XML 문서상에서 키워드 검색을 위한 색인 분할 기법

이 홍 래　이 형 동　유 상 원　김 형 주
서 울 대 학 교　컴 퓨 터 공 학 과
{hrlee, hdlee, swyoo, hjk}@oopsla.snu.ac.kr

Index Partitioning Technique for Keyword Search over XML Documents

Hongrae Lee, Hyungdong Lee, Sangwon Yoo, Hyoung-joo Kim

School of Computer Science & Engineering, Seoul National University

요　약

정보 검색의 대상이 XML 문서가 되면서 구조 정보를 이용하는 것과 같은 단순한 텍스트 기반의 검색에서는 어려웠던 일이 가능해졌다. 그러나 문서 단위로 처리하던 정보를 엘리먼트 단위로 상세하게 해야 하므로 처리의 부담이 가중되어 많은 수의 엘리먼트를 효과적으로 처리할 수 있는 알고리즘이 필요하다. 본 논문에서는 결과가 될 가능성이 있는 엘리먼트들끼리 미리 분할 한 후 저장하여 처리 대상이 되는 엘리먼트들의 수를 줄이는 역색인 방법을 제안한다. 분할은 특정 레벨을 기준으로 하여 이 레벨에서 공통 선조를 가질 수 있는 가의 여부에 따라 수행한다. 그리고 분할 병합을 통하여 분할하지 않은 것과 동일한 결과를 생성할 수 있도록 하였다. 이는 기존의 XML 문서에 대한 키워드 검색의 성능을 향상시키는 결과를 가져왔고 이를 실험적으로 검증하였다.

1. 서론

XML(Extensible Markup Language)는 W3C에 의해 표준으로 제창된 텍스트 포맷이다[1]. 현재 XML은 인터넷을 포함한 다양한 장소에서 데이터 교환의 실질적인 표준으로 자리 잡아서 학계, 산업계 등 거의 모든 분야에서 XML을 이용한 표준이 제정되어 전자책, 신문, 증권, 의료, 학술 등 점점 많은 데이터가 XML로 저장되고 교환되고 있다..

XML로 저장되고 교환되는 데이터의 양이 늘어남에 따라 XML 문서에 대한 검색의 필요성이 점점 커지고 있다. XML 문서의 검색에 사용되는 질의어를 구분하는 한 방법으로 구조적 질의어와 비구조적 질의어 두 가지로 나누는 방법이 있다. 구조적 질의어는 RDBMS 상의 SQL과 비슷한 역할을 하는 질의어로서 XML 문서상에서 특정 부분을 정확하게 처리하여 결과로 생성할 수 있는 질의어로 문서의 내용뿐만 아니라 구조에 대한 표현이 가능한 질의어 이다. 이러한 형태의 질의어로 XQL[19], XML-QL[20] 등 많은 언어가 제안되었고 XPath[21], XQuery[22] 등이 W3C에서 표준으로 제안되었거나 정비 중이다. 이런 구조적 질의어는 그 표현 능력이 뛰어나고 정확한 결과를 얻을 수 있는 반면에 문법이 복잡하고 문서의 구조에 관한 정확한 정보가 필요하다는 단점이 있다. 이보다 좀 더 쉽게 정보에 접근할 수 있는 질의어가 비구조적 질의어로 문서의 구조에 대한 정확한 표현이 어려운 반면에 사용하기가 쉬운 장점이 있다. 이러한 비구조적 질의어로 가장 대표적인 방법이 키워드 검색이다. 키워드 검색은 이미 인터넷의 검색엔진에서 널리 사용되고 있는 방법으로 일반 사용자가 선호하는 검색 방법이다. 본 논문은 대량의 문서가 XML로 존재하나 사용자가 문서들의 정확한 정보를 알기 힘들거나 문서들이 비정형적 구조를 지닌 환경을 가정하여 질의 방법으로써 키워드 검색을 사용하였다.

XML 문서에 더해진 구조적 정보는 검색의 과정에서 여러 가지로 활용할 수 있다. 그 중 가장 중요한 하나는 검색의 결과로 문서 전체가 아니라 일부분을 리턴할 수 있다는 것이다. 과거 텍스트 기반의 연구 중 구문 검색(passage retrieval)에 관한 연구[23,24,25]들이 있었으나 구조에 대한 정보가 한정적이어서 결과가 부정확하거나 응용이 제한적인 경우가 많았다. 그러나 XML 문서의 경우에는 이 구조가 자유롭고 정확하게 정의될 수 있어서 이를 활용하여 검색 결과의 품질을 높일 수 있다. XML 문서 검색의 한 예를 살펴보자.

예제 1 그림 1은 DBLP XML 문서의 한 부분을 간략화 한 것이다. 사용자가 Jagadish가 저술한 XML에 관한 논문을 찾아보기를 원한다고 가정하자.

```
<inproceedings key="conf/sigmod/Jagadish90">
        <author>H. V. Jagadish</author>
        <title>Linear Clustering of Objects with Multiple Atributes.</title>
</inproceedings>
<inproceedings key="conf/sigmod/ZhangRL96">
        <author>Tian Zhang</author>
        <author>Miron Livny</author>
        <title>BIRCH: An Efficient Data Clustering Method for Very Large Databases.</title></inproceedings>
<inproceedings key="conf/dbpl/JagadishLST01">
        <author>H. V. Jagadish</author>
        <author>Divesh Srivastava</author>
        <title>TAX: A Tree Algebra for XML.</title>
</inproceedings>
```

그림 6 DBLP XML 문서의 일부분

일반적인 키워드 검색이라면 위의 문서가 Jagadish와 XML을 모두 포함하고 있기 때문에 질의의 결과로 그림 1의 문서 전체를 반환할 것이다. 그 결과에는 사용자가 원하는 논문에 관한 정보도 있지만 관련 없는 다른 정보도 포함되어 있다. 위의 문서에서 해당 문서에 대한 구조 정보를 활용하여 Jagadish가 저술한 TAX 논문만을 결과로 반환한다면 더 좋은 검색 결과가 될 것이다.

이렇게 일반 문서에 비하여 XML 문서가 검색의 측면에서 장점을 가지기도 하지만 거기에 따르는 단점도 많다. 그 중 가장 대표적인 것은 처리해야 할 정보가 늘어난다는 점이다. 기존의 문서 검색에 있어서는 문서 단위로 질의를 처리하였으나 대상이 XML문서인 경우에는 엘리먼트 수준의 상세한 단위로 질의를 처리한다[6,7,10,11,12,13]. 실제로 사용되고 있는 XML 문서들을 분석한 최근의 연구 결과[2]를 보면 한 문서에서 처리해야 할 엘리먼트의 수가 수백, 수천 개 정도의 단위로 굉장히 많은 것을 알 수 있다. 문서 단위로만 정보를 처리하는 경우에도 문서 집합의 크기가 커질 경우 색인의 크기, 질의 처리의 성능이 문제가 되어서 색인 압축 기법[3, 5], 중단 기법[4]등 많은 연구가 이루어 졌다. 이러한 문제점은 XML 문서 검색의 경우에는 문서 집합의 크기가 커질수록 더욱 심각해진다.

본 논문에서는 이러한 문제점을 해결하기 위하여 XML 검색에서 엘리먼트 단위로 정보를 처리하면서도 큰 규모의 문서 집합에도 적용될 수 있는 효율적인 검색 방법을 연구하였다. 기본적인 접근 방법은 검색의 결과가 될 수 있는 엘리먼트끼리 미리 분할(partition)하여 색인에 저장하고 질의 처리에 이 분할된 정보만을 이용하여 처리되는 엘리먼트의 개수를 대폭 줄이는 것이다. 구체적으로 엘리먼트를 분할하여 색인을 구성하는 방법과 이를 이용하여 질의를 처리하는 알고리즘을 제시한다.

본 논문의 구성은 다음과 같다. 2장에서는 XML 키워드 검색과 관련된 연구들을 고찰하고 문제점을 제기하며 3장에서는 검색 모델을 정의한다. 4장에서는 문제점 해결을 위한 분할 색인 방법을 제시하고 5장에서 이를 실제로 구현하여 실험한 결과를 가지고 고찰한 후 6장에서 결론을 내린다.

2. 관련 연구

XML에 관한 표준이 제정되기 시작한 초기부터 XML 질의 처리에 관한 연구가 활발하게 이루어 졌다. 키워드를 사용한 XML 검색에 관한 초기 연구로는 [9]가 있지만 질의어에 키워드 검색을 포함하였다는 이상의 의의는 찾아보기 힘들다. XKeyword[10]는 그래프로 표현된 XML 데이터 상에서 키워드 검색을 수행하는 시스템으로 노드들 간의 연결 관계에 초점을 맞추었다. 노드들이 복잡한 상관관계를 가지며 연결된 경우에도 중복된 결과 없이 효율적으로 데이터를 처리하나 모델링한 XML 문서 자체가 일반적인 데이터베이스를 변환한 형태로 텍스트가 많은 XML 문서의 경우에는 적용하기 힘들다.

XML 문서는 그 유연성 때문에 단순한 데이터를 표현하는 한 방식이 될 수도 있지만 기본적으로 일반 텍스트를 구조화 한 것이기도 해서 데이터베이스 기반 기술과 정보 검색(IR) 기술의 융합이 필요하다. 그래서 최근에는 데이터베이스 기술과 정보 검색 기술을 융합한 시스템이 많이 연구되고 있다. XRANK[11], XSEarch[12], [13] 모두 이러한 경향을 반영한 최근의 연구 결과이다. XRANK는 최소 공통 선조(least common ancestor) 노드를 질의의 결과로 정의하고 이를 구하기 위한 DIL 색인구조와 질의 처리 알고리즘을 제안하였다. XSEarch는 XML 키워드 검색에서의 의미론적인 면에 좀 더 초점을 맞춘 연구 결과이다. XML 검색 결과의 단위는 여러 연구에 따라 다르게 정의되어 왔는데 이들을 크게 결과의 단위와 형식이 질의 자체에 표현되는 경우, 주어진 조건을 만족하는 최소 서브트리인 경우, 따로 검색 결과가 지정되는 경우, 별도의 로직에 의해서 검색 결과를 결정하는 경우 등이 있다. XSEarch는 이 중 마지막의 접근 방법을 취하는 연구로 노드의 라벨을 분석하여 연결 관계(interconnection relationship)를 정의하여 의미 있는 결과를 추론한다. 본 논문에서는 질의 결과의 단위로는 XRANK와 동일한 최소 공통 선조 노드를 사용하였다. 단어의 가중치를 정하는 문제와 순위화를 하는 문제도 XML 검색에서 많은 관심을 가져왔다. [13]은 기존의 벡터 스페이스 모델[15]를 확장한 용어 가중치와 순위화 알고리즘을 제안한 연구 중의 하나로 여러 가지 가중치 알고리즘들을 비교분석하였다.

이러한 연구들은 공통적으로 기존의 정보 검색 분야에서 개발된 여러 기술들을 XML 문서의 특징을 잘 살려 확장하고 새로운 가능성들을 보여 주었지만 처리해야 할 정보가 늘어난 점을 간과하고 있다. XRANK와 같은 연구는 질의 처리를 효과적으로 하기 위한 색인 구조나 알고리즘 등을 비교 분석하기도 하였지만 이 또한 모든 엘리먼트들을 처리하여 큰 규모의 문서집합에 적용되기

힘든 근본적인 문제점을 지닌다. 본 연구에서는 이러한 점에 초점을 맞추어서 XML 문서 검색의 성능 향상을 연구하였다. 검색의 내용이나 알고리즘은 기존의 연구 결과를 활용면서 더 효율적으로 처리할 수 있는 색인 구조와 질의 처리 알고리즘의 개발에 초점을 맞추었다.

3. 검색 모델

3.1. XML 문서

XML 문서는 여러 가지로 모델링을 될 수 있지만 본 논문에서는 순서가 있는, 노드에 라벨된 트리(ordered node labeled tree)로 모델링을 하였다. 문서 노드(document node)가 트리의 루트노드이고 트리의 레벨은 루트노드를 0으로 정의한다. 그리고 레벨이 루트에 가까울수록 '낮다'고 하고 루트에서 멀어질수록 '높다'고 한다. 즉 레벨이 더 낮은 노드는 루트에 더 가까운 노드를 뜻한다. 그리고 엘리먼트와 애트리뷰트의 구별은 두지 않았다. 애트리뷰트에 정보를 두는 것과 엘리먼트에 정보를 두는 것이 큰 차이가 없는 경우가 많기 때문이다[2].

그림 2는 예제 1의 XML 문서를 트리로 모델링한 그림이다. 트리의 각 노드에는 노드 번호는 노드를 구분하기 위한 식별자이다.

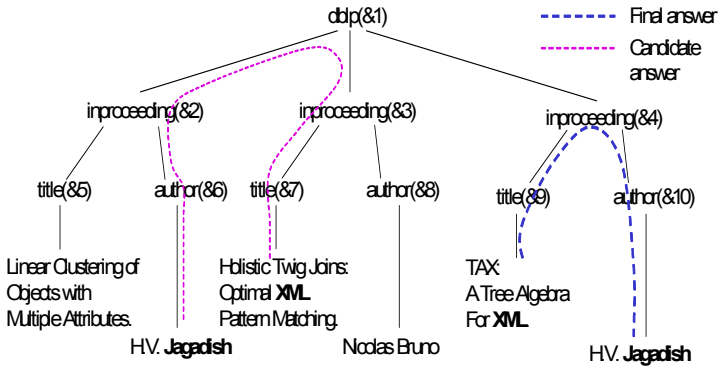

그림 2 예제 1의 문서의 트리 모델과 질의 결과

3.2. 질의 모델

키워드 검색에서 사용자로부터의 입력은 단순한 키워드의 집합이다. 이 키워드들은 보통 두 가지 의미 중에 하나로 해석되는데 첫 번째가 AND로 연결된 단어로 해석하는 방법이고 두 번째가 OR로 연결된 단어로 해석하는 방법이다. 본 논문에서는 첫 번째 의미로 키워드 검색을 정의하여 결과는 모든 키워드들을 포함하여야 하는 것으로 정의한다.

검색의 결과로는 XML 문서 전체가 아니라 XML 문서의 서브 트리를 반환한다. 논문에서 이 서브 트리와 서브 트리의 루트 노드는 서로 같은 의미로 사용한다. 결과는 모든 키워드를 포함하는 전체 문서 트리의 서브 트리이고 결과의 어떤 서브 트리도 전체 키워드를 포함하지 않는다고 정의한다. 이는 최소 공통 선조 노드(LCA, least common ancestor)를 결과로 정의하는 것으로 높은 레벨에 있는 결과일수록 좋은 답으로 보는 것이다. 문서에 관한 DTD정보를 가지고 있거나 관리자가 문서의 형식을 잘 알고 있는 경우에는 이것보다 의미 있는 검색 결과의 단위를 결정하기 쉬우나 본 논문은 인터넷처럼 이질적인 문서가 존재하는 환경을 대상으로 하여 XML 문서에 관한 DTD 정보를 가정하지 않았다. 이러한 경우 검색의 결과의 단위를 결정하는 문제는 현재 연구가 진행되고 있는 분야로 아직 결정적으로 받아들여지고 있는 알고리즘은 없고 가장 선별적인 즉 가장 높은 레벨의 결과를 반환하는 접근 방법은 일반적으로 쓰이는 한 방법이다[10,11].

예제 XML 문서에 대한 "Jagadish가 저술한 XML에 관한 논문을 찾아라"는 질의를 키워드 검색으로 표현하면 ("Jagadish", "XML") 이다. 이 질의에 관한 가장 적절한 결과는 그림 2에서 노드 &4로 표현되는 서브 트리이다. 이 노드는 하위 서브 트리에 "Jagadish", "XML" 두 단어를 모두 포함하고 있다. 노드 &1이 루트인 서브트리도 결과로 볼 수 있으나 하위에 결과가 될 수 있는 다른 노드(&4)를 포함하고 있고 레벨이 &4보다 더 낮으므로 덜 정확한 결과이다.

4. PIX (Partitioned Index for Keyword Search over XML Documents)

4.1. 역색인을 이용한 질의 처리 개관

역색인

역색인(inverted index)은 정보 검색 분야에서 질의 처리를 위해 이용되는 가장 일반적인 색인 구조이다. 역색인은 시스템이나 질의 처리 알고리즘에 따라 다양한 구조를 지니나 기본적인 구조는 특정 단어를 입력하면 해당 단어가 존재하는 위치 정보(포스팅)의 리스트를 얻을 수 있는 구조를 지니고 있다. 이 위치 정보는 단순히 문서 번호에서 시작하여, 문서 번호와 문서 내 위치, 출현 빈도 등 다양한 부가적인 정보를 포함하여 질의 처리를 돕는 구조로 구성된다. XML 문서 검색의 경우 이 위치는 문서 단위가 아니라 엘리먼트 단위의 정보를 가지도록 구성된다. 예를 들면 예제문서의 경우 그림3과 같이 역색인이 구성된다.

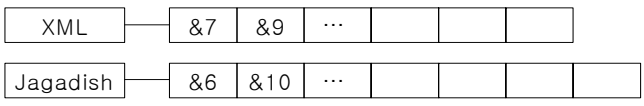

그림 3 예제 1의 문서에 대한 역색인

질의 처리

이 역색인을 이용하여 키워드 검색을 하는 가장 기초적인 알고리즘은 각 키워드 별 위치 정보들의 조합을 검사하는 방법이다. 그림 2에 대한 역색인(그림 3)을 이용한 질의 처리를 예를 들어보면 다음과 같이 할 수 있다. 먼저 사용자가 입력한 키워드 "Jagadish"와 "XML" 두 단어의 포스팅 리스트를 가져온다. 이 두 단어를 모두

포함하는 쌍은 (&7, &6), (&7, &10), (&9, &6), (&9, &10) 이렇게 4가지이고 이들 조합의 결과는 각각 (&1, &1, &1, &4) 이다. 이 중 가장 선별적인 결과는 &4이므로 답으로 &4를 출력한다. 이는 가장 간단한 한 예로 실제로는 DIL[11]과 같은 좋은 알고리즘들이 존재한다. 그러나 이들 알고리즘들도 최소한 각 키워드의 포스팅 리스트를 최소 한 번 검색하여야 질의 처리가 가능하다. 기존에 문서 단위로 색인을 하던 시스템에서도 문서 집합의 크기가 커지면서 이 역색인 리스트의 크기가 커져서 많은 압축과 리스트 구성 기법들이 연구[18]되었던 것을 고려하면 처리 단위가 엘리먼트 수준인 XML 검색에서 이는 성능 상의 큰 문제가 된다. 다음 장에 제시하는 색인 분할 기법은 색인을 분할하여 질의 처리 시에 역색인 리스트의 일부분만을 로드하여 처리할 수 있도록 하여 이러한 문제점을 해결한다.

4.2. 색인 분할

분할의 기본 개념

앞의 예제에서 &9와 &10은 서로 매치되어 결과로 되고 &9와 &6은 매치되어도 루트 노드를 답으로 생성하여 의미 있는 결과가 되지 못한다. 색인 분할의 기본적인 아이디어는 의미 있는 결과를 생성할 수 있는 가능성이 있는 노드들끼리 분할하여 색인에 저장하여 역색인 리스트에서 처리하는 엘리먼트의 개수를 줄이는 것이다.

이런 매치 가능성은 특정 레벨을 기준으로 생각한다. 즉, 기준이 되는 레벨을 정하여 이 레벨 아래에서 공통 선조를 갖는 노드들은 결과로 보지 않고 이 기준 레벨보다 큰 레벨에서 공통 선조를 갖는 노드들만을 의미 있는 결과로 본다. 이 기준이 되는 레벨을 기준 레벨(base level)이라 정의한다. 즉 기준 레벨보다 높은 레벨의 답을 먼저 찾고 차차 레벨이 낮은 답들을 찾는 것이다. 이러한 질의 처리 방법은 Top-k 질의 처리에도 적합하다. 즉 기준 레벨 이상의 답을 먼저 찾고 만약 k개미만의 답이 생성되었을 경우에는 기준 레벨을 낮춰가며 답을 찾다가 충분한 개수의 답이 나오는 시점에서 처리를 중단하는 것이다.

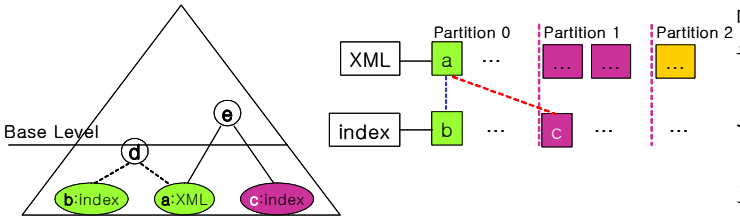

그림 4 공통선조를 갖는 레벨에 의한 분할의 개념

그림 4에서는 노드 a와 b는 기준 레벨 이상에서 공통 선조 노드를 가지므로 의미 있는 답이 될 수 있다. 그리고 노드 a와 c는 기준 레벨 보다 낮은 레벨에서 공통 선조 노드를 가진다. 따라서 이들은 일차적으로 답에서 제외된다. 이런 경우 a와 c를 다른 분할(partition)에 속하도록 하고 a와 b는 같은 분할에 속하도록 엘리먼트들을 나누어 그림 4의 역색인처럼 역색인을 분할하여 저장한다면 서로 다른 분할에 속해 있는 a 와 c는 아예 비교를 하지 않을 수 있을 것이다. PIX는 이렇게 어떤 레벨에서 공통선조를 가질 수 있는 지의 가능성을 가지고 역색인을 분할한다. 이후의 절들에서는 PIX의 구체적인 분할 알고리즘과 구성을 기술한다.

분할함수 PF

기준 레벨에서의 노드들의 매치 가능성[1]에 따라 노드들을 분할하여 주는 기준으로 트리 해쉬 함수 PF를 정의한다.

정의 1 (분할함수 PF) 분할함수 PF는 Value × Node → Value의 도메인을 갖는 함수로 첫 번째 인자는 트리의 레벨인 정수이고 두 번째 인자는 트리의 노드이다. 함수를 적용한 결과는 숫자이다. 레벨 i에서 노드 n에 적용한 PF(i, n)를 $PF_i(n)$으로, 고정된 i에 대하여 PF_i로 표기한다. PF는 다음의 성질을 만족하여야 한다.

트리 T의 임의의 노드 $n_a \in T$, $n_b \in T$ 에 대하여
노드 n_a와 n_b에 대하여 T의 i 레벨 이상에 최소 공통 선조 노드가 존재하면 $PF_i(n_a) = PF_i(n_b)$

다음 예제는 간단한 트리에 정의된 한 분할 함수 PF를 보인다.

예제 2

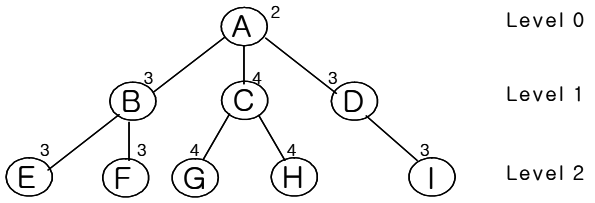

위와 같은 트리에서 함수 f가 f(B) = f(D) = f(E) = f(F) = f(I) = 3, f(C) = f(G) = f(H) = 4 인 매핑을 갖는다고 하자. 그러면 함수 f는 PF_1이다. 임의의 두 노드에 관하여 i = 1 일 때의 PF의 성질을 만족하기 때문이다. 또 노드 G와 노드 I에서 f(G) ≠ f(I) 이고 레벨 1 보다 낮은 레벨 0에서 최소 공통 선조를 갖는다. 여기에서 f(E) = f(I) 이지만 E와 I는 레벨 1에서 공통 선조를 갖지 않음에 주의한다. 즉 PF_i 값이 같다고 하여 반드시 레벨 i 이상에서 반드시 최소 공통 선조를 갖지는 않는다. 따라서 i보다 낮은 레벨에 존재하는 노드들에 대하여도 PF_i 값은 정의될 수 있다.

공통선조관계 $\asymp_i$

PF값을 이용하여 노드들의 잠재적인 매치 가능성을 분류하기 위하여 다음과 같은 관계를 정의한다.

정의 2 (공통선조관계 $\asymp_i$) 공통선조관계는 노드들의 집합에 대하여 특정 레벨i를 기준으로 PF와 함께 정의되며 두 노드에 적용되는 이항관계(binary relation)이다. 트리T의 임의의 노드 $n_a \in T$, $n_b \in T$에 대하여 다음과 같

1) 두 노드가 기준 레벨에서 공통 선조를 가질 수 있는 가능성을 의미한다.

이 정의된다.

$n_a \doteqdot_i n_b \Leftrightarrow \forall j \leqq i,\ PF_j(n_a) = PF_j(n_b)$

직관적으로 이 공통 선조 관계는 두 노드가 공통 선조를 가질 가능성이 있음을 의미한다. 만약 두 노드의 최소 공통 선조가 i 레벨에 존재하면 이들은 i 레벨 이하에서 항상 공통 선조를 갖고 이들은 최소 공통 선조에서 루트까지의 패스 상에 존재하는 노드들이다. 그리고 노드 자신을 자기의 선조라고 본다면 이 관계는 동치 관계이다.

분할 P

공통선조관계는 동치관계 이므로 트리의 모든 노드들을 서로 겹치지 않게 분할한다. PF 함수의 성질의 대우는 PF 값이 틀리면 기준 레벨 이상에서 공통 선조를 가지지 않는다는 것이다. 따라서 이렇게 나눈 서로 다른 분할들 사이의 노드들 간에는 비교를 할 필요가 없다.

정의 3 (공통선조관계에 의한 분할 P) i 레벨의 공통선조관계는 전체 트리 노드들의 집합을 겹치지 않은 부집합들로 분할한다. 같은 분할에 속하는 노드들은 같은 PF_i값을 갖고 이 값을 분할 값으로 정의하고 P-value라 한다. P-value가 v인 i 레벨에서의 분할을 $P_{i,v}$로 표시한다. 그리고 색인 시의 기준 레벨을 색인 레벨(index level)이라 한다.

PIX의 구조

PIX는 이 공통선조관계 분할 P를 이용하여 노드들을 분할하여 저장하는 역색인이다. 특정 키워드의 역색인 리스트 내에서 노드들은 각 분할 별로 그룹핑되어 저장된다. 즉 미리 정의된 PF 함수와 기준 레벨 i를 기준으로 하여 같은 PF_i값을 갖는 노드들끼리 분할하여 색인에 저장한다. 그리고 PIX는 역색인 리스트 내의 각 분할들에 효율적으로 접근하기 위하여 리스트의 처음에 분할 색인 정보 P-index를 가진다. 이 색인 정보에는 해당 키워드의 역색인 리스트 내의 전체 분할 수, 각 분할들의 분할 값과 리스트 내의 오프셋 정보, 포함하는 노드의 수에 관한 정보로 구성되어 있다. 이 구조는 그림 5에 도시되었다.

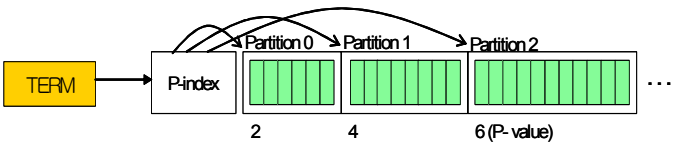

그림 5 PIX의 구조

예제 3 그림 6은 분할을 한 경우의 역색인을 보여준다. 그림의 트리는 예제 1의 XML 을 확장하여 트리로 간략하게 모델링한 것이고 A는 분할을 이용하지 않은 일반적인 역색인, B는 분할을 한 역색인을 나타낸다. 검색 단어는 "XML"과 "index"로 A의 일반적인 역색인을 이용할 경우 두 역색인 리스트의 모든 노드들은 최소 한 번씩은 처리되어 비교된다. 그러나 분할하여 구성된 역색인 B에서 같은 분할에 속하는 노드들끼리만 질의처리를 하면 된다.

B는 분할된 색인의 한 예이다. 레벨 1 이상이 답이 된다할 때 다른 분할에 속하는 (&10, &11)와 (&9)는 루트까지의 경로 중 첫 번째 레벨에 있는 노드가 다르기 때문에 레벨 1에서 답을 가질 수 없는 반면, 같은 분할에 속하는 (&8, &15)과 (&19)는 가능성이 있다. 실제로 &8과 &9는 매치되어 &2를 답으로 생성하지만 &15과 &9는 루트에서 매치되어 답에서 제외된다.

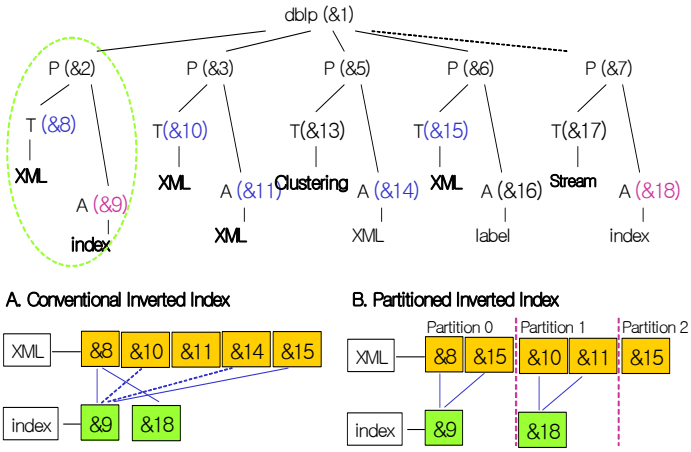

그림 6 분할된 역색인 예시

질의처리 알고리즘

XML 키워드 검색에서 질의처리는 기본적으로 모든 키워드를 포함하는 최소 공통 선조 노드들을 찾는 과정이다. PIX는 이러한 결과노드들을 찾을 수 있는 임의의 알고리즘을 사용할 수 있고, 본 논문은 XRANK[11]의 DIL 알고리즘을 사용하여 주어진 키워드의 노드들의 리스트에서 최소 공통 선조 노드들을 찾는 과정을 구현하였다. PIX에서의 질의 처리의 특징은 이 알고리즘들이 각 분할 내에서만 적용된다는 것이다. 즉 분할값 P-value를 기준으로 같은 P-value를 갖는 분할들 사이에서만 알고리즘을 적용하여 결과를 내면 된다. 다른 P-value를 갖는 분할에 존재하는 엘리먼트들은 서로 매치가 되어도 공통선조가 기준 레벨보다 낮은 레벨에 존재하기 때문에 의미 있는 결과를 생성하지 못하므로 서로 비교할 필요가 없다. 개략적인 질의 처리의 단계는 다음과 같다.

1. 각 단어 별 P-index 정보 검색
2. 단어 별 존재하는 분할들 중 모든 단어에 P-value가 공통되는 분할들만을 선별
3. 해당 분할들 사이에서 최소 공통 선조 노드를 구하는 알고리즘 적용

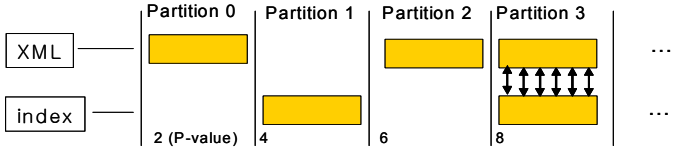

그림 7 분할을 이용한 질의 처리

위의 경우는 XML과 index 두 단어로 검색을 한 경우이다. XML은 P-value가 2, 6, 8인 분할들이 존재하고 index는 P-value가 4, 8인 분할이 존재한다. 이 두 단어의 분할들 중 공통되는 P-value는 8 밖에 없다. 따라서 XML의 해당 분할과 index의 해당 분할에 속하는 엘리먼트들에만 질의 처리 알고리즘을 적용하여 답을 생성하면 된다. 이 PIX 알고리즘은 입력 단어 중 선별적인 단어, 즉 특정 분할에만 존재하는 단어가 있으면 다른 분할들을 전혀 처리하지 않기 때문에 매우 효율적이다.

분할 병합

앞 절에 기술한 질의 처리 알고리즘을 통해 생성된 답은 기준 레벨 이상의 답만을 포함한다. 이는 기준 레벨이 문서의 의미 있는 결과의 레벨과 일치할 때는 타당성을 가지나 그렇지 않은 경우에는 기준 레벨 보다 낮은 레벨에 존재하는 다른 의미 있는 결과들을 생성하지 못하는 단점을 가진다. 분할 병합은 이렇게 기준 레벨만을 기준으로 생각하여 누락되는 답을 생성할 수 있게 하여 준다. 분할 병합은 기준 레벨을 좀 더 낮은 레벨로 이동하는 과정이다. 기준 레벨이 낮아지면 낮아진 레벨까지의 답이 생성되기 때문에 더 많은 결과를 포함한다. 기준 레벨이 낮아지면서 원래의 레벨에서는 서로 다른 P-value를 가졌던 분할들이 낮아진 레벨에서는 같은 P-value를 가지게 된다. 이러한 분할들은 낮아진 레벨에서는 같은 분할에 속하는 분할들로 이러한 같은 P-value를 갖는 분할들을 하나의 분할로 합하는 과정이 분할 병합이다. 분할 병합의 간단한 알고리즘은 다음과 같다.

1. 현재 존재하는 모든 분할들에 대하여
2. 새로운 레벨에서의 P-value를 계산하고 같은 P-value를 갖는 분할들끼리 합병

분할 병합으로 인하여 전체적인 질의 처리 알고리즘은 낮은 레벨부터 차례대로 레벨을 높여가면서 답을 찾는 식으로 구성되며 Top-k 질의 처리를 효율적으로 구현할 수 있다. 즉 특정 레벨에서 충분한 개수(k개 이상)의 답이 생성되면 그 시점에서 처리를 중단하는 것이다.

다음 그림은 분할 병합의 한 예이다.

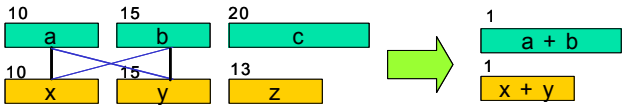

그림 8 분할 합병의 예

위의 색인의 기준 레벨이 4이고 각각 XML과 index의 역색인이라 하자. XML이라는 단어는 $P_{4,10}$[2], $P_{4,15}$, $P_{4,20}$의 세 분할들에 존재하고, index는 $P_{4,10}$, $P_{4,13}$, $P_{4,15}$의 세 분할에 존재한다. 레벨4를 기준으로 질의처리를 하였는데 충분한 개수의 결과가 나오지 않아 기준 레벨을 한 단계 낮춰 레벨3에 있는 답들까지 결과에 추가한다고 하자. 그리고 이들 각 분할의 P-value가 레벨4에서 10이었던 분할들은 레벨 3에서 P-value 1을 가지고, 15였던 분할들은 1, 20이었던 분할들은 2를 가진다고 하자. 이러면 분할 $P_{4,10}$과 $P_{4,15}$는 기준 레벨3에서는 P-value가 1로 같아 의미 있는 답을 생성할 가능성이 있다. 따라서 $P_{4,10}$과 $P_{4,15}$의 분할이 합병되어 새로운 분할 $P_{3,1}$을 형성하여 XML의 $P_{3,1}$ 분할과 index의 $P_{3,1}$ 분할에 다시 최소 공통 선조 알고리즘을 적용한다.

PIX의 구현

PIX는 다음에 정의하는 PIXPF 함수와 PIXMERGE 분할병합 방법을 사용하여 구현하였다. 물론 앞 절에 기술한 분할의 성질을 만족시키는 어떤 PF함수나 합병방법을 사용하여도 된다.

정의 4 PIXPF와 PIXMERGE

$$PIXPF_i(n) = \sum_{k=1}^{i} (o_k(n) mod 2)2^k$$

i: i 트리 레벨
n: 노드
$o_k(n)$: 노드 n에서 루트까지의 경로에 존재하는 노드 중 k 레벨 에 있는 노드의 순서. 해당하는 경로에 노드가 없을 경우에는 0

PIXMERGE (분할 병합 방법)
i 레벨에서 i-1 레벨로 기준 레벨 이동 시에 두 분할 $P_{i,a}$와 $P_{i,b}$에서 $a \bmod 2^i = b \bmod 2^i$ 이면 $P_{i,a}$와 $P_{i,b}$를 병합

직관적으로 PIXPF는 특정 노드에서 루트까지의 경로를 축약해서 나타낸다. 어떤 노드의 i 레벨의 선조의 순서가 그 레벨에서 형제노드(sibling)들 간에 짝수 번째 있으면 0, 홀수 번째 있으면 1을 가지고 있다. 그 숫자를 이진수로 i 번째 비트로 나타낸 것이다. 루트에서 어떤 노드까지의 경로를 생각할 때 첫 번째 레벨에서의 선조가 루트에서 짝수 번째 있고, 그 다음 레벨의 노드는 홀수 번째 있으면 $0\times2^0 + 1\times2^1 = 2$를 P-value로 갖게 된다. 즉 이진수로 나타낸 P-value는 각 i번째 비트가 i 레벨의 선조가 홀수 번째인지, 짝수 번째 인지를 나타내는 것이다.

정리 1 PIXPF는 분할함수 PF의 성질을 만족한다.

증명 트리 T 의 임의의 노드 n_a와 n_b가 i 레벨 이상에서 최소 공통 선조를 갖는다면 n_a에서 루트까지의 경로는 최소한 루트에서 i 레벨까지는 n_b에서 루트까지의 경로와 동일한 경로를 갖는다. 루트에서 i 레벨의 노드까지 공통 선조를 가지므로 n_a와 n_b는 $1 \le k \le i$인 모든 k에 대하여 o_k값이 모두 같으므로 $\sum_{k=1}^{i} (o_k(n_a) mod 2)2^k = \sum_{k=1}^{i} (o_k(n_b) mod 2)2^k$ 이다. $PIXPF_i(n_a) = PIXPF_i(n_b)$ 이 성립하므로 PIXPF 는 PF의 성질을 만족한다.

2) 레벨 4에서 정의된 P-value가 10인 분할. 정의 3 참조

5. 구현 및 실험

PIX는 C++로 구현되었으며 BerkeleyDB[16]을 사용하여 역색인을 구현하였다. 실험은 512MB의 메모리를 가진 PentiumIII 993 MHz의 PC에서 하였다. 실험에 사용한 데이터 셋은 INEX 2003[17]과 Shakespeare[26]이다. 주요 실험 목적은 분할을 한 경우와 하지 않은 경우의 성능의 차이를 테스트하는 것이었으며 이를 위하여 두 가지 실험을 하였다. 첫 번째 실험은 최대 분할의 개수변화에 따른 여러 가지 질의의 수행 속도 변화를 관찰하였고, 두 번째 실험은 검색 단어의 개수를 늘려가면서 분할을 한 경우와 하지 않은 경우의 성능을 비교 평가 하였다. PIXPF는 색인레벨이 i 일 때 최대 2^i개의 분할이 존재하므로 색인레벨을 높이는 것과 분할의 개수를 늘리는 것을 같은 의미이고 분할의 개수는 최대 분할의 개수와 동일한 의미로 사용한다.

첫 번째 실험은 INEX 2003 컬렉션을 가지고 수행하였다. INEX 2003 컬렉션은 현재 XML 문서 검색의 주요 테스트 컬렉션으로 1995 ~ 2001년도 까지의 컴퓨터 관련 저널 XML 문서들로 구성되어 있고 500M 이상의 크기이다. 질의는 이 컬렉션의 비구조적 표준 질의(CO)들을 사용하여 실험을 수행하였다. 이 질의들은 다시 두 가지 군으로 나누어 Q1 ~ Q4의 3,4개의 단어로 이루어진 간단한 질의와 Q5 ~ Q7의 출현 빈도가 매우 높거나 열 개 이상의 단어들로 이루어진 수행 시간이 오래 걸리는 복잡한 질의로 나누어 실험을 하였다.

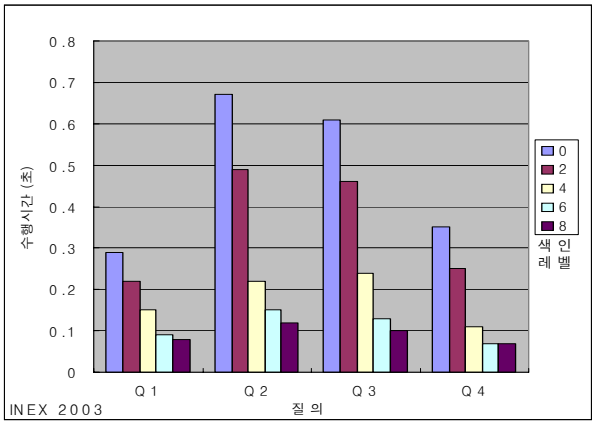

그림 9 분할 개수에 따른 질의 수행 시간 1

그림 9은 Q1 ~ Q4 INEX 질의의 수행 결과이다. 수행 결과는 질의 수행 시간으로 측정했으며 4 가지의 질의를 분할을 전혀 하지 않은 경우부터 두 번째 레벨에서 분할을 수행한 경우, 네 번째, 여섯 번째, 여덟 번째 레벨에서 분할을 수행한 다섯 가지 경우로 나누어 측정하였다. 실험 결과 모든 질의에 대하여 색인레벨이 높아질수록 좋은 수행 결과를 보였다. 단 여섯 번째 레벨 이하에서 성능 향상은 크지 않았다. 이 문서 셋의 경우 여섯 번째 레벨이 가장 평균 노드의 차수가 높고 이 레벨은 성능 향상이 가장 높은 색인레벨과 동일함을 알 수 있다.

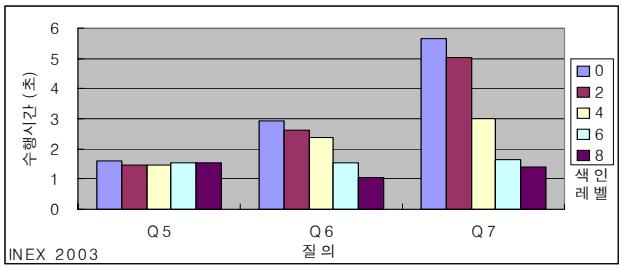

그림 10 분할 개수에 따른 질의 수행 시간 2

그림 10는 빈도수가 높거나 단어수가 많아서 시간이 오래 걸리는 Q5 ~ Q7 INEX 질의들에 대한 실험 결과이다. 그림 9의 실험 결과와 비슷하게 분할의 수가 많을수록 성능이 향상되는 결과를 보였으나 Q5의 경우에는 모든 경우가 거의 동일한 성능을 보였다. Q5를 더 자세하게 분석하여 보면 이 질의에 대하여 레벨 4에서 색인한 경우 모든 단어를 포함하고 있는 분할의 수가 15로, 레벨 4에서 최대 분할 수가 16인 것과 비교하였을 때 거의 모든 분할에 모든 단어가 존재하여 사실상 분할하지 않은 것과 동일한 것을 알 수 있었다. 이와 대조적으로 Q7의 경우에는 모든 단어가 존재하는 분할의 수가 4로 전체 16개의분할 중 4개의 분할만을 처리하여 질의 처리 알고리즘이 효과적이었음을 알 수 있었다. 이 실험에서 알 수 있듯이 PIX는 질의 대상 단어가 전 분할에 골고루 분포할 경우 큰 성능의 효과를 보이지 못하였는데 이는 보다 선별적인 PF함수를 고안함으로써 그런 경우를 줄일 수가 있을 것이다.

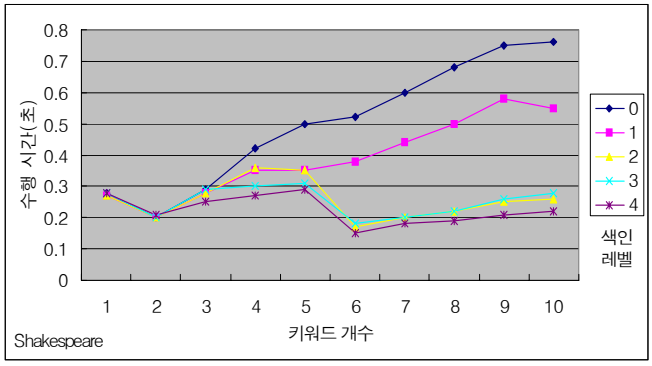

그림 11 키워드 개수에 따른 질의 수행시간

그림 11은 Shakespeare 문서 셋에 대하여 검색 단어의 수를 늘려가면서 분할의 개수에 따른 성능 변화를 측정한 결과이다. 분할을 하지 않은 경우나 한 경우나 검색 단어의 개수와 비례하여 수행 속도가 오래 걸렸다. 그러나 분할을 하지 않은 경우는 단어의 특성과 상관없이 선형적으로 증가하는 데 반하여 분할을 하지 않은 경우는 단어가 추가되면서 오히려 수행 속도가 줄어들기도 하고 전반적으로 검색 단어의 수에 비해 완만하게 수행 속도가 증가하였다. 이는 단어가 늘어나면서 모든 단어가 존재하는 분할의 수가 줄어드는 경우에는 단어의 수가 늘어나더라도 질의 처리의 대상이 되는 엘리먼트의 개수가

오히려 줄어들 수 있기 때문으로 분석할 수 있다. 그리고 분할에 의한 성능 향상은 INEX 컬렉션과는 다르게 레벨 2 이상에서는 거의 없음을 알 수 있다. 가장 성능향상이 큰 색인 레벨이 최고 차수가 가장 높은 레벨인 사실은 INEX 문서의 실험결과와 일치하는 것으로 문서 색인 시 색인레벨을 정하는 한 가이드라인으로 판단할 수 있다.

6. 결론 및 향후 연구

정보 검색의 대상이 XML 문서가 되면서 이전에는 불가능했던 부분 검색 등이 가능해 졌다. 그러나 처리해야 할 정보의 양이 많아져서 이는 질의 처리에 큰 부담이 되었다. PIX는 이러한 XML문서에 단어 검색을 하기 위한 역색인 구조로 내부적인 엘리먼트들의 매칭 가능성에 따라 미리 엘리먼트들을 분할하여 질의처리 시간을 줄일 수 있었다. 분할에 의한 성능의 향상은 전체 역색인 리스트 중 처리가 필요한 분할들만을 로드, 디코딩하여 질의처리를 하였기 때문이다. 분할은 색인 시에 색인레벨을 정하여 이루어 졌고 색인 레벨 보다 더 자세한, 높은 레벨에 존재하는 답만을 생성한다. 더 일반적인 답이 필요한 경우는 분할들을 합병하여 결과를 생성하는 것이 가능하여 분할을 하더라도 분할을 하지 않은 경우와 동일한 답을 생성할 수 있다. 이러한 분할, 합병 알고리즘은 Top-k 질의를 효율적으로 처리할 수 있다.

분할에 의한 성능 향상은 대부분의 질의에 나타났으나 단어들이 굉장히 고르게 분포하는 경우에 성능 향상은 크지 않았다. 이러한 고른 분포를 보이는 단어들에 대하여도 성능 향상을 보일 수 있는 분할 알고리즘의 연구가 필요하다. 또 본 논문은 XML 문서에 대한 단어 검색의 성능 향상을 목표로 하여 검색의 품질에 관한 연구는 하지 않고 기존의 연구 결과를 활용 하였다. 여러 가지 가중치 알고리즘과 순위화 알고리즘을 비교 평가하여 검색의 품질을 높이는 문제와 전체 XML 문서에서 어떤 부분을 결과로 반환할 것인지의 문제는 현재에도 진행되고 있는 연구 분야이고 풀어야 할 문제이다.

참 고 문 헌

[1] http://www.w3.org/XML/

[2] L. Mignet, D. Barbosa, P. Veltri. The XML Web: a First Study. WWW 2003

[3] S. Putz. Using a Relational Database for an Inverted Text Index. XEROX Technical Report '91

[4] V. N. Anh, O. Krester, A. Moffat. Vector-Space Ranking with Effective Early Termination. SIGIR '01

[5] D. Cutting, J. Pedersen. Optimizations for Dynamic Inverted Index Maintenance. SIGIR Conf. on Research & Development in IR '90

[6] N. Fuhr, K. Gro□johann. XIRQL: A Query Language for Information Retrieval in XML Documents. SIGIR '01

[7] A. Theobald, G. Weikum. The Index-based XXL Search Engine for Querying XML Data with Relevance Ranking. EDBT '02

[8] A. Theobald, G. Weikum. Adding Relevance to XML. WebDB '00

[9] D Florescu, et al. Integrating Keyword Search into XML Query Processing. WWW '99

[10] V. Hritidis, Y. Papakonstantinou, A. Balmin. Keyword Proximity Search on XML Graph. ICDE 2003

[11] L. Guo, et al. XRANK: Ranked Keyword Search over XML Documents. SIGMOD '03

[12] S. Cohen, J. Mamou, Y. Kanza, Y. Sagiv. XSEarch: A Semantic Search Engine for XML. VLDB 2003

[13] D. Carmel, Y. S. Maarek, M. Mandelbrod, Y. Mass, A. Soffer. Searching XML Documents via XML Fragments. SIGIR 2003

[15] G. Salton and M.J McGrill, "Introduction to Modern Information Retrieval". McGraw-Hill, New York, 1983.

[16] http://www.sleepycat.com

[17] Initiative for the evaluation of XML retrieval

[18] A. Moffat, J. Zobel. Self-Indexing Inverted Files for Fast Text Retrieval. TODS Vol. 14, No. 4, 1996.

[19] J. Robie, J. Lapp, and D.S Schach. XML query language(XQL). The Query Languages Workshop. W3c, Dec. 1998.
http://www.w3.org/TrandS/QL/QL98/pp/xql.html

[20] A. Deutsch, M. Fernandez, D. Florescu, A. Levy, and D. Suciu. XML-QL: A query language for XML. The Query Languages Workshop. W3c, Dec. 1998. http://www.w3.org/TR/1998/NOTE-xml-ql-19980819/.

[21] XQuery: A query language for XML, Feb. 2001. http://www.w3.org/XML/Query

[22] XPath: XML Path language, Nov. 1999. http://www.w3.org/TR/xpath

[23] J.P. Callan. Passage-Level Evidence in Document Retrieval. SIGIR 1994.

[24] R. Wilkinson. Effective retrieval of structured documents. SIGIR 1994.

[25] J. Zobel, A. Moffat, R. Wilkinson, and R. Sacks-Davis. Effienent retireval of partial documents. Information Processing and Management, 31(3):361-377, 1995

[26] http://www.ibiblio.org/xml/examples/shakespeare/