

GML 데이터에서 연관규칙 추출

Association Rules Extraction from GML Data

김 의 찬*, 황 병 연
Eui-Chan Kim*, Byung-Yeon Hwang
가톨릭대학교 컴퓨터공학과
{eckim*, byhwang}@catholic.ac.kr

요 약

지리 공간 정보에 대한 관심 증가와 더불어 활용 분야도 다양해지고 있다. OGC(Open GIS Consortium)에서는 XML(eXtensible Markup Language)을 GIS 분야에 도입한 GML(Geography Markup Language)을 개발하였으며 여러 활용 분야에서 GML을 사용하고 계속적으로 연구되고 있다. 본 연구에서는 기존의 XML 문서를 기반으로 연구되었던 데이터 마이닝 방법 중 하나인 연관규칙을 GML 데이터에 사용하여 의미있는 규칙을 찾아내려 한다.

규칙을 찾는 방법에는 2가지가 있을 수 있는데 하나는 GML 데이터의 내용만을 뽑아내어 그에 따른 규칙을 찾아내는 방법이고, 다른 하나는 사용된 태그와 속성을 기반으로 규칙을 찾아내는 방법이다. 본 연구에서는 2가지 방법을 통해 규칙을 찾는 것에 대하여 기술할 것이다. 본 연구를 바탕으로 GML 문서를 사용하는 여러 분야에서 기본 정보뿐만 아니라 함축적이고 의미 있는 정보도 얻어낼 수 있을 것으로 기대한다.

1. 서 론

XML(eXtensible Markup Language)[1]은 W3Consortium(W3C)에서 웹 기반의 구조화된 문서를 기술하는 방법에 대하여 표준화한 언어이다. XML은 확장성, 유연성이라는 특징을 가지고 있으며 기존의 HTML(HyperText Markup Language)처럼 정해져 있는 태그들이 아니라 사용자 자신이 지정해서 사용 가능한 언어이다. 이 외에도 다양한 특징과 장점, 그리고 여러 가지 기능들을 제공한다. 이러한 점들로 인하여 현재 XML에 대한 연구는 계속적으로 활발히 이루어지고 있으며 많은 응용분야에서 사용되고 있다.

이렇듯 여러 장점을 가지고 다양한 분야에서 사용되고 응용되고 있는 XML을 OGC(OpenGIS Consortium)에서 GIS 분야에 도

입시키려 GML(Geography Markup Language) 사양[2]을 제시하였다.

본 논문에서는 이러한 GML 문서 데이터를 통해 데이터 마이닝 기법 중 하나인 연관규칙을 적용하여 의미 있는 규칙들을 찾아내려 한다.

GML로부터 정보를 얻기 위하여 우리는 검색을 하게 되고 그로부터 얻어내는 정보들은 기본적이고 단순한 정보들이 된다. 그러나 단순한 질의 검색을 통해서는 얻어낼 수 없는 정보들이 있는데 이러한 정보를 함축적이고 암시적인, 의미 있는 정보라 할 수 있다. 이와 같은 정보를 찾아내는 기법이 데이터 마이닝 기법이다. 데이터 마이닝 기법에는 여러 가지가 있다. 연관규칙(Association Rules), 분류(Classification), 일반화(Generalization), 클러스터링(Clustering) 등 다양하다[3]. 본 논문에서는 여러 데이터 마이닝 기법들 중 연관

규칙기법을 이용하여 GML 데이터로부터 의미 있는 정보를 추출하려고 한다.

연관규칙 기법은 현재 여러 분야에서 응용되며 계속적으로 많이 연구되고 있는 데이터 마이닝 기법이다. 데이터베이스에 저장되어 있는 기본적인 데이터들을 바탕으로 기본 질의문을 통해서는 얻을 수 없는 규칙을 찾아내는 기법이다. 연관규칙을 생성할 때 사용하는 알고리즘으로는 매우 많이 사용되고 잘 알려진 Apriori[4] 알고리즘이 있다. 본 연구에서는 이 알고리즘을 사용할 것이다.

연관규칙을 사용할 때 일반적인 데이터의 경우 데이터 자체의 값을 사용하여 규칙을 찾아내게 되지만 GML 같은 데이터에서는 태그 사이의 내용뿐만 아니라 태그 자체도 중요한 요소이기 때문에 본 논문에서는 태그 사이의 내용과 더불어 태그에 관련한 연관규칙도 찾아낼 것이다.

2장에서는 기존 관련연구에 대한 기술을 하고, 3장에서는 본 논문에서 제시하는 방법을 기술하며, 4장에서는 실험 예제를 통해 본 연구의 내용을 살펴볼 것이다. 5장에서는 결론에 대해 기술한다.

2. 관련연구

연관규칙은 데이터베이스 내의 단위 트랜잭션에서 빈번하게 발생하는 사건의 유형을 발견하는 것이다. 예를 들어, “전체 고객 중에 빵과 버터, 그리고 우유를 구매한 고객이 10% 이상이고, ‘빵과 버터’를 구매한 고객의 50%가 우유도 함께 구매한다.” 이것이 하나의 발견된 사건의 유형, 즉 하나의 규칙이 된다. 여기서 10%는 연관규칙의 지지도 (support)가 되고, 50%는 신뢰도 (confidence)가 된다.

연관규칙을 찾는 전체 과정을 간단하게 살펴보면, 전체 데이터베이스에서 먼저 후보 아이템 항목 집합을 찾고, 이 후보 아이템 항목 집합에서 미리 제시된 최소 지지도 값을 넘는 빈발 항목 집합을 찾아낸다. 빈발 항목 집합을 찾을 때 전체 데이터베이스의 트랜잭션을 반복적으로 검색하면서 조인연산을 계속해서 사용하게 된다. 최종적으로 나

오는 빈발항목 아이템 집합에서 최소 신뢰도 값을 넘는 연관규칙을 찾아내게 되는 것이다. 여기서 지지도(S)란, 전체 사건 또는 거래 중에서 어떤 아이템 X와 아이템 Y를 동시에 포함하는 사건 또는 거래가 어느 정도 되는가 하는 것이다. 이것을 식으로 표현하면 다음과 같다.

$$S = \frac{|X \cap Y|}{N}$$

(N은 전체 트랜잭션의 개수)

그리고 신뢰도(C)는 어떤 아이템 X를 포함하는 사건이나 거래 중에서 Y가 포함된 사건이나 거래가 어느 정도인가 하는 것이다. 이것을 식으로 표현하면 다음과 같다.

$$C = \frac{|X \cap Y|}{|X|}$$

지지도를 통해 나온 빈발항목들에서 신뢰도를 통해 최종 연관규칙을 얻어내는 것이다. 대표적인 연관규칙 알고리즘으로는 앞서서도 언급한 Apriori 알고리즘이 있다.

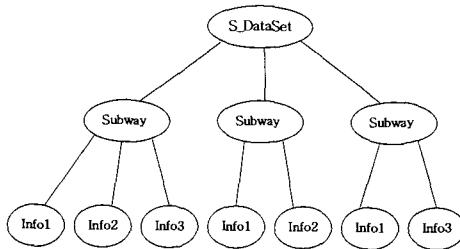
기존의 XML 데이터를 가지고 연관규칙을 적용한 연구들이 있다. [5]에서는 XML 문서에서 빈발경로를 찾는 연구를 하였고, [6, 7]에서는 연관규칙을 찾기 위한 확장된 XQuery를 제안하였다. [8]에서는 FP (Frequent Pattern)-Growth 알고리즘으로부터 XSD-AR(XML Structural Delta Association Rule)이라 부르는 연관규칙 타입을 제안하였다. 또한 지리정보 데이터베이스로부터 공간 (Spatial) 연관규칙을 찾는 연구[9]도 있었는데 본 연구에서는 여러 응용분야에서 사용 가능하도록 지리정보를 담고 있는 GML 데이터로부터 연관규칙을 찾아내는 방법을 제안하였다.

3. GML에서의 연관규칙 추출

3.1 데이터 내용으로부터의 추출

GML 데이터의 내용으로부터 의미 있는 규칙을 추출하기 위해서는 태그가 아닌 내용만을 먼저 추출하고 연관규칙 기법을

적용해야 한다. 하나의 문서로 이루어져 있지 않고 여러 문서로 데이터들이 나누어져 있는 경우 내용만을 추출하기 위해서는 GML 데이터의 스키마가 동일하여야 한다. 스키마가 동일한 많은 GML 데이터로부터 각각의 동일한 태그 내에 있는 내용만을 추출하여 트랜잭션을 구성하여야 연관규칙 기법을 적용할 수 있다.



<그림 1> GML 데이터 구조 예

<그림 1>과 같은 구조를 갖는 문서가 있다고 가정하자. 이것은 전철역 주변의 환경 정보를 GML 문서로 작성하였을 때 나타날 수 있는 구조이다. 각 타원들은 태그들을 나타내고 있으며 각각의 Info# 내에 내용이 들어있는 형태이다. 내용으로는 ‘서점’, ‘분식점’, ‘패스트푸드점’, ‘커피숍’, ‘웃가게’ 등 전철역 주변에 어떠한 상점들이 분포해있는지 정보를 넣을 수 있다.

각 Subway들은 데이터베이스 내에서 트랜잭션이 될 수 있으며 각 트랜잭션의 아이템으로 Info# 내용을 넣어 테이블화 할 수 있다. 테이블의 예는 <표 1>과 같다.

<표 1> GML 내용을 테이블화 한 모습

TID	환경 정보(업종)
ST1	분식점, 호프집, 빵집
ST2	분식점, 커피숍, 패스트푸드
ST3	분식점, 호프집, 커피숍, 빵집, 패스트푸드, 서점
ST4	분식점, 패스트푸드, 커피숍, 빵집
ST5	서점, 웃가게, 신발가게, 쥬얼리, 패스트푸드
ST6	커피숍, 패스트푸드, 서점, 웃가게, 쥬얼리

여기서 ST는 각 Subway들을 트랜잭션으로 본 것이고 각 Info#에 있는 내용들이 환경 정보에 들어가게 된다. 테이블의 내용을 가지고 연관규칙을 찾을 때 좀 더 빠른 수행을 하기 위해서는 [10]에서 사용했던 비트 방식을 이용하여 수행할 수 있다.

<표 1>에 예시된 테이블을 가지고 연관규칙을 적용하여 구할 때는 Apriori 기법을 사용하여 구하면 된다. 실험 예는 4장에서 살펴보도록 한다.

3.2 태그와 속성으로부터의 추출

3.1절에서는 GML 데이터에서 내용만을 이용하여 규칙을 찾아내는 방법을 기술하였다. 이번 절에서는 내용이 아닌 태그와 속성으로부터 규칙을 찾아내는 방법을 살펴보도록 하겠다.

<그림 1>에 나타난 구조를 예를 들어 보면 다음과 같다. <그림 2>에서는 <그림 1>에 나타난 구조를 정리한 모습이다.

/S_DataSet
/S_DataSet/Subway
/S_DataSet/Subway
/S_DataSet/Subway
/S_DataSet/Subway/Info1
/S_DataSet/Subway/Info2
/S_DataSet/Subway/Info3
/S_DataSet/Subway/Info1
/S_DataSet/Subway/Info2
/S_DataSet/Subway/Info1
/S_DataSet/Subway/Info1
/S_DataSet/Subway/Info3

<그림 2> 경로 정리 모습

<그림 2>에 나타난 정보를 이용하여 먼저 빈발 경로를 찾는다. 빈발 경로는 <그림 2>에 나타나 있는 모든 경로를 검색하여 주어진 지지도 임계값보다 큰 경로들만을 찾은 경로이다. 예를 들어 임계값을 3으로 하였다 고 하면 <그림 2>에 나타나 있는 경로들 중에 임계값 이상에 해당하는 경로는 '/S_DataSet'과 '/S_DataSet/Subway', 그리고 '/S_DataSet/Subway/Info1' 이 된다.

빈발 경로를 찾을 때는 서브트리의 개수를 세어서 결정한다. 주의해야 할 점은 서브트리의 개수가 임계값보다 적다고 하더라도 서브트리내의 서브트리까지 계산을 해야 된다는 점이다.

4. 실험 예

4.1 내용을 이용한 예

먼저, GML 데이터의 내용을 추출하여 테이블화 하여야 한다. 이번 절에서는 <표 1>의 내용을 이용하여 설명하도록 한다. 최소 지지도 임계값은 50%로 가정한다. 전체 Subway 트랜잭션을 검색하여 최소 지지도를 만족하는 업종을 뽑아낸다. 그러면 <표 2>와 같은 빈발 업종을 찾아낼 수 있다. 이 표를 이용하여 후보 업종과 빈발 업종을 반복해서 찾아나가게 된다.

<표 2> 빈발 업종

업종	지지도
분식점	66%
커피숍	66%
빵집	50%
패스트푸드	83%
서점	50%

<그림 3>에서는 최소 지지도 임계값에 맞는 빈발 업종을 찾아가는 과정을 보여주고 있다.

최소 신뢰도 임계값을 100%로 가정한다면 다음과 같은 결과가 나오게 된다.

(분식점, 커피숍) → 패스트푸드 (100%)
(분식점, 패스트푸드) → 커피숍(100%)

L2	업종	지지도
	{분식점, 커피숍}	50%
	{분식점, 빵집}	50%
	{분식점, 패스트푸드}	50%
	{커피숍, 패스트푸드}	66%

L3	업종	지지도
	{분식점, 커피숍, 패스트푸드}	50%

<그림 3> 빈발 업종 집합

결과를 바탕으로 분식점과 커피숍이 있는 전철역 근처에는 패스트푸드가 있다는 규칙과 분식점과 패스트푸드가 있는 전철역 근처에는 커피숍이 있다는 규칙이 생성된다.

4.2 태그와 속성을 이용한 예

<그림 4>와 같은 경로집합이 있다고 가정하자. 임계값은 3으로 가정하고 임계값 이상의 빈발 경로를 찾으면 다음과 같다.

```
/gis0
/gis0/gis1
/gis0/gis5
/gis0/gis5/gis16
/gis0/gis1
```

/gis0/gis1 경로의 서브 트리 개수가 3개이므로 /gis0/gis1이 빈발 경로가 되었고, /gis0/gis5의 서브 트리 개수 또한 3개이므로 빈발 경로가 되었다. 여기서 주의 할 부분은 /gis0/gis5/gis16 경로인데 이 경로에서 gis16 태그의 서브트리는 2개이지만, gis16/gis17/gis18과 gis16/gis17/gis20 그리고 gis16/gis19/gis21이라는 3개의 서브트리 경로를 가지고 있기 때문에 /gis0/gis5/gis16은 임계값 3과 크거나 같게 된다. 따라서 빈발 경로가 되었다.

```

/gis0
/gis0/gis1
/gis0/gis1/gis6
/gis0/gis1/gis7
/gis0/gis1/gis8
/gis0/gis2
/gis0/gis2/gis9
/gis0/gis2/gis10
/gis0/gis3
/gis0/gis3/gis11
/gis0/gis3/gis12
/gis0/gis4
/gis0/gis4/gis13
/gis0/gis5
/gis0/gis5/gis14
/gis0/gis5/gis15
/gis0/gis5/gis16
/gis0/gis5/gis16/gis17
/gis0/gis5/gis16/gis17/gis18
/gis0/gis5/gis16/gis17/gis20
/gis0/gis5/gis16/gis19
/gis0/gis5/gis16/gis19/gis21

```

<그림 4> 경로 집합

5. 결 론

본 연구에서는 GML 데이터에서 연관규칙을 추출하는 방법을 기술하였다. GML 데이터에서 연관규칙을 추출할 때 2가지 방법으로 나누어 볼 수 있는데 하나는 GML 데이터 내용을 이용하여 규칙을 찾아낼 수도 있고, 태그와 속성을 이용하여 규칙을 찾아낼 수도 있다.

내용을 이용하여 규칙을 찾는 경우에는 내용들만 추출하여 테이블화 한 다음 각 트랜잭션에 대한 내용 정보들을 바탕으로 기존의 연관규칙 기법을 적용하여 규칙을 찾아내면 된다.

태그와 속성을 이용하는 방법의 경우에는 전체 경로들을 바탕으로 임계값 이상인 빈발 경로들을 찾으면 된다.

추후 연구 방향으로는 내용들 중에서 좌표값을 통한 거리측정이나 각 지점과의 인접 정도를 구분하여 좀 더 자세한 규칙을 찾는 연구가 필요하다.

〈참 고 문 헌〉

- [1] W3Consortium, Extensible Markup Language(XML) 1.0, 1998.
- [2] Open GIS Consortium, Inc., Geography Markup Language Specification (GML) v3.1.1, 2004.
- [3] M.S. Chen, J. Han, and P.S. Yu, "Data Mining: An Overview from a Database Perspective," IEEE Trans. on Knowledge and Data Engineering, Vol. 8, No. 6, Dec. 1996, pp. 866-883.
- [4] R. Agrawal and R. Srikant, "Fast Algorithm for Mining Association Rules in Large Databases," Proc. of the 20th International Conf. on Very Large Databases, Santiago de Chile, 1994, pp. 487-499.
- [5] A. Meisels, M. Orlov and T. Maor, "Discovering Associations in XML Data," Proc. of the 3rd International Conf. on Web Information Systems Engineering, Singapore. Dec. 2002, pp. 178-183.
- [6] D. Braga, A. Campi, S. Ceri, M. Klemettinen, and P.L. Lanzi, "A Tool for Extracting XML Association Rules," Proc. of the 14th IEEE International Conf. on Tools with Artificial Intelligence, Washington DC, USA, Nov. 2002, pp. 57-64.
- [7] D. Braga, A. Campi, S. Ceri, M. Klemettinen, and P.L. Lanzi, "Mining Association Rules from XML Data," Proc. of the 4th International Conf. on Data Warehousing and Knowledge Discovery, Aix-en-Provence, France, Sep. 2002, pp. 21-30.
- [8] L. Chen, S.S. Bhowmick, and L.T. Chia, "Mining Association Rules from Structural Deltas of Historical XML Documents," Proc. of the 8th Pacific-Asia Conf. Sydney, Australia,

- May. 2004, pp. 452–457.
- [9] K. Koperski and J. Han, "Discovery of Spatial Association Rules in Geographic Information Databases," Proc. 4th Int'l Symp. on Large Spatial Databases, Maine, Aug. 1995, pp. 47–66.
- [10] 김의찬, 황병연, “트랜잭션 클러스터링을 이용한 연관규칙 생성,” 제 23회 한국정보처리학회 춘계학술대회논문집, 제12권 제1호, 2005, pp. 15–18.