

Non-stationary VBR 트래픽을 위한 동적 데이터 크기 예측 알고리즘

(On-line Prediction Algorithm for Non-stationary VBR Traffic)

강 성 주 [†] 원 유 집 ^{**} 성 병 찬 ^{***}
(Sungjoo Kang) (Youjip Won) (Byeongchan Seong)

요 약 본 논문에서는 VBR(Variable-Bit-Rate) 트래픽의 비선형적이고 버스티한 특성을 모델화 한 GOP ARIMA(ARIMA for Group Of Pictures) 모델을 칼만 필터 알고리즘을 이용하여 실시간으로 예측 하는 기법을 제안한다. 칼만 필터를 이용한 예측 기법은 GOP ARIMA의 상태공간 모델링 과정과 향후 N 초 간의 트래픽을 예측하는 과정으로 구성된다. 실험을 위해 GOP의 크기가 각각 15인 세 가지 종류의 MPEG VBR 트래픽(뉴스, 드라마, 스포츠)을 제작하였고, 칼만 필터를 이용한 세 가지 종류의 트래픽의 예측 결과를 선형 예측법과 이중 지수 평활법을 이용해 예측한 결과와 비교해 예측 성능이 상대적으로 우수함을 확인할 수 있었다. 또한 예측값에 신뢰 구간을 설정하는 신뢰 구간 분석법을 통해 트래픽 관점에서 장면 변화를 예측하는 방법을 제시하였다. 본 논문의 칼만 필터 기반의 예측 알고리즘은 MPEG 기반 VBR 트래픽을 비롯한 기타 인터넷 트래픽을 실시간으로 예측하는 방법과 이를 이용해 인터넷 서버의 설계 및 자원 할당 정책 등을 위한 트래픽 엔지니어링 연구에 기여할 수 있을 것이다.

키워드 : VBR 트래픽, 트래픽 예측, 칼만 필터, GOP ARIMA, 장면 전환 감지, 멀티미디어 스트리밍

Abstract In this paper, we develop the model based prediction algorithm for Variable-Bit-Rate(VBR) video traffic with regular Group of Picture(GOP) pattern. We use multiplicative ARIMA process called GOP ARIMA (ARIMA for Group Of Pictures) as a base stochastic model. Kalman Filter based prediction algorithm consists of two process: GOP ARIMA modeling and prediction. In performance study, we produce three video traces (news, drama, sports) and we compare the accuracy of three different prediction schemes: Kalman Filter based prediction, linear prediction, and double exponential smoothing. The proposed prediction algorithm yields superior prediction accuracy than the other two. We also show that confidence interval analysis can effectively detect scene changes of the sample video sequence. The Kalman filter based prediction algorithm proposed in this work makes significant contributions to various aspects of network traffic engineering and resource allocation.

Key words : VBR Traffic, Traffic Prediction, Kalman Filter, GOP, ARIMA, Scene Change Detection, Multimedia Streaming

1. 서 론

1.1 연구 동기

하드웨어, 통신망, 저장 장치, 비디오 압축 기술의 발전은 시간과 공간의 제약이 없는 비디오 콘텐츠에 대한

접근 및 이용을 가능하게 하고 있다. 주문형 비디오를 이용한 영화 서비스, 화상 전화, 화상 회의는 물론 뉴스나 스포츠 경기 등의 실시간 스트리밍 서비스 등이 여기에 포함된다. 네트워크(주로 인터넷)를 이용해 스트리밍 서비스를 제공하는 경우에 네트워크의 상황에 따라 발생하는 지연에 의해 패킷 손실이 발생하게 되고 이는 사용자 입장에서의 QoS (Quality of Service)를 떨어뜨리게 된다. 이러한 문제를 일으키는 지연은 네트워크 상의 여러 라우터로 버스티(busy)한 특성의 패킷이 들어올 경우 라우터에서 이들 패킷을 처리하고 전달하는 시간이 길어지기 때문에 발생한다. 비디오 데이터, 특히 MPEG (Moving Picture Experts Group) 표준 방식으

본 연구는 2004년도 서울대학교 복집계 통계 연구센터의 연구비 지원으로 수행하였습니다.

[†] 정 회 원 : 한국전자통신연구원 디지털통신 연구단 연구원
sjkang@etri.re.kr

^{**} 종신회원 : 한양대학교 전자전기컴퓨터공학부 교수
yjwon@ece.hanyang.ac.kr

^{***} 정 회 원 : 중앙대학교 수학과통계학부 교수
bcseong@cau.ac.kr

논문접수 : 2004년 12월 21일

심사완료 : 2007년 3월 20일

로 인코딩된 데이터의 특성은 비선형적이고 버스티한 특성을 가지게 되며 이러한 데이터를 이용해 스트리밍 서비스를 하게 되는 경우 위의 이유로 지연이 발생되게 된다. 이에 대한 한시적인 대책으로는 충분한 양의 대역폭을 할당하는 것이지만 이는 자원의 비효율적인 사용을 야기한다.

트래픽 스무딩과 같은 트래픽 엔지니어링 기법은 자원 효율을 극대화하고 궁극적으로 멀티미디어 서비스의 품질을 극대화 할 수 있다. 트래픽 스무딩이란 네트워크 상에서 발생하는 지터와 패킷 손실을 줄이는 방법으로 서버 측에서 전송 스케줄을 조정하여 전송되는 데이터의 버스티 특성을 최소화 시키는 것이다. 즉, 트래픽 스무딩 기법을 이용함으로써 동일한 대역폭을 가진 네트워크를 이용하면서 보다 월등한 스트리밍 서비스를 가능하게 할 수 있다.

저장된 비디오 데이터를 이용해 스트리밍 서비스를 하는 경우 트래픽 엔지니어링에 필요한 미래의 트래픽의 정보를 미리 알 수 있으므로 트래픽 예측의 중요성은 크지 않다. 그러나 실시간 환경에서의 스트리밍 시에는 미래의 트래픽의 정보를 정확히 알 수 없으므로 이를 위한 트래픽의 동적 예측에 대한 연구가 필수적이다. 그러나 실시간 환경을 위한 트래픽 예측에 대한 연구는 아직 만족스러운 수준에 이르지 못하고 있다. 멀티미디어 스트리밍 서비스의 사용자의 요구가 증가하고 있지만, 현재의 유무선 인터넷은 고품질의 동영상 스트리밍에 적합하지 못한 낮은 대역폭을 지원하며, 이에 따른 지연, 패킷 손실 등으로 인한 QoS 저하는 간과할 수 없다. 본 논문에서는 실시간 멀티미디어 스트리밍을 위한 동적 트래픽 예측 기법을 통해 사용자의 QoS를 극대화시킬 수 있음을 확인하고자 한다.

1.2 관련 연구

광대역 통신망의 트래픽, 특히 VBR (Variable Bit Rate) 트래픽의 통계적 특성에 대한 여러 연구가 진행되어 왔다[1-3]. Leland 등의 연구 결과에 따르면 VBR 트래픽 내에는 자기-유사성(self-similarity)특성과 LRD(long-range dependency) 특성이 존재함을 증명하였다[4]. 또한 Beran 등의 연구는 VBR 트래픽에도 LRD 특성이 존재함을 증명하였다[5]. 일반적으로 신호의 강한 LRD 특성이 존재하면, 여러 예측 기법을 통해 우수한 예측 결과를 얻을 수 있다. 이와 같은 네트워크 트래픽의 LRD 특성은 네트워크 트래픽 모델링 및 예측의 연구를 유발하였다[6].

정확한 VBR 트래픽 모델링을 통한 동적 대역폭 할당 및 혼잡 제어 등을 위한 연구가 꾸준히 진행되어 왔다. 초기에 Krnunz[7]는 히스토그램과 자기-상관함수를 이용해 VBR 트래픽의 통계적 특성을 찾아내었고, 프레임

별 MLE 파라미터를 이용하여 트래픽을 모델링 하였다.

이후 연구에서 트래픽 모델은 stationary와 non-stationary 트래픽 모델로 구분된다[8]. 또한 트래픽 모델은 프레임간의 의존성을 기준으로 SRD(Short-range dependency), LRD 트래픽 모델로 구분된다[5]. Stationary 모델 중 Markov 모델과 AR, DAR, ARMA 등의 회귀 모델이 대표적인 SRD 모델에 속한다[9-12]. 이들은 비교적 작은 lag를 기준으로 상관 구조와 주기성을 잘 표현한다. F-ARIMA(Fractional autoregressive integrated moving average), Markov-Modulated Self-Similar 모델 등은 큰 lag를 기준으로 상관 구조를 잘 표현하는 LRD 모델이다[13]. 그러나 많은 연구에서 실제 트래픽은 non-stationary 특성을 나타냄이 확인되었다[14,15].

Frey는 Heyman의 gamma-beta auto-regression (GBAR) 모델[16]에 기반한 GOP GBAR 모델을 제안하였다[17]. 이 모델은 VBR 트래픽의 주기성을 잘 설명하지만, 천천히 감소하는 자기-상관계수를 설명하지 못한다.

Won 등[18]은 VBR 트래픽의 천천히 감소하는 자기-상관계수와 강한 주기성과 같이 non-stationary 프로세스에서 관찰되는 특성을 모델링한 GOP ARIMA 모델을 제안하였다. 또한 GOP ARIMA 모델은 시간에 의존적인 VBR 트래픽의 프레임 크기 및 GOP 내부 및 GOP 간의 자기 상관성을 잘 설명한다.

VBR 트래픽이 멀티미디어 데이터의 중요 요소로 부각되면서 VBR 비디오 트래픽의 예측에도 많은 연구가 시작되었다. 트래픽 예측은 동적 대역폭 할당과 혼잡되면서, 네트워크의 효율과 QoS의 보장 측면에서 중요한 요소로 인식된다. 이 분야의 초기 연구는 VBR 트래픽 신호의 주파수 영역과 시간 영역의 예측으로 시작되었다.

Chong 등[19]은 주파수 영역에서, Wang 등[20]은 Wavelet 영역에서 VBR 트래픽을 예측하였다. 이들 방법은 계산량의 복잡도가 다소 높았다. 시간 공간에서 트래픽을 다룬 적응형 선형 모델[21]은 계산량은 적지만, 장면 전환과 같이 비트율의 변화가 급격한 상황에서는 예측 오차가 크게 나타난다.

지능형 시스템의 새로운 패러다임이 트래픽 예측에 제안되고 적용되었다. Chen 등[8]은 퍼지 논리(Fuzzy Logic)를 이용해 트래픽을 모델링하고 예측하였다. 이 모델에서는 VBR 트래픽의 LRD 및 non-stationary 특성을 잘 고려하였다. 신경망(Neural Networks) 이론을 이용한 예측 방법은 급격한 트래픽 변화에 비교적 빨리 적응하는 모습을 보여주었다[22-24]. 그러나 이러한 방법은 1 프레임의 예측만이 가능하며, 이는 동적 대역폭 할당을 위해서는 매우 짧은 간격이다.

효과적인 동적 대역폭 할당을 위해서는 트래픽의 통계적 특성을 잘 표현하는 모델과, 계산의 복잡성, 속도, 트래픽 변화에 빠르게 적응하고, 장시간 후의 프레임 크기 예측이 가능한 예측 알고리즘이 필요하다.

2. VBR 트래픽의 통계적 모델링

2.1 VBR 트래픽의 통계적 특성

MPEG VBR 코딩 방식은 연속된 프레임들 사이의 시간적, 공간적 차이를 이용한다. 이 방식으로 인코딩된 데이터는 I,P,B 세 가지 타입의 프레임 구조를 사용하여 영상을 구성하게 된다. 한 프레임으로 한 장의 화면을 구성할 수 있는 I 프레임(intra picture), 이전 I 프레임 또는 P 프레임과 현재 압축하게 될 영상의 차이를 저장하는 P 프레임(predictive picture)과 B 프레임(bidirectionally-predictive picture)를 이용한 이와 같은 압축 방식은 압축률을 높여 디스크의 사용 효율을 높일 수 있으나, 그림 1과 같이 I,P,B 각각의 크기 차이가 발생하게 된다. 이러한 MPEG VBR 트래픽을 통해 여러 가지 통계적 특성을 추출해 낼 수 있으며, 이 특성들을 통해 VBR 트래픽의 특성화가 가능하다.




그림 1 VBR 트래픽

VBR 트래픽의 통계적 특성은 비디오 콘텐츠의 종류에 의존적이다. 따라서 본 연구의 실험에서는 이를 위해 세 가지 서로 다른 종류의 비디오 데이터(드라마, 뉴스, 스포츠) 5개를 사용하였다.

첫 번째로 VBR 트래픽의 1,2차 모멘트(평균,분산)의 특성을 분석하면, 표 1은 세 가지 종류의 트래픽(드라마, 뉴스, 스포츠)의 평균, 분산의 특성을 보여준다. 세 가지 트래픽의 평균은 거의 비슷하지만 분산의 크기는 뉴스, 드라마, 스포츠의 순서로 나타난다. 이는 뉴스 트래픽은 장면 내에서 변화가 적으며, 이 변화를 저장하는 P, B프레임의 크기가 작기 때문이라고 생각할 수 있다. 한편 장면이 매우 빠르게 변화하는 스포츠 트래픽은 P,B 프레임의 크기가 크게 되므로 프레임 크기간의 분

표 1 실험에서 사용된 VBR 비디오의 특성

Video	mean (Byte)	Variance (Byte ²)
Drama 1	16682.26	94097747
Drama 2	16653.38	94174785
News 1	16679.57	97458964
News 2	16698.78	96753456
Sports	16685.52	66973646

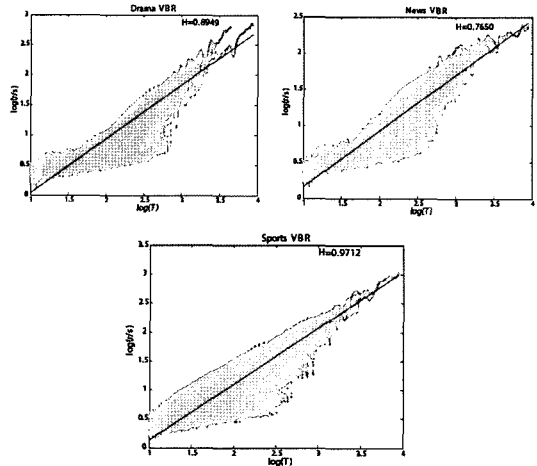


그림 2 VBR 트래픽의 R/S 플롯

산은 상대적으로 작음을 알 수 있다. 결론적으로 VBR 트래픽에는 콘텐츠의 종류와 관련된 1, 2차 모멘트의 특성이 존재한다.

두 번째는 VBR 트래픽의 Non-Stationarity 특성이 다. 그림 1은 VBR 트래픽의 몇 초간의 프레임 크기의 변화를 보여주고 있다. 트래픽의 관찰을 통해 이 트래픽을 이루는 프레임간에 주기성이 존재함을 알 수 있다. 매 15 프레임마다 큰 값을 가지는 프레임은 I 프레임을 나타내며, 3 프레임 간격으로 중간 크기를 갖는 프레임은 P 프레임을, I 프레임과 P 프레임 사이에 존재하는 작은 값들은 B 프레임을 나타낸다. 통계적 프로세스 분야에서 정의된 Non-stationary 개념에 의하면, 임의의 프로세스는 엄격하게 시간 의존적인 행태를 보이며, 그것에 대한 분명한 이유가 있을 때 non-stationary 특성을 갖는다. VBR 트래픽은 그림 1에서 볼 수 있듯이 시간에 의존적이고 결정적인 행태를 보이며, 그 이유가 VBR 트래픽의 고정된 GOP 패턴 때문이란 것을 알 수 있다. 이는 곧 VBR 트래픽의 Non-stationary 특성을 말해준다. 이와 같은 결과는 Non-Stationary 프로세스에서 관찰되는 것으로서, VBR 트래픽이 Non-Stationary 특성을 갖는다는 것을 보여준다.

세 번째는 VBR 트래픽의 LRD(Long Range Dependency)특성이다. 임의의 프로세스 X_t 는 $(0.5 < H < 1)$ 일

때, LRD 특성을 갖는다고 말한다. 그림 2의 H는 Hurst 파라미터를 의미하며, 이는 LRD의 정도를 나타낸다. R/S 플롯 방법을 이용해 구한 VBR 트래픽의 Hurst 파라미터를 구해낸 그림 2에서 보통 H 값이 모두 0.5 이상임을, 즉 VBR 트래픽에 LRD 특성이 존재함을 알 수 있다.

2.2 VBR 트래픽의 GOP ARIMA 모델링

많은 시계열 모델들, AR(Auto Regressive), MA (Moving Average), ARMA(Auto Regressive Moving Average) 등이 VBR 트래픽을 표현하기 위해 사용되어 왔다. ARMA 모델은 데이터가 stationary 특성을 갖고, 자기 상관 함수가 빠르게 감소할 때 적합하다. 그러나 앞서 살펴본 바에 따르면 VBR 트래픽은 non-stationary 특성을 가지며, 그것의 자기 상관 계수는 매우 천천히 감소한다. 이와 같은 특성은 ARMA 모델로는 표현될 수 없다.

Non-Stationary 프로세스는 ARIMA(Auto Regressive Integrated Moving Average)모델을 통해 표현될 수 있다. 이 모델은 프로세스 내에 계절성을 지닌 시계열 (예를 들면 월별 강우량 기록)을 표현할 때 주로 사용된다. 임의의 프로세스를 계절성에 대해 차분한 결과가 ARMA 프로세스로 나타날 때, 이 프로세스를 ARIMA 프로세스라고 한다. 이 ARIMA 모델을 사용해, 우리는 non-stationary 특성을 갖고, 매우 천천히 감소하는 자기 상관 계수를 갖는 프로세스(VBR 프로세스)를 생성할 수 있다.

VBR 트래픽의 자기 상관 함수는 매우 천천히 감소하고 I 프레임 간, 그리고 P 프레임 간 거리의 주기를 갖는 주기성이 나타난다. 본 연구에서는 이와 같은 특성의 VBR 트래픽을 통계적으로 모델링한 GOP ARIMA (ARIMA for Group Of Picture)을 모델로 사용한다. GOP ARIMA는 ARIMA 프로세스[25]의 특별한 부분으로 VBR 트래픽의 주기적인 패턴과 자기 상관 함수의 특성을 매우 잘 설명한다[18]. 다음은 GOP ARIMA의 정의이다.

Definition GOP ARIMA(p,d,q)_sX(P,D,Q)_S 프로세스

s와 S를 각각 P 프레임간 및 I 프레임간의 거리라 하고, d와 D가 음이 아닌 정수라고 하면, 프로세스 $\{X_t\}$ 를 차분한 프로세스 $Y_t \equiv (1-B)^d(1-B^s)^D X_t$ 가 ARMA (p,q) 프로세스이면, 이 때의 $\{X_t\}$ 를 주기 s 및 S에 대한 GOP ARIMA(p,d,q)_sX(P,D,Q)_S로 정의한다.

$$\phi(B^s)\Phi(B^S)Y_t = \theta(B^s)\Theta(B^S)\epsilon_t$$

여기서 $\phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p$, $\Phi(z) = 1 - \Phi_1 z - \dots - \Phi_S z^S$,

$\theta(z) = 1 + \theta_1 z + \dots + \theta_q z^q$, $\Theta(z) = 1 + \Theta_1 z + \dots + \Theta_S z^S$ 이며, $\{\epsilon_t\}$ 는 정규 분포를 따르는 난수 시퀀스이다. s 와 S는 압축시 인코더의 GOP 패턴에 따른다.

3. VBR 트래픽의 동적 예측

3.1 동적 예측의 필요성과 예측 기법

저장된 비디오의 경우 트래픽의 정보를 미리 알기 때문에 전송시 각 프레임의 전송 대역폭 할당이 어렵지 않다. 그러나 실시간 비디오의 전송시에는 미래 프레임에 대한 정보가 없으므로 트래픽 스무딩과 같은 대역폭 할당 방법의 적용이 쉽지 않다. 그러므로 프레임 크기의 동적 예측을 통한 동적 대역폭 할당 문제가 해결되어야 한다.

동적 예측을 위해서는 시계열의 여러 예측 기법이 사용될 수 있으나, 본 논문에서는 GOP ARIMA의 상태 공간 모델링 및 칼만 필터 알고리즘을 이용한 예측 방법을 소개한다. 또한 다른 예측 알고리즘(선형 예측법, 이중 지수 평활법)과의 비교 실험을 통해 예측 성능을 확인한다.

선형 예측법은 ARMA, ARIMA, SARIMA(Seasonal ARIMA) 등의 프로세스를 예측하는 방법으로 많이 사용된다. 이 방법을 이용해 GOP ARIMA를 예측할 수 있다. 다음과 같은 GOP ARIMA가 존재할 때,

$$(1-B^s)^d(1-B^S)^D X_t = Y_t \quad (1)$$

$\{X_t\}$ 는 GOP ARIMA 프로세스이며, $\{Y_t\}$ 는 그것을 차분한 ARMA 프로세스이다.

선형 예측법은 현재 시점 이전의 데이터를 기반으로 만들어진 최적의 선형 예측기 $\{P_n\}$ 를 사용한다. 이 선형 예측기는 n 시점 이전 값 $\{1, X_n, X_{n-1}, \dots, X_1\}$ 의 선형 조합으로 최소 평균 제곱 오차를 갖는 N 단계 뒤의 값 X_{n+N} 을 얻는다.

즉,

$$P_n X_{n+N} = a_0 + a_1 X_n + \dots + a_n X_1 \quad (2)$$

식 (1)을 통해 다음과 같은 N 단계 예측 과정을 얻을 수 있으며,

$$X_{n+N} = Y_{n+N} + \sum_{j=1}^{ds+DS} a_j X_{n+N-j} \quad (3)$$

a_j 는 s, S에 대한 ARMA 계수들의 조합이다.

위의 선형 예측기를 통해 GOP ARIMA의 N 단계 예측은 다음과 같다.

$$P_n X_{n+N} = P_n Y_{n+N} + \sum_{j=1}^{ds+DS} a_j P_n X_{n+N-j} \quad (4)$$

이중 지수 평활법(Double Exponential Smoothing-based Prediction, 이하 DESP)은 컴퓨터 그래픽스 분

야의 트래킹 등에서 사용되며 칼만 필터링에 비해 연산량이 적고, 연산 속도가 빠르다는 장점을 가진 예측 알고리즘이다[26].

이중 지수 평활법은 주어진 시계열을 단순한 선형 회귀 방정식(linear regression equation)을 이용해 모델링한다. 시계열 데이터 상의 t 시점의 값을 X_t 라 하고 다음 두 식을 정의한다.

$$\begin{aligned} S_{X_t} &= \alpha X_t + (1-\alpha)S_{X_{t-1}} \\ S_{X_t}^{[2]} &= \alpha S_{X_t} + (1-\alpha)S_{X_{t-1}}^{[2]} \end{aligned} \quad (5)$$

첫 번째 방정식은 실제 트래픽 데이터를 평활하며, 두 번째 방정식은 첫 번째 방정식의 결과를 평활한다. 또한, α 는 현재 시점으로 부터 가까운 데이터에 대한 가중치이다.

$\overrightarrow{S_{X_t}}$ 와 $\overrightarrow{S_{X_t}^{[2]}}$ 를 이용해 다음 식을 유도할 수 있으며,

$$\begin{aligned} b_1(t) &= \frac{\alpha}{1-\alpha}(S_{X_t} - S_{X_t}^{[2]}) \\ b_0(t) &= 2\overrightarrow{S_{X_t}} - \overrightarrow{S_{X_t}^{[2]}} - tb_1(t) \end{aligned} \quad (6)$$

이 방법으로 N 단계 후의 트래픽 값은 다음과 같이 예측할 수 있다. $b_n(t)$ 는 시간 t 시점에서 각각 n 번 예측되는 기울기를 의미한다.

$$X_{t+N} = b_0(t) + b_1(t+N) \quad (7)$$

간단한 연산으로 다음의 예측 식을 얻을 수 있다.

$$X_{t+N} = (2 + \frac{\alpha N}{1-\alpha})S_{X_t} - (1 + \frac{\alpha N}{1-\alpha})S_{X_t}^{[2]} \quad (8)$$

3.2 GOP ARIMA의 상태 공간 모델링

일반적인 상태 공간 모델은 다음의 식으로 표현된다.

$$\begin{aligned} X_{n+1} &= AX_n + V_n \\ Z_n &= HX_n + W_n \end{aligned} \quad (9)$$

위의 두 개의 식은 차례로 (1) Process 방정식과 (2) Measurement 방정식으로 명명된다. 여기서 두 개의 벡터 X , Z 는 각각 시계열상의 임의의 시점에서의 상태를 표현하는 벡터(X)와 그 시점에서 외부로부터 참조할 수 있는 측정값 벡터(Z)를 나타낸다. (1)식은 X 의 한 시점 후를 추정하기 위한 방정식이다. 즉, 시간이 1만큼 경과했을 때 시계열에서의 값을 의미한다. (2)식은 서로 다른 차원의 상태 변수 X 와 측정값 변수의 Z 로의 전이를 위한 방정식이다.

MPEG VBR의 GOP ARIMA 모델은 위와 같은 형태의 상태 공간 모델링이 가능하다. 이 상태 공간 모델을 이용해 후에 칼만 필터링에 적용할 수 있다.

GOP ARIMA의 상태 공간 모델링을 위해 다음과 같은 GOP ARIMA 식을 생각해보자.

$$GOPARIMA(p, d, q)_s \times (P, D, Q)_S \quad (10)$$

p 와 P 는 AR(AutoRegressive) 파라미터, q 와 Q 는

MA(Moving Average) 파라미터이며, d 와 D 는 각각 계절 s 와 S 에 대한 차분 횟수이다.

예를 들어 GOP ARIMA(1,1,1)₃×(1,1,1)₁₅와 같은 GOP ARIMA 식은 X_t 를 VBR 트래픽, Y_t 를 VBR 트래픽이 d 와 D 로 차분된 프로세스라 할 때, VBR 트래픽 X_t 를 계절 15에 대해 1번 차분하고, 계절 3에 대해 1번 차분한 프로세스 Y_t 가 ARMA(15,15)를 따른다는 의미한다(3 및 15 단계의 계수값만 존재하고 나머지는 0인 ARMA 프로세스).

다음 과정을 통해 위 내용을 유도해 보자[25].

1. Auto Regressive 과정

p 와 P 는 각각 1이므로 AR 과정은 다음과 같다.

$$(1 - \phi B^3)(1 - \Phi B^{15})Y_t = \epsilon_t \quad (11)$$

이를 Y_t 에 대해 정리한다.

$$\begin{aligned} Y_t &= \phi Y_{t-3} + \Phi Y_{t-15} - \phi\Phi Y_{t-18} + \epsilon_t \\ Y_{t+1} &= \phi Y_{t-2} + \Phi Y_{t-14} - \phi\Phi Y_{t-17} + \epsilon_{t+1} \end{aligned} \quad (12)$$

2. Moving Average 과정

q 와 Q 가 각각 1인 MA과정은 다음과 같다.

$$Y_t = (1 + \theta B^3)(1 + \Theta B^{15})\epsilon_t \quad (13)$$

이를 Y_t 에 대해 정리한다.

$$Y_t = \theta\epsilon_{t-3} + \Theta\epsilon_{t-15} + \theta\Theta\epsilon_{t-18} + \epsilon_t \quad (14)$$

3. ARMA 과정

위의 AR 과정과 MA 과정을 합하면 다음과 같은 ARMA 과정이 됨을 알 수 있다.

$$\begin{aligned} Y_t &= \theta\epsilon_{t-3} + \Theta\epsilon_{t-15} + \theta\Theta\epsilon_{t-18} + \phi Y_{t-3} \\ &\quad + \Phi Y_{t-15} + \phi\Phi Y_{t-18} + \epsilon_t \end{aligned} \quad (15)$$

4. 차분 과정

Y_t 는 VBR 프로세스인 X_t 를 s 및 S 에 대해 각각 d 와 D 만큼 차분을 한 프로세스이다(여기서 d , D 는 각각 1이며, s 는 3, S 는 15).

$$\begin{aligned} Y_t &= (1 - B^3)(1 - B^{15})X_t \\ Y_t &= X_t - X_{t-3} - X_{t-15} + X_{t-18} \end{aligned} \quad (16)$$

5. 종합

결론적으로 VBR 프로세스의 임의의 시점에서의 값은 다음과 같이 정리된다.

$$\begin{aligned} &+ \Phi Y_{t-15} + \phi\Phi Y_{t-18} + \epsilon_t + X_{t-3} + X_{t-15} \\ &\quad - X_{t-18} \end{aligned} \quad (17)$$

$$X_t = \theta\epsilon_{t-3} + \Theta\epsilon_{t-15} + \theta\Theta\epsilon_{t-18} + \phi Y_{t-3}$$

이를 정리하면 그림 3과 같은 상태 공간 모델 방정식을 만들 수 있다.

3.3 칼만 필터링을 이용한 동적 예측

칼만 필터링은 주어진 상태 공간 모델에 기반해 상태 벡터(X_t)의 한 시점 뒤의 예측값(X_{t+1})과 한 시점뒤에

$$\begin{bmatrix} Y_{t-17} \\ Y_{t-16} \\ \vdots \\ Y_t \\ Y_{t+1} \\ X_{t-17} \\ X_{t-16} \\ \vdots \\ X_{t-2} \\ X_{t-1} \\ X_t \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 \dots & -\rho\theta & \dots & \rho\theta & \dots & \rho & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ \infty & 0 & \dots & \theta & \dots & \theta & 0 & 1 & -1 & 0 & \dots & 1 & 0 \end{bmatrix} \begin{bmatrix} Y_{t-16} \\ Y_{t-17} \\ \vdots \\ Y_t \\ Y_{t+1} \\ X_{t-16} \\ X_{t-17} \\ \vdots \\ X_{t-2} \\ X_{t-1} \\ X_{t+1} \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ \epsilon_{t+1} \\ 0 \\ 0 \\ \vdots \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

$$[X_t] = [\infty \ 0 \ \dots \ \theta \ \dots \ \theta \ 0 \ 1 \ -1 \ 0 \ \dots \ 1 \ 0] \begin{bmatrix} Y_{t-16} \\ Y_{t-17} \\ \vdots \\ Y_t \\ Y_{t+1} \\ X_{t-16} \\ X_{t-17} \\ \vdots \\ X_{t-2} \\ X_{t-1} \\ X_{t+1} \end{bmatrix}$$

그림 3 상태 공간 방정식

실제로 외부로부터의 측정값(Z_{t+1})과의 오차를 보정하여 새로운 예측값을 얻어내는 과정이다.

칼만 필터링 과정은 앞 장에서 만들어진 상태 공간 모델을 이용해 수행되며, 여기서의 상태 벡터는 현재 시점으로 부터 임의의 시점 만큼 앞선 VBR 트래픽의 데이터($Y_{t-p}, \dots, Y_{t-2}, Y_{t-1}$)들과 그 차분값들($X_{t-p}, \dots, X_{t-2}, X_{t-1}$)의 조합으로 구성된다. 측정값은 예측의 대상이 되는 VBR 트래픽의 값이 사용된다.

예측 오차는 다음과 같이 예측된 상태 벡터와 실제 트래픽의 상태 벡터와의 차이로 정의된다.

$$e_n = X_n - \hat{X}_n \quad (18)$$

칼만 필터는 트래픽 시퀀스에 기반해 다음과 같이 평균 제곱 오차(Mean Square Error)를 최소화하고, 오차의 공분산을 최소화하는 최적 예측기로서 사용된다.

$$P_k = E\{e_k e_k^T\} \quad (19)$$

칼만 필터 알고리즘은 다음의 과정을 통해 그림 4와 같이 예측과 보정을 반복하며 동작한다.

1. 초기 상태 벡터와 공분산의 입력

초기 상태 벡터(\hat{X}_0)와 오차 공분산(\hat{P}_0)을 입력한다. 오차 공분산은 알고리즘의 신뢰 수준을 나타낸다(변수위에 쓰인 모자 기호는 이 값이 예측되어진 값을 의미한다).

2. 칼만 이득 벡터의 계산

다음 과정으로 아래 식과 같이 측정값 전이 벡터(Measurement 방정식의 H 벡터)와 오차 공분산의 연산으로 오차 공분산을 최소화하는 칼만 이득 벡터(Kalman Gain, K_n)를 얻는다.

$$K_k = P_k^- H^T (W + H P_k^- H^T)^{-1} \quad (20)$$

3. 측정값을 통한 상태 벡터의 보정

t-1 시점에 예측되었던 t 시점의 값(\hat{X}_t^-)은 t 시점이

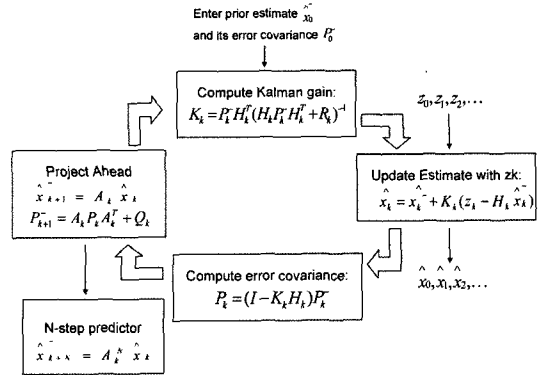


그림 4 칼만 필터 알고리즘

되면 과거의 예측값이 된다(priori estimation, 변수 위의 '-' 기호는 이 예측값임을 의미한다). t 시점에는 실제 측정값을 얻을 수 있는데, 이 값과 칼만 이득값을 통해 t 시점의 보정된 예측값을 얻을 수 있다(posteriori estimation).

$$\hat{X}_k = \hat{X}_k^- + K_k (Z_k - H_k \hat{X}_k^-) \quad (21)$$

4. 오차 공분산의 보정

상태 벡터의 보정과 마찬가지로 칼만 이득을 이용해 보정된 오차 공분산을 구한다.

$$P_k = [I - K_k H] P_k^- \quad (22)$$

5. 상태 벡터 및 공분산의 예측

보정된 상태 벡터와 오차 공분산은 Process 방정식을 통해 1 단계 후의 값을 예측하게 된다(priori estimation).

$$\hat{X}_{k+1}^- = A_k \hat{X}_k \quad (23)$$

$$P_{k+1}^- = A_k P_k A_k^T + Q_k \quad (23)$$

한 시점 후의 상태 벡터를 예측하는 칼만 필터의 반복 연산을 통해 우리는 N 시점 후의 상태 벡터 및 트래픽을 예측할 수 있다. 그림 4의 N-step Predictor가 그 역할을 담당한다.

3.4 예측 알고리즘의 복잡도

실제 응용을 위해서는 알고리즘의 복잡도를 고려해야 한다. 칼만 필터 기반 예측 알고리즘은 고차원의 상태 벡터와 상태값 전이 행렬(Process 방정식의 A 행렬)의 연산에도 불구하고 많은 양의 메모리와 계산 시간을 요구하지 않는다.

칼만 필터 기반 예측 알고리즘에는 몇 가지 중요한 벡터: 상태값 전이 행렬(Process Matrix), 상태 벡터, 측정값 전이 행렬(Measurement Matrix)이 있다. 특히 상태 벡터의 크기는 계산 복잡도에 큰 영향을 준다. 칼만 필터 알고리즘에서 상태 벡터의 크기는 차분 계수(d와 D), 그리고 계절 계수(s와 S)에 의해 좌우되며, $O(2(sd+SD)+1)$ 의 차수를 가진다. 예를 들어 GOP

ARIMA(1,1,1)₃×(1,1,1)₁₅의 상태 벡터의 차수는 37이 된다. 그러므로 이 상태 벡터를 상태 전이 벡터로 전이할 때의 이론적인 복잡도는 $(2(sd+SD)+1)^2$ 이 되며 이는 실제 적용하기에는 어려운 수준이다. 그러나 그림 3의 상태 공간 방정식에서 상태 전이 행렬의 행과 열은 상태 벡터를 한 단계 전이시키는 연산이며, 이는 구현상의 기법으로 복잡도를 제거할 수 있다. 그리고 실제 복잡도를 증가시킬 연산은 상태 벡터의 행 가운데 Y_t 와 X_{t-1} 을 Y_{t+1} 과 X_t 로 전이시키는 부분에만 존재함을 알 수 있다. 그러므로 연산에서 예측을 위한 실제 복잡도는 $O(pP + qQ)$ 이내이며, 실험상 p, P, q, Q 값은 보통 0 또는 1임을 확인하였다. 칼만 필터 기반 예측 알고리즘의 나머지 영역인 칼만 이득 계산, 오차 보정 등은 상대적으로 복잡도가 떨어진다.

결론적으로 고차원의 상태 전이 행렬의 존재에도 불구하고, 칼만 필터의 실제 계산 부하는 매우 작고, 실제 적용에 무리가 없다.

4. 장면 전환과 통계적 특성

4.1 장면 분포 및 통계적 특성 분석

GOP ARIMA는 여러 종류의 VBR 트래픽(드라마, 뉴스, 스포츠 등)의 통계적 특성을 잘 설명한다[18]. 즉, 드라마에는 드라마에 맞는 GOP ARIMA 모델이, 뉴스나 스포츠 역시 각각에 적합한 GOP ARIMA 모델이 존재한다. 그러므로 하나의 비디오는 크게 하나의 GOP ARIMA 모델로 표현될 수 있다.

한편, 같은 콘텐츠의 비디오라 하더라도 전체의 비디오가 한 장면으로 이루어진 경우는 거의 없다. 즉, 장면 전환이 일어난다. 장면 길이(scene duration)은 수 초 이상의 평균 지속시간을 갖고 있다[11]. 표 2는 화면 관찰을 통한 실험 비디오의 총 길이와 장면 전환 횟수, 평균 장면별 길이에 대한 정보를 나타낸다. 또한 그림 5, 6, 7은 각각 드라마, 뉴스, 스포츠 비디오의 장면 전환을 트래픽 관점에서 관찰한 것이다. 이 관찰을 통해 장면별로 트래픽의 형태가 변화하는 것을 확인할 수 있다. 이는 곧 장면별로 다른 통계적 특성을 가질 수 있음을 의미한다.

데이터의 일부를 통해 생성된 GOP ARIMA 모델을

표 2 비디오 트레이스의 장면 변화 분포

Video	Video Length(sec)	Scene Change	Average Scene Length(min:sec)
Drama 1	350	7	0:49
Drama 2	357	6	0:58
News 1	357	36	0:08
News 2	359	38	0:08
Sports	355	26	0:12




그림 5 드라마 트래픽의 장면 전환 분포

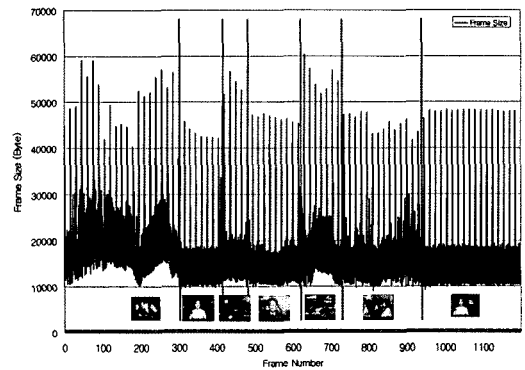


그림 6 뉴스 트래픽의 장면 전환 분포




그림 7 스포츠 트래픽의 장면 전환 분포

이용해 해당 비디오의 트래픽을 예측할 때, 미래의 트래픽의 통계적인 특성이 바뀐다면 기존 모델을 사용한 예측에서는 오차가 발생할 수 있다. 예를 들어 스포츠 뉴스 프로그램을 생각해 보면, 뉴스 프로그램내의 앵커가 말하는 장면에서 스포츠 뉴스의 장면으로 넘어갈 때, 두 장면(뉴스와 스포츠)의 통계적 특성이 다를 수 있다. 즉, 첫 번째 장면에 대한 GOP ARIMA 모델은 두 번째 장면에 적용될 때 오차를 발생시킬 수 있다.

표 3, 4, 5는 각각 드라마, 뉴스, 스포츠 비디오의 장면별 통계적 특성 및 GOP ARIMA 모델이 다름을 보여준다. 또한 그림 8은 실제 장면 전환 시점에서의 예측 오차를 보여준다. 타원으로 표시된 부분은 스포츠 비디오의 첫 번째 장면의 GOP ARIMA 모델을 이용해 만든 상태 공간 모델을 기반으로 칼만 필터링을 이용해 30 단계 예측했을 때, 장면 전환 시점에서 예측값과 실제값 간의 오차를 평균-제곱오차(MSE, Mean Square Error)값을 나타낸다.

표 3 드라마 트래픽의 장면별 통계적 특성

Scene	mean (Byte)	Variance (Byte ²)	GOP ARIMA model
Scene 1	15942	73789957	GOP ARIMA (0,1,1) ₃ ×(0,1,1) ₁₅
Scene 2	20013	101219155	GOP ARIMA (2,1,0) ₃ ×(0,1,1) ₁₅

표 4 뉴스 트래픽의 장면별 통계적 특성

Scene	mean (Byte)	Variance (Byte ²)	GOP ARIMA model
Scene 1	19938	102360999	GOP ARIMA (0,1,1) ₃ ×(0,1,1) ₁₅
Scene 2	15082	72029727	GOP ARIMA (0,1,1) ₃ ×(0,1,0) ₁₅
Scene 3	16910	115799842	GOP ARIMA (0,1,1) ₃ ×(0,1,0) ₁₅
Scene 4	15593	83766902	GOP ARIMA (0,1,1) ₃ ×(0,1,0) ₁₅
Scene 5	18189	126855131	GOP ARIMA (0,1,0) ₃ ×(0,1,0) ₁₅
Scene 6	16490	82708781	GOP ARIMA (0,0,0) ₃ ×(0,1,1) ₁₅
Scene 7	15173	90282004	GOP ARIMA (0,1,1) ₃ ×(0,1,0) ₁₅

표 5 스포츠 트래픽의 장면별 통계적 특성

Scene	mean (Byte)	Variance (Byte ²)	GOP ARIMA model
Scene 1	16895	32120504	GOP ARIMA (1,1,0) ₃ ×(0,1,1) ₁₅
Scene 2	16411	62367342	GOP ARIMA (2,1,0) ₃ ×(0,1,1) ₁₅
Scene 3	16137	35629539	GOP ARIMA (1,1,0) ₃ ×(0,1,1) ₁₅
Scene 4	16934	58407209	GOP ARIMA (0,1,1) ₃ ×(0,1,1) ₁₅

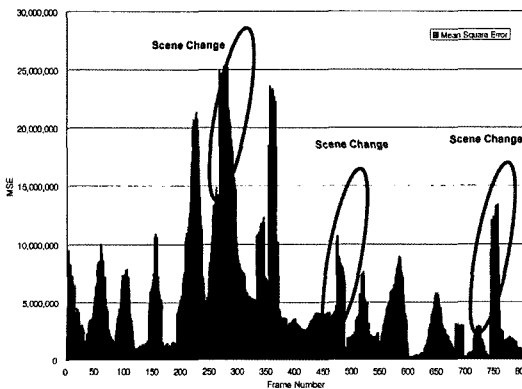


그림 8 스포츠 트래픽의 장면 전환시 오차

그러나 이 그래프에서 볼 수 있는 사실은 한 순간 큰 오차가 발생하더라도 그 오차가 급격히 감소하는 것이다. 그 이유는 칼만 필터 기반 예측 알고리즘이 예측 할 때마다 실제 값의 입력을 통해, 즉 큰 오차가 반영된 보정된 예측값을 얻어내기 때문이다. 또한 장면 사이의 GOP ARIMA 모델은 다르더라도 기본적으로 비슷한 콘텐츠의 비디오이기 때문에 GOP ARIMA 모델의 변경, 즉 예측기의 변경 없이 예측을 할 수 있다. 그러나 비디오 트래픽 내부에서 콘텐츠의 성격이 크게 변화하는 경우에는 장면 전환을 감지하여 GOP ARIMA 모델을 변경하고, 재 예측 과정을 거쳐야 할 것이다.

또한 본 환경이 실시간 환경이란 사실에 주목해야 한다. 저장된 비디오의 경우 비디오 데이터를 디코딩 해 장면 변화를 찾아낼 수 있지만, 이러한 작업은 압축된 비디오를 디코딩해서 장면 전환을 감지할 때 많은 시간을 소요하므로 실시간 환경에서는 적절치 않다. 즉, 디코딩을 하지 않고 실시간으로 장면 변화를 감지하는 방법을 필요로 한다.

4.2 장면 전환의 감지

임의의 개수의 표본을 통해 얻은 표본 집단의 평균, 분산 등을 이용해 그 표본이 속하는 모집단의 평균을 유추할 수 있다. 이 때 유추된 평균값은 임의의 구간 내에 존재하게 되며, 그 구간에 유추값이 실제로 존재할지에 대한 확률을 갖게 된다. 이 구간을 신뢰 구간, 확률을 신뢰도라고 하며, 이와 같이 표본 집단을 통해 모집단의 특성을 유추하는 방법을 신뢰구간 분석법이라고 한다. 신뢰도는 통상 95%와 99%를 사용하며, 이는 전체 유추값 대비 95% 또는 99%의 확률로 신뢰 구간에 유추값이 속할 확률을 의미한다.

GOP ARIMA는 VBR 트래픽의 통계적 특성을 모델링한 것이며, 같은 GOP ARIMA 모델은 같은 통계적 특성을 갖는다. 그러므로 같은 GOP ARIMA 모델은 같은 신뢰 구간을 가지며, 장면 전환시에는 통계적 특성의 변화와 함께 신뢰 구간의 변화가 일어나게 된다. 또한 장면 전환 시에 트래픽의 크기가 변화하게 되는데 이 트래픽의 크기는 기존 신뢰 구간을 벗어나게 되고 이를 통해 장면 전환을 감지할 수 있다.

그림 6은 뉴스 비디오 트래픽이다. 각각의 장면은 서로 다른 GOP ARIMA 모델을 가지고 있을 것이며, 각 장면들의 I, B, P 각 프레임들은 서로 다른 신뢰 구간을 가질 것이다. 그림 9, 10, 11은 뉴스 트래픽에서 장면 전환이 일어나는 한 시점을 찾아, 해당 기간 동안 각 프레임의 95% 신뢰 구간을 나타내었다.

각 그림에서는 장면 전환이 일어나는 부분(그림 9의 20번째 프레임, 그림 10에서 80번째 프레임, 그림 11에서 200번째 프레임) 이후로 새로운 장면의 트래픽이 기




그림 9 뉴스 트래픽의 장면 전환시 I프레임의 95% 신뢰구간




그림 10 뉴스 트래픽의 장면 전환시 P프레임의 95% 신뢰구간







그림 11 뉴스 트래픽의 장면 전환시 B프레임의 95% 신뢰구간



(a) 드라마 트래픽



(b) 뉴스 트래픽



(c) 스포츠 트래픽

그림 12 실험 대상 MPEG 트래픽

존 장면의 신뢰 구간을 벗어나는 빈도가 많아지는 것을 확인할 수 있다. 이는 신뢰 구간을 벗어나는 빈도 및 정도에 대한 기준 설정을 통해 장면 전환을 감지할 수 있음을 보여 준다.

5. 실험

5.1 실험 환경

본 실험에는 MPEG으로 압축된 비디오 트래픽을 예측하기 위해 선형 예측 방법과 이중 지수 평활법, 그리고 칼만 필터 기반 예측 알고리즘을 사용한다. 위 예측

알고리즘의 성능은 실제 VBR 비디오 트래픽의 프레임 크기와 그 것을 예측한 값과의 비교를 통해 확인할 수 있다. 사용된 실제 VBR 트래픽은 MPEG2 인코더를 사용해 초당 30 프레임으로 압축된 세 가지 성격의 비디오 트래픽, “드라마”, “뉴스”, “스포츠”이다. 세 가지 트래픽은 평균, 최대, 최소 비트율이 각각 4Mbps, 9Mbps, 1.5Mbps로 압축되었으며, GOP 패턴은 IBBPBBPBBPBBPBB (GOP 크기는 15)로 제작되었다. 그림 12는 실험에 사용된 세 가지 트래픽의 형태를 보여 준다.

실험에 앞서 예측 성능 평가는 정규화된 평균 제곱

오차(NMSE, normalized mean squared error)를 사용하며, 다음과 같이 정의된다.

$$NMSE = \frac{1}{\sigma^2} \frac{1}{N} \sum [x(t) - \hat{x}(t)]^2 \quad (24)$$

$x(t)$ 는 t 시점에서 관찰되는 시계열의 값이며, $\hat{x}(t)$ 는 같은 시점에서 $x(t)$ 에 대한 예측값이다. 또한 σ^2 은 예측 기간 내의 시계열의 분산이다. NMSE는 다단계 예측 알고리즘의 성능 평가시에 널리 사용된다. NMSE값이 0인 경우는 오차 없는 완벽한 예측기를 의미한다. 또한 실제 트래픽의 통계적 평균값을 예측값으로 사용하는 경우 NMSE 값은 1이 된다. NMSE가 1이상일 경우는 예측기의 성능이 평균 이하라는 것을 의미한다.

5.2 예측 알고리즘의 성능 비교

본 실험에서는 세 가지 알고리즘(선형 예측법, 이중 지수 평활법, 칼만 필터 기반 예측법)으로 예측한 결과의 정확도를 비교하였다. 세 가지 종류의 트래픽(뉴스, 드라마, 스포츠)에 대해 각각 15단계부터 120단계 후까지의 프레임 크기 예측이 수행되었으며, 예측 후 실제 프레임 크기와의 오차를 기반으로 성능을 분석하였다. 실험에 사용된 트래픽 데이터는 초당 30 프레임으로 압축되었으므로, 120단계 예측은 4초 분량의 데이터를 의미한다.

선형 예측법과 이중 지수 평활법은 3장에서 소개한 식을 기반으로 구현되었고, 칼만 필터 기반 예측법은 세 가지 종류의 트래픽의 초반 90개의 샘플로 만든 GOP ARIMA 모델을 3장에서 유도한 방법으로 상태 공간 모델링을 한 후 칼만 필터 기반 예측 알고리즘을 이용해 예측하였다. 다음은 각 트래픽의 GOP ARIMA 모델식이다.

[드라마] $(1 - B^{15})X_t = (1 - 0.63B^{15})\epsilon_t,$

$$\sigma^2 = (2030.6)^2$$

[뉴스] $(1 - B^{15})X_t = (1 - 0.41B^{15})\epsilon_t,$

$$\sigma^2 = (2314.3)^2$$

[스포츠]

$$(1 - 0.514B^3 - 0.405B^6)(1 - B^3)(1 - B^{15})X_t$$

$$= (1 - 0.98B^{15})\epsilon_t, \quad \sigma^2 = (1795.5)^2$$

그림 13과 14는 선형 예측법과 이중 지수 평활법으로 드라마 비디오를 60단계 예측한 후, 예측값과 실제값을 비교한 것이다. 각 그래프의 X 축은 프레임 번호를 나타내며, Y축은 프레임 데이터의 크기를 나타낸다. 또한 실선은 프레임 데이터의 실제값을, 점선은 예측값을 나타낸다. 선형 예측법과 이중 지수 평활법은 예측 과정에서 오차를 실시간으로 보정하지 않으므로, 트래픽 변화에 적용하지 못하여, 예측 오차가 나타남을 확인할 수 있다. 반면 칼만 필터 기반 예측법은 그림 15에서 확




그림 13 선형 예측법을 이용한 드라마 트래픽의 60단계 예측




그림 14 이중 지수 평활법을 이용한 드라마 트래픽의 60단계 예측




그림 15 칼만 필터를 이용한 드라마 트래픽의 60단계 예측

인할 수 있듯이 실제 트래픽 데이터의 크기와 예측값의 차이가 크지 않음을 볼 수 있다.

그림 16은 예측 단계 대비 NMSE 값의 비교를 통해 세 가지 예측 알고리즘의 성능을 비교한다. 세 알고리즘 모두 예측 단계가 증가함에 따라 예측 오차가 커짐을 확인할 수 있으며 칼만 필터 기반 예측 알고리즘에 의한 예측 성능이 선형 예측법과 이중 지수 평활법에 비해 우수한 성능을 보임을 확인할 수 있다.




그림 16 세 가지 알고리즘의 성능 비교

6. 결론

본 연구에서는 MPEG으로 압축된 VBR 비디오 트래픽을 실시간으로 예측하기 위하여 칼만 필터 알고리즘을 제안하였다. 기존 연구 방법에서는 VBR 트래픽을 정확히 표현한 모델을 사용하지 않았고, 비디오의 진행 시 발생하는 노이즈에 대한 적응과 장시간 예측에 취약한 문제가 있었다.

본 연구에서 사용된 GOP ARIMA 모델은 VBR 트래픽의 LRD 특성 및 non-stationary 특성을 정확히 모델링하였고, 이 모델의 상태-공간 모델을 통해 칼만 필터 알고리즘을 적용 하였다. 또한 칼만 필터 알고리즘은 실시간으로 입력 받는 프레임 데이터를 통해 자체적으로 상태 공간 모델을 보정하며 오차를 최소화 하는 예측을 수행한다. 이로써 장면 전환과 급격한 노이즈 같은 통계적 특성 변화에 대한 적응력을 높이고, 또한 수 초간의 장시간 예측이 가능함을 확인할 수 있었다. 또한 칼만 필터 알고리즘에 신뢰 구간 분석법을 도입하여 통계적 특성의 변화가 아주 큰 비디오 입력의 경우 장면 전환을 인식하여 GOP ARIMA 재 모델링에 사용될 수 있는 알고리즘을 제안하였다.

실험은 다양한 통계적 특성을 가진 비디오 트래픽을 제작하여, 칼만 필터를 이용한 트래픽의 예측 결과를 선형 예측법과 이중 지수 평활법을 이용해 예측한 결과와 비교해 예측 성능이 상대적으로 우수함을 확인하였다. 또한 칼만 필터 알고리즘에 신뢰 구간 분석법을 결합해 트래픽 관점에서 장면 전환을 예측하는 방법을 제시하였다.


본 논문의 칼만 필터 기반의 예측 알고리즘은 MPEG 기반 VBR 트래픽을 실시간 예측 방법을 제시하였고, 이 연구의 결과는 실시간 멀티미디어 서비스를 위한 인터넷 서버의 설계 및 자원 할당 정책을 위한 트래픽 엔지니어링 연구 및 사용자의 QoS 극대화에 기여할 것이다. 또한 향후 출현할 새로운 트래픽 특성을 가질 인터

넷 서비스를 위한 시스템 및 네트워크 측면의 트래픽 모델링과 예측 기법 개발 연구에도 크게 기여할 것으로 확신한다.

참고 문헌

- [1] V. Frost and B. Melamed, "Traffic Modeling for Telecommunications Networks," IEEE Communications Magazine, pp. 70-81, Mar., 1994.
- [2] M. Krunz and S. K. Tripathi, "On the characterization of VBR MPEG Streams," ACM SIGMETRICS Performance Eval. Rev., Vol. 25, pp. 192-202, June, 1997.
- [3] A. Adas, "Traffic Models in Broadband Networks," IEEE Communications Magazine, pp. 82-89, July, 1997.
- [4] W. Willinger, D. V. Wilson and E. Leland, "On the Self-Similarity Nature of Ethernet Traffic," IEEE/ACM Trans. on Networking, Vol. 2, pp. 1-15, Jan., 1994.
- [5] M. S. Taqqu, W. Willinger, J. Beran and R. Sherman, "Long-Range Dependency in Variable-Bit-Rate Video Traffic," IEEE Trans. on Communication, Vol. 43, pp. 1566-1579, Mar., 1995.
- [6] Yao Liang, "Real-time VBR Video Traffic Prediction for Dynamic Bandwidth Allocation," IEEE Trans. on Systems, Vol. 34, No. 1, pp. 32-47, Feb., 2004.
- [7] Marwan Krunz and Herman Hughes, "A Traffic Model for Mpeg-Coded VBR Streams," ACM SIGMETRICS 95, pp. 47-55, 1995.
- [8] Bor-Sen Chen, Sen-Chueh Peng and Ku-Chen Wang, "Traffic Modeling, Prediction, and Congestion Control for High-Speed Network: A Fuzzy AR Approach," IEEE/ACM Trans. on Fuzzy System, Vol. 8, No. 5, pp. 491-508, Oct., 2000.
- [9] B. Melamed and D. E. Pendarakis, "Modeling Full-Length VBR Video using Markov-Renewal-Modulated TES Models," IEEE/ACM Trans. on Networking, Vol. 5, pp. 600-612, 1997.
- [10] B. Maglaris, "Performance Models of Statistical Multiplexing in Packet Video Communications," IEEE Journal of Selected Areas in Communications, Vol. 36, pp. 834-844, July, 1988
- [11] Heyman D. P and Lakshman T. V., "Source Models for VBR Broadcasting Video Traffic," IEEE/ACM Trans. on Networking, Vol. 4, No. 1, pp. 40-48, Feb., 1996.
- [12] J. P. Cosmos, A. Odinma-Okafor, R. Grunenfelder and S. Manthorpe, "Characterization on Video Codex as Auto Regressive Moving Average Process and Related Queuing System Performance," IEEE Journal on Selected Areas in Communications, Vol. 9, pp. 284-293, Apr., 1991.
- [13] Nirwan Ansari, Yun Q. Shi and Hai Liu, "Mode-

- ling MPEG Coded Video Traffic by Markov-Modulated Self-Similar Process," Journal of VLSI Signal Processing, Vol. 29, pp. 101-113, 2001.
- [14] David Tipper, Deep Medhi and Y. Qian, "A Nonstationary Analysis of Bandwidth Access Control Schemes for Heterogeneous Traffic in B-ISDN," Proc. of Infocom 96, pp. 730-737, 1996.
- [15] W. Wang, D. Tipper and S. Banerjee, "A Simple Approximation for Modeling Nonstationary Queues," Proc. of Infocom 96, pp. 255-262, 1996.
- [16] D. P. Heyman, "The GBAR Source Model for VBR Videoconferences," IEEE/ACM Trans. on Networking, Vol. 5, pp. 554-560, 1997.
- [17] Michael Frey and Son Nguyen-Quang, "A Gamma-based Framework for Modeling Variable-Rate MPEG Video Sources: The GOP GBAR Model," IEEE/ACM Trans. on Networking, Vol. 8, No. 6, pp. 710-719, 2000.
- [18] Youjip Won, Soohan Ahn and Jungwoo Jeon, "Performance Analysis of Non-Stationary Model for Empirical VBR Process," Globecom 01, 2001.
- [19] S. Chong and S. Li, J. Ghosh, "Efficient Transport of Real Time VBR Video over ATM via Dynamic Bandwidth Allocation," IEEE Journal of Selected Areas in Communication, Vol. 13, pp. 12-23, Jan., 1995.
- [20] X. Wang, S. Jung and J. Meditch, "Dynamic Bandwidth Allocation for VBR Video Traffic using Adaptive Wavelet Prediction," Proc. of IEEE International Conference on Communication, Vol. 1, pp. 549-553, 1998.
- [21] A. Adas, "Using Adaptive Linear Prediction to Support Real-Time VBR Video under RCBR Network Service Model," IEEE/ACM Trans. on Networking, Vol. 6, pp. 635-644, Oct., 1998
- [22] J. Hall and P. Mars, "Limitations of Artificial Neural Networks for Traffic Prediction in Broadband Networks," Proc. of International Conference on Elec. Eng., Vol. 147, pp. 114-118, Apr., 2000.
- [23] P. Chang and J. Hu, "Optimal Nonlinear Adaptive Prediction and Modeling of MPEG Video in ATM Networks using Pipelined Recurrent Neural Networks," IEEE Journal of Selected Areas Communications, Vol. 15, pp. 1087-1100, Aug., 1997.
- [24] Aninda Bhattachary, Alexander G. Parlos and Amir F. Atiya, "Prediction of MPEG-coded Video Source Traffic using Recurrent neural network," IEEE Trans. on Signal Processing, Vol. 51, No. 8, pp. 2177-2190, Aug., 2003.
- [25] Peter J. Brockwell and Richard A. Davis, "Introduction to Time Series and Forecasting," Springer.
- [26] Laviola Jr and Joseph J, "Double Exponential Smoothing: An Alternative to Kalman Filter-based Predictive Tracking," The Eurographics Assosiation, 2003.



강 성 주

2003년 한양대학교 전자전기공학부 졸업(학사). 2005년 한양대학교 전자통신전파공학과 졸업(석사). 2005년~현재 한국전자통신연구원 연구원. 관심분야는 Web 2.0, Software as a Service, 멀티미디어 스트리밍



원 유 집

1990년 서울대학교 계산통계학과 졸업(학사). 1992년 서울대학교 전산학과 졸업(석사). 1997년 University of Minnesota 졸업(박사). 1997년 9월~1992년 2월 Intel 연구원 1999년 3월~현재 한양대학교 전자통신컴퓨터 공학부 부교수
관심분야는 운영체제, 컴퓨터네트워크, 성능평가



성 병 찬

서울대학교 계산통계학과 졸업(이학사)
서울대학교 대학원 계산통계학과 졸업(이학석사, 통계학 이학박사). 미국 워싱턴 주립대학교 경영학과 박사후과정, 포항공과대학교 수학과 방문조교수. 현재 중앙대학교 통계학과 조교수