

프레임간 상관관계를 고려한 장면기반 MPEG 비디오 트래픽 모델링

정회원 유상조*, 김성대*, 최재각**

Scene Based MPEG Video Traffic Modeling Considering the Correlations between Frames

Sang-Jo Yoo*, Seong-Dae Kim*, Jae Gark Choi** *Regular Members*

요약

본 논문에서는 현재 비디오 응용에서 영상압축 기법으로 가장 널리 사용되고 있는 MPEG 압축 기술을 이용한 비디오 트래픽에 대한 새로운 모델링(modeling) 방법을 제안한다. 본 논문에서의 모델링 방법은 장면(scene) 기반의 트래픽 특성을 이용하여 각 GOP(Group Of Pictures)내의 I, P, B 프레임간 상관관계를 고려한다. 간단한 GOP 단위 장면전환 검출을 통해 장면전환 확률의 상태천이(state transition) 모델을 세우고 각 상태에서 머무는 GOP 길이를 기하분포로 모델링 한다. 각 장면 상태에서의 비디오 프레임은 해당 상태에서의 평균 I, B, P 프레임의 크기를 고려하여 모델링 된다. 또한 보다 정확한 트래픽 모델링을 위해 상태변환 모델이 갖고 있는 이산적인 상태 양자화 오류율 AR(Autoregressive) 모델을 이용하여 보상한다. 자기상관함수, 히스토그램, 제한된 길이를 갖는 ATM 멀티플렉서에서의 셀순실 확률 추정 등의 성능분석을 통해 제안된 모델링 방법이 원 영상의 통계적 특성을 잘 모델링 한다는 것을 보였다. 또한 제안된 모델링 방법은 장면기반 모델을 사용하여, 원하고자 하는 레벨(장면, GOP, 프레임, 셀)간의 자동적인 translation이 가능하고 각 레벨별로 정확한 원 영상의 트래픽 특성의 추정이 가능하다.

ABSTRACT

For the performance analysis and traffic control of ATM networks carrying video sequences, we need an appropriate video traffic model. In this paper, we propose a new traffic model for MPEG compressed videos which are widely used for any type of video applications at the moment. The proposed modeling scheme uses scene-based traffic characteristics and considers the correlation between frames of consecutive GOPs. Using a simple scene detection algorithm, scene changes are modeled by state transitions and the number of GOPs of a scene state is modeled by a geometric distribution. Frames of a scene state are modeled by mean I, P, and B frame size. For more accurate traffic modeling, quantization errors (residual bits) that the state transition model using mean values has are compensated by autoregressive processes. We show that our model very well captures the traffic characteristics of the original videos by performance analysis in terms of autocorrelation, histogram of frame bits generated by the model, and cell loss rate in the ATM multiplexer with limited buffers. Our model is able to perform translations between levels (i.e., scene, GOP, frame, and cell levels) and to estimate very accurately the stochastic characteristics of the original videos by each level.

*한국과학기술원 전기 및 전자공학과

**경일대학교 전임강사

論文番號:98043-0203

接受日字:1998년 2월 3일

I. 서 론

ATM을 기반으로 한 초고속 통신망의 출현으로 음성, 영상 및 데이터의 실시간 전송이 가능해 지면서 주문형 비디오(VoD), 원격강의, 흡 쇼핑과 같은 다양한 멀티미디어 서비스의 개발 및 사용이 활발히 진행되고 있다. ATM에서는 각기 다른 전송속도와 서비스 품질 요구사항(QoS : Quality of Service)을 갖는 음성, 데이터 및 영상정보 등, 다양한 트래픽이 동일한 망자원을 이용하면서 셀(cell)이라는 전송단위로 묶이어 함께 전송되게 된다. 망에서는 이러한 다양한 전송속도와 QoS, 복잡한 트래픽 특성을 갖는 서비스에 대해 사용자의 종단대 종단 서비스 품질을 만족시키면서 망자원을 효율적으로 사용하기 위한 연구가 필요한데, 실제적인 서비스 구현에는 아직도 해결해야 할 문제가 많이 있다.

ATM 망에서 멀티미디어 서비스를 제공하기 위해서는 비디오 서비스에 대한 연구가 매우 중요하다. 왜냐하면 비디오 서비스는 많은 통신자원을 요구하고, 멀티미디어 서비스에서 가장 핵심적인 트래픽이기 때문이다. 실제 ATM 망에서 통계적 다중화의 이득을 극대화하고 사용자가 요구하는 QoS를 보장하기 위해서는 효과적인 대역폭 할당과 트래픽 제어가 수반되어야 한다. 이러한 기능을 수행하기 위해서는 먼저 복잡한 특성을 갖는 비디오 트래픽에 대한 정확한 통계적 모델링이 필요하다. 트래픽의 모델링은 망자원 분배의 효율적 설계, 셀 손실 확률 예측, 혼잡제어, 트래픽 파라미터 결정, 종단 단말의 흐름제어(flow control)를 위한 맨 처음의 단계로, 복잡한 특성의 트래픽을 몇 가지 통계적 파라미터로 모델화 하는 것이다.

본 논문에서는 현재 비디오 응용에서 영상압축 기법으로 가장 널리 사용되고 있는 MPEG 압축 비디오 트래픽에 대한 새로운 모델링 방법을 제안한다. 본 논문에서의 모델링 방법은 장면(scene) 기반의 비디오 트래픽 특성을 이용하여 각 GOP(Group of Pictures)내의 I, P, B 프레임 간 상관관계

(correlation)를 고려한다. 간단한 GOP 단위 장면전환 검출을 통해 장면전환 확률의 상태천이(state transition) 모델을 세우고 각 상태에서 머드는 GOP 수를 기하분포로 모델링 한다. 각 장면 상태에서의 비디오 프레임은 해당 상태에서의 평균 I, B, P 프레임의 크기를 고려하여 모델링 된다. 또한 보다 정확한 트래픽 모델링을 위해 상태변환 모델이 갖고 있는 이산적인 상태 양자화 오류를 AR(Autoregressive) 모델을 이용하여 보상한다.

본 논문의 구성은 다음과 같다. 제 2장에서는 MPEG 비디오 트래픽의 특성을 알아보고 기존의 비디오 트래픽 모델링에 관한 연구현황을 살펴본다. 제 3장에서는 제안하는 MPEG 비디오 트래픽 모델링 방법을 설명하고 모델링의 타당성을 분석한다. 제 4장에서는 제안된 모델링 방법이 실제 트래픽을 얼마나 잘 표현하는지를 모의실험을 통하여 검증하고 망에서의 큐잉성능을 포함한 여러 가지 검증 파라미터에 대해 기존의 다른 제안 모델과 비교분석을 수행한다. 제 5장에서는 제안된 장면 기반 모델링 방식을 이용한 레벨 translation에 대해 살펴보고, 마지막으로 제 6장에서 본 논문의 결론을 맺는다.

II. MPEG 비디오 트래픽 특성 및 기존 트래픽 모델링 연구

MPEG 압축기법은 현재 ATM을 비롯한 통신망의 발전과 저장 미디어의 개발로 여러 비디오 응용에서 널리 사용되고 있다. 표준화가 완료되어 현재 사용되고 있는 MPEG 표준으로는 MPEG-I과 MPEG-II가 있는데, MPEG-I은 MPEG-II의 부분집합으로 기본구조는 같으며 중요 차이점은 MPEG-II에서의 계층적 구조를 들 수 있다. 본 논문에서는 MPEG-I, II의 단일계층 구조를 갖는 압축된 비디오 스트림에 대한 모델링에 대해 다룬다.

MPEG 비디오 트래픽은 주기적인 GOP 패턴을 갖는데, GOP 패턴은 연속하는 두 I 프레임 사이의 수 N, I 프레임과 다음의 P 프레임 또는 연속하는 P

프레임 사이의 프레임 수 M으로 정의 할 수 있다. 일반적으로 전체 영상 스트림에서 N과 M은 고정적으로 사용된다.

MPEG 비디오 데이터는 트래픽 발생의 통계적 복잡성으로 모델링하기가 어렵다. 그 이유로는 비디오의 내용에 따라 통계적 특성이 다르고, GOP 패턴에 따라 I, P, B 프레임이 주기적으로 나타나는 특성을 보이고, 프레임간에 상관관계가 존재하기 때문이다. 그림 1은 N=12, M=3인 “스타워즈(Starwars)” 영화영상을 ‘10(I), 14(P), 18(B)’ 양자화 스케일로 MPEG 부호화한 스트림으로 매우 복잡한 트래픽 형태를 가진다. 그림 2에서 알 수 있듯이 GOP 패턴이 결정되면 한 GOP 내에서 I, P, B 프레임들이 규칙적으로 나타난다. 일반적으로 I 프레임의 비트량이 제일 많고 그 다음에 P 프레임, B 프레임의 순이다.

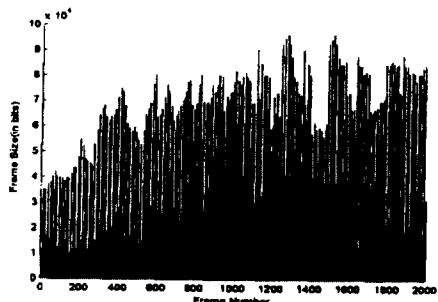


그림1.“스타워즈”프레임시퀀스

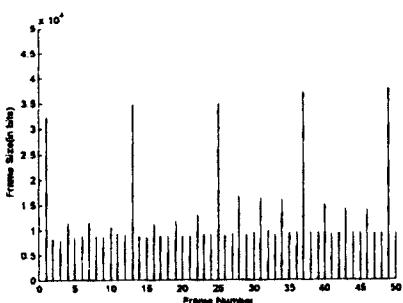
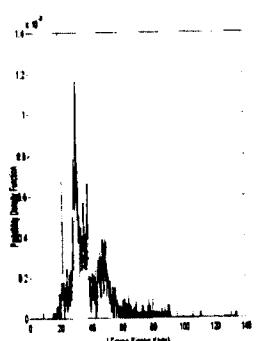
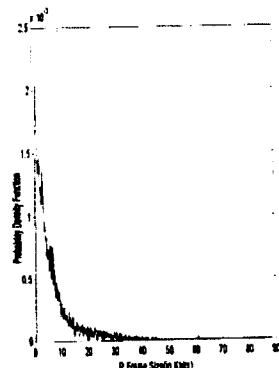


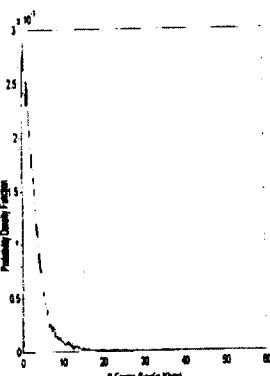
그림2. GOP 패턴에 따른 프레임 시퀀스



(a) I 프레임



(b) P 프레임



(c) B 프레임

그림 3. “스타워즈” MPEG 압축 영상의 비트 발생량 히스토그램

그림 3은 MPEG 비디오 스트림("스타워즈")에 대한 I, P, B 프레임별 비트 발생 히스토그램으로 I, P, B 프레임 종류별로 서로 다른 분포를 갖는다는 것을 알 수 있다. 일반적으로 뒤에 언급할 기준의 모델링 방법 중 히스토그램 기반의 모델링에서는 I, P, B 프레임의 비트 발생을 감마 함수(gamma function)나 로그노말 함수(lognormal function)로 모델링 한다.

비디오 트래픽 모델링에서 가장 중요한 통계적 성질은 영상의 자기상관함수(autocorrelation function)이다. 자기상관함수의 특성은 트래픽의 시간단위 상관관계를 의미하여 망에서의 큐잉 특성을 결정짓는 중요한 변수이다. MPEG 비디오 스트림의 자기상관함수는 압축 패턴(I, P, B)의 GOP단위 주기성과 각 프레임 타입별 평균 비트량의 차이로 인해 그림 4 및 그림5의 형태가 된다.

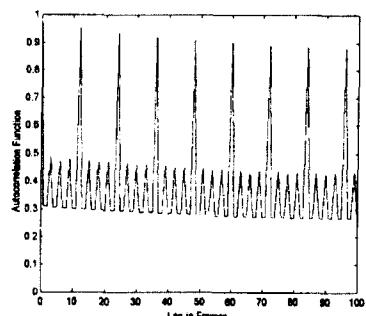


그림 4. GOP 패턴에 따른 자기상관함수

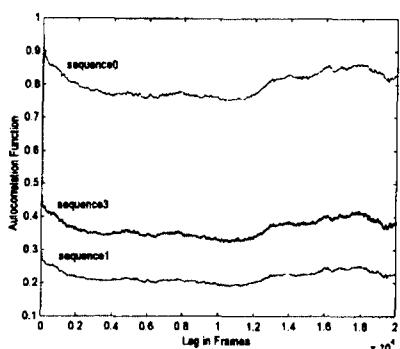


그림 5. 긴 샘플구간의 자기상관함수 특성

그림 4에서 볼 수 있듯이 작은 샘플 구간에서의 상관관계(short-term correlation)은 주로 GOP 패턴(N, M)에 의해 주기적인 특성을 갖는다. 이는 MPEG 압축 비디오 스트림의 경우 GOP 패턴을 고려한 모델링이 필요하다는 것을 의미한다. 그림 5는 MPEG 비디오 스트림이 긴 샘플 구간동안 프레임간 비트 발생량의 상관관계(long-term correlation)가 존재함(long range dependency)을 보여주는데, 이는 비디오 트래픽을 수학적으로 모델링하기 어렵게 하는 요소가 된다. 그림 5에서 'sequence0'은 그림 4의 자기상관함수에서 {0,12,24,...} 샘플의 자기상관함수의 궤적이고 'sequence1'은 {1,2,4,5,7,8,10,11,13,14,...}, 'sequence3'은 {3,6,9,12,15,...} 샘플 시퀀스의 자기상관함수 궤적이다. 그림 5에서 알 수 있듯이 초기 수십 프레임 정도는 지수함수(exponential function)적으로 자기상관함수가 감소하나 그 이후는 지수함수의 특성을 갖지 않는다.

비디오 트래픽 모델링에 대하여 많은 모델들이 제안되었다. 대부분의 비디오 트래픽 모델은 다음과 같은 세가지 형태로 구분될 수 있다.

- 확률 상태전이(probability state transition) 행렬을 이용한 마르코프(Markov) 체인 모델 [1][2][3][4]
- AR(Autoregressive) 프로세스 모델 [1][5][6][7][8][9]
- 프레임 비트발생량의 히스토그램에 근거한 모델[3][10][11]

마르코프 체인 형태의 모델로는 Maglaris[1]가 영상회의와 같이 영상 트래픽의 변이(variation)가 심하지 않은 경우(single activity level)에 대해 마르코프 체인모델을 제안하였다. 이 모델은 Sen[2]에 의해 여러 activity 레벨을 갖는 비디오 트래픽으로 확장되었다. 마르코프 체인 기반의 비디오 트래픽 모델링은 마르코프체인에 대한 큐잉 성능 등에 관한 많은 수학적 해석이 이미 이루어 졌고 또 가능하기 때

문에 해석적인 장점을 가지고 있으나, 모델에서 발생된 트래픽의 자기상관함수가 실제 트래픽과는 달리 지수함수 적으로 감소한다는 단점이 있다.

AR 프로세스 기반의 모델링은 Maglaris[1]과 Nomura[5]에 의해 비디오 트래픽의 시뮬레이션을 위해 처음 제안되었는데, 비디오 트래픽의 자기상관함수를 비교적 잘 표현할 수 있다는 장점으로 여러 모델들이 계속해서 제안되었다. Cortef[6]은 1차 AR 모델로는 긴 주기의 자기상관 함수를 잘 모델링 할 수 없기 때문에 서로 다른 2개의 1차 AR 프로세스를 중합 시킨 AR12 모델을 제안하였다. Ramamurthy[7]은 역시 긴 주기 자기상관 함수를 맞추기 위해 2개의 1차 AR 모델을 중합 시키고 장면 전환 등으로 갑작스러운 비트율 변화를 수용하기 위해 마르코프 체인 형태의 잡음 프로세스를 추가하였다. Yegenoglu[8]은 activity 레벨 변화에 따라 AR 모델도 해당 레벨의 파라미터 값으로 다시 모델링 되는 구조를 제안하였다. 또한 AR 모델에서 생성된 프레임 단위 비트 발생량의 히스토그램은 원래 영상의 히스토그램에 대해 마르코프 모델보다 오차가 심하므로, Wu[9]는 모델 영상의 히스토그램을 원래 영상의 히스토그램 누적분포함수(cumulative distribution function)에 투영(projection)시키는 방법인 PAR(Projected AR) 모델을 제안하였다. AR 모델은 기본적으로 자기상관함수를 비교적 잘 맞추나 모델 영상의 히스토그램 분포가 원래 영상의 히스토그램과 차이가 있고, 아주 큰 비트량을 갖는 프레임은 발생시키지 못하는 경우가 있으며 수학적 해석이 어렵다는 단점이 있다.

비트발생량의 히스토그램을 이용한 모델은 원래 영상으로부터 프레임별 비트발생량에 대한 확률밀도함수(probability density function)를 구하여 이것으로부터 모델 영상의 프레임별 비트를 발생시키는 방법으로 모델링 자체가 쉽다는 장점이 있다. Skelly[10]는 비디오트래픽의 큐잉 해석을 쉽게 하기 위해 히스토그램을 이용하여 M/D/I/N 마르코프 모델 해석에 적용하였다. 프레임의 비트발생량의

확률밀도함수는 정규분포, 감마(gamma)[3], 로그노말(lognormal)[11] 함수 등으로 모델링 된다. 그러나 히스토그램을 이용한 모델링은 프레임간 상관관계를 정확히 모델링 하지 못한다.

기존의 대부분의 비디오 트래픽 모델링 방법들은 MPEG 압축 비디오 스트림에 그대로 적용할 수 없는데, 그 이유는 이전의 연구들은 주로 한가지 압축모드(인터 프레임, 인트라 프레임 압축방법 등)를 이용하여 생성된 압축영상에 대한 모델링이었기 때문이다. MPEG은 앞에서 설명한 바와 같이 I, P, B의 압축모드로 구성되고 GOP패턴으로 주기성을 갖는 구조이므로 MPEG 비디오 스트림을 위한 별도의 모델링 방법이 필요하다. MPEG 압축방법을 고려한 제안들로는 히스토그램을 이용한 Krantz[11]모델, self-similar 모델을 사용한 Huang[12] 모델 등 여러가지 방안이 제시되었으나 기존의 단일 모드 압축방식에 사용되었던 방법들을 I 프레임, P 프레임, B 프레임 시퀀스에 독립적으로 적용하는 형식에서 크게 벗어나지 못하였다.

최근 MPEG 비디오 스트림에서 비트 발생량에 기반한 장면(scene) 검출 후 이를 이용한 모델링 방법이 제안되었다. Rose[13]는 GOP의 평균 비트 발생량의 변이에 기초하여 장면을 검출하고 GOP단위의 비트 발생량에 대한 이산 마르코프 체인(DTMC)을 구성하였다. 이 방법은 기존의 프레임별 비트 발생량 개념의 상태 천이 방식을 장면기반 모델링에 적용한 것으로, GOP 단위의 모델 비트량이 결정되면 프레임 레벨의 비트발생은 전체 영상에서 I, P, B 프레임의 평균 비트 발생비를 이용하여 프레임 단위의 비트량을 얻었다. Krantz[14]는 P, B 프레임에 대해서는 기존 히스토그램 방식을 이용하여 비트량을 모델링하고, I프레임 비트 발생량을 보다 정확히 모델링 하기 위해 GOP의 맨 처음 I 프레임의 비트발생량의 크기 비교를 통해 장면을 검출하고, 장면의 평균 I 프레임 비트량을 히스토그램 방식으로 모델링하고 실제 영상과 평균 I 프레임 발생 비트량과의 차이, 즉 잔여 비트(residual bits)

는 AR2 프로세스를 이용하여 모델링 하였다. 이러한 장면기반 MPEG 비디오 모델링의 장점은 한 가지 모델을 사용하여 장면단위, GOP 단위, 프레임 단위의 비트 발생량을 모두 모델링 할 수 있다는 것이다.

MPEG 압축기법을 이용한 비디오 스트림에서 프레임간 비트 발생량의 상관관계는 다음과 같이 세가지로 구분될 수 있다.

- n 번째 GOP 프레임들과 $n+1$ 번째 GOP 프레임들 간의 상관관계
- GOP내의 서로 다른 타입의 I, P, B 프레임들 간의 상관관계
- 특정 GOP 패턴의 N, M 주기에 따른 프레임간 시퀀스에 따른 상관관계

본 논문에서는 간단한 GOP 단위의 장면검출을 통한 상태천이 모델로 장면 및 GOP 단위의 비디오 트래픽 상관관계를 모델링하고 각 장면상태에서의 I, P, B 프레임간 GOP내 상관관계를 고려하여 프레임 단위 트래픽을 보다 정확하게 모델링하는 방안을 제안한다.

III. 제안된 MPEG 비디오 트래픽 모델링

3.1 장면 및 GOP 레벨 모델링

그림 1과 같이 MPEG 압축된 비디오 스트림은 시간 축 상에서 비트 발생량의 변화(fluctuation)가 계속적으로 일어난다. 전체적인 비트 발생량의 변화점을 장면이라고 정의하고 이를 비디오 트래픽 모델링에 사용한다. 여기에서 중요한 점은 실제 영상에서 눈으로 보는 장면전환과 트래픽 모델링에서의 장면전환이 같을 필요가 없다는 것이다. 트래픽 모델링에서의 장면전환은 망자원의 효과적 분

배 및 사용등에 트래픽의 통계적 특성을 이용하기 위해 사용되기 때문에 실제 시각적인 장면 전환보다는 비트량의 통계적 변화가 더 중요하기 때문이다. 본 논문에서는 전체 MPEG 비디오 스트림에서 장면을 검출하기 위해 식 (1)에서와 같이 GOP 단위 평균 비트 발생량의 차이에 대한 비교를 이용하였다. 식 (1)에서 $\{GOP(n):n=1,2,\dots\}$ 은 원 영상의 GOP 단위 비트 발생량이라고 정의하고, 만약 n 번째 GOP가 i 번째 장면의 시작 GOP일 때 다음조건을 만족하는 $n+k$ 번째 GOP가 i 번째 장면의 마지막 GOP가 되고 $n+k+1$ 번째 GOP는 다음 $i+1$ 번째 장면의 시작 GOP가 된다. 식 (1)에서 두 번째 식은 GOP의 비트를 변화가 연속적으로 일어나는 경우를 장면으로 검출하기 위해 사용되었다. 임계 값(threshold) T_1, T_2 는 비디오의 특성에 따라 적절히 선택되어 진다.

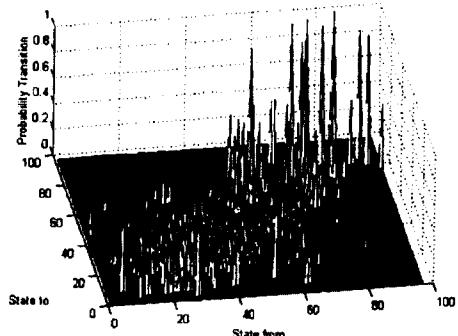
$$\frac{|GOP(n+k+1) - GOP(n+k)|}{\sum_{j=n}^{n+k} GOP(j)/(k+1)} \geq T_1 \quad (1)$$

$$\text{and}, \frac{|GOP(n+k+2) - GOP(n+k)|}{\sum_{j=n}^{n+k} GOP(j)/(k+1)} \geq T_2$$

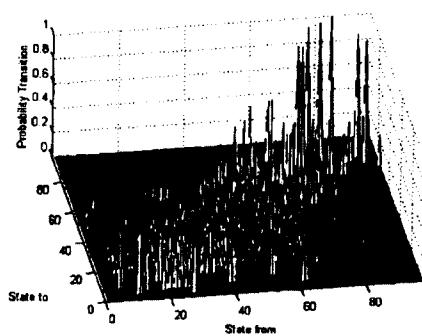
장면검출 후 장면단위 GOP 비트 발생량을 어떻게 모델링 하는 것이 실제 통계적 특성을 잘 반영하는 것인가를 결정하기 위해 두 가지 가능한 방법을 상호 비교하였다. 하나는 장면의 평균 GOP 비트 발생량을 일반적인 상태천이(state transition) 모델로 모델링하는 것이고 다른 하나는 [14]에서 사용된 것과 같이 히스토그램 방식으로 모델링하여 한 장면길이 동안 GOP 프레임의 발생비트를 평균 GOP 비트 발생량 확률밀도함수로부터 생성시키는 것

1 본 논문에서 사용한 장면 검출은 Krunz[13]에서 사용된 방식을 GOP단위 비트량 변화 검출을 위해 약간 다른 접근 방법으로 변환하여 적용하였다.

이다. 그림 6은 “스타워즈” 영상과 “양들의 침묵” 영상을 장면의 평균 GOP 발생량을 기준으로 약 100개의 상태로 구분하고, 한 장면에서 다른 장면으로 바뀌는 확률천이 상황을 3차원으로 도시한 것이다. X축은 현재 장면의 평균 GOP 비트량 상태이고 Y축은 다음 장면의 상태, Z축은 임의의 x에서 y로의 천이 확률(transition probability)을 의미한다.



(a) “스타워즈”



(b) “양들의 침묵”

그림 6. 상태천이 도표

그림 6의 결과를 해석하면 비록 장면 변화가 시각적으로는 임의의 장면에서 다음 장면으로 예측할 수 없이 바뀌지만 비트 발생량의 통계적으로는 장면 변화가 현재의 비트 발생량 상태 근처의 상태로 바뀐다는 것이다 - 이는 ($x=0, y=0$)에서 ($x=100, y=100$)으로 대각선 행태의 확률천이 모형을 보이는 점에서 확인할 수 있다. 이것은 긴 시간 주기에서 관측하면, 장면 변화에 따른 비트율

변화도 대략적인 연속성을 유지하는 확률천이의 패턴을 갖고 있는 것을 의미한다. 만약 히스토그램 방식으로 비디오 영상을 모델링할 경우 모델영상의 상태천이는 현재상태에 관계없이 다음상태가 임의의 분포로 결정되므로 실제 영상에서 얻어진 그림 6의 형태와는 다른 것을 알 수 있다. 이는 히스토그램 기반의 모델링이 장면변화의 패턴 또는 상관관계를 적절히 표현하지 못하는 것을 나타낸다.

위 결과를 기초로 본 논문에서는 장면 전환 모델로 상태천이 방식을 사용한다. 한 장면의 GOP 평균 비트발생 상태에서 다음 장면의 GOP 평균 비트발생 상태로 천이하는 상태천이 체인을 구성한다. 이제 한 장면상태에서 얼마만큼의 GOP 수 동안 머무는가를 모델링 한다. “스타워즈” 비디오 스트림으로부터 실험적으로 얻은 임의 장면 상태의 체류 GOP 수를 그림 7에 도시하였다. 그림 7에서 알 수 있듯이 한 상태에서 머무는 체류시간(sojourn time) 분포는 다음 식 (2)와 같은 기하분포(geometric distribution)로 잘 모델링 된다.

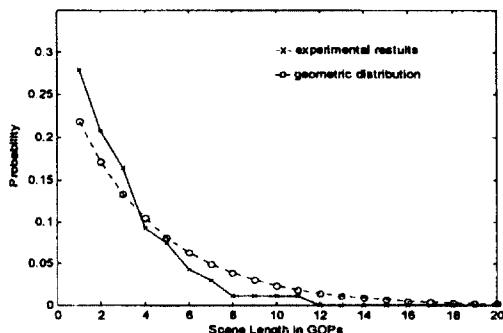


그림 7. 장면 길이(scene length) 분포

기하분포에서 N_i 를 i 번째 장면의 GOP수라고 할 때, N_i 가 k 일 확률은 다음식과 같다.

$$P\{N_i = k\} = q^{k-1} p, \text{ for } k = 1, 2, 3, \dots \quad (2)$$

$$p = 1 - q$$

기하분포에서 $E[N_i] = 1/p$ 이므로, 제안된 장면기반 상태천이 모델에서 평균 장면길이만 알고 있으면 모델로부터 기하분포를 이용하여 모델 영상의 장면길이를 생성할 수 있다. 또 하나의 실험으로, 장면길이의 평균값이 모든 상태에서 동일한 특성을 보이는가를 실험하였다. 만약 장면길이의 평균값이 각 상태마다 다른 특성을 보인다면 이는 각 상태마다 다른 $E[N_i] = 1/p$ 을 갖는 기하분포로 장면길이를 모델링 하여야 원 영상을 올바르게 표현할 수 있게 된다.

그림 8에서 알 수 있듯이 각 장면 상태에서의 평균 GOP 수는 모든 영상에 대해 일반적인 분포를 보이지는 않지만 각 상태마다 상당히 다른 값을 갖는다는 것을 알 수 있다. 따라서 모델 영상이 임의의 상태에서 머무는 시간(GOP 수)은 각 상태에 따라 각각의 평균 장면 체류시간에 의해 기하분포를 갖도록 하여야 보다 정확한 모델링이 가능하다.

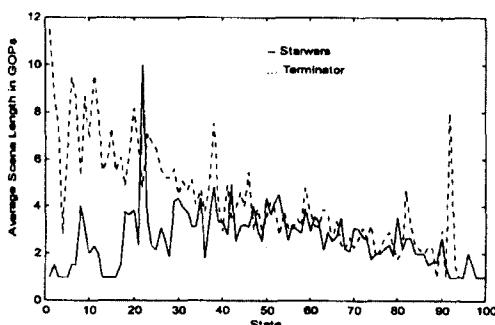


그림 8. 각 상태별 장면 당 평균 GOP수

장면모델을 위해 세운 상태 천이 모델은 다음 그림 9와 같이 구성된다. P_{ij} 는 장면 상태 i 에서 장면 상태 j 로 천이할 확률을 의미한다. 각 상태는 장면의 GOP 평균 발생 비트량, 상태에서의 평균 GOP 수(이는 나중에 기하분포를 이용해 모델영상의 해

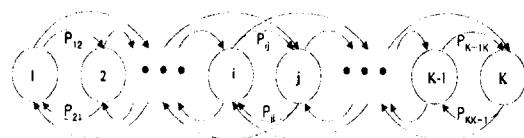


그림 9. 장면전환 상태모델

당 상태에서 연속되는 GOP 수를 결정하기 위해 사용된다.)를 파라미터로 갖는다.

3.2 장면내 프레임 레벨 모델링

그림 9의 장면전환 상태모델에서 장면내 I, P, B 프레임들의 비트 발생량을 모델링 하기 위하여 다음 표 1과 같이 각 상태에 몇 가지 파라미터를 정의하고 원 영상 스트림으로부터 해당 파라미터 값을 얻는다.

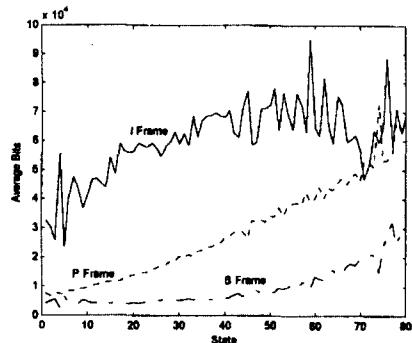
표 1. 각 상태에서의 파라미터

$M_{GOP}[i]$	장면 상태 i 의 평균 GOP 단위 비트 발생량
$M_{length}[i]$	장면 상태 i 의 평균 GOP 수
$M_I[i]$	장면 상태 i 의 평균 I 프레임 비트 발생량
$M_P[i]$	장면 상태 i 의 평균 P 프레임 비트 발생량
$M_B[i]$	장면 상태 i 의 평균 B 프레임 비트 발생량

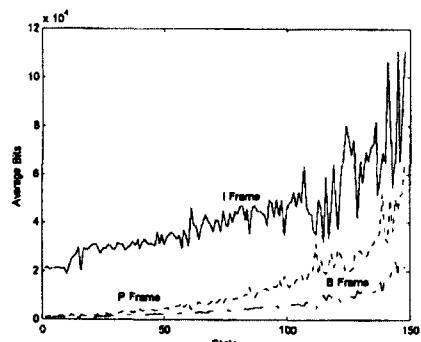
Rose[13]는 본 논문에서의 장면전환 모델과 유사한 상태천이 모델을 만들고 전체영상에서 GOP 평균 비트량에 대한 I, P, B 프레임의 평균 비트량이 갖는 비율(f_I, f_P, f_B)을 계산한 후 $M_{GOP}[i]$ 에 f_I, f_P, f_B 를 곱하여(모든 상태에 동일한 비율이 적용됨) GOP내 I, P, B 프레임에 대한 비트 발생량을 모델링 하였다(GOP내의 같은 종류(I, P, B)의 프레임 발생 비트는 모두 같다). 이는 임의 상태의 평균 GOP 크기가 크면 발생되는 I, P, B 프레임의 비트량도 따라서 같이 커지게 되어 어느 정도의 프레임간 상관관계가 유지되도록 한다². 그림 10은 상태가 증가 할수록 I, P, B 프레임의 평균 발생 비트량도 대략적

2 히스토그램 모델의 경우 I 프레임에 대하여 큰 비트량이 할당되었더라도 이어지는 P, B 프레임은 이전 프레임의 발생 비트량에 독립적으로 히스토그램에서 해당 프레임의 비트량을 발생시킨다.

으로 증가하는 것을 보여준다.



(a) “스타워즈” 영상



(b) “양들의 침목” 영상

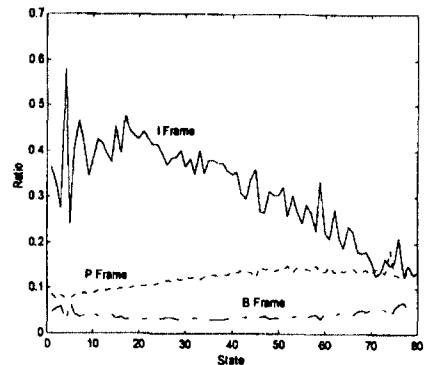
그림 10. 상태 증가에 따른 I, P, B 프레임의 상태별 평균 발생 비트량 변화

그러나 그림 11에서 볼 수 있듯이 K 개로 이루어진 상태천이 모델의 각 상태 i 에서 한 개의 I, P, B 프레임이 차지하는 비율 즉,

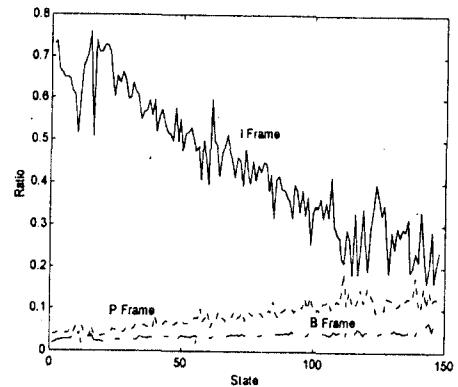
$$g_I[i] = \frac{M_I[i]}{M_{GOP}[i]}, g_P[i] = \frac{M_P[i]}{M_{GOP}[i]}, g_B[i] = \frac{M_B[i]}{M_{GOP}[i]}, \\ 1 \leq i \leq K \quad (3)$$

$g_I[i], g_P[i], g_B[i]$ 가 상태에 따라 일정한 값을 갖지 않는다. 대략적으로 I 프레임은 상태가 증가할 수록 GOP 크기에 대한 비율이 감소하며, P, B 프레임은 증가하는 모습을 보인다. 이는 [13]에서 사용

한 모델, 즉 상태에 독립적으로 일정한 값을 갖는다고 가정,은 실제 영상에 잘 맞지 않음을 보여준다.



(a) “스타워즈” 영상



(b) “양들의 침목” 영상

그림 11. 상태 증가에 따른 $g_I[i], g_P[i], g_B[i]$ 변화

위에서의 결과를 이용하여 본 논문에서는 장면 상태내의 연속되는 GOP의 I, P, B 프레임의 비트 발생량을 모델링 하기 위해 각 상태마다 원 영상으로부터 얻어진 상태 i 의 I, P, B 프레임의 평균 비트 발생량 $M_I[i], M_P[i], M_B[i]$ 를 근거로 모델을 세운다.

그림 12는 장면내의 I, P, B 프레임의 비트 발생 모델을 설명한다. 각 장면상태의 장면의 I, P, B 프레임간의 비트발생량의 상관관계는 $M_I[i], M_P[i], M_B[i]$ 를 통해 표현될 수 있으므로 GOP 패턴에 따른 I, P, B 프레임은 해당 장면상태의 $M_I[i], M_P[i], M_B[i]$ 값을 갖도록 한다. 이렇게 함으로써 원 영상의 각 장면상태의 프레임간 비트발생량의 상관관계를 비

교적 잘 모델링 할 수 있다. 그림 12에서 볼 수 있듯이 GOP 패턴에 따라(즉, $N=12$, $M=3$ 인 경우 프레임 시퀀스는 $\{I, B, B, P, B, B, P, B, B, I, B, B, P, B, \dots\}$ 가 된다) 장면상태의 각 프레임 타입별 평균 값으로 비트량을 모델링 할 경우 상태의 대표값 선정으로 인해 상태 양자화 오류(quantization error)가 발생하게 된다. 즉 실제 원 영상의 각 프레임 비트 발생량에서 해당 장면의 장면상태의 각 프레임별 평균값을 뺀 잔여 비트량(residual bits)이 존재한다.

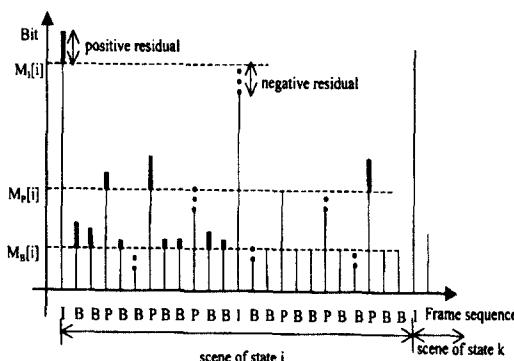


그림 12. 장면 상태의 I, P, B 프레임의 평균 비트량을 기반으로 한 모델링

본 논문에서는 각 프레임별 이 잔여 비트량을 모델링에 그대로 포함시키기 위하여 프레임 타입별 잔여 비트량 시퀀스에 대해 AR 모델을 세운다. n 번째 I, P, B 프레임에 대한 잔여 비트량 $\Delta I(n)$, $\Delta P(n)$, $\Delta B(n)$ 은 식 (4)로 부터 얻어진다. 즉 잔여 비트량은 n 번째 I, P, B 프레임이 상태 i 일 때 원 영상 비트발생량으로부터 상태 i 의 I, P, B 프레임 평균 비트 발생량을 뺀 값이 된다.

$$\begin{aligned}\Delta I(n) &= I(n) - M_I[i], \quad I(n) \in \text{state } i, \quad 1 \leq i \leq K \\ \Delta P(n) &= P(n) - M_P[i], \quad P(n) \in \text{state } i, \quad 1 \leq i \leq K \\ \Delta B(n) &= B(n) - M_B[i], \quad B(n) \in \text{state } i, \quad 1 \leq i \leq K\end{aligned}\quad (4)$$

본 논문에서 장면내 각 프레임 비트량을 모델링하는 방법은 I, P, B 프레임 비트량을 해당 장면상태

의 각 프레임 타입별 평균값으로 발생시키고 원 영상의 발생비트와 평균값과의 양자화 잔여비트는 위의 $\Delta I(n)$, $\Delta P(n)$, $\Delta B(n)$ 을 표현하는 AR 모델로부터 발생시켜 결국 최종적인 모델의 프레임 비트량은 이 두 값을 더한 값이 되도록 한다.

잔여비트를 AR 모델로 표현하기 위해 다음과 같은 3가지 AR 모델을 선정하여 어떤 모델이 효과적으로 잔여비트를 모델링하는가를 살펴본다.

1차 AR 모델 (AR1)

$$X(n) = aX(n-1) + W(n), \quad W(n) : \text{normal}(0, \sigma_w^2) \quad (5)$$

-2차 AR 모델 (AR2)

$$\begin{aligned}X(n) &= a_1 X(n-1) + a_2 X(n-2) + W(n), \\ W(n) &: \text{normal}(0, \sigma_w^2)\end{aligned}$$

(6)

2개의 1차 AR 모델 중합 (AR12)

$$\begin{aligned}X(n) &= a_1 Y(n-1) + b_1 W_1(n) + a_2 Z(n-1) + b_2 W_2(n), \\ W_1(n), W_2(n) &: \text{normal}(0, \sigma_w^2)\end{aligned}\quad (7)$$

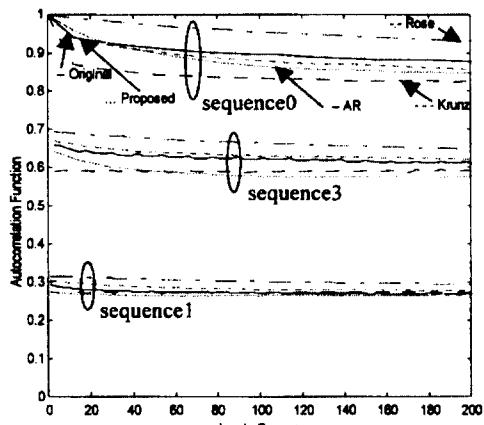
위 3가지의 AR 모델에서 $X(n)$ 은 I, P, B 프레임에 대해 각각의 잔여비트 모델을 위한 $\Delta I_{ar}(n)$, $\Delta P_{ar}(n)$, $\Delta B_{ar}(n)$ 을 의미한다. 세가지 AR 모델링에 필요한 파라미터들을 추정하는 방법은 AR1의 경우[8], AR2의 경우 [3], AR12의 경우 [6]의 논문에 제시되어 있다.

그림 13은 “양들의 침묵” 영상의 I 프레임 잔여비트를 AR 모델링하여 모델에서 생성한 모델 잔여비트 프레임 스퀸스와 원 영상의 잔여비트 스퀸스의 자기상관함수를 서로 비교한 것이다.

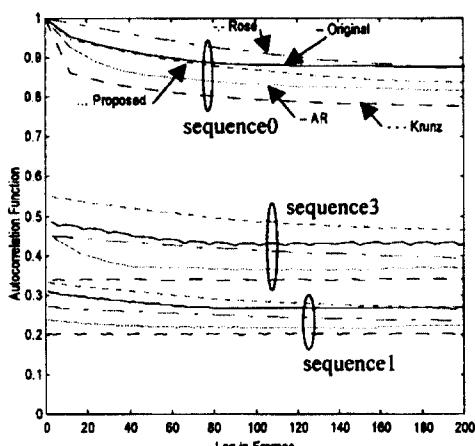
실험적 비교에 의하면 AR2가 AR1보다 원 영상의 잔여비트의 자기 상관함수를 약간 더 잘 반영하며, AR12의 경우 긴 주기 자기상관함수는 원 영상

IV. 모의실험을 통한 성능비교

본 장에서는 제안된 장면기반 모델링 기법에 대해 기존의 모델링 방법과의 비교를 수행한다. 성능 비교는 먼저 프레임간 상관관계 특성을 보여주는 자기상관함수가 얼마나 원 영상의 것과 일치하게 나타나는가 하는 점과, 트래픽 모델을 이용한 망에서의 통계적 큐잉 특성 예측이 원 영상의 큐잉특성과 얼마나 일치하는가를 비교한다.



(a) “스타워즈” 영상



(b) “양들의 침목” 영상

그림 14. 모델간 자기상관함수 비교

MPEG 비디오 모델에서 제안된 방법과의 비교 대상 모델들은 상태천이를 이용한 장면 기반 모델인 Rose[13] 모델과, B, P 프레임에서는 프레임단위 히스토그램 모델을, I 프레임에 대해 장면단위 히스토그램 모델을 사용한 Krantz[14]모델, 장면기반 모델이 아닌 단순 프레임 타입별(I, P, B)로 비트 발생량을 1차 AR 프로세스로 모델링[1][5][8]한 것에 대해 비교 평가를 수행한다. 실험영상에서 장면기반 모델링의 경우 1개 장면의 평균길이는 5 GOP길이(약 2.5초) 정도를 갖도록 하였고 상태수는 100-150개 정도의 상태를 정의하였다.

그림 14는 MPEG 압축영상인 “스타워즈”와 “양들의 침목” 비디오 스트림에 대해 원 압축영상의 프레임 길이 변화에 대한 자기상관함수와 모델에서 발생시킨 비트 프레임의 자기상관함수를 비교한 것이다.

모델 프레임의 비트 스트림에 대한 자기상관함수를 살펴보면 제안된 방법이 원래 영상의 자기상관함수를 제일 근사적으로 따라감을 알 수 있다. 앞에서 설명한 바와 같이 자기상관함수는 망에서의 큐잉 특성 등을 예측하는 중요한 파라미터이다.

그림 15는 “양들의 침목” 영상에 대해 원 영상의 프레임 단위 비트 발생 히스토그램과 모델로 부터 발생시킨 영상의 프레임 단위 비트발생 히스토그램을 비교한 것이다. 히스토그램 모델에 근거한 Krantz[14] 모델이 가정 근사하게 비트 스트림을 발생시켰고, 제안된 방법도 원래 영상의 히스토그램에 근사하였다. 상태천이 기반의 Rose[13] 모델이 상태의 대표 값으로 비트를 발생시키므로 제일 좋지 않은 결과를 보였다.

그림 16은 입력영상의 트래픽이 ATM 멀티플렉서에서 출력링크 대역폭의 60%의 로드로 입력될 때 멀티플렉서에서의 버퍼크기를 50에서부터 1000 셀 크기로 변화 시킴에 따라 모델과 원영상의 trace에 대한 셀 손실 확률(cell loss rate)을 도시한 것이다. 제안된 방법이 원래 영상의 셀 손실율을 거의 정확히 따라가고 있음을 알 수 있다. 그림 17은 “양들의

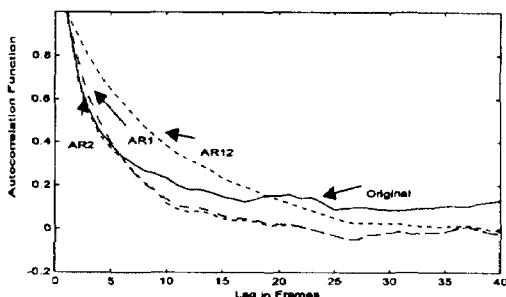


그림 13. 잔여 비트 모델링을 위한 AR 모델들의 자기상관 함수 특성 비교

의 잔여비트 자기상관함수를 잘 따라가나, 작은 프레임 길이에 대한 자기상관함수는 AR2가 더 우수

한 것을 알 수 있다. 원래 AR12는 비디오 스트림이 긴 프레임 길이에 대해서도 자기상관함수가 지수 함수 적으로 감소하지 않는 특징을 모델링하는데 사용된 것이나 잔여비트의 자기상관함수는 비교적 짧은 길이에 자기 상관 함수가 0 주위로 떨어지므로 AR2가 잔여 비트 시퀀스에 대해서는 더 좋은 모델링 특징을 보인다고 볼 수 있다.

따라서 본 논문에서는 I, P, B 프레임의 잔여 비트량 모델링을 위해 AR2 모델을 사용하여 모델링하였다. 본 논문에서 제안한 모델링 방법 및 모델 파라미터로 부터 모델 영상 시퀀스의 비트량을 발생시키는 절차는 다음과 같다.

모델링 절차

1. MPEG 압축 비디오 스트림으로부터 제안된 장면 검출 알고리즘을 이용하여 장면을 검출한다.
2. 장면의 평균 GOP 발생 비트량을 기준으로 상태 천이 모델을 위한 상태를 정의하고 상태 천이 확률을 구한다.
3. 각 상태의 평균 I, P, B 프레임 크기와 평균 GOP 수를 계산한다.
4. 원 MPEG 비디오 스트림의 I, P, B 프레임의 비트량에서 해당 프레임이 속한 장면상태의 평균 I, P, B 프레임 비트량을 뺀 잔여 비트를 AR2 모델을 이용하여 모델링하고 AR2 모델 파라미터를 추정한다.

모델로부터 프레임별 비트발생

1. 장면 상태 천이 모델에서 해당 상태에서의 평균 GOP 수로 부터 기하분포를 이용하여 해당 상태에서 연속되는 GOP 수를 도출한다.
2. 상태 체류 GOP 수 동안 I, P, B 프레임에 대해 GOP 패턴에 따라 다음 식에 의해 I, P, B 프레임의 모델 비트를 발생시킨다.
($I(n)$, $P(n)$, $B(n)$ 이 상태 i 에 속한다고 가정)
i) I 프레임 : $I(n) = M_I[i] + \Delta I_{AR}(n)$,
여기서, $\Delta I_{AR}(n) = a_{1I} \Delta I_{AR}(n-1) + a_{2I} \Delta I_{AR}(n-2) + W_I(n)$
ii) P 프레임 : $P(n) = M_P[i] + \Delta P_{AR}(n)$,
여기서, $\Delta P_{AR}(n) = a_{1P} \Delta P_{AR}(n-1) + a_{2P} \Delta P_{AR}(n-2) + W_P(n)$
iii) B 프레임 : $B(n) = M_B[i] + \Delta B_{AR}(n)$,
여기서, $\Delta B_{AR}(n) = a_{1B} \Delta B_{AR}(n-1) + a_{2B} \Delta B_{AR}(n-2) + W_B(n)$
3. 원하는 프레임 길이가 될 때까지 상태 천이 모델에서 다음 상태를 결정하여 단계 1 부터의 절차를 반복한다.

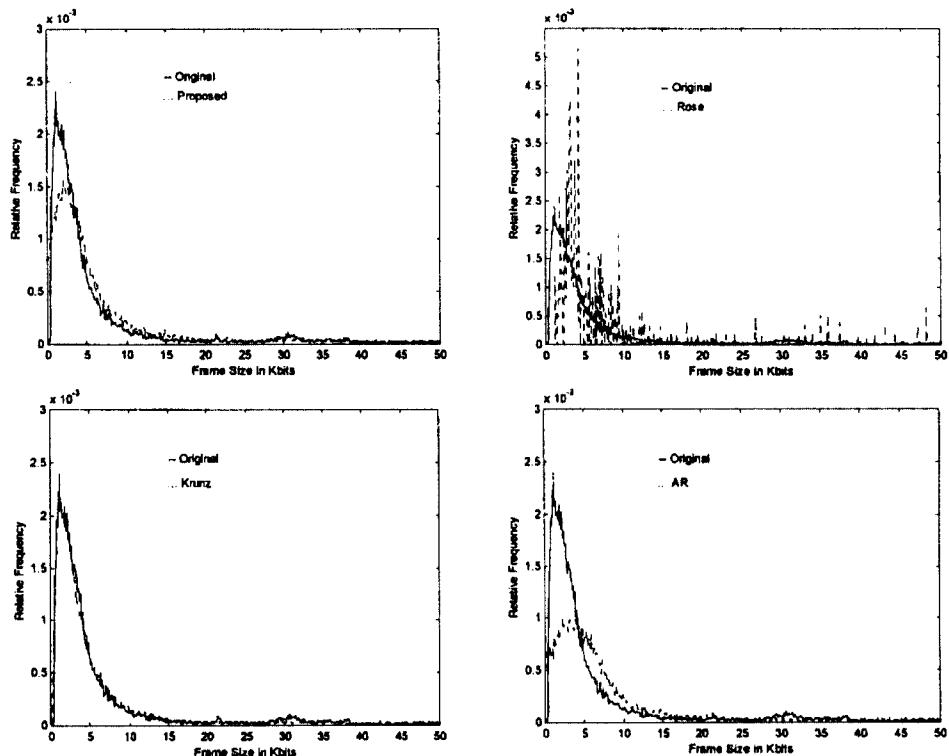
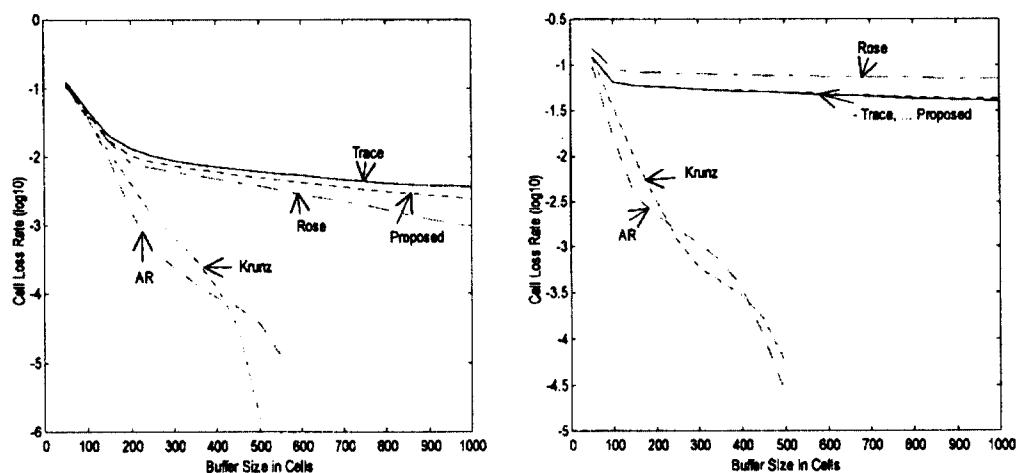


그림 15. 원 영상의 히스토그램과 모델영상의 히스토그램 비교



(a) "스타워즈" 영상

(b) "양들의 침묵" 영상

그림16 . 셀 손실 확률 비교

침묵” 영상에 대해 멀티플렉서의 출력링크 대역폭 대 입력 트래픽의 비트율을 40%, 50%, 60%, 70%, 80%로 변화 시켰을 때 셀 손실 확률을 제안된 모델링 방식이 정확히 예측할 수 있는가를 실험하였다. 제안된 모델링 방법은 입력 로드의 변화에도 셀 손실 확률을 잘 예측할 수 있음을 알 수 있다.

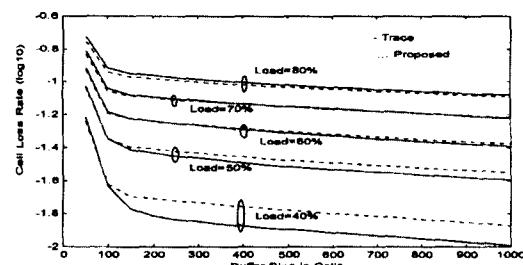
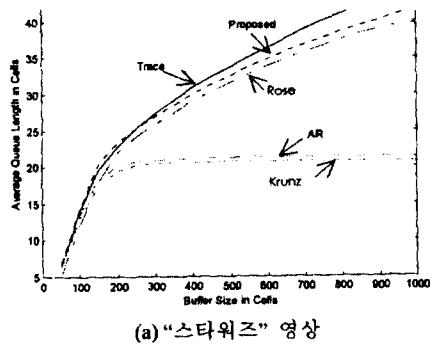
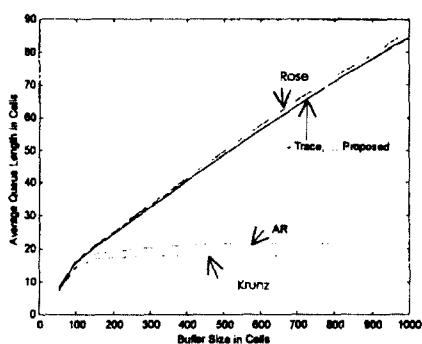


그림 17. 입력 로드 변화에 따른 셀 손실 확률 추정



(a) “스타워즈” 영상



(b) “양들의 침묵” 영상

그림 18. 평균 버퍼 대기 셀 수 비교

그림 18은 프레임 단위 셀발생이 한 프레임 주기에 균일하게 분포하여 발생된다고 가정하고 입력 로드가 60%일 때 평균 버퍼 대기 셀 수를 도시한 것이다. 실험영상 스트림에 대하여 제안된 모델링 방법이 원 영상의 버퍼 특성을 가장 잘 따르고 있다.

위와 같은 실험을 통하여 제안된 프레임간 상관 관계를 고려한 장면기반 MPEG 비디오 트래픽 모델링 방법이 실제 영상의 비트발생량 통계적 특성을 잘 반영하고 실제 시뮬레이션이나 분석적인 응용에 효과적으로 사용될 수 있음을 알 수 있다.

V. 장면 기반 모델을 사용한 레벨 translation

장면기반 모델링의 장점은 한가지 모델을 사용한 파라미터 집합(set)을 이용하여 실제 관심 있는 여러 레벨의 정보를 얻을 수 있다는 것이다. 즉 망에서 비디오 영상의 비트열에 대한 망자원의 할당을 통계적인 장면단위로 할당 할 경우 장면단위의 통계적 특성을 모델로부터 추정할 수 있고, 역시 필요할 경우 GOP 단위, 프레임 단위, 셀단위 정보를 한 모델에서 자동으로 얻을 수 있다. 이는 관심 있는 레벨 별로 따로 모델링 할 필요가 없음을 의미한다. 본 논문에서는 다음과 같은 두 가지 용어를 정의하고 레벨간 translation을 통해 원하는 레벨의 특성을 도출한다.

순방향(forward) translation

순방향 translation은 실제 모델링을 위한 절차와 같이 장면 단위 특성을 얻기 위해서는 상태모델에서 해당 상태의 평균 GOP 단위 비트 발생량과 기하분포를 이용한 해당 장면 상태에서의 연속 GOP 수를 이용하고, GOP 레벨의 정보는 장면단위 비트발생량을 연속되는 GOP 수로 나누어 그대로 변환하고, 프레임 레벨은 GOP 레벨에서 해당 장면 상태의 평균 프레임 탑입별 발생 비트량에 AR 모델을 이용한 잔여 비트를 더해주는 방식으로 얻는다. 셀 레벨은 프레임 레벨에서 응용프로그램의 프레임 패

킹(packing) 방식, 사용되는 ATM 적응계층 프로토콜 등을 고려해 프레임 레벨 비트량을 48 바이트의 ATM 유료정보(payload)로 변환시키면 된다.

역방향(backward) translation

순방향 translation은 레벨이 장면에서 셀로 내려올 수록 더 정확한 정보를 가지게 되므로 최상위 레벨의 장면 및 GOP 모델에서는 평균값에 의해 간주기의 특성이 표현된다. 보다 정확한 모델로 부터의 정보를 원할 경우 제안된 모델링 방법을 이용하여 최하위 레벨까지 일단 모델로 부터의 정보를 발생시킨 뒤에 다시 상위레벨 정보를 도출하는 방식을 취하면 된다.

VI. 결 론

본 논문에서는 MPEG 압축 비디오의 통계적 모델링을 위하여 프레임간 상관관계를 고려한 장면기반 모델링 방법을 제안하였다. 간단한 GOP 비트 발생량을 기초로 한 장면 검출 알고리즘을 이용하여 장면 검출 후 장면의 상태천이 모델을 세우고 상태천이 모델이 히스토그램 모델 보다 장면변화를 보다 잘 모델링 한다는 것을 보였다. 장면의 GOP 체류기간은 기하분포로 모델링하고 프레임 단위의 비트 발생을 위하여 장면 상태의 평균 I, P, B 프레임의 비트 발생량이 상태마다 다른 특성을 보인다는 것을 분석하고 I, P, B 프레임의 상태별 비트 발생량 상관 관계를 이용하여 프레임 레벨의 모델링을 수행하였다. 또한 보다 정확한 모델링을 위해 상태 천이 모델이 갖는 양자화 오류(잔여비트)를 정의하고 이를 AR 프로세스를 이용하여 제안된 모델에 포함시켰다.

여러가지 MPEG 비디오 영상에 대해 제안된 모델링 방법의 성능을 분석하였다. 제안된 모델링 방법을 이용하여, 발생시킨 모델영상은 원 영상의 자기상관함수를 잘 따르고 프레임 당 발생비트의 히스토그램도 원 영상의 것과 거의 일치함을 보였다.

또한 실제 ATM 망에서 유한한 버퍼 크기를 갖는 멀티플렉서에서 셀 손실률을 측정한 결과 제안된 방식은 원 영상의 셀손실 확률을 거의 오차 없이 추정할 수 있음을 보였다. 제안된 모델링 방법은 장면기반 모델을 사용하여 원하고자 하는 레벨(장면, GOP, 프레임, 셀)간의 자동적인 translation이 가능하고 각 레벨 별로 정확한 원 영상 특성의 추정이 가능하다. 따라서 제안된 모델링 방법은 실제 통신 망에서 여러 망자원의 할당, QoS 파라미터 설정, 트래픽 파라미터의 추정 등에 다양하게 활용될 수 있을 것이다.

참 고 문 헌

1. B. Maglaris, D. Anastassiou, P. Sen, G. Karlsson and J. D. Robbins, "Performance models of statistical multiplexing in packet video communication", IEEE Trans. Communications, Vol. 36, No.7, pp. 834-844, 1988.
2. P. Sen, B. Maglaris, N. Rikli, and D. Anastassiou, "Models for packet switching of variable-bit-rate video sources", IEEE Journal on Selected Areas in Communications, Vol. 7, No. 5, pp. 865-869, 1989.
3. D. P. Heyman, A. Tabatabai, and T. V. Lakshman, "Statistical analysis and simulation study of video teleconference traffic in ATM networks", IEEE Trans. on Circuit and Systems for Video Technology, Vol.2, No.1, pp. 49-59, 1992
4. D. M. Lucantoni, M. F. Neuts, and A. R. Reibman, "Methods for performance evaluation of VBR video traffic models", IEEE/ACM Trans. on Networking, Vol. 2, No.2, pp.176-180, 1994.
5. M. Nomura, T. Fujii, and N. Ohta, "Basic characteristics of variable rate video coding in ATM environment", IEEE Journal on Selected Areas in Communications, Vol.7, No.5, pp. 752-

- 760, 1989.
6. A. L. Corte, A. Lombardo, S. Palazzo, and S. Zinna, "Modeling activity in VBR video sources", *Signal Processing : Image Communications* 3, pp. 167- 178, 1991.
 7. G. Ramamurth, and B. Sengupta, "Modeling and analysis of a variable bit rate video multiplexer", *IEEE INFOCOM' 92*, pp. 817-827, 1992.
 8. F. Yegenoglu, B. Jabbari, and Y. Zhang, "Motion-classified autoregressive modeling for variable bit rate video", *IEEE Trans. on Circuits and Systems for Video Technology*, Vol.3, No.1, pp.42-53, 1993
 9. J. C. Wu, Y Chen, and K Jiang, "Two models for variable bit rate MPEG sources", *IEICE Trans. on Communications*, Vol. E78-B, No.5, pp. 737-745, 1995.
 10. P. Skelly, M. Schwartz, and S. Dixit, "A histogram-based model for video traffic behaviour in an ATM multiplexer", *IEEE/ACM Trans. on Networking*, Vol. 1, No.4, pp. 446-459, 1993.
 11. M. Krunz, and H. Hughes, "A traffic model for MPEG-coded VBR streams", *IEEE ICC' 95*, 1995.
 12. C. Huang, M. Devetsikiotis, I. Lambadaris, and A. Kaye, "Modeling and simulation of self-similar variable bit rate compressed video: A unified approach", *ACM SIGCOMM '95*, 1995.
 13. O. Rose, "Simple and efficient models for variable bit rate MPEG video traffic", *Performance Evaluation* 30, pp. 69-85, 1997.
 14. M. Krunz, and S. Tripathi, "Scene-based characterization of VBR MPEG-compressed video traffic", *ACM SIGMETRICS '97*, University of Maryland CS-TR-3573, 1997.



유 상 조(Sang-Jo Yoo) 정회원

1966년 10월 15일생

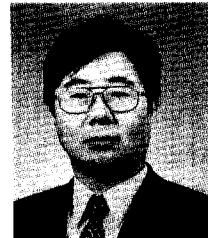
1984년 3월 ~ 1988년 2월 : 한양
대학교 전자통신공
학과 졸업(공학사)

1988년 3월 ~ 1990년 2월 : 한국과학기술원 전기 및
전자공학과 졸업(공학석사)

1990년 3월 ~ 현재 : 한국통신 연구개발본부

1997년 3월 ~ 현재 : 한국과학기술원 전기 및 전자
공학과 박사과정

*주관심분야: 멀티미디어 통신, 트래픽 모델링
e-mail:sangjo@sdvision.kaist.ac.kr



김 성 대(Seong-Dae Kim) 정회원

1953년 12월 26일생

1977년 : 서울대학교 전자공학
과 졸업(공학사)

1979년 : 한국과학기술원 전기 및
전자공학과 졸업(공학석사)

1983년 : 프랑스 INPT ENSEEIHT 졸업(공학박사)
1984년 ~ 현재 : 한국과학기술원 전기 및 전자공
학과 교수

*주관심분야: 영상처리, 영상통신, 컴퓨터 비
전, VLSI 구현등

최 재 각(Jae Gark Choi)

정회원

1961년 5월 9일생

1980년 3월 ~ 1984년 2월 : 경북대학교 전자공
학과(공학사)

1985년 3월 ~ 1987년 2월 : 한국과학기술원 전기
및 전자공학과(공학석사)

1992년 3월 ~ 1997년 8월 : 한국과학기술원 전기
및 전자공학과(공학박사)

1987년 2월 ~ 1998년 2월 : 한국전자통신연구원
선임연구원

1998년 3월 ~ 현재 : 경일대학교 전임강사

*주관심 분야: 영상처리, 영상통신, 컴퓨터비전,
멀티미디어 신호처리등