

비주얼 센서 네트워크에서 트래픽 예측 방법

박상현*

Traffic Estimation Method for Visual Sensor Networks

Sang-Hyun Park*

요 약

최근 비주얼 센서 기술의 발달로 센서 네트워크에 영상을 추가하기 위한 다양한 연구가 진행되고 있다. 비주얼 센서는 다른 센서 정보에 비해 데이터가 크기 때문에 데이터의 크기를 효율적으로 관리하는 것이 무엇보다 중요하다. 본 논문에서는 효과적인 데이터 관리에 필요한 비디오 트래픽 예측 방법을 제안한다. 제안하는 방법은 비디오 센서에서 획득되는 영상의 특성을 반영하여 1차 AR 모델로 비디오 트래픽을 모델링하고 칼만 필터 알고리즘을 적용하여 트래픽을 예측한다. 제안하는 방법은 계산량이 많지 않아 센서 노드에 적용되기 적합하다. 실험 결과는 제안하는 방법이 비교적 간단한 형태이지만 전체 평균 트래픽의 1% 이내로 오차로 정확하게 트래픽을 예측하는 것을 보여준다.

ABSTRACT

Recent development in visual sensor technologies has encouraged various researches on adding imaging capabilities to sensor networks. Video data are bigger than other sensor data, so it is essential to manage the amount of image data efficiently. In this paper, a new method of video traffic estimation is proposed for efficient traffic management of visual sensor networks. In the proposed method, a first order autoregressive model is used for modeling the traffic with the consideration of the characteristics of video traffics acquired from visual sensors, and a Kalman filter algorithm is used to estimate the amount of video traffics. The proposed method is computationally simple, so it is proper to be applied to sensor nodes. It is shown by experimental results that the proposed method is simple but estimate the video traffics exactly by less than 1% of the average.

키워드

Visual Sensor Network, Traffic Modeling, Traffic Estimation, Video Traffic Management
비주얼 센서 네트워크, 트래픽 모델링, 트래픽 예측, 비디오 트래픽 관리

1. 서론

센서 네트워크는 다양한 응용분야에 다양하게 이용될 수 있는 기술로 이에 대한 많은 연구가 이루어졌고 이를 실제로 적용하기 위한 노력도 많이 이루어져서 현재는 기술적으로 많이 성숙한 단계에 이르렀다

[1]. 센서 네트워크는 기본적으로 센서가 설치된 주위의 물리적인 현상을 센서의 기능에 따라 측정하고 이 데이터를 전송하여 데이터를 수집할 수 있게 하는 네트워크이다. 일반적으로 센서 네트워크에서는 많은 센서들이 상호 무선 통신을 통해 망을 구성하는 Ad-hoc 방식으로 연결되며 각 센서는 전력 소모를

* 교신저자: 순천대학교 멀티미디어공학과

• 접수일 : 2016. 10. 04
• 수정완료일 : 2016. 11. 13
• 게재확정일 : 2016. 11. 24

• Received : Oct. 04, 2016, Revised : Nov. 13, 2016, Accepted : Nov. 24, 2016

• Corresponding Author : Sanghyun Park
Dept. of Multimedia Engineering, Sunchon National University,
Email : shark@schnu.ac.kr

최소로 하는 시스템 구성을 가지기 때문에 센서 네트워크는 큰 용량의 데이터를 전송하는 데는 적합하지 않다. 따라서 주로 온도, 습도 등의 비교적 간단한 형태의 데이터를 수집하는 용도로 주로 연구 및 개발되어 왔다[2].

기존의 센서 네트워크 활용분야에 원격감시와 같은 영상을 이용한 분야를 포함하고자 하는 노력도 꾸준히 진행되었다. 이를 위해서는 비교적 큰 데이터를 처리하는 비주얼 센서에 대한 연구가 필수적이다. 센서는 기본적으로 한번 설치되면 장시간 동작하여야 하는데 비주얼 센서의 경우 영상을 캡처하고 이를 압축하여 전송하는데 많은 계산이 필요하기 때문에 센서의 수명이 항상 문제가 되었다. 하지만 해변 침식 및 자연 재해 감시, 동물 관찰 등의 응용을 위한 연구에서 태양광을 이용한 전력 공급 방식이 제안되면서 비주얼 센서의 전력에 대한 문제는 어느 정도 해소되었다. 또한 저렴한 CMOS 카메라가 상용화되면서 센서의 가격도 낮아지고 있다. 따라서 다양한 비주얼 센서 네트워크 (Visual Sensor Network : VSN) 플랫폼들이 제안되고 있다[1-3].

VSN은 전력 소비에 매우 민감하기 때문에 전력 소비량에 따라 VSN 플랫폼을 구분해 보면 세 가지 정도로 나눌 수 있는데, 전력 소모를 최소화한 저전력 플랫폼과 전력 소모가 많은 PDA급 플랫폼, 그리고 전력 소모가 중간 정도인 중간 단계 플랫폼으로 나눌 수 있다. 전력이 비교적 안정적으로 공급되는 환경에서 사용되는 PDA급 플랫폼에서는 실시간 스트리밍까지 가능한 사용으로 플랫폼이 구성된다. 반면 저전력 플랫폼은 비교적 긴 시간을 주기로 센서가 깨어나 영상을 촬영하고 전송하는 형태로 전력의 소모를 최소화한다. 중간 단계 플랫폼은 실시간 스트리밍까지는 아니지만 센서가 설치된 환경의 영상을 실시간으로 확인할 수 있는 정도의 영상을 제공한다[1-4].

본 논문에서는 센서가 설치된 지역의 상황을 실시간으로 제공해주는 중간 단계 플랫폼을 대상으로 센서가 영상을 압축할 때 필요한 압축 영상의 트래픽 양을 예측하는 방법을 제안한다. 센서는 센서 네트워크에서 하나의 노드로 다른 센서의 데이터를 전송하는 기능도 포함되기 때문에 트래픽에 대한 정확한 예측은 전체 센서 네트워크의 성능에 영향을 미치게 된다. 제안하는 방법에서는 비주얼 센서 네트워크의 특

성을 고려한 트래픽 모델을 사용하고 이 모델에 칼만 필터 알고리즘을 적용하여 트래픽의 양을 예측한다.

본 논문의 구성은 다음과 같다. 2장에서는 제안하는 방법에서 사용하는 비주얼 센서 네트워크 플랫폼의 특성과 고려점을 설명한다. 3장에서는 제안하는 방법에 적용된 트래픽 모델과 이를 이용한 예측 방법을 설명하고, 4장에서는 제안하는 알고리즘의 성능을 분석한다. 마지막으로 5장에서 결론을 맺는다.

II. 관련 연구

VSN은 다양한 기술이 복합적으로 사용된다. 저전력을 필요로 하는 비디오 카메라 기술, 각 노드를 연결하는 최적의 라우팅 기술을 포함한 센서 네트워킹 기술, 태양광을 이용한 전력 생산 기술 등이 복합적으로 적용된다. 뿐만 아니라 영상은 데이터가 크기 때문에 획득된 영상을 압축하고 스트리밍 하는 기술도 중요한 요소이다.




그림 1. VSN의 일반적인 형태
Fig. 1 General structure of VSN

일반적으로 VSN은 노드와 게이트웨이로 구성되면 각 노드는 무선 통신을 통해 정보를 주고받는다. 여기서 노드는 비디오 센서를 의미하며 각 비디오 센서는 무선 네트워크를 구성하는 부분과 저전력 비디오 카메라로 구성된다. 각 노드는 영상을 획득하여 무선 링크를 통해 데이터를 전달한다. VSN의 네트워크 형태는 그림 1과 같다. 각 노드는 자신이 캡처한 영상뿐만 아니라 다른 노드에서 획득된 영상도 게이트웨이로 전달하게 된다. 여기서 게이트웨이는 이렇게 수집된 영상을 활용하기 위해 외부 망으로 전송하는 노드를

의미한다[5-7].

영상을 압축할 때는 크게 다른 영상 프레임을 이용하여 시간적인 중복성을 제거하는 인터 코딩과 현재 프레임의 공간적인 중복성만을 제거하는 인트라 코딩으로 구분할 수 있다. 인터 코딩의 경우 압축 효율이 떨어지지만 추가적인 메모리가 필요 없고 계산량도 인터 코딩에 비해 매우 적다. 인터 코딩은 참조할 영상을 저장해야 하기 때문에 추가적인 메모리가 필요하고 시간적인 중복성이 있는 부분을 찾기 위한 작업이 필요하기 때문에 많은 계산이 필요하며 무선 통신에서 발생할 수 있는 데이터 손실에도 취약한 단점이 있다. 따라서 VSN에서는 일반적으로 인트라 코딩을 사용하며 실제로 사용되는 압축 표준은 JPEG, MPEG-4, H.264 등이다[1-8].

영상의 크기는 응용에 따라 다양할 수 있는데, 상용 제품의 사양을 보면 저 해상도의 경우 40×30 정도의 해상도에서 QCIF(176×144)까지 다양하며 고 해상도의 경우도 VGA(640×480) 정도의 해상도까지 지원한다. 영상의 크기가 커지면 좀 더 정확한 정보를 제공할 수 있지만 데이터를 처리하는 비용과 전송하는 비용이 증가하기 때문에 전체 망의 성능을 고려하여 해상도를 결정하여야 한다[1-4].

III. 제안하는 트래픽 예측 방법

영상 데이터는 가변적이고 용량이 크기 때문에 VSN 내에서 최적의 경로를 찾을 때 각 노드의 데이터 양을 예측하는 것은 매우 중요하다. 각 노드는 제한된 메모리와 전송 대역폭을 가지기 때문에 허용치 이상의 데이터가 유입되는 데이터 손실이 발생하게 된다. 본 논문에서는 VSN에서 사용 가능한 계산량이 많지 않은 비디오 트래픽 예측 방법을 제안한다.

네트워크 트래픽에서 비디오가 차지하는 비율이 증가함에 따라 VBR 비디오 트래픽을 예측하기 위한 다양한 연구가 진행되었다. 많은 대역폭을 필요로 하는 비디오 트래픽의 경우 MPEG이나 H.264 등의 비디오 압축 표준을 따르는 영상들이며 트래픽 모델도 이러한 압축 표준의 통계적 특성을 반영하는 방향으로 많은 연구가 진행되었다. MPEG이나 H.264 등의 비디오 압축 표준의 경우 GOP 구조라는 주기적인 패턴을

가지게 되는데 이를 효과적으로 반영하기 위한 모델들이 많이 제안되었다. 하지만 VSN의 경우 획득된 영상을 인트라 코딩 방식으로 압축하기 때문에 복잡한 GOP 구조를 고려할 필요가 없어 GOP의 주기적인 패턴을 반영할 필요가 없다.

VBR 트래픽 모델은 크게 프레임간의 의존성에 따라 SRD(: Short-Range Dependency) 모델과 LRD(: Long-Range Dependency) 모델로 나눌 수 있다. LRD 모델의 경우 많은 이전 프레임들을 고려하기 때문에 메모리가 증가하는 특징이 있다. 또한 각 프레임의 통계적 특성이 일정하다고 가정하는 Stationary 모델과 시간에 따라 변한다고 가정하는 Non-stationary 모델로 구분할 수 있다. 일반적으로 VBR 트래픽은 LRD 특성과 Non-stationary 특성을 가지는 것으로 알려져 있지만 이러한 특성을 반영하기 위해서는 트래픽 모델이 복잡해지고 실시간 예측을 위한 계산량도 많아져서 센서노드에 적용하기에 적합하지 않게 된다. VSN 트래픽의 경우 카메라가 한 방향으로 고정되어 원하는 목표물을 감시하는 형태이기 때문에 트래픽의 통계적 특성이 일정하다고 가정할 수 있고 또한 인접한 프레임의 정보로도 충분히 트래픽을 예측할 수 있다. 화면의 복잡도에 대한 분석을 이용하여 트래픽을 예측하는 방법들이 있지만 VSN 영상 트래픽에 잘 맞지 않는데 이것은 영상의 각 프레임들을 비교하면 같은 목표물을 촬영하기 때문에 화면의 복잡도가 일정한 형태를 띠기 때문이다. 따라서, 제안하는 방법에서는 VSN 트래픽을 Stationary 특성과 SRD 특성을 가진다고 가정한다. 그리고 이러한 가정에 맞는 트래픽 모델 중 계산량이 많지 않고 간단한 형태여서 센서노드에 적합한 1차 Autoregressive(: AR) 모델을 사용하여 VSN 트래픽을 모델링한다.

비디오 트래픽은 시간에 따라 측정되는 형태를 띠기 때문에 시계열 데이터로 간주할 수 있다. AR 모델은 시계열 데이터들 사이에 존재하는 상호간의 종속성과 상관성을 과거의 값을 이용하여 모델링한다. 즉, 예측값은 과거의 관측값과 확률성분인 잡음의 일차 결합 형태로 표현되며, 1차 AR 모델의 경우 바로 이전 관측값을 이용하여 식(1)과 같이 표현한다[9].

$$x_t = \alpha \cdot x_{t-1} + \delta + u_t \quad (1)$$

$$(E(u_t) = 0, E(u_t^2) = \sigma^2,$$

$$E(u_t u_\tau) = 0, \text{ for } t \neq \tau.$$

여기서 x_t 는 시간 t 에서 발생한 트래픽 양을 의미하고, δ 는 상수, u_t 는 백색 가우시안 잡음을 의미한다. 또한, α 는 이전 관측값의 반영 비율을 나타낸다.

트래픽 모델은 실제로 발생하는 트래픽의 통계적 특성을 수식으로 표현한 것으로 이 모델을 이용하여 트래픽을 직접 예측하게 되면 정확도가 떨어진다. 제안하는 방법에서는 1차 AR 모델에 칼만필터를 적용하여 트래픽을 예측한다.

칼만필터는 대상 시스템의 확률적인 모델과 측정값을 이용하여 시스템에서 정의한 상태변수를 추정하는 기법으로 오차 공분산을 최소화하는 최적화된 해결책을 제시한다. 칼만필터를 적용하여 최적의 예측값을 구하기 위해서는 먼저 시스템 모델이 선형 형태로 표현되고 시스템에 백색 가우시안 잡음이 포함된 상태공간 방정식으로 표현되어야 한다. 이 상태공간 방정식을 이용하여 예측값에 대한 확률분포를 계산하여 가장 높은 확률을 가지는 예측값을 계산하고 관측값을 통해 적절히 예측값을 보정하여 최종 결과값을 얻게 된다.

칼만필터를 적용하기 위해서는 수식의 상태변수 항을 제외한 항들의 평균이 0이 되도록 수정하여야 한다. 식(1)을 칼만필터를 적용할 수 있는 상태공간 방정식 형태로 표현하면 식(2)와 같다.

$$y_t = \alpha \cdot y_{t-1} + u_t, \quad (2)$$

$$y_t = x_t - \mu_t, \quad (3)$$

$$\mu_t = \delta / (1 - \alpha). \quad (4)$$

여기서 μ_t 는 x_t 의 평균에 해당된다. AR 모델은 Stationary 특성을 가지기 때문에 μ_t 는 식(4)와 같이 상수여야 하지만 실제로 적용할 때는 시간적인 변화를 반영하여 이동평균 값을 이용하였다. VSN 환경에서는 μ_t 값이 크게 변하지 않기 때문에 이동평균을 적용하는 것이 큰 문제를 발생시키지는 않는다.

칼만필터 알고리즘을 적용하기 위한 시스템의 일반적인 상태공간 모델은 프로세스 방정식과 측정 방정

식이라는 두 개의 방정식으로 다음과 같이 표현된다.

$$Y_t = A Y_{t-1} + V_{t-1}, \quad (5)$$

$$Z_t = H Y_{t-1} + W_{t-1}. \quad (6)$$

여기서 Y_t 는 시계열 신호에서의 상태를 나타내고 Z_t 는 측정값을 의미하며, V_t 는 시스템에 부가되는 프로세스 잡음을 나타내고 W_t 는 신호를 측정할 때 발생하는 잡음을 나타낸다. 시스템에 대한 상태공간 모델이 적절할 경우 이 두 잡음은 평균이 0인 백색 가우시안 잡음의 특성을 가진다. 식(2)를 이용하여 식(5)와 식(6)의 상태공간 모델에 적용하면 파라미터들은 다음과 같다.

$$A = \alpha, \quad (7)$$

$$H = 1,$$

$$V_t \sim N(0, Q),$$

$$W_t \sim N(0, R).$$

칼만필터 알고리즘에 맞게 시스템 모델의 파라미터들이 결정되면 예측값을 계산하기 위한 각 단계별 칼만필터 알고리즘이 적용된다. 칼만필터 알고리즘은 다음과 같이 크게 네 단계로 이루어지며 네 단계를 반복적으로 수행하게 된다[10].

1단계 : 상태변수 추정치 계산과 공분산 추정

$$\bar{Y}_t = A \hat{Y}_{t-1}$$

$$\bar{P}_t = A P_{t-1} A + Q$$

2단계 : 칼만 이득 계산

$$K_t = \bar{P}_t H (H \bar{P}_t H + R)^{-1}$$

3단계 : 예측값 계산

$$\hat{Y}_t = \bar{Y}_t + K_t (Z_t - H \bar{Y}_t)$$

4단계 : 오차 공분산 계산

$$P_t = \bar{P}_t - K_t H \bar{P}_t$$

1단계에서는 시스템 모델에 따라 1차적인 추정이

이루어지고 2단계에서는 이를 바탕으로 추정치와 오류 수정값의 반영 비율을 결정하는 칼만 이득을 계산한다. 3단계에서는 1차로 추정한 값과 오류 성분에 칼만 이득을 반영하여 실제 예측값을 계산하고 4단계에서는 예측값이 얼마나 정확했는지를 나타내는 오차 공분산 값을 업데이트한다.

관측된 결과 데이터를 바탕으로 다음 비디오 프레임의 압축 트래픽에 대한 예측은 3단계에서 이루어지며 예측값 \hat{Y}_t 는 y_t 에 대한 상태변수이기 때문에 식 (3)에 따라 \hat{Y}_t 에 이동 평균값 μ_t 를 더하여 최종 비트율에 대한 예측값을 구할 수 있다.


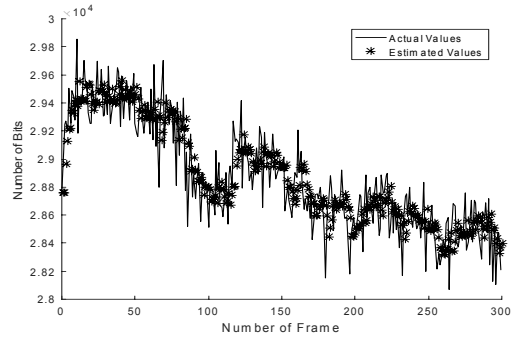


그림 2. 실험에 사용된 시퀀스들의 대표 영상 (a) Bridge-Close (b) Bridge-Far (c) Container (d) Hall
Fig. 2 Representative images of test sequences (a) Bridge-Close (b) Bridge-Far (c) Container (d) Hall


IV. 실험 결과

제안하는 트래픽 예측 방법의 성능을 분석하기 위해서 VSN 트래픽의 형태를 가지는 테스트 영상을 이용하여 실험을 수행하였다. 본 논문에서 목표로 하는 시스템은 원격 감시 형태로 여기에 부합하는 테스트 영상은 Bridge-Close, Bridge-Far, Container, Hall 시퀀스들이다. Bridge-Close와 Bridge-Far 영상은 다리라는 시설물을 목표로 원격으로 감시하는 영상이고 Container와 Hall 영상은 카메라가 설치된 지역을 지나가는 객체를 감시하는 영상으로 볼 수 있다.

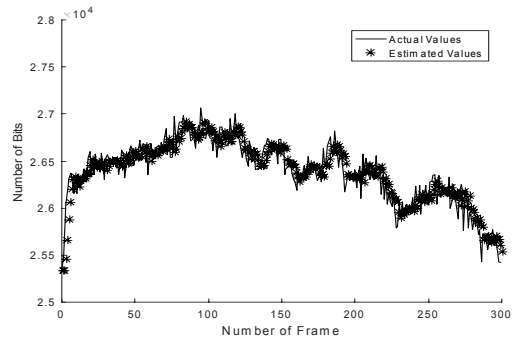
그림 2는 실험에 사용된 영상 시퀀스들의 대표 이미지를 보여준다. 압축에 사용된 표준은 H.264/AVC 이고 사용한 참조 소프트웨어 코덱은 JM14.3이다. 전체 300 프레임을 인트라 코딩 방식으로 압축하였고, 모든 영상은 QCIF (176 × 144) 크기로 압축하였다. 압축에 사용된 양자화 파라미터는 28로 고정하였다. 따라서 모든 압축 영상의 품질은 비슷한 값을 가지게 된다. 식(3)에 사용된 μ_t 를 계산하기 위해서 윈도우의 크기를 30으로 설정하여 이동 평균값을 계산하였다.



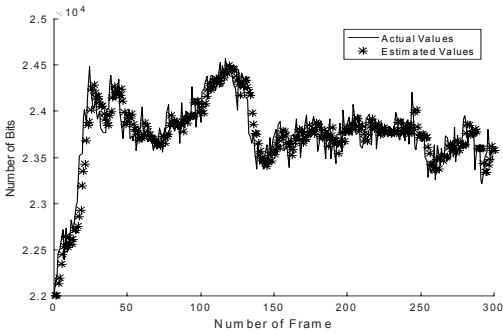
(a)



(b)



(c)



(d) Hall

그림 3. 예측값과 관측값 비교 (a) Bridge-Close (b) Bridge-Far (c) Container (d) Hall

Fig. 3 Comparison of estimated values and measured values (a) Bridge-Close (b) Bridge-Far (c) Container (d) Hall

그림 3은 제안하는 방법으로 트래픽을 예측한 값과 실제 발생한 트래픽 양을 비교한 결과를 보여준다. 그림 3(a)는 Bridge-Close 시퀀스에 대한 결과로 동일한 목표에 대한 영상임에도 적지 않은 트래픽의 변화를 볼 수 있다. 다리 위를 지나가는 사람들과 다리 아래로 움직이는 물체 등이 영상의 변화를 만들고 이러한 변화가 압축된 트래픽의 차이를 만들게 된다. 이렇게 변화하는 트래픽에 대해서 제안하는 방법이 가변적인 트래픽의 특성을 잘 예측하고 있는 것을 볼 수 있다. 그림 3(b)는 Bridge-Far 시퀀스로 Bridge-Close 시퀀스에 나오는 동일한 다리를 좀 더 멀리서 촬영한 시퀀스이다. 전체적으로 시작 부분에서 트래픽의 큰 변화가 있을 뿐 나머지 영상에서는 Bridge-Close 시퀀스에 비해 트래픽의 변화가 작은 특성을 가진다. 제안하는 방법이 적절하게 실제 발생하는 데이터양을 추적하고 있는 것을 볼 수 있다. 그림 3(c)는 컨테이너선이 지나가는 영상을 담은 시퀀스이다. 영상에서 큰 객체가 움직이는 형태이지만 컨테이너선이 느리게 움직이고 주위 배경이 비교적 선명하게 촬영되어 제안하는 방법이 실제 발생한 데이터를 잘 추적하는 것을 보여준다. 그림 3(d)는 야외가 아닌 실내에 설치된 비디오 센서를 가정할 수 있는 영상이다. 전체 영상에서 사람이 차지하는 비중이 크지 않아 영상의 변화도 초반을 제외하면 크지 않은 것을 알 수 있으며 제안하는 방법이 트래픽의 변화를 잘 예측하는 것도 알 수 있다.

표 1. 예측 정확도 비교

Table 1. Comparison of estimation accuracy

Sequence Name	Average		Improve-ment (%)
	Frame (10 ⁴)	Error (10 ²)	
Bridge-Close	2.888	1.4386	20.39
Bridge-Far	1.137	1.131	20.58
Container	2.639	1.018	15.75
Hall	2.376	1.239	12.16

표 1은 실험 시퀀스에 대한 예측 성능을 보여준다. 네 개의 시퀀스들에 대해서 예측 오차가 매우 적은 값을 가지는 것을 알 수 있다. Bridge-Close, Container, Hall 시퀀스들의 경우 평균 트래픽의 0.5% 이하의 오차를 발생하고 있다. 반면, Bridge-Far 시퀀스의 경우 평균 트래픽의 1% 정도의 오차가 발생하고 있지만 평균 트래픽이 다른 시퀀스에 비해 작기 때문에 오차의 양은 비슷한 수준을 유지하고 있는 것을 볼 수 있다. VSN의 경우 영상의 변화가 비교적 크지 않기 때문에 이전 트래픽의 양을 이용하여 다음 프레임의 트래픽을 예측하는 것이 일반적이다. 따라서 이전 프레임 값을 그대로 예측값으로 사용하는 방법과 제안하는 방법의 성능을 비교하였다. 정확도 개선은 이전 값을 예측에 그대로 사용하는 방법 대비 얼마 정도의 예측 성능이 향상되었는지를 보여준다. Bridge-Close 시퀀스와 Bridge-Far 시퀀스는 비교적 많은 개선이 있음을 보여준다. Container 영상과 Hall 영상의 경우 오차가 작은 값을 가짐에도 개선정도가 낮은 것은 영상이 점진적으로 변하기 때문에 이전 프레임 값을 그대로 이용할 때도 비교적 좋은 예측값을 보이기 때문이다. 전체적으로 제안하는 방법이 트래픽 평균의 1% 이하의 오차를 발생시키는 것을 알 수 있으며, 단순히 이전 프레임의 결과값을 이용하는 것보다 우수한 성능을 보이는 것도 확인할 수 있다.

V. 결 론

본 논문에서는 VSN에서 사용할 수 있는 비디오 트래픽 예측 모델을 제안하고 있다. VSN에 사용되는 비주얼 센서는 전력소모를 최소화하여야 하기 때문에 비교적 간단한 하드웨어 사양을 가지게 된다. 제안하는 방법은 비디오 센서에서 획득되는 영상이 Stationary 특성과 SRD 특성을 가진다는 가정을 바탕으로 비교적 간단한 1차 AR 모델을 이용하여 트래픽을 모델링하고 칼만필터 알고리즘을 적용하여 트래픽을 예측하였다. 칼만필터는 역행렬 계산 등 계산량이 많은 알고리즘이지만 제안하는 방법에서는 상태변수가 스칼라이기 때문에 역행렬을 계산할 필요가 없어 비디오 센서에 큰 부담을 주지 않는다. 실험결과 비교적 간단한 알고리즘임에도 트래픽의 예측을 정확하게 하는 것을 확인할 수 있다.

트래픽의 예측은 비교적 제한적인 자원을 가지는 센서 네트워크에서 트래픽을 관리하는데 중요하게 사용될 수 있다. 네트워크 자원을 초과하는 트래픽이 발생할 경우 비트율 제어를 통해 양자화 파라미터를 조절하여 적절한 트래픽이 발생할 수 있도록 조절하는 것도 가능하다. 따라서 제안하는 방법은 VSN에서 효과적으로 트래픽을 관리하는 다양한 알고리즘에 적용될 것으로 기대된다.

References

- [1] B. Tavli, K. Bicakci, R. Zilan, and J. Barcelo-Ordinas, "A survey of visual sensor network platforms," *Multimedia Tools and Applications*, vol. 60, no. 3, 2012, pp. 689-726.
- [2] J. Zhang, Q. Xiang, Y. Yin, C. Chen, and X. Luo, "Adaptive compressed sensing for wireless image sensor networks," *Multimedia Tools and Applications*, vol. 64, 2016, pp. 1-16.
- [3] K. Nam, "A Study on Yeong-sna River Ecological Environment Monitoring based on IoT," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 10, no. 2, 2015, pp. 203-210.
- [4] P. Porambage, A. Heikkinen, E. Harjula, A. Gurtov, and M. Ylianttila, "Quantitative Power Consumption Analysis of a Multi-tier Wireless Multimedia Sensor Network," *In Proc. European*

- Wireless 2016*, Oulu, Finland, May 2016, pp. 1-6.
- [5] J. Park, S. Lee, and W. Oh, "Congestion Control Mechanism for Efficient Network Environment in WMSN," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 10, no. 2, 2015, pp. 289-296.
- [6] K. Lee, Y. Kim, and H. Lee, "Receive Prediction based Period Adaptive Wakeup Technique for WSN," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 10, no. 11, 2015, pp. 1265-1270.
- [7] T. Little, J. Konrad, and P. Ishwar, "A wireless video sensor network for autonomous coastal sensing," *In Proc. Conf. on Coastal Environmental Sensing Networks*, Boston, USA, Apr. 2007, pp. 1-5.
- [8] M. Chen, S. González, H. Cao, Y. Zhang, and S. Vuong, "Enabling low bit-rate and reliable video surveillance over practical wireless sensor network," *The J. of Supercomputing*, vol. 65, no. 1, 2013, pp. 287-300.
- [9] G. Kirchgässner, J. Wolters, and U. Hassler, *Introduction to modern time series analysis*. Berlin: Germany:Springer Science & Business Media, 2012.
- [10] D. Simon, *Optimal state estimation: Kalman, H infinity, and nonlinear approaches*. Hoboken, New Jersey: John Wiley & Sons, 2006.

저자 소개

박상현(Sang-Hyun Park)



1995년 고려대학교 전자공학과 졸업(공학사)

1997년 고려대학교 대학원 전자공학과 졸업(공학석사)

2002년 고려대학교 대학원 전자공학과 졸업(공학박사)

2004년 순천대학교 멀티미디어공학과 교수

※ 관심분야 : 영상처리, 패턴인식

