

멀티콥터의 효율적 멀티미디어 전송을 위한 이미지 복원 기법의 성능

황유민*, 이선의*, 이상운**, 김진영*

Performance of Image Reconstruction Techniques for Efficient Multimedia Transmission of Multi-Copter

Yu Min Hwang*, Sun Yui Lee*, Sang Woon Lee**, and Jin Young Kim*

요 약

본 논문에서는 무인항공기인 방송용 멀티콥터를 이용한 Full-HD급 이상 화질의 이미지를 효율적으로 전송하기 위해 이미지 압축 센싱 기법을 적용하고, Sparse 신호의 효율적 복원을 위해 Turbo 알고리즘과 Markov chain Monte Carlo (MCMC) 알고리즘의 복원 성능을 모의실험을 통해 비교 분석하였다. 제안된 복원 기법은 압축 센싱에 기반하여 데이터 용량을 줄이고 빠르고 오류 없는 원 신호 복원에 중점을 두었다. 다수의 이미지 파일로 모의실험을 진행한 결과 Loopy belief propagation(BP) 기반의 Turbo 복원 알고리즘이 Gibbs sampling기반 알고리즘을 수행하는 MCMC 알고리즘 보다 평균 복원 연산 시간, NMSE 값에서 우수하여 보다 효율적인 복원 방법으로 생각된다.

Key Words : Compressed Sensing(CS), Turbo Reconstruction, Markov chain Monte Carlo (MCMC), Normalized Mean Squared Error(NMSE), Multi-Copter.

ABSTRACT

This paper considers two reconstruction schemes of structured-sparse signals, turbo inference and Markov chain Monte Carlo (MCMC) inference, in compressed sensing(CS) technique that is recently getting an important issue for an efficient video wireless transmission system using multi-copter as an unmanned aerial vehicle. Proposed reconstruction algorithms are setting importance on reduction of image data sizes, fast reconstruction speed and errorless reconstruction. As a result of experimentation with twenty kinds of images, we can find turbo reconstruction algorithm based on loopy belief propagation(BP) has more excellent performances than MCMC algorithm based on Gibbs sampling as aspects of average reconstruction computation time, normalized mean squared error(NMSE) values.

I. 서 론

무인항공기(Unmanned Aerial Vehicle; UAV)는 항공기에 사람이 탑승하지 않은 상태에서 원격 또는 자동으로 조종되는 항공기를 지칭한다. 무인항공기는 원격탐사, 환경감시, 기상관측, 국경감시, 재난구호 등 광범위한 분야에서의 활용이 가능한 장점이 있다. 본 논문에서는 이러한 무인항공기에 방송 장비용 카메라와 LTE기반 무선 통신시스템을 탑재시켜 공중에서 최고품질의 동영상 획득 및 획득한 영상을 실시간으로 무선 멀티미디어 전송이 가능한 무인항공촬영기인 ‘멀티콥터’에 주목하고자 한다. 최근 멀티미디어 시장은 언제 어디서나 최고품질의 동영상을 끊임없이 전송하고 수신하는데 초점이 맞추어져 왔다. 그래서 현재에는 무인항공촬영기인 멀티콥터를 이용한 동영상 촬영에 대한 관심이 더욱 높아졌고 멀티콥터 영상을 더욱 선명하고 빠르게 전송하는 연구가 활발히 진행되고 있다. 또한 방송용 멀티콥터에는 Full HD급 이상 화질을 구현하는 카메라의 장착이 요구되는데, Full HD 이상의 방송 영상 콘텐츠를 효율적으로 취득하고

간으로 무선 멀티미디어 전송이 가능한 무인항공촬영기인 ‘멀티콥터’에 주목하고자 한다. 최근 멀티미디어 시장은 언제 어디서나 최고품질의 동영상을 끊임없이 전송하고 수신하는데 초점이 맞추어져 왔다. 그래서 현재에는 무인항공촬영기인 멀티콥터를 이용한 동영상 촬영에 대한 관심이 더욱 높아졌고 멀티콥터 영상을 더욱 선명하고 빠르게 전송하는 연구가 활발히 진행되고 있다. 또한 방송용 멀티콥터에는 Full HD급 이상 화질을 구현하는 카메라의 장착이 요구되는데, Full HD 이상의 방송 영상 콘텐츠를 효율적으로 취득하고

* 본 연구는 미래창조과학부 및 정보통신기술진흥센터의 정보통신-방송 연구개발사업의 일환으로 수행하였음. [2014(2014-044), '방송 중계차량 탑재형 멀티콥터 캡 시스템 기술개발']

*광운대학교 전파공학과 유비쿼터스 통신 연구실(yumin@kw.ac.kr), (sunnyui@kw.ac.kr), (jinyoung@kw.ac.kr)

**남서울대학교 멀티미디어학과 이동멀티미디어 연구실 (Quattro@nsu.ac.kr)

접수일자 : 2014년 11월 17일, 수정완료일자 : 2014년 12년 19일, 최종 게재확정일자 :2014년 12월 19일

무선 전송하기 위한 초고해상도 영상 압축 및 복원기법에 관한 연구가 필요하다[1-2]. 사용자가 더 고품질의 서비스를 원할수록 시스템이 요구하는 데이터 량은 더욱더 증가 하게 되고 제한된 주파수 자원을 이용하여 고품질의 영상을 전송 하기 위해 본 논문에서 기존 이미지 압축 센싱(Compressed Sensing; CS) 기법 대비 고효율의 압축 기법을 제시하고 그 성능을 분석하고자 한다.

Compressed sensing 기법은 매우 적은 수의 데이터만 측정하여 최종 이미지를 복원하는 기술이며, 무왜곡 복원을 위해 필요한 측정 데이터 수는 영상의 성긴(Sparse) 정도에 따라 달라질 수 있다. 또한 나이퀴스트 주파수 이상으로 샘플링 하지 않아도 원 신호를 복원할 수 있는 Compressed sensing 기술은 불필요한 샘플링을 피할 수 있다. 어떤 신호를 입력받아 푸리에 변환을 수행했을 때, 적은 숫자의 주파수에서만 값이 존재하고, 대부분의 주파수에서의 값이 0인 경우 이러한 신호를 sparse신호라고 한다[3-5]. 이러한 sparse신호에 한해서 샘플링하는 개수가 $O(K\log(N/K))$ 근처가 되면, 원본 이미지에 가까운 이미지 복원이 가능하다. N 은 원본 신호의 길이이고, K 는 그중 0이 아닌 신호의 개수가 된다. 특별한 형태의 신호에 대해서만 사용 가능한 방법이지만, 거의 대부분의 분야에서 사용될 수 있다.

본 논문에서는 멀티미디어를 이용한 실시간 고품질 방송 기술의 구현뿐만 아니라 미래의 동영상, 다양한 미디어 중심의 통신환경에서 급증하는 트래픽문제를 해결하기 위해 압축 센싱(Compressed Sensing) 기술을 적용시키는 연구를 진행하였다. 논문의 구성은 2장 CS 기술의 기초적인 개념을 설명하고 3장 및 4장에서 신호 복원 알고리즘의 종류인 Turbo 알고리즘과 MCMC를 설명한다. 5장에서 이미지 파일을 압축 후 전송하고 복원하여 복원된 이미지의 시각적 비교와 두 알고리즘의 Computational time값 및 NMSE값을 비교하여 우수한 성능의 알고리즘을 판단하며 결론을 맺는다.

II. 압축 센싱

신호 처리기법인 압축 센싱(Compressed Sensing; CS)에 관한 이론 연구는 최근 대단히 활발하게 진행되어 학계에 대량의 연구 결과를 내놓고 있다. 왜냐하면 압축 센싱 이론은 Nyquist 샘플링 속도보다 낮은 속도의 샘플링을 통해 원래의 신호로 완전하게 복원 가능하여 송신 신호의 데이터 용량을 획기적으로 감소시켜 전송할 수 있기 때문이다. 우리가 일반적으로 이미지 신호를 포함한 대부분의 신호들은 특정 Domain으로 Transform 하였을 때 상당수의 값이 0이고 상대적으로 아주 적은 개수의 값들만이 non-zero값을 가지는 Sparse신호로 표현 가능하다. 이러한 Sparsity를 갖는 신호, 즉 non-zero값들만 추출하여 행렬을 만들면 대단히 적은 데이터 용량으로 신호를 감축시킬 수 있다.

압축 신호 처리 기법을 이용하여 데이터 용량을 크게 감소시켜 전송하는 방법은 멀티미디어의 실시간 동영상 전송(방송 영상 전송 분야), 의료 스캐너, 고속 Analog to digital converters (ADC), 고속 레이더 시스템에서 다양하게 응용될 수 있다. 여기서 고속 ADC장치 구현 응용은 오늘날 디지털 시스템에서 Shannon-Nyquist 샘플링 이론에 기반하여 아날로그 신호를 디지털 신호로 변화시켜주는 필수 불가결한 장치임에 착안했을 때 압축 센싱 이론의 잠재력이 매우 크다고 할 수 있다. 압축 센싱 기법은 최근에는 전송 데이터가 고품질의 이미지인 이미지 압축 전송분야에 특히 연구가 활발하였지만, 이후 차세대 5G 이동통신 시스템에서 Spectrum sensing, Big data 처리 등 다양한 분야에 이바지할 것으로 기대한다.

CS 이론에서 사용하는 기본적인 선형 측정 방법과 신호 복원 방식 다음 등식의 해를 찾는 것으로 요약 할 수 있다.

$$y = Ax, \tag{1}$$

식 (1)에서 x 는 원본 신호, A 는 N 보다 작은 M 값을 갖는 $[M \times N]$ 행렬이고, y 는 원본 신호 x 와 어떤 행렬 A 를 곱해서 얻은 선형 측정된 $[M \times 1]$ 행렬이다. 여기서 선형 측정의 개념은 신호 x 를 선형측정 행렬 A 를 곱하여 측정벡터 y 를 얻는 것을 의미한다. A 행렬에 x 를 곱하는 과정에서 y 를 얻을 수 있는데, 원 신호 복원방식은 이 벡터 y 로부터 x 벡터를 찾는 과정으로 알 수 있다. 이 때 A 행렬 M 값이 N 값보다 작은 값을 갖지 않으면 데이터를 압축한다고 볼 수 없으며, M/N 은 신호 압축률로써 이것을 높이기 위해 주어진 N 을 두고 M 을 최대한 줄여야한다.

신호 x 가 직접적으로 sparse 신호가 아닐 때에는 어떤 선형 변형 과정을 거치면 sparse 신호로 표현될 수 있다.

$$\begin{aligned} y &= Ax \\ &= ATs \\ &= Fs, \end{aligned} \tag{2}$$

여기서 T 는 역이 존재하는 $[N \times M]$ 행렬이고 s 는 sparse 신호가 된다. 이때는 선형측정행렬을 $F=AT$, sparse 신호를 s 라 놓고 진행하면 다시 기본식 (1)의 형태가 된다.

신호 복원 방식은 y 로부터 원 신호 x 벡터를 완벽하게 복구하기 위해 행렬 A 가 RIP(Restricted Isometry Property) 조건을 만족해야 한다.

$$(1 - \delta_K) \|x\|_2 \leq \|Ax\|_2 \leq (1 + \delta_K) \|x\|_2, \tag{3}$$

식 (3)는 RIP 조건으로 $0 < \delta_K < 1$ 는 RIP 상수이고 0에 가까울 때 RIP 조건이 의미를 가진다. 이때, K 는 원 신호 x Sparsity, 즉 non-zero값들의 개수이다. 이 조건을 간략히 말하면, 행렬 A 가 모든 sparse 신호 x 를 균일하게 측정해야

한다는 것이다. 측정 벡터 x 에서 0이 아닌 신호의 위치는 항상 다르므로 어떤 임의의 벡터 x 도 비슷하게 A 벡터가 투사할 수 있어야 신호 복원이 될 수 있다는 의미이다. 이렇게 균일한 에너지로 투사하는 A 가 가장 좋은 측정 행렬이다.

한편, 식 (1)의 해는 무수히 존재하는데 그 해를 구할 수 있는 3가지 방법을 알아본다.

$$\bar{x} = \operatorname{argmin} \|x\|_2, \quad (4)$$

먼저 L2최소화를 이용한 복원인데 가장 보편적으로 사용되어온 방식으로 이런 최적화 문제의 해는 $\bar{x} = A^T(AA^T)^{-1}y$ 식을 푸는 것으로 알려져 있지만 L2최소화는 non-sparse 해를 찾아주기 때문에 sparse 해를 직접적으로 찾는 것과 올바른 해를 찾는 방법에서 비교적 많은 오류를 가져올 수 있다. 반면 L0최소화를 이용하면 sparse 신호의 특성을 최대한 활용한 해를 구할 수 있는데 샘플의 개수가 $M \geq 2K$ 정도로 충분하면, sparse 신호를 얻을 수 있다. 하지만 L0 방식은 $\binom{N}{K}$ 개의 sparse 벡터를 모두 점검해야 되기 때문에 실용성이 떨어진다는 단점이 있다. 그래서 새로 제안된 방식이 L1-norm 최소화를 이용하여 선형문제로 접근하는 방식이다. 다음 식 $M \geq cK \log(N/M)$ 을 만족하는 M 이 존재하면 원 신호 x 벡터를 복원할 수 있다. 이 최적화 문제는 Basis Pursuit 이라 불리는 복잡도 $O(N^3)$ 를 가지는 선형 문제로 변환하여 풀 수 있는데 이와같은 방법으로 sparse 신호 x 를 찾을 수 있다[6].

III. 이미지 복원 기법: Turbo Approach

Sparse 신호를 복원하는 문제는 많은 공학적 어플리케이션에서 심장과 같은 위치에 놓여있다. 이에 대한 주요한 목적은 선형 noisy 측정값 $y \in C^M$ 로부터 sparse 신호 $x \in C^M$ 추산하는 것이다.

$$y = Ax + w, \quad (5)$$

여기서 $A \in C^{M \times N}$ 은 주어진 행렬이고 $w \in C^M$ 는 additive white Gaussian noise이다. 즉, $w \sim CN(0, \sigma^2 I)$. 또한 "sparse signal"을 N 보다 아주 적은 K 개의 non-zero coefficient를 갖는 신호로 정의한다.

언급했다시피 우리의 최종 목표는 식(5)로부터 주어진 관측값 $y = y_0$ 에 대한 sparse 신호 x 를 복원하는 것이다. 특별히 우리는 mean-squared error estimation(MMSE) 계산을 이용하여 $\{x_n\}$ 을 추산하고자 한다.




그림 1. 사후확률(posterior probability) $p(x, s | y = y_0)$ 의 Factor graph.

3.1 정밀 추산

앞서 언급한대로 우리의 최종 목표는 식(10)로부터 주어진 관측 값 $y = y_0$ 에 대한 sparse 신호 x 를 복원하는 것이다. 특별히 우리는 mean-squared error estimation(MMSE) 계산을 이용하여 $\{x_n\}$ 을 추산하고자 한다. 그림 1은 사후확률 (posterior probability) $p(x, s | y = y_0)$ 의 Factor 그래프이며, 검정 네모 노드들은 식 (7)에서 정의된 constraint 노드, 동그라미 노드는 변수 노드를 의미한다. 또한 점선을 통해 factor 그래프를 두 sub-graph로 나눌 수 있다.

$$p(x, s | y = y_0) \propto p(y = y_0 | x, s) p(x, s) \quad (6)$$

$$= \frac{p(s)}{\approx h(s)} \underbrace{p(y = y_0 | x)}_{\approx g(x)} \prod_{n=1}^N \underbrace{p(x_n | s_n)}_{\approx f_n(x_n, s_n)}. \quad (7)$$

MMSE 추정치 x_n 은 주변 사후 확률(marginal posterior probability) $p(x_n | y = y_0)$ 의 의미로서 주어졌다. 그리고 다음과 같이 표현될 수 있다.

$$p(x_n | y = y_0) = \sum_{s \in \{0,1\}^{N-1}} \int_{x_{-n}} p(x, s | y = y_0), \quad (8)$$

$$\propto \sum_{s_n=0}^1 f_n(x_n, s_n) p(s_n) \int_{x_{-n}} g(x) \prod_{q \neq ns_n} \sum_{s_q=0}^1 f_q(x_q, s_q) \times \sum_{s_{-n,q} \in \{0,1\}^{N-2}} p(s_{-n} | s_n), \quad (9)$$

여기서 z_{-n} 은 n^{th} 번째 값이 누락된 벡터 z 를 의미하며, $z_{-z,q}$ 는 n^{th} 와 q^{th} 번째 엘리먼트가 누락된 z 벡터열을 의미한다. $p(s_{-n} | s_n)$ 를 $p(s_{-n,q} | s_q, s_n) p(s_q | s_n)$ 로 표현하면 식 (9)에서의 마지막 SUM 항을 $p(s_q | s_n)$ 로 줄일 수 있다.

$$p(x_n | y = y_0) \propto \nu_{f_n \rightarrow x_n}^{exact}(x_n) \nu_{g \rightarrow x_n}^{exact}(x_n) \quad (10)$$

$$\nu_{f_n \rightarrow x_n}^{exact}(x_n) \approx \sum_{s_n=0}^1 f_n(x_n, s_n) p(s_n) \quad (11)$$

$$\nu_{g \rightarrow x_n}^{exact}(x_n) \approx \int_{x_{-n}} g(x) \prod_{q \neq ns_n} \sum_{s_q=0}^1 f_q(x_q, s_q) p(s_q | s_n). \quad (12)$$

그리고 notation $\nu_{A \rightarrow B}^{exact}(\cdot)$ 는 다음 3.2절 근사 추산에서 계속 설명하도록 한다.

3.2 근사 추산

식 (10)~(12)에서 구한 정밀 사후확률(exact posterior) 계산법은 컴퓨터 계산학 관점에서 일반적 문제를 풀 때에 통용되는 계산법이 아니기 때문에, 근사 추산 계산법이 요소 그래프 그림 1의 MP(message passing[9]) 즉 신뢰 전파(Belief Propagation; BP)를 이용할 때 보다 효과적일 수 있다. 또한 우리는 notation $\nu_{A \rightarrow B}^{exact}(\cdot)$ 을 그림 1에서 어떤 노드 A 로부터 인접 노드 B 로 통과한 메시지들로 표현한다. 이러한 메시지들은 실수 직선으로서 확률분포함수로 표현될 수 있고 문맥적으로 보다 정확하게 표현가능한 이진 확률질량함수(Probability mass function; pmf)로도 표현 될 수 있다. BP는 다음 두가지 규칙에 의해서 계산한다[9]: i) 주어진 가장자리의 변수 노드들에 의한 메시지들은 다른 가장자리의 변수 노드들의 메시지의 곱과 같다. ii) 주어진 가장자리의 함수 노드들에 의한 메시지는 다른 가장자리의 Constraint function(노드와 연관된)과 기능 노드들로 들어오는 모든 메시지들을 곱한 값의 적분을 취한 값과 같다. BP 알고리즘을 이용하면, 3.1장 정밀 추산에서의 함수 $\nu_{f_n \rightarrow x_n}^{exact}(\cdot)$ 와 $\nu_{g \rightarrow x_n}^{exact}(\cdot)$ 가 scaling factor값 까지 정상 상태형의 메시지로 추산될 수 있다.

$$\nu_{f_n \rightarrow x_n}^{(t)}(x_n) \propto \sum_{s_n=0}^1 f_n(x_n, s_n) \nu_{s_n \rightarrow f_n}^{(t)}(s_n) \quad (13)$$

$$\nu_{g \rightarrow x_n}^{(t)}(x_n) \propto \int_{x_{-n}} g(x) \prod_{q \neq n, s_q=0} f_q(x_q, s_q) \underbrace{\nu_{s_q \rightarrow f_q}^{(t)}(s_q)}_{\nu_{f_q \rightarrow x_q}^{(t)}(x_n) = \nu_{x_q \rightarrow g}^{(t)}(x_n)}, \quad (14)$$

이것은 다른 메시지들에 의존한다.

$$\nu_{s_n \rightarrow f_n}^{(t)}(s_n) = \nu_{h \rightarrow s_n}^{(t)}(s_n) \quad (15)$$

$$\propto \sum_{s_{-n} \in \{0,1\}^{N-1}} h(s) \prod_{q \neq n} \underbrace{\nu_{s_q \rightarrow h}^{(t-1)}(s_q)}_{= \nu_{f_q \rightarrow s_q}^{(t)}(x_q)}. \quad (16)$$

$$\nu_{f_n \rightarrow s_n}^{(t)} \propto \int_{x_n} f_n(x_n, s_n) \underbrace{\nu_{x_n \rightarrow f_n}^{(t)}(x_n)}_{= \nu_{g \rightarrow f_n}^{(t)}(x_n)}. \quad (17)$$

우리는 터보 반복을 표현하기 위해 superior- (t) 표현을 이용하였다. 이러한 메시지들은 이후에 marginal inference와 결합될 수 있다.

$$\hat{p}^{(t)}(x_n | y = y_0) \propto \nu_{f_n \rightarrow x_n}^{(t)}(x_n) \nu_{g \rightarrow x_n}^{(t)}(x_n) \quad (18)$$

$$\hat{p}^{(t)}(s_n | y = y_0) \propto \nu_{f_n \rightarrow s_n}^{(t)}(s_n) \nu_{h \rightarrow s_n}^{(t)}(s_n) \quad (19)$$

여기서 $\hat{p}^{(t)}$ 는 확률 분포 함수에서 반복- t 근사 값을 표현한다. 그림 1의 factor 그래프에서 많은 루프선을 가지기 때문에 정밀 추산은 NP-hard[10] 문제로 알려져 있고, 그러므로 BP알고리즘이 단일해법으로 지명된다. 더욱 규모가 큰 시스템으로 인한 제한 즉 M/N 값이 고정된 상태에서 M, N 값이 무한대로 갈 때, BP 알고리즘이 최근 다양한 최적화 문제에서 해법으로 제시된다.[11-12]

실질적으로 구현의 관점에서 바라본다면, 우리는 그림 1 factor 그래프를 두 개의 부분으로 나눌 수 있다. 메시지 $\{\nu_{f_n \rightarrow s_n}^{(t)}(\cdot)\}_{n=1}^N$ 는 왼쪽의 sub-graph의 output으로 볼 수 있고 또 오른쪽 sub-graph의 input이라고 할 수 있다. 이것으로부터 우리는 BP scheme을 두 sub-graph 사이에서 반복하여 추산하는 기법으로 해석할 수 있다[7].

IV. 이미지 복원 기법: MCMC 추산

다음은 Gibbs sampling에 기반한 Markov chain Monte Carlo(MCMC) 방법[13]에 의한 사후 확률 계산 추정 방법을 소개한다. Gibbs sampling은 일반적으로 두 개 혹은 그 이상의 변수들의 결합확률분포 (joint probability distribution)로부터 연속적인 표본을 채취(sampling)하는 것을 말한다. 이 방법은 특히 광역적 최적화 기법에 있어 매우 중요한 기여를 하였는데, 특히 MCMC 방법에서 대상분배(target distribution)의 추정에 매우 중요한 역할을 한다. 다음 식은 독립성을 갖는 랜덤 변수들의 사전 확률이다.

$$\begin{aligned} & p(\alpha_n, \{\alpha_s\}_{s=1:L}, \pi_r, \{\pi_s^0, \pi_s^1\}_{s=2:L}), \\ & = \Gamma(a_0, b_0) \left\{ \prod_{s=1}^L \Gamma(c_0, d_0) B(e_0^s, f_0^s) \right. \\ & \left. \times \left\{ \prod_{s=2}^L B(e_0^s, f_0^s) B(e_0^1, f_0^1) \right\} \right\}. \quad (20) \end{aligned}$$

여기서 α_n 은 노이즈 변수, a_s 는 non-zero 값의 신뢰도 변수, π_r 은 mixing weight, π_s^0, π_s^1 는 wavelet scaling 계수 s ($s > 1, L=3$)에 대한 전체 통계치 합 특성[8]이다. Hyperparameter e_0^s 과 f_0^s 는 계수 π_s^1 에 의한 균일 사전 확률이다. 각각의 MCMC 반복에서 조건적 사후 분포로부터 다음과 같이 샘플을 표현할 수 있다.

$$p(\theta_{s,i} | -) = (1 - \tilde{\pi}_{s,i}) \delta_0 + \tilde{\pi}_{s,i} N(\tilde{\mu}_{s,i}, \tilde{\alpha}_{s,i}^{-1}). \quad (21)$$

$\theta_{s,i}$ 는 $i=1, \dots, M_s$ 에 대해 s 에 의해 스케일링된 wavelet coefficient이고, M_s 는 s 스케일링된 전체 wavelet coefficient의 수이다[8].

$$\tilde{\alpha}_{s,i} = \alpha_s + \alpha_n \Phi_j^T \Phi_j, \quad (22)$$

$$\tilde{\mu}_{s,i} = \tilde{\alpha}_{s,i}^{-1} \alpha_n \Phi_j^T \tilde{v} \quad \text{with} \quad \tilde{v}_j = v - \sum_{k=1, k \neq j}^M \Phi_k \theta_k. \quad (23)$$

$$\frac{\tilde{\pi}_{s,i}}{1 - \tilde{\pi}_{s,i}} = \frac{\pi_{s,i}}{1 - \pi_{s,i}} \frac{N(0|0, \alpha_s^{-1})}{N(0|\tilde{\mu}_{s,i}, \tilde{\alpha}_{s,i})}. \quad (24)$$

여기서 Φ_j 는 크기 $N \times M$ 의 임의 투영 행렬(Random projection matrix)의 j 번째 열 값을 의미한다.

$$p(\alpha_s | -) = \Gamma(c_0 + 1/2 \sum_{i=1}^{M_s} 1(\theta_{s,i} \neq 0), d_0 + 1/2 \sum_{i=1}^{M_s} \theta_{s,i}^2), \quad (25)$$

$$p(\pi_r | -) = B(e_0^r + \sum_{i=1}^{M_s} 1(\theta_{s,i} \neq 0), f_0^r + \sum_{i=1}^{M_s} 1(\theta_{s,i} = 0)), \text{for } s = 1. \quad (26)$$

$$p(\pi_s^0 | -) = B(e_0^{s1} + \sum_{i=1}^{M_s} 1(\theta_{s,i} \neq 0, \theta_{pa(s,i)} = 0), f_0^{s0} + \sum_{i=1}^{M_s} 1(\theta_{s,i} = 0, \theta_{pa(s,i)} = 0)), \text{for } 2 \leq s \leq L. \quad (27)$$

$$p(\pi_s^1 | -) = B(e_0^{s1} + \sum_{i=1}^{M_s} 1(\theta_{s,i} \neq 0, \theta_{pa(s,i)} \neq 0), f_0^{s1} + \sum_{i=1}^{M_s} 1(\theta_{s,i} = 0, \theta_{pa(s,i)} \neq 0)), \text{for } 2 \leq s \leq L. \quad (28)$$

$$p(\alpha_n | -) = \Gamma(a_0 + N/2, b_0 + (v - \Phi\theta)^T (v - \Phi\theta) / 2). \quad (29)$$

여기서 $\theta_{pa(s,i)}$ 는 $\theta_{s,i}$ 의 parent 계수이다. 각각의 MCMC 반복 추산에서 θ 는 θ 의 모든 요소들이 jointly 샘플링 되며 $\theta_{s,i}$ 는 모든 s 와 i 연속적으로 샘플링 될 수 있다. 또한 MCMC 반복 추산에서 연산 속도 면에서 빠르게 수렴값을 얻는 방법에서 Block sampling 방법보다 sequential sampling 방법이 더 나음을 보았다[8]. 보통 128x128 사이즈의 이미지는 200회의 반복주기로 충분히 복원될 수 있고, 100개의 샘플에 상응하는 수집 주기를 갖는다.

V. 이미지 복원 실험

우리는 이미지 데이터를 압축하고 복원하는 실험을 Turbo 방법과 MCMC 알고리즘을 이용하여 두 성능을 비교하였다. 실험 원본 이미지로서 그림 2를 샘플링하여 원본 이미지 데이터를 행렬로 나타내고 이미지 압축 후에 각각 Turbo 알고리즘과 MCMC 알고리즘을 통하여 다시 복원했을 때의 이미지와 연산 수행시간의 성능을 비교분석하였다.

그림 2는 실험에 사용된 128*128 픽셀의 한 사진작가의 원본 흑백 사진이다. 그림 3은 Turbo 알고리즘을 통하여 이미지를 복원하여 다시 출력한 결과 이미지이며, 그림 4는 MCMC 기법을 이용하여 복원한 결과 이미지이다. 두 이미지

를 시각적으로 비교해 보았을 때 복원 후 손상된 정도를 통하여 Turbo 알고리즘의 복원 성능이 더 우수한 것으로 볼 수 있다. 또한 복원 연산 시간 값을 그림 5에서 비교하였을 때에도 Turbo 알고리즘과 MCMC 기법의 각각 평균 복원 연산 시간이 742(sec), 859(sec)로 연산 시간에 있어서도 우수하다. 그리고 그림 6에서 두 복원기법에 대해 원본 이미지 값과의 normalized mean squared error (NMSE) 값을 분석해 보았을 때에도 MCMC가 -20.10(dB) Turbo 알고리즘이 -20.31(dB)로 나타났다. 이와같은 성능 지표로 멀티콥터를 이용한 실시간 무선 영상 전송 기술에 Turbo 복원 알고리즘이 MCMC 복원 기법에 비해 비교적 효율적인 복원 방법으로 생각할 수 있다.



그림 2. 원본 이미지.



그림 3. Turbo approach를 통한 복원 이미지.



그림 4. MCMC를 통한 복원 이미지.

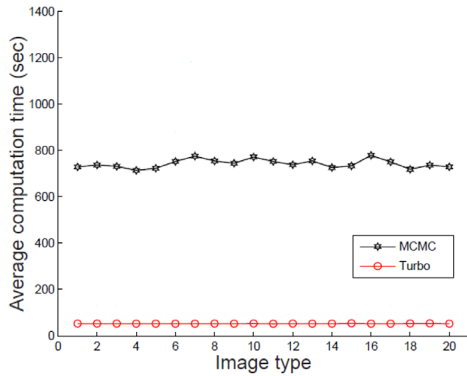


그림 5. MCMC와 Turbo 알고리즘의 평균 복원 연산 시간.




그림 6. 각 이미지의 NMSE.

VI. 결론

본 논문에서는 멀티컴퓨터를 이용한 끊임없는 실시간 Full HD급 이상 고화질 무선 영상전송 기술의 구현을 위해 이미지 압축 센싱 기법에 대한 Turbo 알고리즘과 MCMC 알고리즘 두 가지의 복원 기법의 성능을 비교 분석하였다. Turbo 알고리즘의 경우 정밀 추산 방법은 연산 시간의 측면에서 실질적 구현이 적합하지 않기 때문에 BP를 기반으로 한 근사 추산 방법을 통해 모의실험을 진행하였다. 실험 결과 실제 복원 이미지를 시각적 비교해 보았을 때 Turbo 알고리즘의 복원 방법이 비교적 선명하게 보일 뿐 만 아니라 Turbo 알고리즘과 MCMC 기법의 평균 복원 연산 시간, NMSE 면에서 Turbo 알고리즘의 성능이 우수한 것으로 나타났다. 향후 위와 같은 실험 결과를 멀티컴퓨터 영상 전송에 적용하여 더욱 효과적인 멀티미디어 전송 시스템이 구현되길 기대한다.

참고 문헌

[1] D. L. Donoho, "Compressed sensing," *IEEE Trans. Inf. Theory*, vol. 52, no. 4, pp. 1289-1306, Apr. 2006.
 [2] D. L. Donoho and J. Tanner, "Precise undersampling theorems," *IEEE Signal Process. Mag.*, vol. 98, no. 6, pp. 913-924, June. 2010.

[3] I. F. Akyildiz, W. Y. Lee, M. C. Vuran and S. Mohanty, "NeXt generation/dynamic spectrum access/cognitive radio wireless networks," *Computer Networks*, vol. 50, no. 13, pp. 2127 - 2159, 2006.
 [4] D. Cabric, S. Mishra, R. Brodersen, "Implementation issues in spectrum sensing for cognitive radios," in *Proc. of Asilomar Conf. on Signals, Systems and Computers*, vol. 1, pp. 772 - 776, 2004.
 [5] Zhu Han, H. Li and W. Yin, *Compressive sensing for wireless networks*, Cambridge, 2013.
 [6] H. N. Lee, S. J. Park and S. C. Park, "Introduction of Compressed Sensing," *Journal of the Institute of Electronics Engineers of Korea (J. IEEK)*, vol. 38 no. 1, pp. 19-30, Jan. 2011.
 [7] P. Schniter, "Turbo reconstruction of structured sparse signals," in *Proc. Conference on Information Sciences and Systems*, Mar. 2010.
 [8] L. He and L. Carin, "Exploiting structure in wavelet-based Bayesian compressive sensing," *IEEE Trans. Signal Process.*, vol. 57, no. 9, pp. 3488 - 3497, Sep. 2009.
 [9] J. Pearl, *Probabilistic Reasoning in Intelligent Systems*. San Mateo, CA: Morgan Kaufman, 1988.
 [10] G. F. Cooper, "The computational complexity of probabilistic inference using Bayesian belief networks," *Artificial Intelligence*, vol. 42, 1990.
 [11] D. L. Donoho, A. Maleki, and A. Montanari, "Message passing algorithms for compressed sensing," in *Proc. National Academy of Sciences*, vol. 106, pp. 18914 - 18919, Nov. 2009.
 [12] D. Guo, D. Baron, and S. Shamai, "A single-letter characterization of optimal noisy compressed sensing," in *Proc. Allerton Conf. Commun. Control Comput.*, (Monticello, IL), Oct. 2009.
 [13] C. P. Robert and G. Casella, *Monte Carlo Statistical Methods*, 2nd ed. New York: Springer, 2004.

저자

황 유 민 (Yu Min Hwang)

준회원



· 2012년 2월 : 광운대학교 전파공학과 학사
 · 2012년 3월 ~ 현재 : 광운대학교 전파공학과 석박통합과정

<관심분야> : 4G 이동통신, 디지털 통신, 압축 센싱, WLAN, LBS

이 선 의(Sun Yui Lee)

준회원



- 2013년 2월 : 광운대학교 전파공학과 학사
- 2013년 2월 ~ 현재 : 광운대학교 전파공학과 석박통합과정

<관심분야> : 가시광 통신, 협력통신, 인지무선통신, 양자통신, 압축 센싱

이 상 윤(Lee SangWoon)

종신회원



- 1987년 2월 : 연세대학교 전기공학과 학사졸업
- 1989년 2월 : 연세대학교 전기공학과 석사졸업
- 2005년 2월 : 연세대학교 전기전자공학과 박사졸업

· 1991년 5월 ~ 2005년 5월 : MBC 기술연구소
· 2005년 6월 ~ 2009년 2월 : 연세대학교 연구교수 (차세대방송기술연구센터)
· 2009년 3월 ~ 현재 : 남서울대학교 멀티미디어학과 교수
<관심분야> : Mobile Broadcasting, ITS

김 진 영(Jin Young Kim)

종신회원



- 1998년 2월 : 서울대학교 전자공학과 공학박사
- 2001년 2월 : SK텔레콤 네트워크연구소 책임연구원
- 2001년 3월 ~ 현재 : 광운대학교 전자융합공학과 교수

<관심분야> : 디지털통신, 가시광통신, UWB, 부호화, 인지무선통신, 4G 이동통신.