데이터 스트림에서 데이터 마이닝 기법 기반의 시간을 고려한 상대적인 빈발항목 탐색

박태수 *, 전석주**, 이주홍 *, 강윤희 *, 최범기 *
인하대학교 컴퓨터·정보공학과 *, 서울교육대학교 컴퓨터교육과**

요 약

최근 들어 저장장치의 발전과 네트워크의 발달로 인하여 대용량의 데이터에 내재되어 있는 정보를 빠른 시간 내에 처리하여 새로운 지식을 창출하려는 요구가 증가하고 있다. 연속적이고 빠르게 증가하는 데이터를 지칭하는 데이터 스트림에서 데이터 마이닝 기법을 이용하여 시간이 흐름에 따라 변하고, 무한적으로 증가하는 데이터 스트림에서의 빈발항목을 찾는 연구가 활발하게 진행되고 있다. 하지만 기존의 연구들은 시간의 흐름에 따른 빈발항목 탐색방법을 적절히 제시하지 못하고 있으며 단지 집계를 이용하여 빈발항목을 탐색하고 있다. 본 논문에서는 데이터 스트림에서 시간적 측면을 고려하여 상대적인 빈발항목을 탐색하기 위한 새로운 알고리즘으로 한정적인 메모리를 고려하여 빈발항목과 부분 빈발항목만을 저장하고 시간의 흐름에 따른 빈발항목의 갱신방법에 관하여 제안하였다. 논문에서 제안하는 알고리즘의 성능은 다양한 실험을 통해서 검증된다. 제안된 방법은 웹 코스웨어로 학습하는 학생들의 행동패턴을 시간대별로 파악하여 빈발항목 및 상대적인 빈발항목을 탐색함으로써 학생들의 학습효과 증진 및 지도 방향을 설정하는데 활용할 수 있다.

키워드 : Datamining, Frequent itemsets, FP-growth

Finding the time sensitive frequent itemsets based on data mining technique in data streams

Tae-Su Park*, Seok-Ju Chun**, Ju-Hong Lee*, Yun-Hee Kang*, Bum-ghi Choi*
Dept. of Computer Science & Information Eng., Inha University*
Dept. of Computer Education, Seoul National University of Education**

ABSTRACT

Recently, due to technical improvements of storage devices and networks, the amount of data increase rapidly. In addition, it is required to find the knowledge embedded in a data stream as fast as possible. Huge data in a data stream are created continuously and changed fast. Various algorithms for finding frequent itemsets in a data stream are actively proposed. Current researches do not offer appropriate method to find frequent itemsets in which flow of time is reflected but provide only frequent items using total aggregation values. In this paper we proposes a novel algorithm for finding the relative frequent itemsets according to the time in a data stream. We also propose the method to save frequent items and sub-frequent items in order to take limited memory into account and the method to update time variant frequent items. The performance of the proposed method is analyzed through a series of experiments. The proposed method can search both frequent itemsets and relative frequent itemsets only using the action patterns of the students at each time slot. Thus, our method can enhance the effectiveness of learning and make the best plan for individual learning.

1)본 연구는 대학IT연구센터 육성·지원사업의 연구결과로 수행되었음.

1. 서론

최근 들어 저장장치의 발전과 네트워크의 발달로 인하여 지속적으로 많은 양의 데이터가 매우 빠른 시간 내에 증가되고 있다. 예를 들어 네트워크의 침입 탐지나 유비쿼터스, e-commerce등 많은 응용분야에서 대용량의 데이터가 발생되고 있으며 이러한 응용 환경에서 가치 있는 정보를 추출하기 위한 많은 노력들이 여러 분야에 걸쳐 이뤄지고 있다. 데이터 마이닝 기법을 통한 데이터 스트림에서의 가치 있는 정보 추출은 주요 연구 분야 중 하나이다.

지속적으로 빠르게 입력되는 데이터를 데이터 스트림이라고 한다. 데이터 스트림은 매우 빠른 시간 내에 지속적으로 데이터가 증가되는 특성을 가지고 있다. 그렇기 때문에 데이터 마이닝에서 데이터 스트림을 처리하기 위한 요구조건은 다음과 같다.

첫째, 매우 빠른 시간 내에 증가하는 데이터를 한정적인 저장 공간에 모두 저장하는 것은 불가능하기 때문에 메모리 공간을 유연하게 사용하여 정보의 손실 없이 데이터를 효율적으로 저장하는 방법이 필요하다.

둘째, 데이터 스트림에서는 데이터가 매우 빠른 시간 내에 생성되고 현 시점에서의 마이닝 결과가 중요하기 때문에 마이닝 결과를 원하는 즉시 생성해 주어야 한다. 그러기 위해서는 데이터 스트림에서의 각 트랜잭션을 생성되는 즉시 오직 한번만 읽고 마이닝 결과를 즉각 생성해야 한다.[1]

데이터 스트림에서 가장 기본적인 문제는 빈발항목들을 찾는 것이다.[5] 기존의 데이터 마이닝 기법은 정적인 트랜잭션들에 대해서 한번의 탐색으로 일정한 후보 빈발항목을 만든 후에 미리 정의된 특정 임계값 보다 높은 지지도를 가지는 빈발항목을 찾기 때문에 메모리의 사용량이 많고 처리 시간이 길다.

데이터 스트림은 빈발항목이 아니었던 단위 항목들이 시간의 흐름에 영향을 받아 빈발항목으로 변경될 수 있기 때문에, 단위 항목의 빈발도수를 동적으로 갱신하고 저장해야 한다. 또한 데이터 스트림은 매우 많은 양의 데이터가 끊임없이 들어오기 때문에 모든 단위 항목들을 저장할 수 없으므로, 기존의 데이터 마이닝 기법을 데이터 스트림에 그대로 적용하는 것은 적합하지 않다. 따라서 데이터 스트림에서 빈발항목을 찾는 새로운 알고리즘들이 연구되고 있다[1, 3, 4, 5, 6, 7, 8, 9, 10].

하지만 데이터 스트림에서의 빈발항목 탐색 방법들은 단순히 빈발항목의 집계를 통해 빈발항목을 탐색하거나 또는 일정한 크기의 슬라이딩 윈도우를 임의로 설정하여 그 시간 즉 구간에 국한된 빈발항목을 탐색하고 있으며, 시간이 흐름에 따라 총체적으로 빈발항목을 집계하기 때문에 현 시점에서 빈발항목의 변화 및 시간이 흐름에 따른 상대적인 빈발항목을 간과하고 지나쳐 빈발항목 탐색의 정확도를 보장하지 못한다.

본 논문에서는 이러한 문제점을 개선하기 위해서 데이터 스트림에서 시간적 요소를 고려하여 상대적인 빈발항목을 효율적으로 탐색하는 새로운 마이닝 기법을 제안하였다.

본 논문에서 제안된 방법을 이용하여 학생들이 웹 코스웨어 기반의 학습을 할 경우 시간대별로 학생들의 행동패턴을 분석하여 빈발항목 및 상대적인 빈발항목을 탐색함으로써 학생들의 학습향상을 위해 좀더 정확한 서비스를 제공할 수 있다.

논문의 구성은 다음과 같다. 제 2장에서는 기존의 관련 연구들을 기술하고, 제 3장에서는 제안하는 빈발항목의 탐색 방법에 대해 상세히 기술한다. 제 4장에서는 다양한 실험을 통하여 제안된 방법의 성능을 평가하며 제 5장에서는 결론 및 향후 개선해야 할 과제에 대하여 기술하였다.

2. 관련 연구

기존의 데이터 마이닝 기법에서의 빈발항목 탐색은 단순히 데이터베이스의 트랜잭션을 탐색하여 사전에 미리 정의된 최소지지도 이상의 지지도를 가지는 최대 항목들을 탐색하는 것이다. 이전에 연구된 빈발항목에 대한 알고리즘들은 대부분 Apriori 원칙에 기반을 두고 있다[11]. 이 원칙은 빈발항목의 모든 부분집합은 반드시 빈발항목이었어야 한다는 것이다. Apriori알고리즘은 빈발항목의 최대 길이가 n이면 n+1까지 탐색하여 후보 집합을 생성하고 빈발 항목을 탐색하기 때문에 메모리의 사용량이 크고 반복적인 데이터베이스 탐색으로 인하여 빈발항목을 탐색하는데 많은 시간이 소요된다.

반면에, 분할-정복기법(divide-and-conquer)을 사용하는 FP-growth는 후보 집합을 생성하지 않는다[12]. FP-growth는 길거나 짧은 빈발 항목을 마이닝하는데 매우 효율적이고, 확장성을 가지며 Apriori 알고리즘보다 속도 측면에서 한 차원 앞선다는 것을 보여주고 있다. 하지만 위에서 기술된 두 기법 모두 데이터 집합을 다중 탐색해야하며 새로운 트랜잭션이 발생하였을 때 전체를 재탐색해야 한다. 또한 데이터 집합이 지속적으로 빠르게 증가하면

가용 메모리의 한정성으로 인하여 성능이 낮아진다.

최근 들어 저장장치의 발전과 네트워크의 발전으로 지속적으로 대량의 데이터가 생성되고 있으며 이 데이터들을 데이터 스트림이라 지칭한다. 데이터 스트림에서의 빈발항목 탐색방법들은 다양하게 연구되고 있다[1, 3, 4, 5, 6, 7, 8, 9, 10].

Count Sketch 알고리즘은 데이터 스트림에서 단위 항목들의 빈발도수에 중점을 두고 있으며[5], Lossy Counting 알고리즘은 최소 지지도와 최대 허용 오차 조건이 주어졌을 때 데이터 스트림에서 발생한 빈발항목들의 집합을 찾는다[3]. 이들 알고리즘들은 시간을 고려하지 않고 단순히 빈발항목을 탐색하는데 중점을 두고 있다.

한정적인 가용 메모리 공간을 사용하는 슬라이딩 윈도우에 대한 빈발항목 탐색뿐만 아니라 빈발항목에 근접한 항목들까지 탐색하는 Moment 알고리즘은 CET (Closed enumeration tree) 라는 prefix tree와 유사한 트리 구조를 사용한다[7]. CET에서는 최대 빈발항목과 빈발항목, 근접 빈발항목을 저장하기 때문에 시간이 흐름에 따른 빈발항목의 변화를 알아낼 수 있으며, 메모리를 효율적으로 관리하며 빈발항목을 탐색할 수 있다.

FP-stream알고리즘은 FP-growth를 데이터 스트림에 적절하게 변형시킨 알고리즘이다[4]. 이 알고리즘은 데이터 집합을 최소 지지도와 최대 허용오차를 통하여 크게 빈발 항목, 부분 빈발 항목, 빈발하지 않은 항목으로 구분하며 Pattern-tree와 tilted time window를 사용한다. 또한 Pattern tree에 빈발항목을 저장하고 tilted time window라는 고정된 크기의 윈도우를 사용하여 현 시점까지의 빈발항목을 축적하여 최근의 빈발항목의 변화를 용이하게 파악한다. 하지만 고정된 크기의 시간을 이용하기 때문에 유동적인 빈발항목을 탐색하기 어렵다.

최근에 데이터마이닝의 연관 규칙을 교육적으로 활용하려는 시도가 있었다[2].[2]는 학교 홈페이지 방문자들의 접근 패턴을 추출하는 알고리즘과 이를 통한 적응형 학교 웹 사이트 구현 방안을 제안하였다. [2]에서는 연관 규칙을 찾기 위해 변형된 FP-growth 알고리즘을 이용하여 빈발 항목집합을 구하고 최소 지지도를 만족하는 웹 문서들의 패턴 트리를 구성하여 이들과 연관성이 높은 다른 문서들을 하이퍼링크 함으로써 학교 홈페이지 방문자들에게 편리한 웹 네이게이션을 제공하려고 시도하였다.

3. 데이터 스트림에서 빈발항목 탐색

데이터 스트림은 시간의 영향을 받기 때문에 현재의 빈발항목이 시간이 지난 후에는 빈발항목이 아닐 수 있다. 또한 현재의 출현빈도가 가장 높다고 해도 출현빈도가 높게 나타나는 시간의 간격이 멀어지면 현 시점에서의 빈발항목이라고 보기 어렵다. 이러한 경우에는 상대적으로 출현빈도는 최대 빈발항목보다는 작지만 현재까지 출현빈도의 간격이 조밀하고 주어진 최소 지지도이상의 출현빈도를 가지는 부분 빈발항목이 현재의 상대적인 빈발항목이라고 볼 수 있다.

본 논문에서는 기존에 연구되었던 데이터 스트림에서의 빈발항목 탐색기법에서 적용되지 않은 상대적인 빈발항목 탐색기법을 제안하였다.

3.1 상대적인 빈발항목 탐색

데이터 스트림에서 빈발항목을 탐색하기 위해서 먼저 탐색대상이 되는 데이터 집합에 대해 정의하도록 하겠다.

$S_N = \{T_1, T_2, T_3, ..., T_N\}$는 현재까지 발생한 트랜잭션의 집합, 즉 전제 데이터 집합을 의미하며 현재의 트랜잭션은 $T_t = \{I_1, I_2, I_3, ..., I_n\}$로 표현되고 각각의 트랜잭션은 TID라고 하는 고유한 식별인자를 가진다. 그리고 트랜잭션의 구성요소인 단위 항목에 대한 집합은 $I = \{i_1, i_2, i_3, ..., i_n\}$로 나타낸다.

데이터 스트림에서의 데이터는 지속적으로 빠른 시간 내에 증가한다. 그렇기 때문에 기존의 방법처럼 모든 항목을 저장할 수 없다. 또한 데이터 스트림은 시간의 영향을 받기 때문에 빈발항목이 시간이 흐름에 따라서 변경된다. 따라서 현재 시점에서 빈발항목이 아니라 해서 간과할 수 없다.

본 논문에서는 위의 문제점을 효과적으로 해결하기 위하여 FP-stream[4]알고리즘에서와 같이 사전에 사용자에 의해 정의되는 최소 지지도 ($S_{min} \in (0,1)$)와 최대 지지도 오차($e \in (0, S_{\min})$)를 이용하여 단일 항목을 빈발항목, 부분 빈발항목, 빈발하지 않은 항목으로 구분하였다. 출현 빈도가 최소 지지도 이상의 값을 가질 경우는 빈발항목으로 간주하고 최소 지지도보다는 작지만 최대 지지도 오차 이상의 값을 가질 경우는 부분 빈발항목이라고 정의한다. 최대 지지도 오차보다 작은 경우는 빈발하지 않은 항목으로 간주하여 처리하지 않는다.

하지만 기존의 연구에서는 빈발항목과 부분 빈발항목에 대해 단지 집계 값의 비교를 통해서 빈발항

목을 탐색한다. 따라서 시간에 민감한 상대적인 빈발항목을 간과하고 지나칠 수 있다. 즉 현재까지 집계된 값이 현재의 빈발항목보다는 작지만 상대적인 출현빈도가 현재의 빈발항목에 비해 상대적으로 클 경우의 항목에 대한 고려가 필요한 것이다. 따라서 본 논문에서는 다음과 같이 상대적인 빈발항목에 대하여 정의한다.

<표 1> 상대적인 빈발항목 기본 요소

기 호	의 미
S_{min}	최소 지지도
e	최대 지지도 오차
f	빈발항목
R_t	상대적인 빈발항목
$A_i(x)$	항목 x에 대한 출현 판단 함수
$F(x)$	항목 x의 출현빈도
$C_m(x)$	항목 x에 대한 출현 간격의 총합
$E_m(x)$	항목 x의 상대적인 출현빈도

상대적인 빈발항목 집합 R_t은 현재의 빈발항목의 출현빈도보다 출현빈도가 작지만 상대적인 출현빈도가 현재 빈발항목의 상대적인 출현빈도보다 큰 항목들의 집합으로 정의된다. 여기서 f는 현재의 빈발 항목을 나타낸다.

$$R_t = \{ x | F(f) > F(x), E_m(x) > E_m(f) \}$$

상대적인 출현빈도란 유동적인 트랜잭션의 개수 m을($m < N$) 출현 빈도 간격에 대한 차의 합으로 나눈 것이며, 상대적인 빈발항목을 탐색하기 위한 기준이 된다.

$$E_m(x) = \frac{m}{C_m(x)}$$

또한, 출현빈도는 지속적으로 입력되는 트랜잭션에 대해서 항목이 출현했는지 출현하지 않았는지를 파악하여 집계한 값이다.

$$A_i(x) = \begin{cases} 1 & x \in T_i \\ 0 & otherwise \end{cases}$$

$$F(x) = \sum_{i=1}^{N} A_i(x)$$

그리고 출현 빈도 간격에 대한 차를 구하는

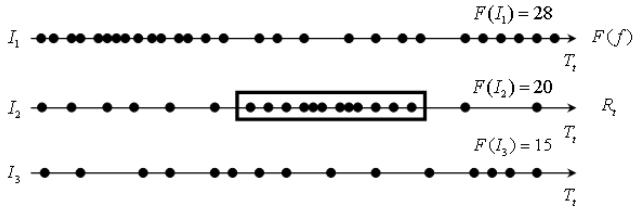

(그림 1) 상대적인 빈발항목 개념도

것은 상대적인 빈발항목이 발생하는 시점을 파악하기 위한 것으로 현재 출현한 시점과 이전에 출현했던 시점 사이에 대한 시간차로 정의된다. 여기서 y_t는 항목 x를 포함하는 트랜잭션 T_t가 발생한 시점을 의미한다.

$$C_m(x) = y_t - y_{t-m+1}$$

위의 내용을 바탕으로 상대적인 빈발항목에 대하여 살펴보도록 하겠다. <그림 1>은 상대적인 빈발항목에 대한 개념도이다. 여기서 각각의 I_1, I_2, I_3는 최소지지도 이상의 값을 가지는 빈발항목과 최소지지도 보다는 작지만 최대 지지도 오차보다는 큰 부분 빈발항목을 나타내고, 각각 화살표의 점은 출현빈도를 나타낸 것이다. 또한, T_t는 현재까지의 트랜잭션을 의미한다. 첫 번째 줄의 I_1을 살펴보면 현재까지의 출현빈도가 28로 가장 높은 것을 알 수 있다. 즉 빈발항목을 의미한다. 그리고 두 번째 줄과 세 번째 줄은 부분 빈발항목을 의미한다. <그림 1>을 살펴보면 첫 번째 항목 즉 빈발항목에서는 초반에 출현빈도가 높고 중간으로 갈수록 출현간격이 점점 벌어지는 것을 알 수 있다. 하지만 두 번째 줄은 중간 부분에서 급격하게 출현빈도가 높아진 것을 볼 수 있다. 그리고 상대적으로 첫 번째 항목보다 더욱 빈번하게 출현하고 출현간격 또한 첫 번째 항목 보다 좁기 때문에 중간 부분에서는 두 번째 항목을 빈발항목으로 지정해야 정확한 것이라고 볼 수 있다. 즉 두 번째 항목이 중간부분에서는 첫 번째 항목보다는 상대적인 빈발항목이 되는 것이다.

여기서 중요한 요점은 상대적인 빈발항목으로 변경되는 시점에 대한 기준을 찾는 것이다. 그래서 본 논문에서는 다음과 같은 상대적인 빈발항목에 대한 기준을 제시한다.

1. 상대적인 출현빈도가 빈발항목에 대한 상대적인 출현빈도보다 커야한다.

$$E_m(f) < E_m(x) \text{ and } E_m(f) > 0$$

2. 상대적인 빈발항목의 출현 시점은 바로 이전의 상대적인 출현빈도의 값에서 현재의 상대적인 출현빈도의 값을 뺀 결과가 0보다 작아지는 시점부터 0보다 커지는 시점까지이다.

$$E_m(z) - E_m(x) \leqq 0 \quad (z \in T_{t-1})$$
$$until\ E_m(z) - E_m(x) > 0$$

즉, 빈발항목에 대하여 상대적인 출현빈도가 높아지고 출현간격이 빈발항목에 비해 급격히 좁아졌을 때를 의미하는 것이다. 본 논문에서는 수치를 일반화시키고 계산을 간편하게 하기 위하여 상대적인 출현빈도를 계산할 경우 소수점 첫째 자리까지 만을 고려하였다.

3.2 FP-Tree 알고리즘을 이용한 저장기법

본 절에서는 모든 빈발항목과 상대적인 빈발항목들을 메모리에서 효율적으로 유지, 관리하는 prefix tree구조의 FP-Tree 알고리즘을 이용한 저장기법을 제안하였다.

데이터 스트림에서 데이터는 무한집합이라고 간주한다. 그렇기 때문에 모든 항목들을 저장하는 것은 사실상 불가능하다. 따라서 FP-Tree에서는 빈발항목과 상대적인 빈발항목을 효율적으로 유지, 관리하기 위하여 (items, 출현 빈도, TID)의 3가지 정보만을 저장한다. 여기서 items은 빈발항목이나 부분 빈발항목들을 의미하고, 출현 빈도는 현재까지 items이 출현한 총 횟수가 된다. 또한 TID는 현재의 트랜잭션 아이디를 뜻하며, 상대적인 빈발항목이 발생하는 시점을 알 수 있는 척도로 사용된다.

FP-Tree 알고리즘은 크게 4단계로 구성 된다. 트랜잭션이 추가될 때마다 4단계를 반복적으로 수행하게 된다.

제 1단계는 데이터 스트림의 트랜잭션을 탐색하여 각 항목에 대한 출현 빈도를 갱신하는 단계로 새로운 트랜잭션이 추가되면 전체 데이터집합 $|S_N|$의 크기는 1씩 증가된다. 그리고 새로 추가된 트랜잭션에서 출현한 항목들이 FP-Tree에 해당하는 노드에 존재하면 출현 빈도와 TID값을 갱신한다.

제 2단계는 부분 빈발항목이 추가되는 단계로 새롭게 추가된 트랜잭션에 출현하는 항목들이 FP-Tree에 존재하는 노드들 중에 없는 경우, 최소

<표 2> FP-Tree 알고리즘

```
FP-Tree
Input : a minimum support threshold, S_min
        a maximum support error, e
        Data stream S_N
Output : complete frequent itemsets & relative
         frequent itemsets

Algorithms :
begin
  initialize FP-Tree;
  for each S_N = { T_1, T_2, T_3, ..., T_N }
    read current transaction T_c
      |S_N| = |S_N| + 1
    for all itemsets update frequency
  /* sub frequent itemsets insert */
  Insert(items, frequency, TID)
    if I_c > S_min or (I_c < S_min & I_c > e)
      I_c -> (sub) frequent itemset & insert
    else
      I_c -> infrequnet itemset & Eliminate
  /*find current frequent itemsets*/
   Frequent_itemsets(items, frequent, TID)
     for all S_N
      if I_c > S_min & max F(I_c)
        I_c -> frequent itemset
        print I_c
  /*find the relative frequent itemsets*/
  RF_search(items, frequency, TID)
  /* m : unfixed transaction size, */
    SET E_m(x) = m / C_m(x)
    if E_m(f) < E_m(x)
       & E_m(z) - E_m(x) < 0
        E_m(x_c) -> R_t
      /* until E_m(z) - E_m(x) > 0 */
      print R_t
      /*notice relative frequent itemsets*/
end
```

지지도보다는 작지만 최대 지지도 오차보다는 큰 값을 가지는 항목을 부분 빈발항목으로 구분하여

FP-Tree의 노드로 삽입한다. 여기서 최대 지지도 오차보다 작은 항목들은 빈발항목이 될 가능성이 희박하기 때문에 제거된다. 그렇기 때문에 메모리 사용공간을 줄이고 FP-Tree의 노드에 삽입하는 추가적인 작업이 없으므로 수행시간을 줄일 수 있다.

제 3단계는 현재의 빈발항목을 찾는 단계로 사용자의 요구에 의해 현재까지 총 빈발도수가 가장 크고 최소 지지도($S_{\min}$)이상의 지지도를 갖는 항목의 (items, 출현 빈도, TID) 정보를 출력해 준다.

제 4단계는 상대적인 빈발항목을 찾는 단계로 빈발항목의 상대적인 출현빈도가 커졌을 때, 즉 출현간격이 좁아졌을 경우에 현재의 빈발항목보다 상대적으로 빈번하게 출현하는 항목을 찾는 것이다.

이렇게 현재의 빈발항목 뿐만 아니라 간과하고 지나칠 수 있는 상대적인 빈발항목을 탐색함으로써 신뢰도 및 정확도를 보장해주며 빈발항목과 부분 빈발항목에 대한 (items, 출현 빈도, TID)만을 관리하기 때문에 한정적인 메모리를 효율적으로 사용할 수 있다.

4. 실험 결과

본 절에서는 논문에서 제안된 상대적인 빈발항목과 FP-Tree에 대한 성능을 다양한 실험을 통하여 검증한다. 데이터 집합은 [10]에서 제안된 데이터 생성 방법에 따라 T10.I4.D1000K와T10.I4.D100K, T15.I6.D1000K의 데이터 집합을 생성하여 사용하였다. 각 데이터 집합에서 T는 트랜잭션의 평균적인 길이를 의미하며, I는 잠재적인 최대 빈발 항목의 평균적인 길이를 의미한다. 또한 D는 데이터 집합에 대한 트랜잭션의 총수를 의미한다. 본 논문에서 모든 실험들은 512MB 램(RAM)을 가진 AMD XP 2600+의 컴퓨터 환경에서 실험되었으며, 제안된 방법은 C언어로 구현하였다.

실험은 크게 3가지 부분으로 나누어져 실행된다. 첫 번째는 빈발항목 및 상대적인 빈발항목 탐색의 정확도에 대한 검증이다. 두 번째는 빈발항목과 상대적인 빈발항목을 탐색하는 수행 시간에 대한 검증이다. 마지막으로 세 번째는 빈발항목과 부분 빈발항목을 관리하는 FP-Tree에 대한 메모리 사용량에 대한 검증한다.

(그림 2)는 T10.I4.D1000K 데이터 집합을 이용한 상대적인 빈발항목과 빈발항목에 대한 정확도를 보여준다. 빈발항목이 상대적인 빈발항목보다 다소 높은 정확도를 보여주고 있다. 그 이유는 상대적인

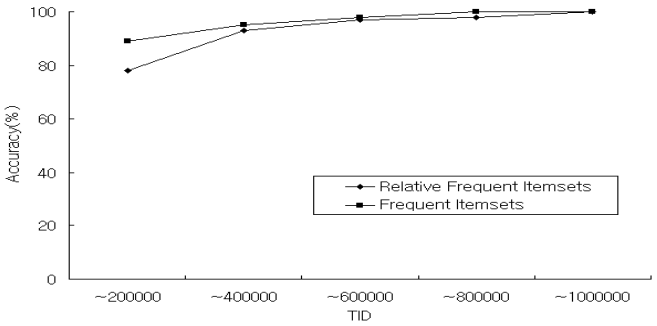

(그림 2) 빈발항목 및 상대적인 빈발항목의 정확도

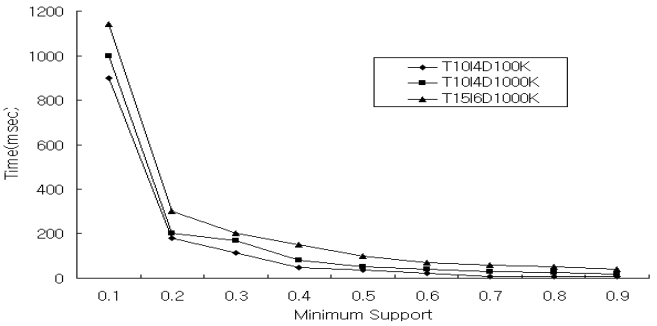

(그림 3) 최소 지지도에 따른 평균 수행시간

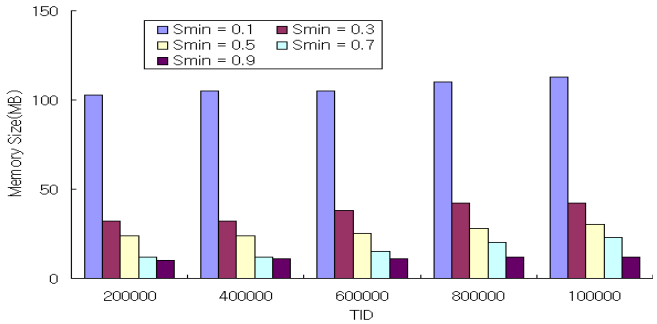

(그림 4) 최소 지지도에 따른 메모리 사용량

빈발항목은 빈발항목보다 시간의 영향을 많이 받아 수시로 변하기 때문에 빈발항목보다 탐색하는 것이 더욱 어렵기 때문이다. 그럼에도 불구하고 높은 정확도를 보여주고 있다.

(그림 3)은 최소지지도를 다양하게 변화시켰을 때 각 구간에 대한 평균 수행시간을 비교한 것이다. 평균 수행시간은 새로운 트랜잭션이 추가되었을 때 빈발항목 및 상대적인 빈발항목을 탐색하는데 소요되는 평균적인 시간을 의미한다. 최소지지도가 낮을수록 평균 수행시간이 커진다. 그 이유는 최소지지도가 낮을수록 빈발항목과 부분빈발항목에 대한 허용범위가 넓어져서 빈발항목을 탐색하기 위한 비교 횟수가 증가되기 때문이다.

(그림 4)는 최소 지지도에 따른 FP-Tree에서의 메모리 사용량을 보여준다. 각 데이터 집합사이의 메모리 사용량에 대한 차이는 크지 않다. 그 이유는 FP-Tree알고리즘에서 최소지지도와, 최대 지지도 오차를 이용하여 빈발항목과 부분 빈발항목만을 관리함으로 메모리의 사용량이 작다. 각 데이터 집합 중 T15.I6.D1000K이 가장 많은 메모리를 사용한다. T15.I6.D1000K는 잠재적인 최대 빈발항목의 평균적인 길이가 다른 데이터 집합에 비해 크기 때문에 상대적으로 많은 메모리를 사용한다.

5. 결 론

데이터 스트림에서 가장 기본적인 문제는 스트림에서 발생하는 빈발적인 항목들을 탐색하는 것이다. 하지만 데이터 스트림은 시간의 영향을 받기 때문에 시간이 흐름에 따라 빈발항목이 유동적으로 변경 된다. 또한, 데이터 스트림은 데이터의 무한집합으로 정의될 수 있기 때문에 데이터 스트림에서 발생되는 모든 항목들을 저장하는 것은 불가능하다. 본 논문에서는 위와 같은 문제를 해결하기 위하여 상대적인 빈발항목이라는 개념과 FP-Tree 알고리즘을 제안하였다.

제안된 알고리즘에서는 전체 빈발도수와 빈발 간격에 따른 상대적인 빈발도수를 계산하고, 빈발항목과 부분 빈발항목에 따른 상대적인 빈발도수를 비교하여 간과하고 지나칠 수 있는 상대적인 빈발항목을 탐색한다. 또한, FP-Tree에서 빈발항목과 부분 빈발항목을 효율적으로 관리하기 위하여 (items, 출현 빈도, TID)의 3가지 정보만을 저장한다. 그러므로 시간에 민감한 빈발항목을 탐색할 수 있으며, 빈발항목 탐색에 대한 정확도도 높일 수 있고, 한정적인 메모리를 효율적으로 사용할 수 있다.

본 논문에서 제안된 알고리즘은 웹 코스웨어로 학습하는 학생들의 시간적인 행동패턴 분석에 활용할 수 있다. 웹 코스웨어에는 대용량의 학생 데이터가 축적되어 있다. 이 대용량의 학생 데이터를 기반으로 학생들의 행동패턴을 파악할 수 있다. 즉 시간대별로 행동패턴의 빈발항목 및 상대적인 빈발항목을 탐색함으로써 학생들이 선호하는 학습 콘텐츠와 시간대를 확인할 수 있다. 이를 바탕으로 학생들의 지도 방향을 설정하여 학습 효과 및 능률을 증진시킬 수 있다.

참고문헌

[1] 장중혁, 이원석 (2003), 데이터 스트림에서 개방 데이터 마이닝 기반의 빈발항목 탐색. 정보처리학회 논문지, 10-D(3).

[2] 이정민 (2005), 연관규칙을 이용한 적응형 학교 웹사이트 구축 알고리즘, 석사학위논문, 서울교육대교 대학원.

[3] Manku, G. S., & Motwani, R (2002), Approximate frequency counts over data streams, In Proc. of the 28th Conference on Very Large Databases.

[4] Giannella, C., Han, J., Pei, J., Yan, X., & Yu, P.S (2003), Mining Frequent Patterns in Data Streams at Multiple Time Granularities, Next Generation Data Mining, AAAI/MIT.

[5] Charikar, M., Chen, K., & Farach-Colton, M (2002), Finding Frequent Items in Data Streams. International Colloquium on Automata,Languages, and Programming, 508-515.

[6] Zhang, D., Gunopulos, D., Tsotras, V. J. & Seeger, B (2002), Temporal Aggregation over Data Streams using Multiple Granlarities, Proc. of 8th International Conference on Extending Database Technology.

[7] Yun, Chi., Haixun, Wang., Philip, S., Yu, Richard, R (2004), Moment: Maintaining Closed Frequent Itemsets over a Stream Sliding Window .Proceedings of the IEEE International Conference on Data Mining.

[8] Babcock, B., Babu, S., Datar, M., Motwani, R. & Widom, J (2002), Models and issues in data stream systems. In Proceedings of PODS.

[9] Chang, J. H., & Lee, W. S (2003), Finding Recent Frequent Itemsets Adaptively over Online Data Streams. The 9th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 24-27.

[10] Karp, R. M., Papadimitriou, C. H., & Shenker, S (2003), A simple algorithm for finding frequent elements in streams and bags. ACM Trans. Database Systems.

[11] Rakesh Agrawal,, & Ramakrishnan Srikant

(1994), Fast Algorithms for Mining Association Rules. Proc. 20th Int. Conf. Very Large Data Bases, 487-499.

[12] Han, J., & Yin, Y (2000), Mining frequent patterns without candidate generation. In Proc. IEEE Symposium on Foundations of Computer Science, 359-366.

저자 소개

박 태 수

2004 공주대학교 정보통신 공학부졸업(학사)
현재 인하대학교 컴퓨터정보공학과(석사)
관심분야 : 데이터마이닝, 신경망, 컴퓨터교육

전 석 주

1989년 경북대학교 전자공학과 학, 석사(컴퓨터공학전공)
1989년 ~ 1995년 현대중공업 중앙연구소
2002년 한국과학기술원 컴퓨터공학 박사
1997년 ~ 2003년 안산대학 인터넷정보과 교수
2004년 ~ 현재 서울교육대학 컴퓨터교육과 교수
관심분야 : 컴퓨터교육, 데이터마이닝, 멀티미디어 DB

이 주 홍

1983년 서울대학교 컴퓨터공학과 졸업(학사)
1985년 서울대학교 대학원 컴퓨터공학과 졸업(석사)
2001년 한국과학기술원 정보 및 통신공학과 (컴퓨터공학전공) 졸업(박사)
한국통신공학사(KT) 연구소 전임연구원
한국IBM 소프트웨어연구소 선임연구원 근무
관심분야 : 데이터마이닝, 데이터베이스, 정보검색, 소프트컴퓨팅, 신경망, 컴퓨터교육

강 윤 희

2003년 인하대학교 교육대학원 정보·컴퓨터 교육 졸업(석사)
현재 인하대학교 컴퓨터정보공학과(박사)
관심분야 : 데이터마이닝, 웹마이닝, WBI, ICT

최 범 기

1986년 서울대학교 자연대학 수학과 졸업(학사)
1995년 Florida State University 대학원 Computer Science(M.S.)
1986-1990년 조선일보 전산기획부 근무
1998년 ~ 현재 쿼크(주) 대표이사
2004년 ~ 현재 인하대학교 겸임교수
관심분야 : 데이타 베이스, 데이타 마이닝, 정보검색, 퍼지 시스템, 신경망