

带谓词的 XPath 查询的即时处理

吴年^{1,2}, 张昱^{1,2}

(1. 中国科学技术大学计算机科学技术系, 合肥 230027; 2. 中国科学院计算机科学重点实验室, 北京 100080)

摘要:介绍了一种立即计算谓词并即时输出的 XML 流数据查询系统 XSIEQ。XSIEQ 采用修改了的下推自动机技术, 对多个 XPath 式按前缀共享的方式构造 NFA, 并对 NFA 状态进行类型标记和添加索引; 从而在运行时能快速确定谓词计算和数据缓存等动作的时机, 实现了即时处理; 最后给出了 XSIEQ 和 YFilter 的查询性能对比及分析。

关键词:XML 流; 谓词计算; 下推自动机

Immediate Processing of XPath Query with Predicates

WU Nian^{1,2}, ZHANG Yu^{1,2}

(1. Department of Computer Science & Technology, University of Science & Technology of China, Hefei 230027;
2. Key Lab of Computer Science, Chinese Academy of Sciences, Beijing 100080)

【Abstract】 XSIEQ(XML stream query with immediate evaluation), a kind of XML stream query system, can evaluate predicates immediately and output in time. The design and implementation of XSIEQ are presented. XSIEQ uses a modified pushdown automata technique, and its idea is to convert all XPath expressions into a single NFA, then to attach type label and corresponding index info on NFA state. Accordingly, XSIEQ can quickly decide the opportunity of predicate evaluation and data cache in runtime, and implement immediate processing. In the end, the query performance comparison between XSIEQ and YFilter is given and analyzed.

【Key words】 XML stream; Predicate evaluation; Push down automata(PDA)

1 概述

在 Web 服务及其相关应用中, XML 数据大多以流的形式进行传递、分发。XML 流查询也被广泛用于信息选择分发、数据集成、管道处理、连续查询等应用中。

基本的 XML 流查询条件是一组 XPath 式。一个 XPath 式是对 XML 文档节点进行定位的一个字符串, 并且可能包含对节点的谓词选择条件。XPath 式中去除谓词后剩余的部分称为主 XPath 式, 它确定 XML 查询匹配的候选结果节点。流查询的主流做法是根据查询 XPath 式构造查询自动机。如 YFilter^[1]将 XPath 式构造为 NFA; XMLTK^[2]从 NFA 构造 Lazy DFA; SPEX^[3]将单个 XPath 式转换为多个 PDA(Push down automata)并连接为 SPEX 网。

在管道处理、连续查询等应用中, 需要在查询过程中即时地输出当前查到的部分结果。实现即时输出的最大障碍是 XPath 式中存在的谓词。

例 1 考虑 XPath 式 $P_1: /a[//b=2][e=3]/c[d]$ 和 XML 片段:
`<a>2<c><d/></c><e>3</e>`

$/a/c$ 是 P_1 的主 XPath 式。当 SAX 解析获得 XML 片段中的 $/a/c$ 节点时, 谓词 $[e=3]$ 尚未计算, 故阻碍了查询结果的即时输出。

XMLTK 只支持能在当前位置步计算的谓词, 故实现有限的即时输出。YFilter 在解析 XML 时缓存所有的候选结果节点和谓词中 XPath 式匹配的节点, 在解析结束后通过后处理获得最终的查询结果。XPush^[4]使用修改了的 PDA, 通过自底向上的计算对满足谓词的状态进行转换, 到文档解析结束时根据最终匹配的状态集得到查询结果。

XSIEQ(XML Stream Query with Immediate Evaluation)旨

在建立一套高效的、能立即计算谓词并即时输出的 XML 流查询引擎。当前, XSIEQ 支持 XPath 式的孩子、子孙、自身和属性轴, 支持含相对 XPath 式的复杂谓词(包括嵌套谓词)。XSIEQ 采用索引技术和缓冲机制, 通过构造 PDA 实现谓词的立即计算和查询结果的即时输出。

2 XSIEQ 自动机

XSIEQ 根据要查询的 XPath 式构造自动机。为支持谓词, XSIEQ 使用带栈的 NFA, 即下推自动机(PDA)。

2.1 从 XPath 式构造自动机状态

从 XPath 构造自动机状态分为两步。

(1)将 XPath 式构造为 NFA。XSIEQ 采用和 YFilter 类似的方法, 将 XPath 式中的主 XPath 式和谓词中的 XPath 提取出来, 通过前缀共享的方法增量式地构造 NFA。在 NFA 中, XPath 式的位置步被映射到状态, 节点测试是状态间的转换条件。对于谓词中的相对 XPath 式, 是以包含该谓词的位置步到达的状态为起始状态, 进而构造为 NFA 中的分支路径。

(2)对 NFA 状态进行类型标记并添加索引信息。需要标记以下 3 类 NFA 状态:

定义 1 结果状态是指由主 XPath 式的最后一个位置步到达的 NFA 状态。该状态将保存它所对应的主 XPath 式对象列表 LR。

基金项目:国家自然科学基金资助项目(60473068); 中国科学院计算机科学重点实验室开放课题基金资助项目(SYSKF0502)

作者简介:吴年(1976—), 男, 硕士, 主研方向: XML 数据处理; 张昱, 副教授

收稿日期:2005-07-10 E-mail: nwu@ustc.edu

定义 2 叶子状态是指谓词中 XPath 式的最后一个位置步到达的 NFA 状态。该状态将保存它所关联的谓词对象列表 LP。

定义 3 对于某个 XPath 式，主路径上具有分支到谓词中 XPath 式的 NFA 状态被称为分支状态。该状态将保存从该状态分支出去的谓词对象列表 LB。

例 2 按照上述转换步骤，对例 1 中的 P_1 构造出图 1 所示的带索引信息的 NFA。状态用圆圈表示，双圈表示结果状态；弧代表状态转换，其中虚线表示子孙轴类型的转换，实线表示孩子轴类型的转换，弧上的标记表示节点测试。状态 S1 由于包含子孙轴类型的转换弧而具有到自身的转换弧。

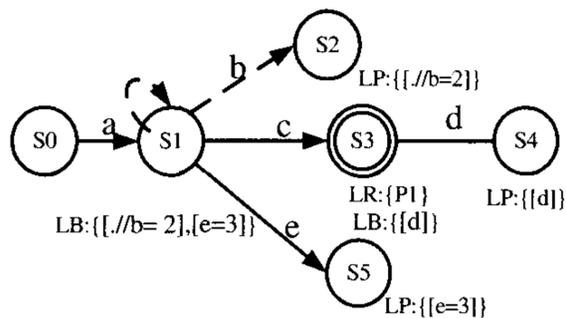


图 1 P_1 对应的带索引信息的 NFA

SAX 解析 XML 流时，SAX 事件触发自动机的状态转换。到达结果状态可以确定匹配待查 XPath 式的候选 XML 节点；到达叶子状态可以对谓词进行计算；分支状态是确定分支下各谓词最终计算状态的场所。通过标记这些状态就可以在 SAX 解析时快速确定谓词计算和数据缓存等动作的时机，实现即时查询。

2.2 定义

XSIEQ 自动机是一个修改了的非确定的 PDA，它包含普通的 PDA 状态、缓冲区状态和谓词计算状态；并且转换函数也包含对谓词进行计算的函数。以下 Σ 为 XML 元素名的集合， V 表示字符串值集合， D 表示 XML 片段的集合。

定义 4 一个 XSIEQ 自动机是元组 $(Q^s, Q^b, Q^p, q^s_0, q^b_0, q^p_0, F, PF, B, \delta)$ ，其中：

- (1) Q^s 是普通的 PDA 状态集合， Q^b 是缓冲区状态集合， Q^p 是谓词状态集合；
- (2) $F \subseteq Q^s$ 是结果状态集合， $PF \subseteq Q^s$ 是叶子状态集合， $B \subseteq Q^s$ 是分支状态集合；
- (3) $Q = Q^s \times Q^b \times Q^p$ 为状态集合，状态 $q = (q^s, q^b, q^p) \in Q$ ， $q^s \in Q^s$ ， $q^b \in Q^b$ ， $q^p \in Q^p$ ；
- (4) $(q^s_0, q^b_0, q^p_0) \in Q$ 是初始状态；
- (5) $\delta = \{t_{forward}, t_{collect}, t^p_{eval}, t^p_{reset}, t^b_{add}, t^b_{set}, t_{accept}\}$ 是一组状态转换函数，定义如下：

$$\begin{aligned}
 t_{forward}: Q^s \times \Sigma &\rightarrow Q^s \\
 t_{collect}: D \times F \times (\Sigma \cup V) &\rightarrow D \\
 t^p_{eval}: Q^p \times PF \times (\Sigma \cup V) &\rightarrow Q^p \\
 t^p_{reset}: Q^p \times B &\rightarrow Q^p \\
 t^b_{add}: Q^b \times D \times Q^p &\rightarrow Q^b \\
 t^b_{set}: Q^b \times Q^p &\rightarrow Q^b \times Q^p \\
 t_{accept}: Q^p &\rightarrow P(I)
 \end{aligned}$$

若 XPath 式 P 没有谓词，则 $Q^b(P)$ 和 $Q^p(P)$ 均为空。若 P 包含 m 个顶层谓词，则用 m 位位组标识 P 中各谓词的计算状态(即谓词状态)。单个谓词的状态分未确定、确定为假、确定为真 3 种。当某谓词确定为假后，与该谓词相关的缓存数据将被清除，这样谓词又处于未确定状态。为此，位组中各位用 0 表示未确定和确定为假，1 表示确定为真。当实现 n

个 XPath 式的查询时，每个 XPath 式 P_i 有自己的谓词状态 $Q^p(P_i)$ 和缓冲区状态 $Q^b(P_i)$ ，则

$$\begin{aligned}
 Q^b &= Q^b(P_1) \cup \dots \cup Q^b(P_n) \\
 Q^p &= Q^p(P_1) \cup \dots \cup Q^p(P_n)
 \end{aligned}$$

$t_{forward}$ 为状态转换操作。 $t_{collect}$ 为候选结果的收集操作，它在进入到结果状态时启动一次收集过程，回溯到结果状态时结束。 t^p_{eval} 表示到达叶子状态时根据当前 XML 数据计算谓词并更新谓词状态； t^p_{reset} 表示回溯到分支状态时对谓词状态进行复位。 t_{accept} 是在谓词状态确定时标记候选结果是否是最终要输出的结果并执行输出。 t^b_{add} 、 t^b_{set} 是对缓冲区的操作，在下节中说明。

2.3 缓冲区管理

在 XML 流解析过程中，收集到主 XPath 式匹配的候选结果时，相关的谓词条件可能尚未完全确定，这时需要缓存候选结果。由于 XPath 式的谓词状态是实时变化的，而缓存数据项的谓词状态与当前 XPath 式的谓词状态变化不同步，因此缓存数据项必须保存它所关联的谓词状态，即每个缓存的数据项是一个二元组 $\langle data, pStatus \rangle$ ， $data \in D$ ， $pStatus \in Q^p$ 。

自动机定义了两种缓冲区操作：

- (1) t^b_{add} 将收集到的候选结果和当前谓词状态 $\langle data, q^p \rangle$ 加入到缓冲区 q^b 中；
- (2) $(q^b, out) \leftarrow t^b_{set}(q^b, q^p)$ 表示根据 q^p 对 q^b 进行维护，维护后缓冲区状态为 q^b ，并将已确定的结果通过 out 带回。分两种情况：

1) 当 q^p 中谓词 $pred$ 的计算为真时，执行 t^b_{set} 将缓冲区中 $pStatus$ 的状态为 0 的 $pred$ 修改为 1。若某数据项的 $pStatus$ 各位均为 1，则将其移入 out 中；

2) 当回溯到分支状态时，若 q^p 中存在有谓词 $pred$ ，且状态为 0，则说明该谓词不满足；执行 t^b_{set} 将清除缓冲区中 $pStatus$ 的 $pred$ 状态为 0 的数据项。

自动机在两种场合会调用 t_{accept} 处理输出：一是上述的 1)；二是在候选结果收集完毕， q^p 已完全确定时。

3 XSIEQ 自动机的运行

3.1 运行过程

XSIEQ 自动机在运行时维持一个当前状态 $q = (q^s, q^b, q^p)$ 、当前收集的数据 d 和栈 s ，其中 q^s 由 NFA 状态集组成， q^b 和 q^p 为各 XPath 式相应状态的并置。自动机的运行由 SAX 事件驱动，初始时 $q = (q^s_0, q^b_0, q^p_0)$ ， q^s_0 由 NFA 根状态组成。

```

startDocument()
   $q^s \leftarrow q^s_0; q^p \leftarrow q^p_0; q^b \leftarrow \phi; \text{push}(s, q^s); d \leftarrow \phi;$ 
startElement(a)
   $q^s \leftarrow t_{forward}(q^s, a); \text{push}(s, q^s);$ 
  if ( $q^s \in PF$ ) {
     $q^p \leftarrow t^p_{eval}(q^p, q^s, a);$ 
     $(q^b, out) \leftarrow t^b_{set}(q^b, q^p); t_{accept}(out);$ 
  }
  if ( $q^s \in F$ )  $d \leftarrow t_{collect}(\phi, q^s, a);$ 
character(str)
  if ( $q^s \in PF$ ) {
     $q^p \leftarrow t^p_{eval}(q^p, q^s, a);$ 
     $(q^b, out) \leftarrow t^b_{set}(q^b, q^p); t_{accept}(out);$ 
  }
  if ( $q^s \in F$ )  $d \leftarrow t_{collect}(d, q^s, str);$ 
endElement(a)
  if ( $q^s \in F$ ) {
     $d \leftarrow t_{collect}(d, q^s, str);$ 
    if ( $q^p$  is true)  $t_{accept}(\langle d, q^p \rangle);$ 
    else  $q^b \leftarrow t^b_{add}(q^b, d, q^p);$ 
  }
  if ( $q^s \in B$ ) {
     $q^p \leftarrow t^p_{reset}(q^p, q^s);$ 
     $(q^b, out) \leftarrow t^b_{set}(q^b, q^p);$ 
  }
   $q^s \leftarrow \text{pop}(s);$ 
endDocument() do nothing.

```

