

Shifting-Level Process에 기반한 영상트래픽 모델 (1부: 모델링과 대기체계 영향 분석)

정회원 안희준*, 강상혁**, 김재균*

A Video Traffic Model based on the Shifting-Level Process (Part I: Modeling and the Effects of SRD and LRD on Queueing Behavior)

Heejune Ahn*, Sang H. Kang**, Jae-kyoon Kim* *Regular Members*

요약

본 논문에서는 ‘shifting-level (SL) process’을 기초로한 모델을 사용하여, VBR 부호화된 영상트래픽의 long-range dependence (LRD) 특성이 대기체계에 미치는 영향에 대해서 연구하였다. 연구 내용은 제1부와 제2부로 나누어 전개된다. 제 1부에서는 실제 영상트래픽의 자기상관함수가 exponential과 hyperbolic의 복합함수로 매우 정확히 표현될 수 있음을 보이고, 이러한 조건을 만족하는 SL process with compound correlation(SLCC)를 제안한다. 대표적인 SRD 모델인 DAR(1)모델과의 대기성능 비교를 통하여 hyperbolic한 상관도가 대기체계에 끼치는 영향을 분석한다. 분석결과 영상의 LRD 특성이 대기체계에 끼치는 영향의 중요도는 단순히 ‘Yes/No’로 답할 수 없으며, 트래픽 부하가 높아지면 그 영향이 강하게 나타나고, 반대로 트래픽 부하가 낮은 경우에는 무시할 수 있을 정도로 약하게 나타남을 알 수 있다. 여기에 사용하는 SL/D/1/K 대기체계의 해석방법은 제2부에서 다루게 된다.

Abstract

In this paper, we study the effects of long-range dependence (LRD) in VBR video traffic on queueing system. This paper consists of Part I and Part II. In Part I, we present a (LRD) video traffic model based on the shifting-level (SL) process. We observe that the ACF of an empirical video trace is accurately captured by the shifting-level process with compound correlation (SLCC): an exponential function in short range and a hyperbolic function in long range. We present an accurate parameter matching algorithm for video traffic. In the Part II, we offer the queueing analysis of SL/D/1/K called ‘quantization reduction method’.

Comparing the queueing performances of the DAR(1) model and the SLCC with that of a real video trace, we identify the effects of SRD and LRD in VBR video traffic on queueing performance. Simulation results show that Markovian models can estimate network performances fairly accurately under a moderate traffic load and buffer condition, whereas LRD may have a significant effect on queueing behavior under a heavy traffic load and large buffer condition.

* 한국과학기술원 전기및전자공학과 영상통신 연구실 (cityboy@viscom.kaist.ac.kr),
논문번호 98550-1228, 접수일자 : 1998년 12월 28일

** 서울시립대 정보전자공학부

※ 이 연구는 부분적으로 한국과학재단(KOSEF:98-0101-02-01-3)의 지원으로 수행되었음.

I. 서 론

VBR 영상트래픽은 종합정보통신망(고속 inter-net과 B-ISDN)에서의 주요 부하원이 될 것이다. 이러한 종합정보통신망에서의 효율적인 정보전송은 입력트래픽에 대한 충분한 이해를 통해서만이 가능하다. 이러한 이유로 트래픽의 특성화와 모델링이 트래픽제어 연구에 있어서 주요 연구주제가 되어 왔다. 그 결과 트래픽의 특성 중에 1차, 2차 통계특성인 입력분포(rate distribution)과 자기상관함수(auto-correlation function: ACF)가 망의 전송품질을 예측하는데 있어서 가장 중요한 요소로 받아들여지고 있다^[3,7,13].

기존의 트래픽 모델들은 주로 Markovian process에 기초하였다. 그러나 최근에 영상트래픽에 long-range dependence (LRD, 종종 self-similarity라고 불림) 특성이 존재한다는 사실이 실험적인 연구를 통하여 발표되었다^[2,5,6,10]. 그러한 모델들로 fractional Brownian motion (fBn)^[12,13], fractional ARIMA processes, chaotic maps, 그리고 semi-Markovian processes^[1,10] 등이 있다.

그 이후, LRD 특성을 갖는 여러 가지 트래픽 모델들이 제안되었고, LRD가 망에 미치는 영향에 대한 기초적인 연구들도 수행되었다^[10,12]. Norros^[12]와 Erramilli^[4]는 각각 fBn 모델을 이용한 연구와 실제 LAN 데이터에 바탕을 둔 연구에서 LRD 특성이 대기시간분포를 hyperbolic 형태로 만든다는 사실을 보였다. 이는 기존의 Markov 모델들을 사용하였을 때, 대기 지연 분포가 exponential 형태인 것과 비교할 때, 기존의 Markov 모델에 기반한 예측보다 실제 셀손실이 훨씬 클 수 있을 의미한다.

이러한 사실에도 불구하고, 여전히 전통적인 Markov 모델들이 트래픽 연구에 사용되고 있다. 더욱이 여러 연구에서 Markov 모델이 LRD 특성이 없음에도 불구하고, 망에서의 성능예측에 문제가 없다는 것이 주장되었다^[3,8]. 따라서 이러한 일견 상반되는 연구결과들에 대하여 “VBR 영상트래픽에 있어서 LRD 특성이 망의 성능, 특히 대기체계에 결정적인 영향을 주는 조건은 무엇인가?”라는 문제를 제기할 수 있다.

본 연구에서는 기존 연구들이 이처럼 일견 서로 상반되는 결과를 보이는 원인이 영상트래픽의 SRD (short-range dependence, 작은 지역거리의 상관성)과 LRD (long-range dependence, 먼 지역거리에서의

상관성)을 효과적으로 반영하는 모델이 없었기 때문이라고 보고 shifting-level (SL) process에 기반하여 전 범위에 걸쳐 ACF를 잘 반영할 수 있는 트래픽 모델을 제안한다.

SL process는 Mandelbrot^[11]가 경제분석을 위하여 처음 제안하였으며, Grasse^[6] 등에 의하여 영상트래픽에 응용된 바 있다. 간략히 기술하면, SL process는, 두 개의 i.i.d. process $\{S_i\}$ 과 $\{T_i\}$ 에 따라, 발생되는 데이터량 (S_i)과 상태지속시간 (T_i)이 정해지는 유체입력모델이다. 제II장에서 설명하겠지만, SL process는 입력분포와 자기상관함수가 독립적으로 매칭될 수 있기 때문에 각각의 영향을 이해하는데 매우 효과적인 모델이다. 이 연구에서는 입력분포에 관해서는 기존의 연구^[3,5,8]에서와 같이 negative binomial 분포를 가정하고, 자기상관함수의 특성이 대기체계에 미치는 영향에 대해서 중점적으로 살펴본다.

특히, 본 연구에서 실험을 통하여 실제 트래픽의 ACF은 exponential과 hyperbolic의 복합함수에 의하여 정확히 모델된다는 것을 발견하였고, 이러한 특성을 만족하는 구조를 갖는 SL process를 shifting-level process with compound correlation (SLCC)이라 명명한다. 특히, SLCC 모델의 자기상관함수가 실제 트래픽의 자기상관함수와 일치하도록 하는 효과적인 변수 추출 방식을 제안한다.

한편, 영상 트래픽모델로서 가장 널리 사용되고 있는 DAR(1) 모델은^[8] Markov 연쇄에 기초하고 있는 SRD 모델이다. 그런데, DAR(1) 모델의 연속 시간 버전인 C-DAR(1) 모델은 exponential 상관도만을 갖는 형태의 SLCC 모델과 수학적으로 동일하다. 따라서, 모델변수를 조정하여, 입력분포와 SRD 성분은 동일하고, LRD 성분의 유무만이 차이가나는 두 모델을 구성할 수 있고, 이 두 모델을 입력으로 하는 대기체계의 성능 차이는 곧 LRD 특성이 대기체계에 미치는 영향이라고 볼 수 있다. 한편 제2부에서는 효과적으로 SL/D/1/K 대기체계를 분석할 수 있는 방안을 제안한다.

본 논문의 구성은 다음과 같다. 우선 제II장에서 SL process를 정의하고, 변수 매칭에 유용한 SL process의 성질을 소개한다. 제III장에서는 SL process의 특별한 형태인 SLCC 모델을 제안하고 변수 추출 방법에 대하여 기술한다. 제IV장에서는 대기체계 분석에 대한 수치 결과를 제시한다. 마지막으로 제V장에서, 본 연구의 결과에 대하여 기술한다.

II. Shifting-level 확률과정

1 Shifting-Level 확률과정과 그 특성

우선 두 i.i.d. 확률과정 $T_n = t_n - t_{n-1} INR^+$, $n=1, 2, \dots$ 과 $S_n \in \{0, 1, 2, \dots, i, \dots, M\}$, $n=0, 1, 2, \dots$ 를 생각하자. 그러면 정의에 따라 $N(t) = \max\{n: t_n < t\}$ 는 생신 시점 $t_0 (=0) < t_1 < t_2 < \dots$ 을 갖는 생신과정 (renewal process)^[1] 된다. 여기서 첫 번째 생신시간 t_1 이 일반적인 생신시간 확률변수 T 의 잔여시간 분포를 따른다고 가정하면, shifting-level process $X(t)$ 는 입력율이 $S_{N(t)} = i$ 으로 주어지는 유체입력 모델(fluid input model)이고 식(1)로 표시할 수 있다.

$$X(t) \equiv S_{N(t)} = \sum_{n=0}^{\infty} S_n \mathbf{1}_{\{t_n \leq t < t_{n+1}\}} \quad (1)$$

이때 $X(t)$ 는 평균 $E[X(t)] = E[S]$, 분산 $Var[X(t)] = Var[S]$ 을 갖는 stationary 확률과정이 됨을 보일 수 있다. 또한, $F_{T(\cdot)}, f_T(\cdot), \mu_T$ 이 각각 확률변수 T 의 확률분포, 확률밀도함수, 평균을 나타내고, $f_S(\cdot)$ 이 확률변수 S 의 이산확률분포를 나타낸다고 하자.

이제 ACF

$$\rho(\tau) = \frac{E[(X(t) - \mu_X)(X(t+\tau) - \mu_X)]}{Var[X(t)]} \quad (2)$$

과 확률분포 $F_T(\cdot)$ 의 관계를 살펴보자. 이미 Mandelbrot^[11]가 스펙트럼 영역 상에서 이들의 관계를 증명하였다. 이 결과를 정리하면 ACF와 T 의 관계식이 다음과 같이 얻어진다.

$$\rho(\tau) = 1 - \frac{\tau}{\mu_T} + \frac{1}{\mu_T} \int_0^\tau (t-\tau) f_T(\tau) d\tau. \quad (3)$$

또한 이 식을 미분하여 다음 식을 얻는다.

$$f_T(t) = \mu_T \rho'(\tau). \quad (4)$$

또한 이산시간의 경우 같은 방식을 사용하면, f_T 에 해당하는 이산확률분포 \hat{f}_T 에 대하여 다음과 같은 결과식을 얻을 수 있다.

$$\rho(n) = 1 - \frac{n}{\mu_T} + \frac{1}{\mu_T} \sum_{k=1}^n (n-k) \hat{f}_T(k), \quad (5)$$

$$\hat{f}_T(k) = \mu_T \nabla_2 \rho(k). \quad (6)$$

여기서 $\nabla_2 \rho(k) = \rho(k-1) - 2\rho(k) + \rho(k+1)$ 을 의미한다.

2 영상트래픽 모델로서의 SL process

이제 SL process의 영상트래픽에의 응용을 생각하자. 일반적으로 영상트래픽의 특성은 영상정보원 자체가 가지고 있는 정보량의 변화뿐만 아니라, 영상 정보를 부호화 하는데 사용되는 부호화 알고리즘에 따라 달라지게 된다. 특히, MPEG 부호화기는 화면에 따라 다른 부호화 방식을 적용하기 때문에 이에 따른 주기적인 패턴을 갖는 트래픽을 발생시킨다. 따라서 본 연구에서는 JPEG이나 H.261과 같은 단일 부호화 방식만을 사용하여 발생된 트래픽, 특히 intra 부호화된 ‘Star Wars’ 트래픽^[8]을 고려한다. 이 데이터의 기본적인 통계치를 표1에 나타내었다. 여기서는 ATM 셀의 53 바이트 가운데 48 바이트 사용자영역을 모두 사용하는 것으로 가정하였다.

표 1. 인트라 부호화된 스타워즈 영상의 주요 통계 특성

평균 (cells/frame)	표준편차 (cells/frame)	coef. of var.	최대치 (cells/frame)	최대치/ 평균
578.9	130.2	0.23	1,634	2.82

SL process를 영상트래픽에 적용하였을 때, S_n 은 ‘장면크기’(한 장면에서의 데이터 발생률)에, 그리고 T_n 은 ‘장면길이’에 해당한다. 그럼 1은 실제 영상트래픽의 ACF를 exponential과 hyperbolic 함수와 비교하고 있다. 실제 트래픽의 ACF은 작은 거리에서는 exponential (SRD)에 가깝고, 먼 거리에서는 hyperbolic (LRD)에 가까운 것을 보여 준다. 따라서 우리는 이 두 함수를 복합적으로 사용한 식(7)으로 ACF를 모델하고, 이 특수한 형태의 SL process를 shifting-level process with a compound correlation (SLCC)라고 부르기로 한다.

$$\rho(t) = \begin{cases} \rho_e(t) = e^{-t/\tau} & \text{for } 0 < t \leq t_0 \\ \rho_h(t) = c_0(t+t_1)^{-\beta} & \text{for } t_0 < t \end{cases} \quad (7)$$

우선,

$$\begin{cases} \rho''_e(t) = (-e^{-\beta t}/t)' = e^{-\beta t}/t^2 \\ \rho''_h(t) = c_0(-\beta(t+t_1))^{-(\beta+1)}' \\ = c_0(\beta(\beta+1)(t+t_1)^{-(\beta+2)}) \end{cases} \quad (8)$$

이므로 T 역시 exponential 과 hyperbolic의 복합분포를 따라야한다는 것을 알 수 있다. 그럼 2는 다음에 제안할 변수추출방식에 의해 얻어진 SLCC process의 예를 보여준다.

여기서 SLCC process와 매우 잘 알려진 DAR(1)^[8]를 비교해보자. DAR(1)모델은 다음과 같은 전이행렬을 갖는 Markov연쇄 모델이다.

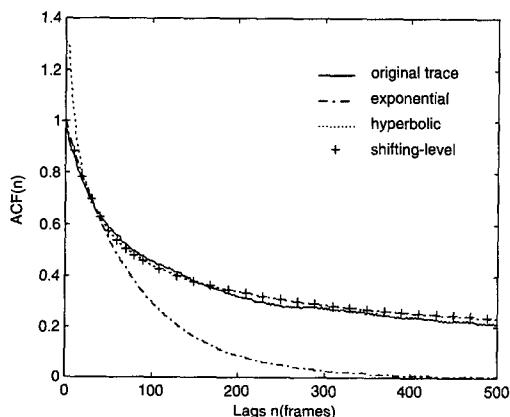


그림 1. ACF의 비교(실제 영상 트래픽, exponential 함수, hyperbolic 함수, SLCC 모델)

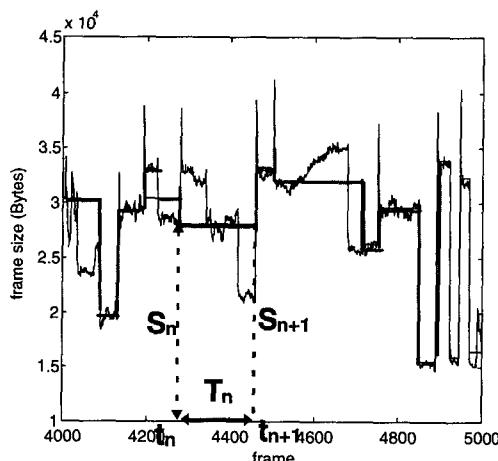


그림 2. 스타워즈 영상과 이영상과 입력분포와 자기상관 함수가 같은 SLCC 모델의 예

$$P = \rho I + (1-\rho) Q, \quad (9)$$

여기서 ρ 는 상관계수이고 Q 는 각 행이 각 상태의 정상상태 확률을 따르는 특수한 형태의 전이 행렬이다. 즉 매 전이시점마다, 이전상태와 상관없이 정상상태 분포에 따라 다음 상태가 정해지게 된다. 이는 SL process에서의 경우와 동일한 성질이다. 따라서, DAR(1) 모델의 연속시간 버전인 C-DAR(1) 모델^[14]은 exponential 형태($\rho = e^{-\Delta t/\tau}$, $\Delta t = \text{one frame time}$)의 상관함수만을 갖는 SLCC process 과 수학적으로 동일하다. C-DAR(1) 모델에 대한 보다 구체적인 연구는 [14]에 나와 있다. C-DAR(1)모델은 기본적으로 SRD 모델이기 때문에 ($\sum \rho(t) < \infty$), 영상스트래픽에서의 LRD 특성을 반영하지 못한다. 반면 SLCC 모델은 C-DAR(1)에서의 특성을 고스란히 갖으면서 LRD 성질($\sum \rho(t) = \infty$)을 갖고 있다. 따라서 같은 변수를 사용한 두 입력, C-DAR(1) 과 SLCC모델에 대한 대기해석결과의 차이는 결국 LRD에 의한 영향으로 볼 수 있다.

III. SLCC 모델의 변수 추출 방법

1. 제안된 변수 추출 방법

SL process는 앞서 설명한 바와 같이, 입력분포와 ACF의 각기 S_n 과 T_n 에 의하여 독립적으로 결정할 수 있다. 우선, SLCC process의 ACF, 즉, 장면 길이에 대한 확률변수 T_n 의 분포를 결정하는 방법을 설명한다. SLCC 모델의 T_n 은 식(7)과 식(8)에서 보는 바와 같이, exponential 과 hyperbolic의 두 함수의 결합으로 표현되고, 이 두 함수의 5 변수($\tau, \beta, t_0, t_1, c_0$)들은 다음과 같이 결정된다. exponential함수의 감소율에 해당하는 τ 는 식(10)에 의해 구해진다

$$\tau = -t / \ln(\rho(t)) \quad (10)$$

여기서는 t 에 해당하는 값으로 10 frames를 사용한다. LRD 정도를 나타내는 β 는 hyperbolic 함수의 감소율을 나타내고, Hurst 변수 예측방식^[2]을 사용한 다음, Hurst변수와의 관계 식(11)에 의해 구해진다.

$$\beta = 2 - 2H \quad (11)$$

변수 c_0 와 t_0 는 ACF 과 T_n 의 누적분포함수

(CDF)가 연속이라고 가정하여 정한다.

$$\text{즉}, \begin{cases} \rho_e(t) = \rho_h(t) \\ \rho'_e(t) = \rho'_h(t) \end{cases} \text{ at } t = t_0 \quad (12)$$

이를 다시 풀어쓰면,

$$\begin{cases} e^{-t_0/\tau} = c_0(t_0 + t_1)^{-\beta} \\ -\frac{1}{\tau} e^{-t_0/\tau} = c_0(-\beta)(t_0 + t_1)^{-(\beta+1)} \end{cases} \quad (13)$$

이 되고 이 연립방정식을 풀면,

$$t_0 = \beta\tau - t_1 \quad (14)$$

$$c_0 = (\tau\beta)^\beta e^{-(\beta-\tau)/\tau} \quad (15)$$

이 얻어진다. 여기서 c_0 와 t_0 는 모두 t_1 의 함수로 표현된다. 최종적으로 t_1 을 결정할 때 least square 매칭을 사용하여 실제 데이터의 ACF와 일치시킨다. 또한, 관계식 $f_T(t) = \mu_T \rho'(t)$ 과 $\int_0^\infty f_T(t) dt = 1$ 에서 부터, $\mu_T = \tau$ 임을 얻을 수 있다. 이렇게 해서 얻어진 T 의 누적확률분포 $F_T(\cdot)$ 는 다음과 같다.

$$F_T(t) = 1 + \mu_T \rho'(t) \quad (16)$$

$$= \begin{cases} 1 - e^{-t/\tau}, & \text{for } t < t_0, \\ 1 - \tau\beta c_0(t + t_1)^{-(\beta+1)}, & \text{for } t \geq t_0. \end{cases}$$

다음으로 S_i 의 이산화를 분포 $f_S(\cdot) = (f_S(0), f_S(1), \dots, f_S(M-1), f_S(M))$ 는 [9,12]등의 연구들에서 밝혀진 바에 의하여 negative binomial 분포를 가정하여 구한다.

즉,

$$f_S(i) = \binom{i+r}{i} p^r (-q)^i = \sum_{i=0,1,2,\dots,M-1} \binom{i+r-1}{i} p^r q^i, \quad (17)$$

$$f_S(M) = 1 - \sum_{i=0}^{M-1} f_S(i).$$

여기서 M 은 화면 당 최대 입력률 $\max(X(t))$ 을 나타낸다. negative binomial 분포는 평균과 분산 두 측정치에 의해 결정지어질 수 있는데, 평균, 분산과 negative binomial 분포의 매개변수와의 관계식은 $E[X(t)] = r(1-p)/p$ 과 $\text{Var}[X(t)] = r(1-p)/p^2$ 로 주어진다(단, $0 < p < 1, q = 1 - p, r > 0$). 따라서 매개변수는 다음 식(18)과 식(19)에 의해 얻을 수 있다.

$$p = E[X(t)] / \text{Var}[X(t)] \quad (18)$$

$$r = E[X(t)]^2 / (\text{Var}[X(t)] - E[X(t)]) \quad (19)$$

여기서 지금까지 설명한 변수추출방법을 요약하면 다음과 같다.

(A) F_T 에 대해

A.1. τ : 식(10) β : 식(11)

A.2. t_1 : least square 매칭

A.3. t_0 : (식14), c_0 : 식(15)

(B) f_S 에 대해

B.1. 실제 트래픽에서 평균, 분산, 최대치를 구한다.

B.2. p 식(18), r : 식(19).

2 변수 추출 예

Star Wars 트래픽을 대상으로 추출한 SLCC process의 변수는 다음과 같다. F_T 에 대하여 $\tau = 82.83$ frames, $\beta = 0.39$, $t_0 = 30.13$ frames, $t_1 = 3.0$ frames, 그리고 $c_0 = 2.82$ 을 얻었다. f_S 에 대해서는 $E[X(t)] = 578.9$ cells/frame,

$\sqrt{\text{Var}[X(t)]} = 130.2$, $M = 1,634$ cells를 얻었고, 따라서 매개변수로 $p = 0.0341$ 과 $r = 20.44 \sim 20.1$ 을 구해졌다. 또한, 이에 대응하는 C-DAR(1) 모델의 변수는 SLCC process와 같은 값을 사용하는 τ, p, r, M 을 사용한다.

그림 1은 이렇게 얻어진 변수에 의한 SLCC 모델이 거의 정확히 실제트래픽의 ACF를 모사하고 있음을 보여준다. 이 그림에서 곡선 (a), (b), (c), (d)는 각기 실제영상의 ACF, exponential 함수 (DAR(1) 모델에 의한 결과와 같음), hyperbolic 함수, 그리고 SLCC 모델에 의한 ACF를 보여 주고 있다. 여기서, DAR(1) 모델에 해당되는 exponential ACF은 약 30 frames에서부터 실제트래픽의 ACF와 큰 차이를 보여 주고 있다. 앞서 언급한 바와 같이 입력분포는 negative binomial분포에 의하여 충분히 정확히 모델되고 있다고 가정하면, SLCC 모델은 1차, 2차 통계 특성에서 실제트래픽과 정확히 일치한다.

IV. 대기 해석 결과

전송용량 C (cells/frame) 버퍼의 크기 K (cells)을 갖는 FIFO 서비스 대기체계를 생각한다. SL process의 유체입력으로 가정한다. 이 SL/D/1/K 대기체계에 대한 해석은 SL process^o] 상태가 변하

는 순간 t_n 에 시스템의 상태가 $[0, K]$ 에서 연속적인 값을 취하고, 각 상태에 머무는 시간이 일반적으로 exponential이 아니기 때문에 정확한 분석은 매우 어렵다. 제2부에서는 이러한 문제점을 해결하여, 근사치를 효과적으로 얻을 수 있는 방안을 제안하였다. 특히, 여기서 제시되는 결과는 오차율 1% 이내에 해당하도록 하였다.

실제트래픽을 이용한 실험에서는, 회기방정식 $L_{n+1} = \min(\max(L_n + X_n - C, 0), K)$ 을 사용하였는데, 데이터를 임의의 시점부터 시작하여 한 바퀴 회전할 때까지 발생시키는 것으로 하여, 171,000개의 데이터를 모두 사용하였다.

첫 번째 실험으로 한 개의 입력 원이 입력되는 경우에 입력부하(U)를 0.8(heavy load), 0.6(moderate load), 0.4(light load)로 변화시키면서 실험하였다. 단일 입력모델은 사용자 감시나, 부호화기 제어에 중요하게 사용될 수 있다. 그럼 3은 각 경우의 셀손실 확률을 정리하여 보여 주고 있다. 이 결과에서 버퍼의 크기가 작은 범위에서는 C-DAR(1) 모델과 SLCC 모델 모두 셀손실을 상당히 정확히 예측하고 있는 반면, $U = 0.8$ 과, 버퍼사이즈가 큰 경우에 있어서는 SLCC 모델은 계속해서 정확한 예측을 하지만, C-DAR(1)은 셀손실은 실제보다 작게 예측하고 있다.

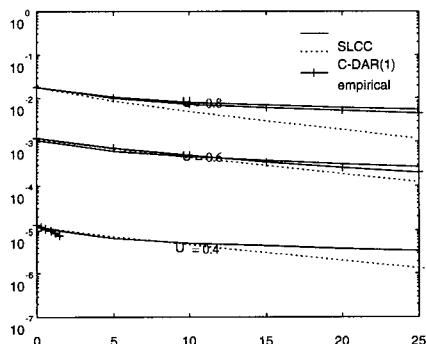


그림 3. 세 가지 종류(SLCC 모델, DAR(1) 모델, 실제 영상 데이터)의 단일 입력에 대한 셀 손실 확률

이러한 결과의 차이는 다음과 같이 설명될 수 있다. 일반적으로 대기체계는 일종의 기억시스템으로 볼 수 있다. 즉, busy period에 있어서, 앞선 시점에서 많은 양의 입력이 들어왔을 경우에는 대기체계 안에 많은 데이터가 저장되고, 적은 양이 들어왔을 때는 적은 양이 저장되어 있게 된다. 그러다가,

대기체계가 완전히 비게 되면 이전시점의 도착한 데이터 양에 대한 정보를 잊어버리게 된다. 이러한 현상을 ‘초기화 현상’(resetting events)라고 명명한다. 따라서, 보다 자주 초기화 현상이 일어나는 저부화 상태에서는 긴 시간 동안의 상관도는 대기체계에 영향을 거의 못 주게 되지만, 항상 대기체계가 차있는 고부하의 경우에는 먼 시간간격의 상관도가 대기체계에 상당한 영향을 줄 수 있다.

다음으로 다중화된 입력의 대기체계를 살펴본다. 동일한 입력의 다중화시, ACF은 변화하지 않는다. 단지, 입력분포만이 영향을 받게 된다. 따라서 SL 모델에서는 T_n 에 대한 변수는 단일입력의 경우와 동일하고, 단지 S_n 에 대한 분포만이 입력개수 N만큼의 convolution으로 구할 수 있다. 표 2는 트래픽 부하 $U = 0.8$ 인 경우에 다중화 입력의 수 $N = 5, 10$ 인 경우의 셀손실율을 나타낸다. 여기서 LRD에 의한 영향을 살펴보기 위해 표를 버퍼의 크기에 따라 1000 cells이하, 10,000 cells 이하, 그리고 100,000 cells이하의 3개의 스케일 영역으로 나누었다. 그 결과를 살펴보면, 다중화에 의한 완만화 현상으로 인하여 10,000 cells 이하의 범위에서 SLCC 모델과 실제 트래픽에서의 LRD의 영향을 크게 찾아보기는 힘들다. 반면, 10,000 cells 이상의 범위에서, 앞서 단일입력의 경우에서와 마찬가지로 SLCC 모델과 DAR(1) 모델에 있어서 셀손실 확률이 크게 차이나고 있음을 알 수 있다.

표. 2. 다중화된 입력에 대한 셀손실확률: 다중화 입력 수 $N = 5, 10$, 부하도 $U = 0.8$)

큐 크기 (cells)	5개 다중화 입력의 셀 손실율		
	실제 영상	SLCC	C-DAR
200	2.7E-3	3.4E-3	3.4E-3
400	7.6E-4	8.3E-4	8.3E-4
600	5.2E-4	5.2E-4	5.2E-4
800	4.1E-4	5.2E-4	5.1E-4
1000	3.7E-4	5.0E-4	5.0E-4
2000	2.9E-4	4.6E-4	4.6E-4
4000	2.7E-4	4.0E-4	3.9E-4
6000	1.6E-4	3.6E-4	3.4E-4
8000	1.1E-4	3.3E-4	2.9E-4
10000	9.4E-4	3.0E-4	2.6E-4
20000	7.8E-5	2.4E-4	1.5E-4
40000	5.6E-5	1.8E-4	6.4E-5
60000	0	1.5E-4	3.0E-5
80000	0	1.3E-4	1.6E-5
100000	0	1.2E-4	8.9E-6

큐 크기 (cells)	10개 디중화 입력의 셀 손실율		
	실제 영상	SLCC	C-DAR
200	2.6E-3	3.1E-3	3.1E-3
400	5.8E-4	6.1E-4	6.1E-4
600	6.4E-5	7.1E-5	7.1E-5
800	2.1E-5	3.0E-5	3.0E-5
1000	1.6E-5	2.0E-5	2.0E-5
2000	1.3E-5	1.9E-5	1.8E-5
4000	1.0E-5	1.6E-5	1.6E-5
6000	0	1.5E-5	1.4E-5
8000	0	1.3E-5	1.2E-5
10000	0	1.2E-5	1.1E-5
20000	0	1.0E-5	6.8E-6
40000	0	7.6E-5	3.0E-6
60000	0	6.5E-6	1.5E-6
80000	0	5.8E-6	8.3E-7
100000	0	5.3E-6	4.7E-7

이 실험결과들을 통하여 얻을 수 있는 결론은 다음과 같다. 우선 SLCC 모델은 대기체계의 셀손실 측면에서 정확하고 일관성 있는 예측을 하고 있다. 따라서 트래픽의 1차, 2차 통계특성은 대기체계 예측에 있어서 우선적으로 고려되어야 할 변수라고 볼 수 있다. 또한, C-DAR(1) 모델이 영상트래픽의 LRD를 반영하고 있지 못하지만, 가벼운 부하나 적당한 부하상의 작은 버퍼크기에서는 LRD를 고려한 SLCC와 차이가 없는, 정확한 셀손실을 예측할 수 있다. 이는 앞서의 설명에서처럼 초기화 현상이 빈번하게 나타내게 되기 때문이다.

V. 결 론

본 연구에서는 영상의 LRD 특성이 대기체계에 미치는 영향에 대하여 분석하였다. 시험결과, 실제 영상트래픽이 ACF이 exponential과 hyperbolic의 두 함수의 결합으로 잘 모델되는 것을 보였고, 이 사실을 이용하여 SLCC 모델을 제안하였다. 또한, 동일한 rate-distribution과 SRD을 갖으면서 LRD의 유무만이 차이가나는 두 모델을 입력(DAR(1)과 SLCC)으로 사용함으로써, LRD가 대기체계에 미치는 영향을 분석할 수 있었다. 구체적으로 C-DAR(1) 모델은 많은 경우에서 정확히 셀손실을 예측하는 반면, 큰 버퍼와 높은 부하에서 셀손실을较大 예측하는 것을 발견하였다. 반면, SLCC 모델은 모든 범위에서 상당히 정확히 셀손실을 예측하였다. 이 결과는 “초기화 현상”에 기초하여 설명할 수 있

었다. 이는 큰 버퍼와 높은 부하의 경우에 있어 초기화 현상이 적게 나타나고, 따라서 시간적으로 먼 위치의 트래픽에 영향을 보다 많이 받기 때문이라고 해석되어진다. 따라서, 트래픽제어 및 자원 할당 등을 할 경우, 크지 않은 버퍼와 낮은 부하상태에서는 DAR(1)과 같은 Markov 모델을 사용할 수 있으나, 그렇지 않은 경우에는 영상의 LRD 을 고려하는 SLCC과 같은 모델을 사용하여야 한다.

참 고 문 헌

- [1] H. Ahn, B. Kim, B. D. Choi, J.-K. Kim, “A self-similar traffic model for VBR video sources and its queueing analysis,” in *Proc. of APCC/ICCS’98*, Singapore, November, 1998.
- [2] J. Beran, *Statistics for Long-Memory Processes*, Chapman-Hall, Albany, NY, 1994.
- [3] A. Elwalid, D. Heyman, T. V. Lakshman, D. Mitra, A. Wiess, “Fundamental bounds and approximations for ATM multiplexor with applications to video teleconferencing,” *IEEE J. Select. Areas Commun.*, . 13(6), pp. 1004-1016, Aug. 1995.
- [4] A. Erramilli, O. Narayan, W. Willinger, “Experimental Queueing Analysis with Long-Range Dependent Packet Traffic,” *IEEE/ACM Trans. Networking.*, 4(2) pp. 209-223 Apr. 1996.
- [5] M. W. Garrett W. Willinger, “Analysis, modeling and generation of self-similar VBR video traffic,” in *Proc. ACM SIGCOM’94*, London, England, Aug. 1994, pp. 269-280.
- [6] M. Grasse, M. R. Frater, J. F. Arnold, “Origins of long-range dependence in variable bit rate video traffic,” in *Proc. ITC-15*, Washington DC, USA, 23- 27, June, 1997, pp. 1379-1388.
- [7] B. Hajek L. He, “On variations of queue responses for inputs with identical means and autocorrelation functions,” in *Proc. CISS’96*, Princeton University, Princeton, NJ, Mar. 1996, pp. 1195-1201.
- [8] D. P. Heyman A. Tabatabai, and T. V. Lakshman, “Statistical analysis and simulation study of video teleconferencing traffic in ATM networks,” *IEEE Trans. Circuits Syst. Video*

- Technol., 2(1), pp. 49-59 Mar. 1992.
- [9] D. P. Heyman, T. V. Lakshman, "What are the implications of long-range dependence for VBR video traffic engineering?", *IEEE/ACM Trans. Networking*, 4(3), pp. 301-317 June 1996.
- [10] P. R. Jelenkovic, A. A. Lazar, and N. Semret, "The effect of multiple time scales and subexponentiality in MPEG video streams on the queueing behavior," *IEEE J. Select. Areas Commun.*, 15(6), pp. 1052-1071 Aug. 1997.
- [11] B. Mandelbrot, "Some noise with 1/f spectrum: a bridge between direct current and white noise," *IEEE Trans. Information Theory*, 13(2) pp. 289-298 Apr. 1967.
- [12] I. Norros, "On the use of fractional Brownian motion in the theory of connectionless networks," *IEEE J. on Select. Areas in Commun.*, 13(6) pp. 953 -962 Aug. 1995.
- [13] J. W. Roberts, U. Mocci, J. Virtamo Ed., *Broadband network teletraffic: Final Report of Action COST 242*, Springer, 1996.
- [14] S. Xu, Z. Huang, Y. Yao, "A theoretic analysis model for VBR video traffic in ATM networks," in Proc. ICC'97 Montreal, Canada, May, 1997, pp. 844-848.

김재균(Jae-kyoon Kim) 종신회원
1962년 2월 : 한국항공대학교 응용전자과(공학사)
1967년 2월 : 서울대학교 전자과(공학석사)
1971년 8월 : 미국 남가주대학 전자과(공학 박사)
1972년 4월~1973년 3월: 미 우주과학연구소 연구원
1973년 9월~현재 : 한국과학기술원 전기및전자과 교수
1993년~현재 : 한국과학기술원 멀티미디어통신 공동
연구센터장
<주관심 분야> 영상통신, 영상신호처리, 정보이론

안희준(Heejune Ahn) 정회원
1993년 2월 : 한국과학기술원 전기및전자과(공학사)
1995년 2월 : 한국과학기술원 전기및전자과(공학석사)
2000년 2월 : 한국 과학기술원 전기및전자과(공학박사)
1996년 4월~현재: LGIC 중앙연구소 연구원
1999년 8월~2000년 2월 : 독일 Erlangen-Nuremberg
대학 Telecommunication 연구소 초빙
연구원
<주관심 분야> 멀티미디어 통신

강상혁(Sang H. Kang) 정회원
1990년 2월 : 한국과학기술원 전기및전자과(공학사)
1992년 2월 : 한국과학기술원 전기및전자과(공학석사)
1997년 8월 : 한국과학기술원 전기및전자과(공학 박사)
1997년 9월~현재 : 서울시립대 조교수
<주관심 분야> 트래픽 제어