

Self-Similar 트래픽하에서 ATM 스위치 큐의 적응성에 관한 연구

진 성 호[†] · 임 재 홍^{††} · 김 동 일^{†††}

요 약

네트워크를 설계하고 서비스를 구현하는데 있어서 중요한 변수중의 하나는 트래픽의 특성을 파악하는 것이다. 기존의 트래픽 예측과 분석은 포아송(Poisson) 또는 마코비안(Markovian)을 기본으로 하는 모델을 사용하였다. LAN, WAN 및 VBR(Variable Bit Rate) 트래픽 특성에 관한 최근의 실험적 연구들은 기존의 포아송 가정에 의한 모델들이 네트워크 트래픽의 장기간 의존성 및 self-similar 특성들을 과소평가 함으로써 실제 트래픽의 특성을 제대로 나타낼 수 없다는 것을 지적해 왔다. 따라서 최근 실제 트래픽 모델과 유사한 모델로서 self-similarity 특성을 이용한 접근법이 대두되고 있다. 본 논문에서는 self-similarity 트래픽의 정의에 대해서 논한다. 그리고 실제 트래픽을 수집하고, 인위적으로 self-similarity한 트래픽과 포아송 모델을 적용시킨 트래픽을 발생시켜 비교한 다음 ATM 스위치의 큐(Queue)에 적용하였다. 본 논문에서는 ATM 스위치의 큐에 self-similarity 트래픽을 적용했을 경우 low bound상에서 버퍼 오버플로우 확률 및 셀 손실 확률에 대해 평가하였다.

A Study on Adaptation of ATM Switch Queue under Self-Similar Traffic

Sung-Ho Jin[†] · Jae-Hong Yim^{††} · Dong-Il Kim^{†††}

ABSTRACT

One of the most important matters in designing network and realizing service, is to grip on the traffic characteristics. However, we used the models which based on the Poisson or Markovian such as conventional traffic prediction and analysis. Recently, experimental research on the LAN, WAN and VBR traffic properties have been pointed out that they weren't able to display actual real traffic specificities because the models which based on the Poisson assumption had been underestimated the long range dependency of network traffic and self-similar peculiarities. Therefore, it has been lately presented that the new approach method using self-similarity characteristics as similar as the real traffic models. In this paper, we are going to discuss the definition of self-similarity traffic. Moreover, we collected the real traffics and applied to the queue on the ATM switch after compared artificial self-similarity traffics with the traffics which were applied Poisson model. So, we estimated the probability of buffer overflows on the low-bound and the cell losses in the case of applying the self-similarity traffic to the queue on the ATM switch.

키워드 : ATM 스위치(ATM switch), 자기유사성(Self-similarity), 트래픽(Traffic), 트래픽 성능분석(Traffic analysis)

1. 서 론

1990년대 이후 네트워크 환경에서는 인터넷 사용자의 폭발적인 증가와 응용프로그램의 멀티미디어화로 인해 트래픽의 양에 대해 급속적인 증가를 가져오고 있다. 그리고 사용자의 서비스 품질에 대한 요구가 점점 커지고 있기 때문에 지속적으로 네트워크 확충이 계속되고 고속의 네트워크 기술이 개발되고 있으나, 사용자들에게 충분한 만족을 주기에는

아직 미비한 실정이다. 이러한 서비스의 품질을 높이기 위해 다양한 기법이 개발되고 있으며, 현재 ATM(Asynchronous Transfer Mode)이 이러한 요구를 만족시켜주는 해법으로 귀착되고 있으며 여러 장비제조 업체에서 ATM 스위치 제품을 생산하여 현장에서 운영을 하고 있다. 하지만 현장에서 이러한 장비를 운영했을 경우 그 장비의 기대치에 대한 효율을 충분히 가져오고 있지 못한 실정이다. 그러한 이유에는 여러 가지가 있으나 중요한 요소 중의 하나가 장비 설계시 모델링을 하는 트래픽의 특성이 실제 운영중인 네트워크의 트래픽 특성과 많은 차이를 보인다는 것이다.

기존의 데이터 트래픽에 관련된 일반적인 가설은 많은

† 준 회 원 : 한국해양대학교 대학원 전자통신공학과
 †† 정 회 원 : 한국해양대학교 전자통신공학과 교수
 ††† 정 회 원 : 동의대학교 공과대학 전기·전자 정보통신공학부 교수
 논문접수 : 2001년 3월 24일, 심사완료 : 2001년 5월 22일

수의 독립적인 트래픽 스트림들을 멀티플렉싱하는 것이 포아송 과정으로 귀착된다는 것이다. 기존의 이러한 가정과 결과적인 큐잉분석이 초창기의 ATM 스위치가 매우 적은 버퍼(10~100cell)를 가진 스위치를 생산하도록 하였다. 과거의 텍스트 기반의 네트워크 환경에서는 문제점이 드러나지 않았지만 현재의 트래픽 특성은 사용자의 증가와 특히 트래픽의 종류가 일반적인 텍스트가 아닌 멀티미디어화로 인해 그리고 대용량의 파일 전송이 많아지면서 매우 버스트(burst)한 특성을 보이고 있기 때문에 기존의 모델을 사용한 경우 많은 문제점을 나타내고 있다. 현재 기존에 설치된 ATM 스위치는 실제 발생하는 트래픽을 수용하였을 때, 엄청난 cell 손실들이 발생하게 되었고 그 스위치들을 다시 설계하는 결과를 초래하게 되었다. 그러므로, 네트워크의 장비설계 및 성능평가에 앞서 그 네트워크의 트래픽 특성을 이해하는 것이 매우 중요하다 하겠다.

네트워크 트래픽에 관한 최근의 논문들은 LAN, WAN 및 VBR 비디오 트래픽이 통계학적으로 self-similar 과정에 의해 더욱 잘 모델링 된다는 것이 설득력 있게 주장되어 왔다 [1, 2, 10]. 이것은 기존의 단기간 의존성만을 고려한 포아송 과정에 비해 매우 다른 이론적 특성을 가진다. 즉, 광범위한 타임스케일에서 aggregation의 정도가 변하더라도 통계학적으로 동일한 특성을 지니게 된다는 것이다. 이러한 특징들은 자기유사성(self-similarity), 장기간 의존성(Long-range dependence, Joseph effect), 무한 분산 증후군(Infinite Variance Syndrome, Noah Effect), 천천히 감소하는 분산(Slowly Decaying Variance) 등으로 대변된다[11-13].

본 논문에서는 첫 번째로 self-similarity 이론의 기본 개념에 대해 설명하고 두 번째로 기존의 포아송 트래픽과 self-similarity한 트래픽을 발생시키는 모델을 만들어 트래픽을 발생한 후 실제 운영중인 네트워크와 비교 분석한다. 세 번째로 이 트래픽을 ATM 스위치의 큐에 적용하여 low bound에서 버퍼 오버플로우 확률 및 셀 손실 확률에 대해 성능분석을 한다.

2. Self-Similarity 특징

Self-similarity는 최근에 들어서 데이터 통신 트래픽 분석에 적용된 중요한 개념이다. self-similarity는 차원상의 서로 다른 확률대비율이나 서로 다른 스케일에서 보았을 때 동일하게 보이거나 동일하게 행동하는 것이 자기 유사한 현상을 말한다. 즉, 데이터 트래픽의 타임 시퀀스가 해상도의 정도에 상관없이 동일한 패턴으로 나타나는 것이다 [2]. 이것이 self-similarity의 핵심이다. 네트워크 성능의 관점에서 self-similarity 특징은 집단화의 지속성이며, 포아송 트래픽에서 집단화는 단기간 내에 발생하지만 장기간이 지

나면 smooth out 되어 버린다.

2.1 Self-Similar Traffic

일반적으로 self-similarity는 결정론적인 시계열에 대해 구성되어진다. 그러나 데이터 트래픽은 확률적인 과정으로 가장 잘 고찰되어지고, 통계적인 방법으로만 self-similarity를 언급할 수 있다[1]. 일반적으로 결정적이고 주기적인 신호는 시간이동에 관하여 불변인 특징이 있다. 즉 그 신호는 시간상으로 여러 주기가 이동하더라도 동일한 신호이다. 이에 반해, 정상확률 과정에 대해서는 그 과정의 통계는 시간 이동에 불변이다. 또한 평균은 시간에 독립적이고 자기상관함수는 단지 시간의 차이에만 의존한다[1, 2].

결정적인 self-similar 신호는 스케일의 변화에 무관하다. 즉, 확률과정에 대해서, 그 과정의 통계가 시간 스케일의 변화에 따라 변하지 않는다. 정성적이고 정량적인 측면에서, 그 과정은 스케일의 특징이 없다. 비결정적인 self-similarity는 자연적, 인공적 현상에서 매우 일반적이다. 이것은 자연의 풍경, 지진의 분포, 파도, 난류, 주식의 변동, 통신채널의 에러와 데이터 트래픽의 패턴에서 찾을 수 있다.

self-similar 확률과정은 기존의 논문에서 여러가지 방법으로 정의되어져왔다. 본 논문에서는 먼저 연속시간 확률과정에 대해 살펴본 후 데이터 트래픽과 관련된 이산시간 확률과정에 대해 살펴본다.

2.1.1 연속시간 정의

Self-similar 확률과정의 일반적인 정의는 다음과 같이 연속시간 변수의 직접 스케일링에 기초한다. 어떠한 실수 $a > 0$ 에 대해, 확률과정 $a^{-H}x(at)$ 가 $x(t)$ 와 통계적으로 동일한 특성을 가진다면, 확률과정 $x(t)$ 는 파라미터 $H(0.5 \leq H \leq 1)$ 를 가지고 통계적으로 self-similar하다. 이러한 관계는 식 (1), 식 (2), 식 (3)의 3가지 조건으로 표현된다[1, 2].

$$E[x(t)] = E[x(at)] \quad \text{Mean} \quad (1)$$

$$Var[x(t)] = \frac{Var[x(at)]}{a^{2H}} \quad \text{Variance} \quad (2)$$

$$R_x(t, s) = \frac{R_x(at, as)}{a^{2H}} \quad \text{Autocorrelation} \quad (3)$$

Hurst 또는 self-similarity 파라미터 H는 self-similarity의 핵심척도이다. 다시 말하면, H는 통계적인 현상의 지속성에 대한 척도이고 확률과정의 장기간 종속에 대한 척도이다. H=0.5의 값은 self-similarity의 부재를 나타내고, H가 1에 가까울수록, 지속성의 정도 또는 장기간의 종속의 정도는 더욱 커진다. 즉, H=0.5에 대하여 과거와 미래의 증가에 대한 상관성이 없어지고, H>0.5에 대하여 지속성의 두드러진 특징을 가진다. 후자의 경우 과거에서의 증가(또는 감소)하는 경향은 미래에서의 증가(또는 감소)하는 경향을 의미한다. 이러한 상관성은 임의의 큰 값 t에 대해

적용되고, 상관성의 강도는 H값이 증감함에 따라 증가한다. 이러한 지속성의 행동은 확률적 현상들에 대해 일반적으로 가정했던 것과 상충된다[7].

2.1.2 이산시간 정의

정상 시계열(stationary time series) x 에 대해, m-aggregated 시계열 $x^{(m)} = \{x_k^{(m)}, k=0, 1, 2, \dots\}$ 은 인접한 m크기의 블록을 겹침 없이(nonoverlapping) 원래의 시계열을 합계함으로써 정의한다. 이에 대한 정의는 식 (4)와 같이 표현된다[1, 2, 7].

$$x_k^{(m)} = \frac{1}{m} \sum_{i=km-(m-1)}^{km} x_i \quad (4)$$

만약 식 (4)의 확률과정의 통계(mean, variance, correlation, etc)가 동일한 압축 사본을 간직하고 있다면, self-similar 과정으로 다룰 수 있다. 확률과정 x 가 모든 $m=1, 2, \dots$ 에 대해서 식 (5), 식 (6)과 같다면 파라미터 $\beta (0 < \beta < 1)$ 에 대하여 정확하게 self-similar하다고 한다.

$$Var(x^{(m)}) = \frac{Var(x)}{m^\beta} \quad \text{Variance} \quad (5)$$

$$R_{x^{(m)}}(k) = R_x(k) \quad \text{Autocorrelation} \quad (6)$$

파라미터 β 는 앞에서 정의했던 Hurst 파라미터 H와 관련하여 $H = 1 - (\beta/2)$ 로 나타내어진다. 정상과정 및 에르고딕 과정(ergodic process)에서는 $\beta=1$ 인 경우로써, 시간 평균의 분산은 $1/m$ 비율로 감소하게 되지만, self-similar 과정에서는 시간평균의 분산은 더욱 천천히($1/m^\beta$) 감소하게 된다. 그러므로 $H = 0.5$ 의 값은 self-similarity의 부재를 나타내고, H가 1에 가까울수록, 지속성의 정도 또는 장기간의 종속의 정도는 더욱 커진다. 확률과정 x 가 충분히 큰 모든 k 에 대해 식 (7)와 식 (8)과 같다면 근사적으로 self-similar하다고 한다.

$$Var(x^{(m)}) = \frac{Var(x)}{m^\beta} \quad \text{Variance} \quad (7)$$

$$R_{x^{(m)}}(k) \rightarrow R_x(k), \text{ as } m \rightarrow \infty \quad \text{Autocorrelation} \quad (8)$$

따라서, 이러한 self-similarity의 정의에 의해서, 집합 과정의 자기상관은 원래의 확률과정과 동일한 형태를 가진다. 이것은 변이성 또는 버스트한 정도가 서로 다른 타임 스케일에서 동일하게 나타난다는 것을 의미한다[2, 7].

2.1.3 장기간 의존성(Long-Range Dependence)

Self-similar 과정의 중요한 특징들 중의 하나는 장기간 의존성으로 나타난다. 일반적으로, 단기간 의존과정에서 자기공분산(autocovariance) $C(k)$ 는 최소한 지수적으로 급격히 감소한다는 조건을 만족시킨다.

$$C(k) \sim a^{|k|}, |k| \rightarrow \infty, 0 < a < 1 \quad (9)$$

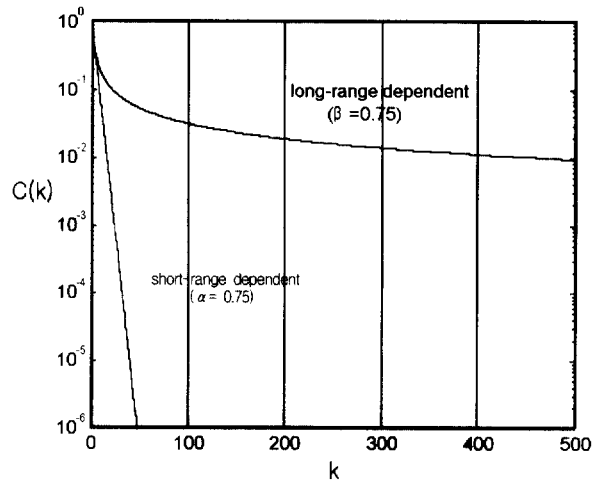
일반적으로 기존의 논문에서 고려된 데이터 트래픽 모델들의 형태는 단기간 의존 과정을 고려했다. 그리고 이러한 조건은 식 (10)과 같이 나타내어진다.

$$\sum_{k=0}^{\infty} x^k = \frac{1}{1-x}, |x| < 1 \quad (10)$$

식 (10)에서 $\sum_k C(k)$ 가 유한하다는 것을 쉽게 알 수 있다. 이에 반해, 장기간 의존과정은 hyperbolic하게 감소하는 자기공분산을 가지고, 식 (11)과 같이 나타내어진다.

$$C(k) \sim |k|^{-\beta}, |k| \rightarrow \infty, 0 < \beta < 1 \quad (11)$$

식 (11)에서 β 는 앞에서 정의된 파라미터이고 $H = 1 - (\beta/2)$ 이기 때문에 Hurst 파라미터와 연관이 있다. 이 경우 $\sum_k C(k) = \infty$ 이 됨을 알 수 있다.



(그림 1) 장기간의존성과 단기간 의존성의 비교


(그림 1)은 k 에 따른 자기공분산의 단기간 의존성과 장기간 의존성을 도시한 것이다. 장기간 의존성은 self-similar 과정들에서의 지속적 현상을 반영한다. 즉, 모든 타임스케일에서의 군집 및 버스트한 특성의 존재를 나타낸다[1, 11-13].

3. Source 모델링 및 트래픽 측정


3.1 Self-Similar 트래픽 모델링

Self-similar 트래픽은 수많은 Pareto-like ON/OFF 소스들의 중첩(superposition)에 의해 생성되어진 것으로 모델링할 수 있다. 그러한 소스들은 ON 주기(버스트한 패킷이 전송될 때)와 OFF 주기(idle, period)간을 번갈아 수행하고, 그 주기들이 독립적이고, 동등하게 분포된 랜덤변수에 의해 특징 지워진다. 각각의 소스들이 동일한 분포에 의해 좌우된

다고 가정한다면, 결론적으로 이러한 독립된 소스들의 중첩 또는 멀티플렉싱은 self-similar 트래픽이 된다. 본 논문에서는 self-similar 트래픽 모델링을 위해 100개의 독립적인 Pareto-like ON/OFF 소스모델을 중첩시켜 발생시켰다. ON 기간에서는 단위크기의 패킷이 CBR로 발생하고, OFF 기간에서는 트래픽이 발생하지 않는다고 가정하였다. 이 과정의 블록 다이어그램은 (그림 2)와 같다. 또한 self-similarity 트래픽과 비교를 하기 위해 (그림 3)과 같이 동일한 모델을 적용하여 ON, OFF 주기를 포아송 분포를 사용하여 트래픽을 발생 시켰다[6, 8, 9].



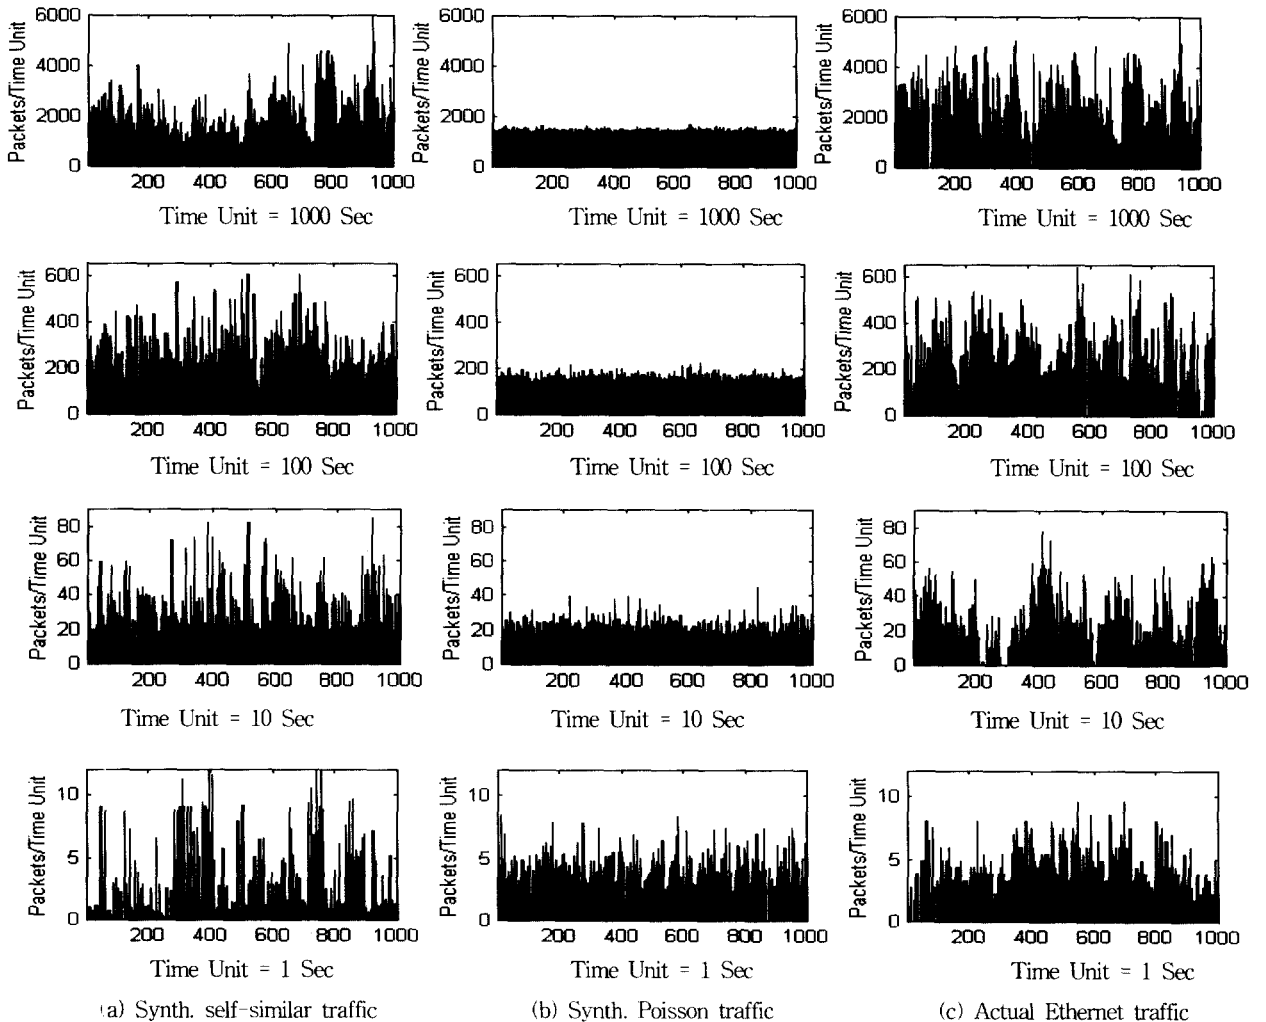
(그림 2) Pareto 트래픽 발생기의 블록 다이어그램



(그림 3) Poisson 트래픽 발생기의 블록 다이어그램

3.2 실시간 운영중인 LAN 트래픽 측정

트래픽의 self-similarity에 대한 수학적, 통계학적으로 정확한 특성을 연구하기 위해서는 많은 양의 트래픽 수집이 필요하다[4]. 본 논문에서 실시간 운영중인 네트워크 트래픽 샘플을 측정하기 위해 사용한 네트워크 환경은 본 교의 네트워크를 이용하였다. 샘플 측정은 C급 클래스인 203.230.252 네트워크에서 측정을 하였고 샘플 측정 도구는 HP사의 Internet Advisor를 사용하였다. 측정 파라미터는 전체 패킷수를 측정 하였으며, 패킷 수는 신뢰성을 기하기 위하여 100만개 이상을 1초 단위로 측정하였고 측정 기간은 2000년 6월 12



(a) Synth. self-similar traffic

(b) Synth. Poisson traffic

(c) Actual Ethernet traffic

(그림 4) Aggregation 레벨에 따른 실제 트래픽과 합성 트래픽의 비교

일부터 6월 26일까지 측정을 하였다. 측정기간 평균 이용률은 약 7% 정도로 나타났고 최고 이용률은 14%로 나타났다. 그리고 순간 평균 사용자 수는 약 45명으로 측정이 되었다.

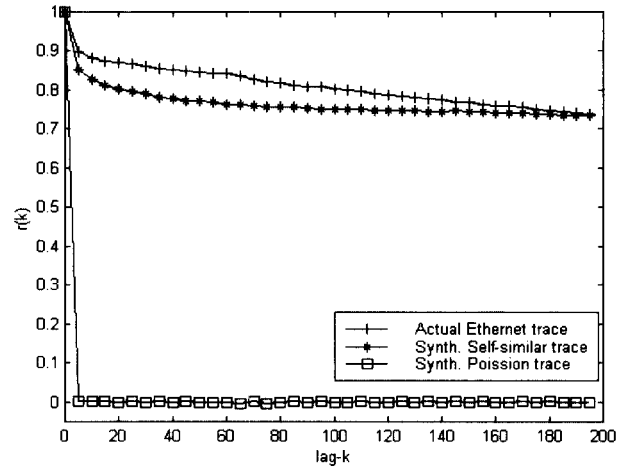
4. 트래픽 분석

4.1 Aggregation 레벨에 따른 실제 트래픽과 합성 트래픽의 비교

Aggregation 레벨에 따른 실제 트래픽과 합성 트래픽의 비교는 (그림 4)와 같다. 분포적인 관점에서 살펴보면 (c)의 실제의 데이터는 1초에서 1000초까지의 타임 스케일 범위에 대해 결과적인 트래픽은 동일하게 보이는 경향이 있고, 백색잡음과는 뚜렷하게 차이를 알 수 있다. 또한, 버스트에 대한 고유한 길이가 없고, 모든 타임 스케일에서 버스트는 더욱 작은 버스트한 부주기에 의해서 분리되는 버스트한 부주기로 구성된다. 즉, 프랙탈(fractal)적인 특성을 나타낸다. 그리고, (a)의 self-similar 모델링에 의해 발생시킨 트래픽은 실제의 데이터와 통계학적인 관점에서 거의 동일한 특성을 지니는 것을 알 수 있다. 즉, aggregation 레벨에 상관없이 버스트함이 유지됨을 알 수 있다. 이에 반해, (b)의 기존의 포아송 과정에 의해 발생시킨 트래픽은 낮은 aggregation 레벨에서는 그 버스트함을 볼 수 있으나, aggregation 레벨이 높아짐에 따라 버스트함이 급격하게 사라지는 것을 볼 수 있다. 즉, 분산이 aggregation의 레벨이 높아짐에 따라 급격하게 "0"으로 수렴하게 되며, 그 감소의 정도는 aggregation 레벨 m에 비례함을 알 수 있다. 이것은 백색잡음과 거의 동일한 성질을 나타내며, 포아송 모델에서 정의된 것처럼 정상 및 에르고딕 확률과정으로부터 기인한 것이다. 결과적으로 aggregation 레벨이 증가함에 따라 실제의 트래픽과 뚜렷한 차이가 나타나게 된다. 결론적으로, 기존의 포아송 과정을 사용하는 큐잉분석이 네트워크 데이터 트래픽을 모델링 하는데 적합하지 않음을 단적으로 알 수 있다.

4.2 장기간 의존성 비교

LRD 특성을 고찰하기 위해 각 트래픽 트레이스(trace)의 자기상관함수를 구했다. (그림 5)는 시차(lag)에 따른 자기상관함수를 나타낸다. 여기에서도 알 수 있듯이 실제의 트래픽 데이터와 Pareto 분포 데이터 모두 시차(lag-k)에 따라서 아주 높은 상관성을 지니는 것을 알 수 있다. 즉, 장기간 의존성을 가진다. 이에 반해, 포아송 분포에 의한 트래픽의 경우 시차 k가 0의 경우에는 1의 상관을 가지는 반면에 시차 k가 커짐에 따라 급격하게 0으로 수렴함을 알 수 있다. 이는 백색 잡음과 같은 특성이며, 단기간 의존성을 가진다.



(그림 5) 시차(lag-k)에 따른 자기상관함수

즉 실제의 트래픽은 버스트함이 스위치의 버퍼에 계속적으로 영향을 미치는 반면에 기존의 모델을 사용하여 시뮬레이션을 수행하였을 경우 단기간의 의존성만이 고려되어 실제 트래픽의 영향을 나타내지 못했다는 것을 알 수 있다[11-13].

4.3 Hurst 파라미터 측정

앞에서 설명한 self-similarity를 나타내는 기준으로 많이 사용되는 Hurst 파라미터를 구하는 방법은 Variance-time plot, R/S plot, Periodogram 방법 등 여러 가지가 있다. 본 논문에서는 Variance-time plot를 사용했다. Variance-time plot의 정의는 다음과 같다. self-similarity 과정의 m-aggregated 시계열 $x^{(m)}$ 에 대해 분산은 매우 큰 m에 대해 식 (12)와 같이 나타내어 진다.

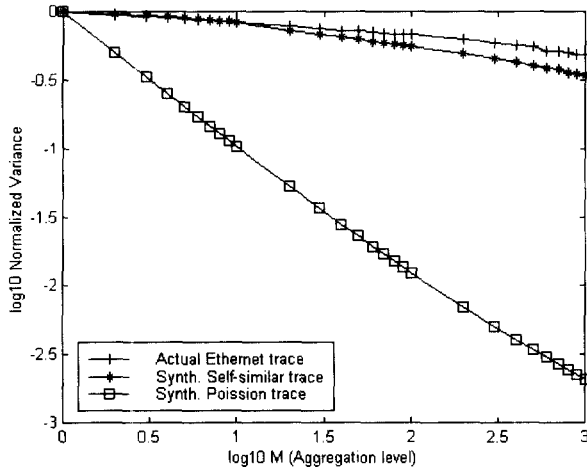
$$Var(x^{(m)}) \approx \frac{Var(x)}{m^\beta} \tag{12}$$

식 (12)에서, self-similarity 파라미터 $H = 1 - (\beta/2)$ 이다. 그리고, $\log[Var(x)]$ 는 m과 무관한 상수이기 때문에 이 식 (12)는 식 (13)과 같이 고쳐 쓸 수 있다.

$$\log[Var(x^{(m)})] \approx \log[Var(x)] - \beta \log(m) \tag{13}$$

식 (13)을 log-log 그래프 상에 m에 대한 $Var(x^{(m)})$ 을 그리게 되면, $-\beta$ 값의 기울기를 가지는 직선이 나오게 된다[3]. 그리고 이 직선에 대한 기울기가 Hurst 파라미터값을 나타내게 된다. (그림 6)은 실제의 트래픽과 self-similar 모델링 그리고 포아송 모델링의 트래픽에 대한 Variance-time plot이다. 각 트래픽에 대한 Hurst 파라미터는 <표 1>과 같다. 실제의 트래픽과 self-similar 모델링에 의해 인위적으로 생성된 트래픽의 경우 1에 가까운 아주 높은 Hurst 파라미터 값을 가짐을 알 수 있다. 이는 self-similarity의 강도가 아주 강함을 나타낸다. 이에 반해서 기존의 포아송 과정으로

생성한 트래픽의 경우 0.5에 가까운 H값을 가짐을 알 수 있다. 즉, 거의 백색잡음에 가까운 특성을 나타낸다. 이러한 결과에서 알 수 있듯이, self-similar 모델링에 의해 발생된 트래픽의 실제 트래픽 특성을 잘 나타내는 반면, 포아송 과정의 경우 실제 트래픽의 버스트한 성질을 제대로 나타내지 못함을 알 수 있다.



(그림 6) 각 트래픽의 Variance-time plot

<표 1> 각 트래픽에 대한 Hurst 파라미터 값

트래픽 트레이스	β	H
Actual trace	0.1054	0.9473
Synth. self-similar trace	0.1688	0.9156
Synth. Poisson trace	0.9478	0.5261

5. Low Bound하에서 ATM 스위치 큐의 성능분석


본 논문에서는 ATM 스위치 큐의 성능을 분석하기 위해 GY/D/1/h 모델을 사용 하였다. 여기서 G는 길이 1을 가지는 일반적인 트래픽을 나타내며, Y는 Pareto 형태의 분포 ($Pr\{\tau = n\} = cn^{-a-1}$)를 가지는 트래픽을 나타낸다. 즉 self-similarity한 트래픽을 적용한 것이다. D는 셀에 대해 일정한 서비스 시간을, 1은 1개의 서버, 그리고 h는 버퍼의 크기를 나타낸다. 이러한 모델로서 low bound하의 버퍼 오버플로우 확률 및 버퍼 셀 손실 확률을 구하면 식 (14)와 식 (15)는 같다.

$$P_o = \frac{c}{a(a-1)(E_r + E_k)^2} \left(\left[\frac{h + (E_r + E_k)^{-1} + 1}{(E_r + E_k)^{-1}} \right] + 2 \right)^{-a-1} \quad (14)$$

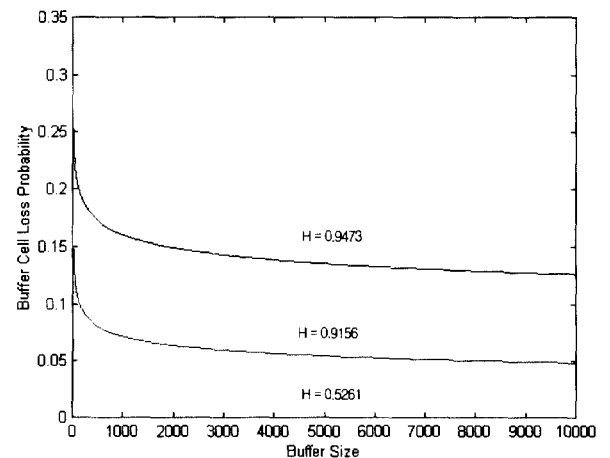
$$P_{loss} = \frac{P_o}{\lambda E_r} \quad (15)$$

여기서 P_o 는 버퍼 오버플로우 확률이고 P_{loss} 는 버퍼의 셀 손실 확률이다. 또한 $E_r = c \sum_{n=1}^{\infty} n^{-a} c = \left(\sum_{n=1}^{\infty} n^{-a-1} \right)^{-1}$, $E_k = (1 - e^{-\lambda})^{-1} - 1$ 이며 λ 는 포아송 분산이다[5]. 본 논문에서

는 Pareto 분포, 포아송 분포를 가지는 트래픽, 그리고 실제 측정된 트래픽을 사용하여 버퍼에서 오버플로우 확률과 버퍼에서 셀 손실 확률에 대한 시뮬레이션을 수행하였다. (그림 7)과 (그림 8)은 시뮬레이션 결과이다. (그림 7)에서 알 수 있듯이 Hurst 파라미터 $H = 0.9473$ 에서는 버퍼 오버플로우 확률이 버퍼의 크기가 증가하더라도 0.02% 이상이 됨을 알 수 있다. 그리고 $H = 0.9156$ 에서는 0.01% 이상 self-similarity 특성이 드러나지 않는 포아송 분포인 $H = 0.5261$ 에서는 버퍼의 오버플로우 확률이 0으로 됨을 알 수 있다. 이 결과에서 보듯이 H가 높을수록 즉 self-similarity의 강도가 높을수록 버퍼의 오버플로우 확률이 높아짐을 알 수 있다. 또한 버퍼의 크기를 증가시키면 오버플로우의 확률이 낮아질 거라고 예상할 수 있으나 실제의 결과는 예측과는 달리 self-similarity의 강도가 높은 경우 즉 버스트의 강도가 높을수록 이러한 영향은 장기간 계속적으로 버퍼에 영향을 미침을 알 수 있다.



(그림 7) 버퍼 크기와 Hurst 파라미터 값에 대한 버퍼 오버플로우 확률



(그림 8) 버퍼 크기와 Hurst 파라미터 값에 대한 버퍼 셀 손실 확률

(그림 8)은 Hurst 파라미터 값에 따른 셀 손실 확률을 나타낸 결과로서 (그림 7)에서와 같이 H가 높을수록 버퍼의 셀 손실 확률이 높음을 알 수 있다. 또한 버퍼의 크기를 증가하여도 H가 높을 경우에는 트래픽의 버스트함이 장기간 영향을 미쳐 셀 손실 확률이 낮아지지 않음을 알 수 있다. 이러한 결과는 현재 ATM이 TCP와 연동을 할 경우 TCP의 재전송 알고리즘이 적용되므로 약간의 셀 손실은 TCP 프레임의 전체적인 재전송을 야기시키므로 버퍼와 혼잡에 더욱 더 치명적인 영향을 미치게 된다는 것을 알 수 있다.

6. 결 론

본 논문에서는 Pareto 분포, 포아송 분포를 가지는 트래픽을 발생하였고, 그리고 실제 트래픽을 측정하여 Hurst 파라미터를 구하였다. 이 트래픽을 ATM 큐에 적용을 시켰을 때 기존의 포아송 분포를 모델링하여 시뮬레이션한 결과와는 많은 차이점이 있었다. 즉 aggregation 레벨이 낮을 경우에는 각 트래픽의 차이점이 없었으나 aggregation 레벨을 증가시키면 실제 측정된 트래픽과 self-similar 모델을 적용한 경우의 트래픽의 버스트함을 그대로 살리고 있지만 포아송 모델을 사용한 트래픽의 경우에는 버스트함이 사라지고 백색잡음과 같이 됨을 알 수 있었다. 또한 이러한 트래픽을 ATM 스위치의 버퍼에 적용했을 경우에도 많은 차이점이 있음을 알 수 있었다. H의 강도가 높을수록 오버플로우 확률 및 셀 손실 확률이 높아짐을 알 수 있었고, 버퍼의 크기를 높게 하여도 self-similarity 트래픽의 특성으로 인해 큐 내의 오버플로우 확률과 셀 손실 확률에 대한 의존성은 큐 내에 셀이 도착하여 처리되는 이벤트 발생시점을 넘어 서더라도 장기간 유지됨을 알 수 있었다. 이러한 결과로서 포아송 분포를 모델로 제작된 ATM 장비들은 실제 현장에 배치 했을 때 성능면에서 시뮬레이션 결과와 많은 차이점이 있음을 알 수 있다. 즉 앞으로 네트워크 장비의 설계시 포아송 모델과 같은 기존의 모델로는 실제 네트워크에서 발생하는 트래픽을 충분히 수용할 수가 없음을 알 수 있고 또한 본 논문에서 제시한 self-similar한 모델을 적용 시켜야 함을 알 수 있다. 본 논문에서는 low bound에서 버퍼 오버플로우 확률과 셀 손실 확률에 대한 성능을 분석하였으나 향후 high bound에서도 이러한 성능분석을 수행해야 할 것이다.

참 고 문 헌

[1] William Stalling, 'High-Speed Network,' Prentice Hall, 1998.
 [2] Peyton Z. Peebles, JR. 'Probability, Random Variables, and Random Signal Principles,' McGraw Hill, 1993.

[3] 김창호, 김동일 외, "실시간 운영중인 Ethernet 트래픽의 장기간 의존성 및 Self-similar 특성에 관한 연구", 한국해양정보통신학회 추계종합학술발표대회, Vol.3 No.2, pp.331-335, 1999.
 [4] 진성호, 임재홍, "실시간 운영중인 네트워크 상에서 Self-similarity 특성 및 Hurst 파라미터 추정", 한국해양정보통신학회 추계종합학술발표대회, Vol.3 No.2, pp.266-279, 1999.
 [5] Boris Tsybakov and Nicolas D.Georganas, "On Self-Similar Traffic in ATM Queues : Definitions, Overflow Probability Boun, and Cell Delay Distribution," IEEE/ACM Trans on Networking, Vol.5 No.3, pp.48-52, 1997.
 [6] W. Willinger, M. S. Taquq, R. Sherman, "Self-similarity through high-variability-statistical analysis of Ethernet of LAN traffic at the source level," IEEE/ACM Trans on Networking, Vol.5, No.1, pp.71-86, 1997.
 [7] Will E. Leland, Walter Willinger, Bellcore, Murad S. Taquq, Daniel V. Wilson "On the Self-similar Nature of Ethernet Traffic," Computer Communication Review, Vol.25 No.1, pp. 203-214, 1995.
 [8] Tsybakov B, Georganas ND, "Self-similar traffic and upper bound to buffer-overflow probability in an ATM queue," Performance Evaluation, Vol.32, No.1, pp.57-80, 1998.
 [9] Patrick Droz, Jean-Yves Le Boudec, "A High-Speed Self-Similar ATM VBR Traffic Generator," Proceedings of the Globecom Vol.1, pp.586-590, 1996.
 [10] V. Paxson, S. Floyd, "Wide-area traffic : The failure of Poisson Modeling," IEEE/ACM transaction on Networking, Vol.3, pp.226-244, 1994.
 [11] J. Beran, R. Sherman, M. S. Taquq and W. Willinger, "Long- Range Dependence in Variable Bit Rate Video Traffic," IEEE Tracsaction on Communications 43, No.2/3/4, pp. 1566-1579, 1995.
 [12] M. Grossglauser, J. C. Bolot, "On the relevance of long-range dependence in network traffic," Computer Communication Review, Vol.26, No.4, pp.15-24, 1996.
 [13] M. S. Taquq, V. Teverovsky, W. Willinger., "Estimators for long-range dependence : and empirical study," Fractals, 3(4) : pp.785-788, 1995.



진 성 호

e-mail : deodato@korea.com

1994년 동의대학교 전자통신공학과
(공학사)

1998년 동의대학교 전자공학과
(공학석사)

2001년 한국해양대학교 전자통신공학과
(박사수료)

관심분야 : 프로토콜 성능분석, 트래픽 엔지니어링, ATM



임재홍

e-mail : jhyim@kmaritime.ac.kr

1986년 서강대학교 전자공학과 졸업
(공학사)

1988년 한양대학교 대학원 전자공학과 졸업
(공학석사)

1988년 한양대학교 대학원 전자공학과 졸업
(공학박사)

1995년~현재 한국해양대학교 전자통신공학과 부교수

관심분야 : 그룹웨어, 분산처리, 초고속통신망



김동일

e-mail : dikim@hyomin.donggeui.ac.kr

1981년 광운대학교 공과대학 전자통신
공학과(공학사)

1983년 광운대학교 대학원 전자통신 공학과
(공학석사)

1992년 광운대학교 대학원 전자통신공학과
(공학박사)

1983년~1991년 LG중앙연구소 정보통신부문 연구개발실장

1991년~현재 동의대학교 공과대학 전기·전자 정보통신공학부
부교수

관심분야 : 전자교환망 성능분석, 무선망 프로토콜