接收和或删除)属于该模块的指定规定类型的信息包,处理后按约定的方式向管道中发送新的信息包。

[0093] 各模块的如下所示:

[0094] 1、WEB 管理系统模块:

[0095] WEB 管理系统模块在系统初始化时使用,用于输入待采集站点 URL 信息(例如,待采集站点的首页 URL、待采集站点的站内 URL 黑名单等),得到待下载 URL 集合,并根据所述待下载 URL 集合,生成“URL 下载包”发送给管道。

[0096] 所述待下载 URL 集合中包括多个 URL,例如 1000 个,根据所述待下载 URL 集合生成的“URL 下载包”可以为多个,每一“URL 下载包”中可以包括若干个待下载 URL,例如 10 个。

[0097] 由于是数据采集的初始化阶段,因此该步骤中 URL 分配策略设置为空。

[0098] 2、URL 下载模块:

[0099] 所述 URL 下载模块主要用于下载 URL,其主要包括以下步骤:

[0100] 1) 在管道中获取“URL 下载包”,把待下载 URL 存到 URL 下载对列中;所述 URL 下载队列的容量有限,例如长度为 100,即仅能存储 100 个待下载 URL。当 URL 下载对列中的 URL 小于某固定值(例如 90)时,所述 URL 下载模块可以主动向管道发送“请求 URL 包”,以

请求新的待下载 URL。

[0101] 2) 从 URL 下载对列中获取待下载 URL, 把待下载 URL 发送给客户端。

[0102] 如图 5 所示为本发明实施例的 URL 下载模块的示意图, 所述 URL 下载队列可以位于一服务器上, 而具体的 URL 下载任务可以由一个或多个客户端执行, 服务器与客户端之间可以通过 socket(套接字) 通信, 在待下载 URL 数据较大时, 通常采用多个客户端同时执行下载任务。

[0103] 3) 获取客户端下载的 URL 源码, 并生成“URL 源码包”向管道发送。

[0104] 3、信息抽取模块 :

[0105] 1) 在管道中获取“URL 源码包”, 对所述“URL 源码包”进行分析, 从 URL 源码中抽取出 URL 列表, 生成“URL 列表包”, 所述“URL 列表包”用于待采集站点 URL 信息的更新;

[0106] 2) 从 URL 源码中抽取出情报信息, 生成“信息分析包”;

[0107] 3) 向管道发送所述“URL 列表包”和“信息分析包”。

[0108] 4、信息价值分析模块 :

[0109] 所述信息价值分析模块主要用于获取用户所需数据, 其可以包括以下步骤 :

[0110] 1) 在管道中获取“信息分析包”, 根据时间过滤规则以及语料库, 对所述

[0111] “信息分析包”中的情报信息进行分析, 得到用户所需数据。如 6 图所示为本发明实施例的信息价值分析模块的示意图。

[0112] 2) 将分析得到的用户所需数据的相关信息(信息价值、所属类别等)以及情报信息整合在一起, 生成“日志分析包”, 并向管道发送。

[0113] 5、URL 分析模块 :

[0114] 如 7 图所示为本发明实施例的 URL 分析模块的示意图, 所述 URL 分析模块的工作流程主要包括以下步骤 :

[0115] 1) 在管道中获取“URL 列表包”, 获取满足预设条件的 URL, 所述满足预设条件的 URL 为不属于特定类型的 URL, 且属于待采集站点的 URL, 且不属于站内 URL 黑名单;

[0116] 2) URL 排重 :

[0117] 判断内存映射文件中是否存在重复的 URL, 如果存在重复的 URL, 则判断 URL 的更新时间是否发生变化, 如果 URL 的更新时间发生变化, 则修改内存映射文件中存储的该 URL 的相关信息, 例如: 修改 URL 更新时间、URL 下载时间(可以将下载时间置为空); 如果 URL 的更新时间未发生变化, 则结束;

[0118] 如果不存在重复的 URL, 则对 URL 的级别进行计算, 得到 URL 的级别信息, 并将 URL 信息插入内存映射文件。

[0119] 6、日志分析模块 :

[0120] 在管道中获取“日志分析包”, 将所述“日志分析包”中的数据存入数据库中的两个表格中, 其中第一个表格主要包含的字段为: URL、信息价值、类别 ID、标题、内容、记录插入时间(即数据插入数据库的时间)等, 第二个表格主要包含的字段为: URL、信息价值、类别 ID(用户所需数据所属的类别的编号)、站点 ID(用户所需数据对应的待采集站点的编号)、站内目录 ID(用户所需数据对应的待采集站点的站内 URL 目录的编号)、记录插入时间等。

[0121] 如图 8 所示为本发明实施例的日志分析模块的示意图, 所述日志分析模块的工作流程主要包括以下步骤 :

[0122] 1) 定期对第一个表格进行分析, 提取特定时间范围内的数据, 把信息价值度高的信息, 推送给对应类别的语料文件, 更新语料库, 推送方式由机器自动推到和人工审核两种方式。

[0123] 2) 定期对第二个表格进行分析, 提取特定时间范围内的数据(将用户所需数据对应的 URL 称为有效 URL);

[0124] A : 统计待采集站点中有效 URL 所占的比重, 对于比重高的待采集站点, 赋予更高的下载权重;

[0125] B : 统计待采集站点的站内 URL 目录中有效 URL 所占的比重, 把比重低的站内 URL 目录, 列入站内 URL 黑名单; 此时, 为了提高准确度, 还可以由人工来审核系统推送的 URL 是否需要列入 URL 黑名单;

[0126] C : 统计待采集站点与数据类别的比重, 调整数据类别在待采集站点中的阈值。

[0127] 根据上述分析结果, 对 URL 分配策略进行更新。

[0128] 7、URL 分配策略模块:

[0129] 如图 9 所示为本发明实施例的 URL 分配策略模块的示意图。

[0130] 1) 当“URL 调度队列”中的 URL 的个数小于一定值时, 例如小于 100 时, 扫描 URL 分析模块产生的映射文件, 以及日志分析模块产生的 URL 分配策略, 生成“URL 调度队列”; 所述“URL 调度队列”用于存储通过 URL 分配策略从所述内存映射文件中获取的待下载 URL 集合。

[0131] 或者, 所述“URL 调度队列”也可以定时(例如每天零点)扫描 URL 分析模块产生的映射文件, 以及日志分析模块产生的 URL 分配策略, 生成“URL 调度队列”;

[0132] 2) 在管道中获取“请求 URL 包”, 从“URL 调度队列”中, 向管道发送“URL 下载包”。

[0133] 以上所述仅是本发明的优选实施方式, 应当指出, 对于本技术领域的普通技术人员来说, 在不脱离本发明原理的前提下, 还可以作出若干改进和润饰, 这些改进和润饰也应视为本发明的保护范围。

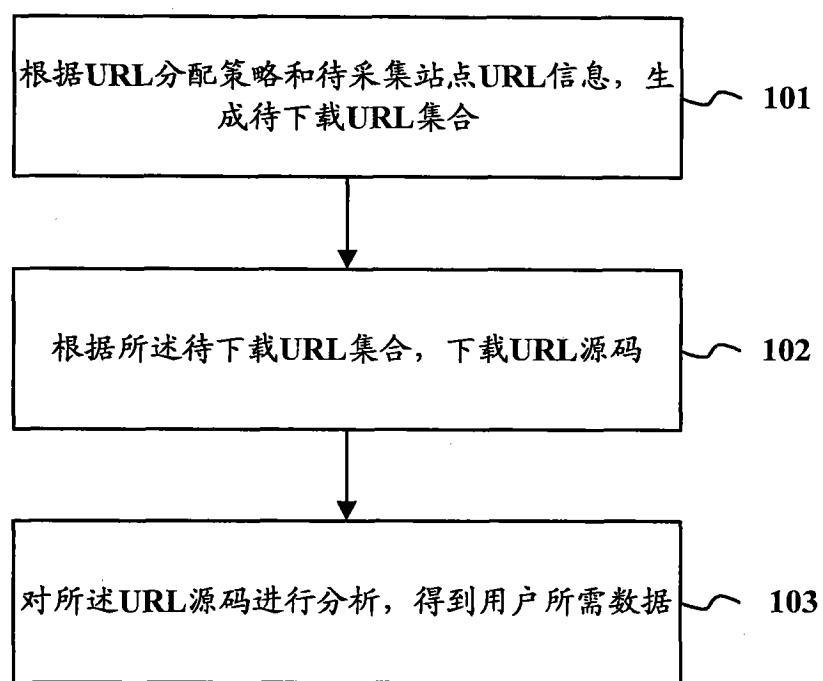


图 1

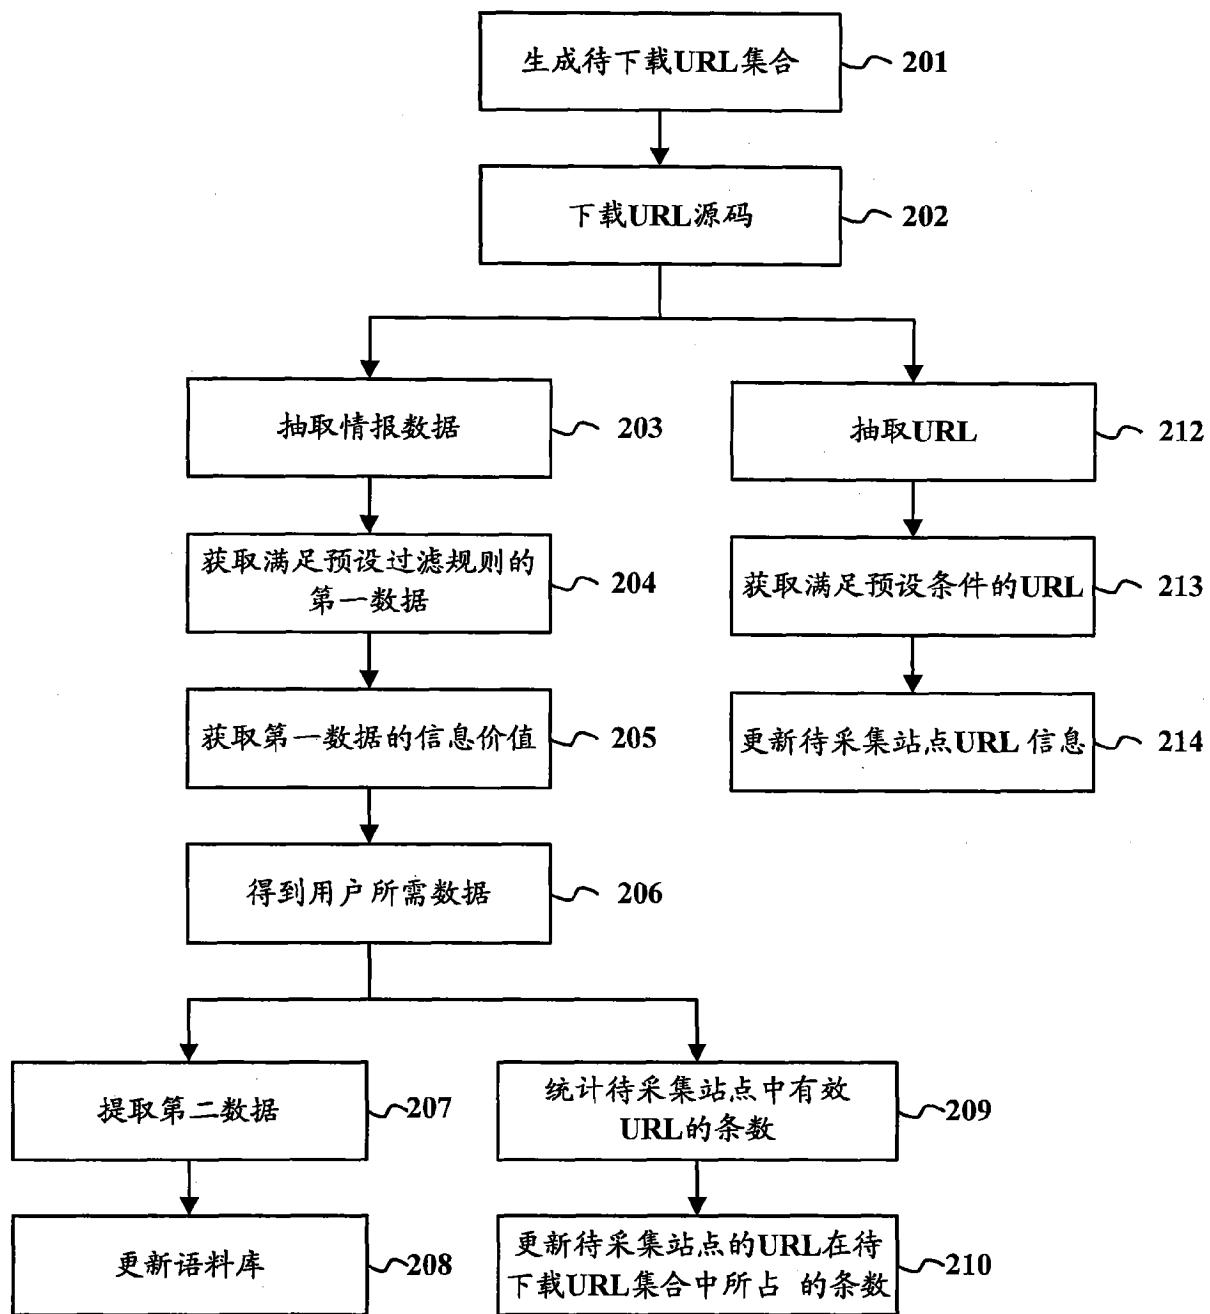


图 2

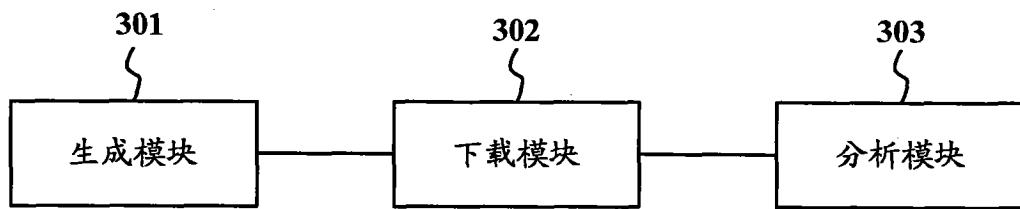


图 3

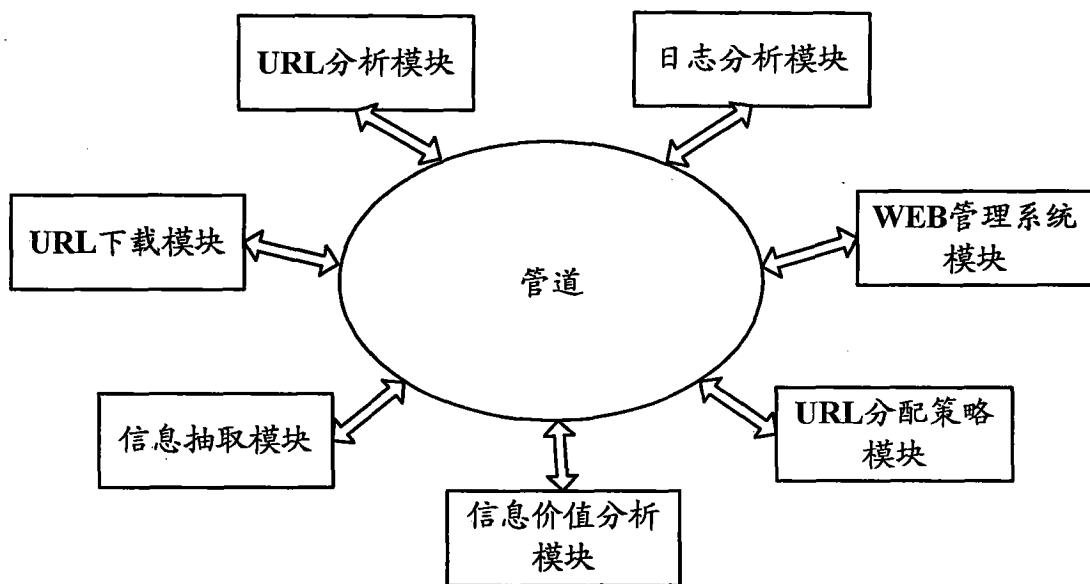


图 4

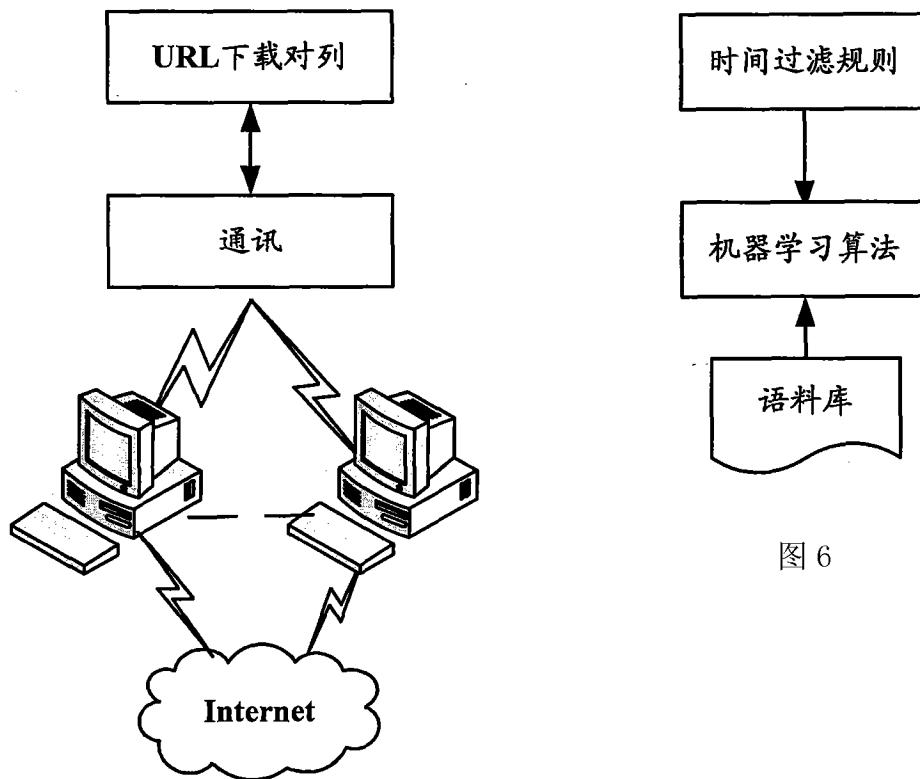


图 6

图 5

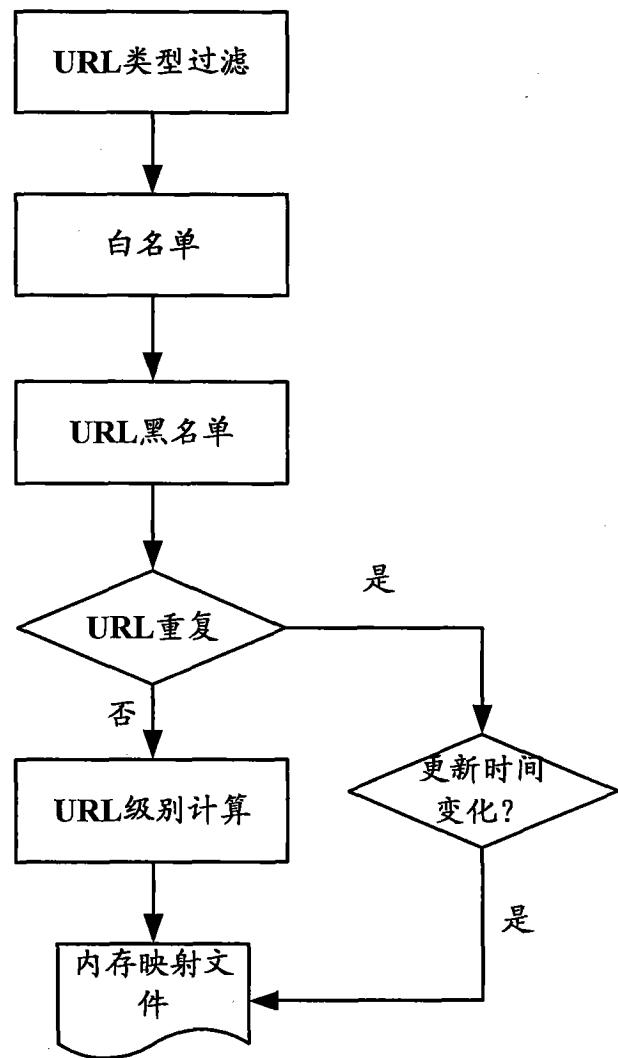


图 7

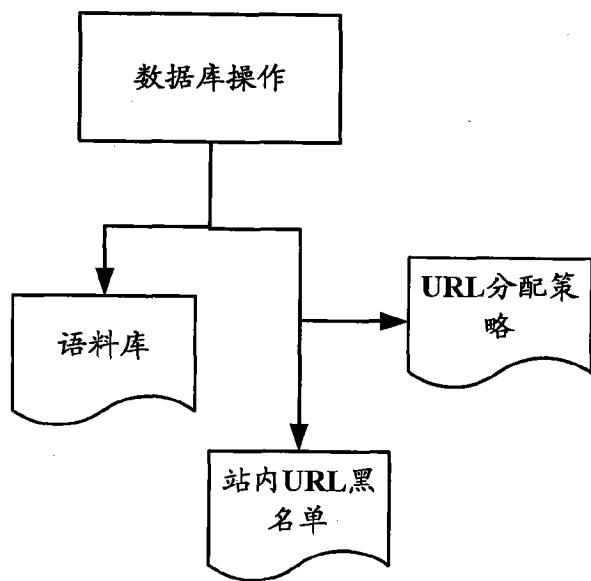


图 8

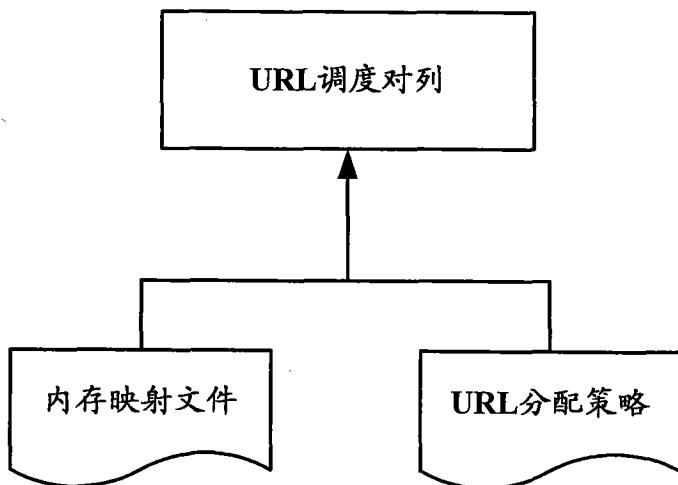


图 9