

An Improved Multi-resolution image fusion framework using image enhancement technique

Hojin Jhee*, Chulhee Jang**, Sanghun Jin***, Yonghee Hong****

Abstract

This paper represents a novel framework for multi-scale image fusion. Multi-scale Kalman Smoothing (MKS) algorithm with quad-tree structure can provide a powerful multi-resolution image fusion scheme by employing Markov property. In general, such approach provides outstanding image fusion performance in terms of accuracy and efficiency, however, quad-tree based method is often limited to be applied in certain applications due to its stair-like covariance structure, resulting in unrealistic blocky artifacts at the fusion result where finest scale data are void or missed. To mitigate this structural artifact, in this paper, a new scheme of multi-scale fusion framework is proposed. By employing Super Resolution (SR) technique on MKS algorithm, fine resolved measurement is generated and blended through the tree structure such that missed detail information at data missing region in fine scale image is properly inferred and the blocky artifact can be successfully suppressed at fusion result. Simulation results show that the proposed method provides significantly improved fusion results in the senses of both Root Mean Square Error (RMSE) performance and visual improvement over conventional MKS algorithm.

▶ Keyword: Multi-resolution Image fusion, Quad-tree structure, Multi-scale Kalman Smoothing

I. Introduction

다중센서 기반의 영상융합은 취득방식과 특성이 서로 다른 센서로부터 획득된 영상데이터를 융합하여 개별 영상만을 통하여 획득할 수 없었던 유용한 정보를 얻어내는 영상처리 기법이다. 다양한 종류의 다중센서 기반 영상융합 기술이 연구되어왔으며, 적용분야에 따라 크게 화소기반 (pixel), 특징기반 (feature), 그리고 결정기반 (decision)으로 분류할 수 있다[1]. 특히, 화소기반 융합 중 서로 다른 공간해상도를 가진 2개 이상의 영상을 이용하여 각 영상이 지니고 있는 장점 및 특징을 포함하는 단일영상을 재구성하는 다 해상도 (multi-resolution) 영상융합 기술은 해상도는 다르나 개별 영상이 보유한 독특한 정보가 융합됨으로써 보다 유용한 정보를 새롭게 생성할 수 있

다는 점에서 원격탐사, 군사, 의료등의 분야에서의 응용이 가능하다. 정확한 영상정보 분석을 위하여 고 해상도의 영상을 활용하는 것이 이상적이지만 광학장치와 이미지 센서의 물리적 한계로 인하여 정보획득이 제한적일 경우가 많기 때문에 다 해상도 영상융합 기법을 이용하여 높은 공간해상도의 영상을 생성하는 다양한 기술들이 제안되었다[2]. 해상도가 다른 영상들을 융합하기 위해서는 영상처리를 위한 효율적인 알고리즘을 포함하는 융합 프레임워크가 필요하며, 다중 스케일 (multi-scale) 기반의 영상신호 모델링 기법은 신뢰성과 효율성 측면에서 많은 이점을 제공한다. 다중 스케일 모델은 영상의 공간모델을 해상도의 증감에 따른 fine-coarse 스케일 (scale) 공간으로 변

• First Author: Hojin Jhee, Corresponding Author: Yonghee Hong

*Hojin Jhee (hojin.jhee@lignex1.com), LIG Nex1 Co.,Ltd.

**Chulhee Jang (cholhee.jang@lignex1.com), LIG Nex1 Co.,Ltd.

***Sanghun Jin (sanghunjin@lignex1.com), LIG Nex1 Co.,Ltd.

****Yonghee Hong (yonghee.hong@lignex1.com), LIG Nex1 Co.,Ltd.

• Received: 2017. 10. 11, Revised: 2017. 11. 01, Accepted: 2017. 11. 17.

환하여 영상 픽셀들 사이의 상관관계를 이미지 피라미드 상에서 쿼드트리(quad-tree)와 같은 트리구조를 통하여 매핑 한다. 이미지 피라미드 구조에서 각 레벨은 스케일로 정의되며 스케일의 변화에 따라 처리하고자 하는 원본영상의 해상도는 증감하게 된다. 피라미드 최 하단 레벨인 finest 스케일에서 최 상부의 coarsest 스케일로 영상은 다운샘플링 되고 결과적으로 fine 스케일에서 coarse 스케일로 이동함 따라 각 스케일 별 영상의 크기는 설정된 비율만큼 감소하여 해상도는 감소하고 영상의 단일 화소가 포함하는 영역의 크기는 증가하게 된다. 트리구조에서 영상픽셀은 노드 (node)로 표현되고 스케일 내부에서 또는 스케일 사이에서 픽셀들 간의 연관관계는 노드들 사이의 에지(edge)를 통하여 모델링 된다. 다중 스케일 쿼드트리 구조는 fine 스케일에서 4개의 자손노드 (children nodes) 가 한 단계 coarse 스케일의 단일 부모 (parent node) 노드와만 관계된다는 Markov 특성을 가정하며 이는 다 해상도 융합 알고리즘 구현 시 스케일 노드별 연산의 독립성을 보장될 수 있다는 점에서 효율적인 구조이다[3].

본 연구에서는 다 해상도 영상융합을 위하여 Rauch-Tung-Striebel (RTS)[4] 알고리즘을 트리구조 Gaussian Markov 프로세스 모델과 접목시켜 구현한 Multi-scale Kalman Smoothing (MKS)[5] 방식을 적용하였다. Fig. 1. (a)와 같이 쿼드트리 구조의 특정 스케일에는 다중 센서에 의해 획득된 해상도가 다른 영상이 위치하며 MKS 알고리즘은 트리구조의 finest 스케일에서 coarsest 스케일로의 상향 Kalman 필터링과 역순의 smoothing 으로 구성된다. 다중 스케일 모델을 통하여 상향 Kalman 필터링을 수행함으로써 해상도가 다른 영상들이 융합되고 다시 하향 smoothing을 수행하여 각 스케일 별로 LMSE (Least Mean Squared Error) 기준으로 최적화된 융합결과를 생성하게 된다. 측정된 영상 데이터가 없는 스케일에서 MKS 프레임워크는 모델추정에 의하여 해당 스케일의 융합결과를 최적 추정하여 제공한다. 트리구조의 Markov 특성에 의해 각 스케일 노드별 픽셀 정보들은 상/하 두 방향의 알고리즘 절차를 통하여 반복적 연산과정 없이 융합되어 질 수 있고 이는 알고리즘의 연산측면에서 매우 효율적이다. 그러나 이러한 연산적 효율성에도 불구하고 finest 스케일의 일부 노드에 측정 데이터가 없을 경우 (data missing) 상향 Kalman 필터링 과정 중 coarse 스케일로 새로운 정보가 전파되지 않는다는 단점이 존재한다. Finest 스케일 영상 중 픽셀정보가 없는 영역에서는 하향 smoothing 단계에서 단순히 coarse 스케일에서의 추정 값이 보간법(nearest interpolation)에 의해 쿼드트리 에지를 통하여 fine 스케일로 전파되게 되며 이는 융합 결과의 해당영역에서 anti aliasing에 의한 blocky 왜곡 (artifact)을 발생시킨다. (Fig. 1. (b)) 이는 쿼드트리 구조의 covariance 구조가 blocky한 형태를 가지게 됨으로써 나타나는 현상이다. 알고리즘 측면에서 해석해 볼 때 MKS 융합 방식은 쿼드트리 구조에서 스케일 노드로 정의된 불규칙 변수를 MAP (Maximum a posterior) 방식[6]으로 추정하는 기법이다. MAP 방식은 신호

모델의 covariance 구조와 밀접한 관계를 가지며 MKS에서 쿼드트리 구조가 가지는 blocky한 covariance 구조는 inference 수행과정에서 추정 (estimate)결과에 반영되어 최종 융합결과에 나타나게 된다. 따라서 본 논문에서는 MKS 융합 프레임워크를 적용한 다 해상도 영상융합 방식에서 finest 스케일 데이터 부재로 발생하는 blocky 왜곡을 효율적으로 경감시키는 새로운 방식을 제안하였다. 이를 위하여 학습방식의 Super Resolution (SR)[7] 영상복원 방식을 적용하여 추가적인 finest 스케일 영상 데이터를 생성하고, 새로 생성된 SR 영상을 융합 프레임워크의 입력으로 활용하는 Super Resolution MKS (SR-MKS)를 구현하였다.

본 논문은 다음과 같이 구성되어 있다. II장에서 영상융합 기술 동향을 기술하였고, III장에서는 다중 스케일 영상 모델링 방식과 다 해상도 융합 알고리즘인 MKS 알고리즘에 대하여 설명하였다. IV장에서는 다양한 트리구조의 특성분석을 통하여 MKS에서 발생하는 blocky artifact의 원인을 분석하고 제안한 SR-MKS 알고리즘에 대하여 기술하였다. V장에서는 본 연구의 결론을 다룬다.

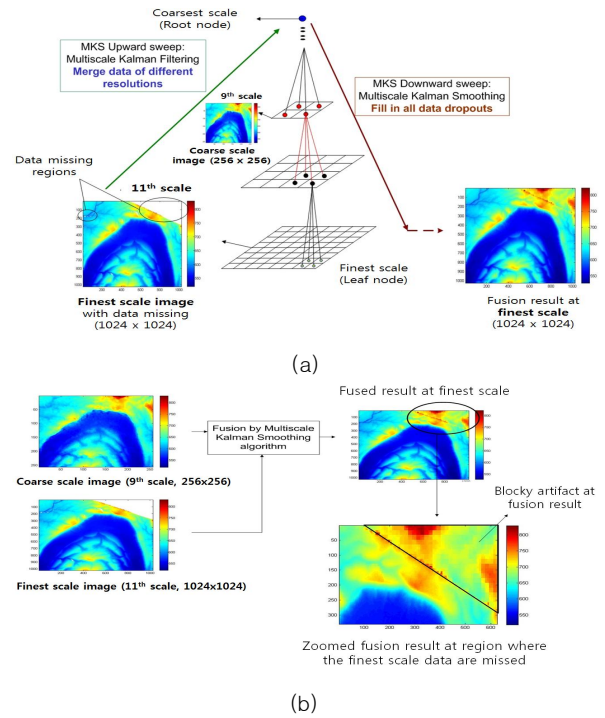


Fig. 1. (a) Coarse scale image (at 9th scale) and finest scale image (at 11th scale) with data missing are optimally fused by MKS algorithm, and (b) At fusion result, there is region suffered by blocky artifact where finest scale data are not available

II. Preliminaries

다중 스케일 모델을 이용한 영상처리 방식은 위성 및 비행체에

탑재된 센서를 통하여 획득된 다양한 종류의 영상을 분석하는 원격 탐사 (remote sensing) 분야에서 널리 연구되어 왔다[8]. 픽셀정보의 인과성 (causality) 분석을 위하여 단일 스케일 영상모델인 MRFs (Markov Random Fields)[9] 방식이 널리 사용되어 왔으나 에너지 함수의 최적화 과정에서 노드 간 상관관계를 획득하기 위하여 영상 전체 픽셀을 고려하기 때문에 모델 파티션 함수의 파라미터 식별을 위한 알고리즘의 복잡도는 영상사이즈와 지수 관계로 비례하여 증가하게 된다. [10]은 다중 스케일 트리구조를 활용하여 픽셀 사이의 상관관계를 스케일 간 노드와 에지를 이용하여 모델링하는 방식을 제안하였으며, 이는 inference 수행 시 알고리즘 연산량이 영상 사이즈와 선형적 관계를 가진다는 장점을 가진다. [11]은 스케일 기반의 영상모델 기법을 이용하여 쿼드트리 구조에 Kalman 필터 방식의 선형 추론 프레임워크를 제안하여 해양 표면 데이터 분석을 위한 영상처리에 적용하였다. [12]은 Markov 트리구조에 recursive 방식의 다중 스케일 MKS 알고리즘을 제안하였고, [13]은 본 방식을 이용하여 측정 반경은 넓으나 해상도가 낮은 위성기반 ERS (European Remote Sensing Satellite) 영상과 해상도는 높으나 취득 반경이 좁아 특정 지역의 데이터만이 존재하는 고해상도 TOPSAR (Topographic Synthetic Aperture Radar)[14] 영상을 융합시키기 위하여 적용하였다. [15]은 단일 저해상도 영상과 다수의 고해상도 영상을 융합하기 위하여 기존의 MKS를 개선하여 순차 반복 업데이트를 적용한 벡터 화 MKS (vector valued MKS) 알고리즘을 제안하였다. 이는 동일 스케일에 다수의 영상데이터가 존재 할 때 영상융합을 위한 알고리즘 연산량을 효과적으로 감소시켰다. Markov 쿼드트리 구조가 가지는 blocky 왜곡에 대응하기 위하여 동적 트리 및 루피 트리와 같은 다양한 방식의 비정형 형태 유동 트리(flexible tree) 구조[16]가 제안되어왔다. 하지만 이 같은 유동적인 트리구조는 영상 artifact 경감에 효과적이지만 트리 구조 내 각 노드의 연관관계 분석 및 inference 시 최적결과 생성을 위한 반복 연산이 요구되기 때문에 사이즈가 큰 고해상도 영상 처리적용에 매우 제한적이다.

III. Multi-Scale Data Representations

1. State space model on quad-tree structure

쿼드트리 구조에서 노드 인덱스 s 로 정의된 상태변수 $x(s)$ 의 동적모델과 그에 상응하는 측정모델 $y(s)$ 는 Gaussian auto-regressive 형태로 식 (1)과 (2)같이 표현된다[10].

$$x(s) = \Phi(s)x(Bs) + \Gamma(s)w(s), \quad w(s) \sim N(0, Q(s)) \quad (1)$$

$$y(s) = H(s)x(s) + v(s), \quad v(s) \sim N(0, R(s)) \quad (2)$$

식 (1)에서 상태변수 $x(s)$ 는 노드 s 에서의 픽셀을 표현한다. Fig. 2와 같이 이미지 피라미드에서 노드 s 는 coarse 스케일에서 단일 부모노드(Bs)와 연결되고, fine 스케일에서 다수의 자손노드

들 ($s\alpha_i$)과 연결된다. 일반적으로 트리구조의 차수는 스케일 내에서 개별 노드가 보유하고 있는 자손노드의 개수로 정의된다[10]. 식 (1)에서 B 와 $\Phi(s)$ 는 각각 fine 스케일에서 coarse 스케일로의 전향 연산자, coarse 스케일에서 fine 스케일로의 전향 연산자이며, $\Gamma(s)$ 는 상태변수 $x(Bs)$ 가 한 단계 fine 스케일로 전이될 때 생성되는 stochastic detail 함수를 나타낸다. 또한, 식 (2)에서 $H(s)$ 는 상태변수 $x(s)$ 와 측정치 $y(s)$ 를 관계시켜 주는 매핑 함수이다. 스케일 간 regression은 트리구조의 최상단인 coarsest 스케일에서 초기화되며 트리구조의 최하부인 finest 스케일 방향으로 진행된다.

2. Markov property on quad-tree structure

다중 스케일 모델에서 쿼드트리 구조는 Markov 특성을 가진다. 특정 스케일 m 에서 x_s 를 노드 s 에 의해 표현된 상태변수와 할 때, s 를 기준으로 분기된 노드들로 표현된 상태 변수들의 부분집합 (subset) 들은 서로 독립적이라고 가정한다. 다시 말해서, Ψ_{s_i} (쿼드 트리 경우 $i = 1, 2, 3$)를 노드 s 로부터 분리되어진 상태변수들의 부분집합 이라고 하면, 부분집합에 포함 된 상태변수들은 식 (3)을 만족한다.

Fig. 3. 은 쿼드트리구조의 Markov 특성을 2차 트리를 활용하여 설명하였다.

$$P_{\Psi_{s_1}, \Psi_{s_2}, \Psi_{s_3} | x_s} (\Psi_{s_1}, \Psi_{s_2}, \Psi_{s_3} | x_s) = P_{\Psi_{s_1} | x_s} (\Psi_{s_1} | x_s) P_{\Psi_{s_2} | x_s} (\Psi_{s_2} | x_s) P_{\Psi_{s_3} | x_s} (\Psi_{s_3} | x_s) \quad (3)$$

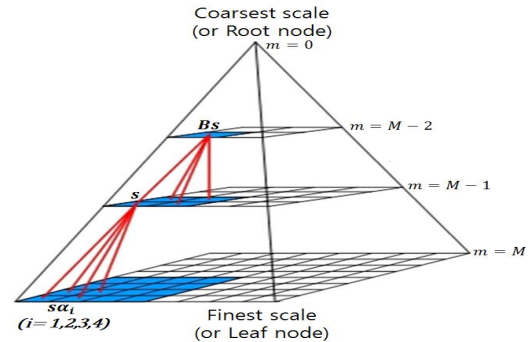


Fig. 2. Quad-tree structure defined on image pyramid. Each level of pyramid m represents the scale




Fig. 3. Conditioned on node s , the nodes in the corresponding 3 subset of nodes $(\Psi_{s_1}, \Psi_{s_2}, \Psi_{s_3})$ extending away from s are uncorrelated

식 (3)의 Markov 특징은 직관적이지만 효율적인 추정 (estimation) 알고리즘 구현이 가능하다는 점에서 활용도가 높다. 특정 노드 s 에서 분기된 자손노드들의 집합은 Markov 특성에 의해 서로 decoupled 되며, 이는 각 자손노드들에 의해 표현된 상태변수들이 독립적으로 추정될 수 있을 뿐 아니라 결과적으로는 트리구조를 통한 효율적인 병렬구조의 알고리즘 구현을 가능하게 한다[12].

3. Multi-scale Kalman Smoothing (MKS) algorithm

MKS 알고리즘은 RTS 방식을 다중 스케일 모델에 적용하여 각 스케일에서의 픽셀 추정 값과 그에 대한 error covariance 를 제공하며 쿼드트리 구조에서 finest 스케일에서 coarsest 스케일 방향으로의 상향 Kalman 필터링과 역방향 하향 smoothing으로 구성된다. 트리구조 Kalman 필터링이 일반적인 1차원 필터링과의 다른 점은 fine 스케일에서 coarse 스케일로의 recursion과정에서 fine 스케일 노드에서의 추정 값들이 coarse 스케일 부모노드로 전파될 때 해상도 매칭을 위하여 merge 단계가 추가된다는 점이다. 스케일이 감소될 때마다 merge 단계를 수행하여 쿼드트리 구조의 상부로 필터링이 가능하도록 한다. MKS 알고리즘의 상세설명은 [12]에 기술되어 있으며 본 절에서는 알고리즘 수행단계를 간략히 요약한다.

단계 1. 초기화 (Initialization)

$$\begin{aligned} \hat{x}(s|s+) &= 0 \\ P(s|s+) &= P_s \end{aligned} \tag{4}$$

식 (4)에서 $s+$ 는 자손노드를 표현하며 $\hat{x}(s|s+)$ 와 $P(s|s+)$ 는 상향 Kalman 필터링에 의해 추정된 상태변수 $x(s)$ 의 a priori 추정 값 와 error covariance 이다. P_s 는 노드 s 에서 상태변수 $x(s)$ 의 covariance 이며 $E[x(s)x^T(s)]$ 로 정의된다.

단계 2. 상향 Kalman 필터링 (Upward Kalman Filtering)

Fig. 2. 의 finest 스케일 M 에서 식 (4)의 초기 값을 적용하여 해당 노드 s 에 대한 Kalman 필터링을 식 (5)와 같이 수행한다.

$$\begin{aligned} K(s) &= P(s|s+)H^T(s)[H(s)P(s|s+)H^T(s) + R(s)]^{-1} \\ \hat{x}(s|s) &= \hat{x}(s|s+) + K(s)[y(s) - H(s)\hat{x}(s|s+)] \\ P(s|s) &= [I - K(s)H(s)]P(s|s+) \end{aligned} \tag{5}$$

$K(s)$ 는 Kalman 이득, $\hat{x}(s|s)$ 와 $P(s|s)$ 는 각각 상태변수 $x(s)$ 의 a posteriori 추정 값과 error covariance를 나타낸다. 노드 s 에서 식 (5)의 필터링을 거친 후 그 결과는 coarse 스케일로 식 (6)과 (7)같이 프로젝션 되어 merge 된다.

단계 3. 프로젝션 & Merging (Projection & Merging)

$$\begin{aligned} \hat{x}(s|\alpha_i) &= F(s\alpha_i)\hat{x}(s\alpha_i|s\alpha_i) \\ P(s|\alpha_i) &= F(s\alpha_i)P(s\alpha_i|s\alpha_i)F^T(s\alpha_i|s\alpha_i) + Q(s\alpha_i) \end{aligned} \tag{6}$$

식 (6)에서 $s\alpha_i$ 는 노드 s 로 프로젝션 되는 자손노드를 나타내며 (쿼드트리의 경우 $i=1,2,3,4$), $F(s\alpha_i)$ 는 fine 스케일에서 coarse 스케일로의 프로젝션 연산자 이다.

$$\hat{x}(s|s+) = P(s|s+) \sum_{i=1}^4 P^{-1}(s|\alpha_i) \hat{x}(s|\alpha_i) \tag{7}$$

$$P(s|s+) = [(1-q)P_s^{-1}(s) + \sum_{i=1}^4 P^{-1}(s|\alpha_i)]^{-1}$$

노드 s 에서 식 (5) 에 의해 계산된 상태변수 $x(s)$ 의 추정 값과 error covariance 는 식 (6)과 (7)을 통하여 프로젝트 및 merge 되어 부모노드에서 Kalman 필터링을 위한 prior 정보로 활용된다. 식 (5)~(7) 까지의 상향 필터링 단계는 쿼드트리의 coarsest 스케일에 도달할 때까지 지속되며 각 스케일에는 노드별 추정 값 ($\hat{x}(s)$)과 error covariance가 저장된다.

단계 4. 하향 Smoothing (Downward Smoothing)

식 (4)~(7)의 상향 Kalman 필터링 완료 후 각 스케일 노드에는 상태변수들의 추정 값과 error covariance 들이 저장되어 있다. 하향 smoothing 은 coarsest 스케일에서 초기화 되어 finest 스케일 까지 지속되며 식 (8)을 통하여 계산된다.

$$\begin{aligned} \hat{x}^s(s) &= \hat{x}(s|s) + J(s)[\hat{x}^s(Bs) - \hat{x}(Bs|s)] \\ P^s(s) &= P(s|s) + J(s)[P^s(Bs) - P(Bs|s)]J^T(s) \\ J(s) &= P(s|s)F^T(s)P^{-1}(Bs|s) \end{aligned} \tag{8}$$

$\hat{x}^s(s)$ 와 $P^s(s)$ 는 노드 s 에서의 smoothing 결과이고 $\hat{x}^s(Bs)$ 와 $P^s(Bs)$ 는 노드 s 의 부모노드 Bs 에서 식 (5)에 의해 계산된 추정 값과 error covariance 이다. 또한 $\hat{x}^s(Bs|s)$ 와 $P(Bs|s)$ 는 식 (6)을 통하여 계산된 결과이다.

Fig. 4. 의 (a) 와 (b)는 각각 상향 Kalman 필터링과 하향 smoothing 과정을 도식화하여 표현하였다.




Fig. 4. The MKS algorithm. (a) Upward Kalman filtering, and (b) Downward smoothing

MKS에서 finest 스케일 노드에 측정값이 없을 경우 (data missing) 하향 smoothing을 통하여 해당 영역의 픽셀 값들이 부모 노드로부터 추정되고 자손노드로 전파되어 채워지게 된다. MKS 알고리즘의 연산 복잡도는 finest 스케일 노드의 수가 S_M 일 때, $O(S_M)$ 이다.

4. Covariance characteristic of quad-tree structure and blocky artifact

MKS방식을 통한 다 해상도 영상 융합방식은 매우 효율적이지만, 쿼드트리 구조의 covariance 특성에 의해 융합결과에 계단형태의 blocky 왜곡을 발생 시킨다. MKS 융합방식은 궁극적으로 스케일 노드로 정의된 Gaussian 상태변수 $x(s)$ 를 주어진 모델과 측정치를 이용하여 MAP (Maximum a posterior) 방식으로 추정하는 기법이며 [12], inference 수행과정에서 쿼드트리 구조의 blocky한 covariance 특성이 최종 추정결과에 반영되어 왜곡 형태로 나타나게 된다. 특히, Fig. 1. (b)와 같이 융합하고자 하는 finest 스케일 영상에서 측정 데이터가 없을 경우 해당 영역의 융합결과에서 이러한 현상이 두드러지게 나타난다. 본 절에서는 Fig. 5. 와 같이 3가지 다른 트리모델의 covariance 특성을 비교하여 쿼드트리 구조로부터 발생하는 blocky artifact의 원인을 분석하였다.

Jointly Gaussian 불규칙 벡터 $x = [x_1, x_2, \dots, x_n]^T$ 에 대하여 불규칙 변수들의 joint pdf 함수 $p(x)$ 는 식 (9)와 같다.

$$p(x) \propto \exp\left(-\frac{1}{2}x^T \Theta x + z^T x\right), \quad x \sim N^{-1}(z, \Theta) \quad (9)$$

$$\Theta = P^{-1} = (E[(x - m_x)(x - m_x)^T])^{-1}, \quad z = \Theta m_x$$

식 (9)에서 $p(x)$ 는 information form [6]으로 표현되었고, m_x 는 불규칙 벡터 x 의 mean 벡터, Θ 는 covariance 매트릭스 P_x 의 역행렬을 나타낸다. 주어진 측정 벡터 $y = Hx + v$, $v \sim N(0, R)$ 에 대하여 조건부 pdf $p(x|y)$ 는 식 (10)과 같다.

$$p(x|y) \propto \exp\left(-\frac{1}{2}x^T (\Theta_{prior} + H^T R^{-1} H)x + x^T (z_{prior} + H^T R^{-1} y)\right) \quad (10)$$

식(10)을 최대화 시키는 MAP (Maximum a priori) 추정결과 \hat{x} 과 error covariance \hat{P} 는 식 (11)과 같으며, MKS 알고리즘은 Markov 쿼드트리 구조에서 식 (11)의 노드별 추정 값 \hat{x} 와 \hat{P} 를 역행렬 연산 없이 계산할 수 있는 방식으로 일반화 할 수 있다.

$$\hat{x} = \operatorname{argmax}(p(x|y)) = \Theta^{-1} z \quad (11)$$

$$\hat{P} = E[(x - \hat{x})(x - \hat{x})^T | y] = \Theta^{-1}$$

$$\Theta^{-1} = (\Theta_{prior} + H^T R^{-1} H)^{-1}, \quad z = z_{prior} + H^T R^{-1} y$$

식 (10)과 (11)에서 z_{prior} 는 식 (9)에 의해 0을 가진다. 식 (11)과 같이 \hat{x} 는 Θ^{-1} 와 밀접한 관계를 가지고 있으며 특히, Θ_{prior} 와 직접적으로 관련되어 있다. Θ_{prior} 는 적용하고자 하는 트리모델에 따라 특성이 다르며, Fig. 5.에서 보느냐와 같이 (b)의 쿼드트리 구조에서는 단일 스케일 MRF 모델 (a)와 스케일내의 노드가 공간적으로 연결된 트리 구조 (c) 대비 blocky한 형태의 Θ_{prior} 를 가짐을 알 수 있다. 이러한 결과는 식 (11)의 MAP 추정 값 계산 시 \hat{x} 와 \hat{P} 에 blocky한 패턴을 포함하게 되며 MAP 기반의 MKS

융합 알고리즘 결과에도 동일하게 나타나게 된다.

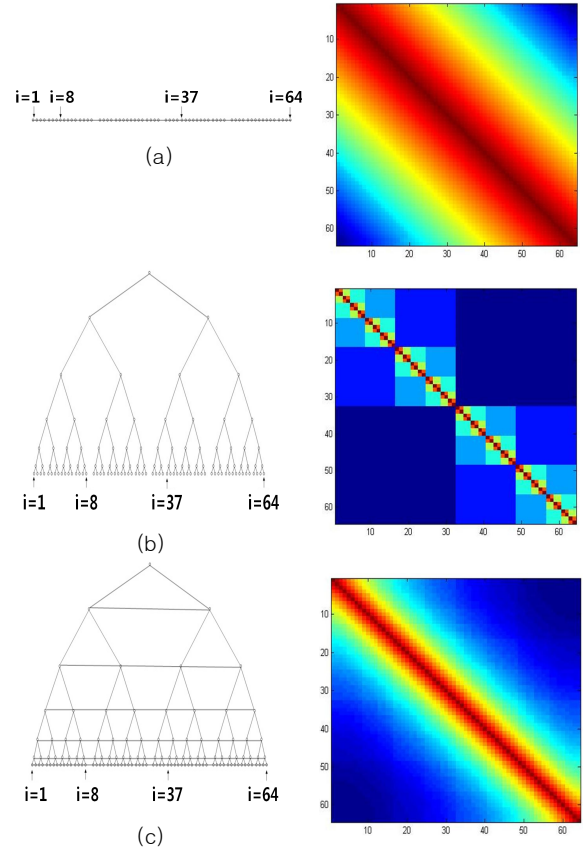


Fig. 5. Three tree structures and their Θ_{prior} s. (length of 64) (a) Mono-scale Markov chain, (b) 2nd order tree (dyadic tree), and (c) spatially connected structure in (b). Red color represents higher values. Edge in each tree represents the statistical dependency between particular node and its neighboring node

IV. The Proposed Scheme

본 장에서는 MKS의 blocky 왜곡을 억제시키기 위한 새로운 융합 프레임워크를 제안한다. Blocky 왜곡은 융합 결과 중 finest 스케일 영상의 data missing 영역에서 발생하며, 이를 경감시키기 위하여 Super Resolution (SR)에 의해 복원된 새로운 고 해상도 영상을 융합 프레임워크에 포함시킨다.

1. Single image based Super Resolution(SR) method

Super Resolution (SR)은 단일 혹은 다수의 저해상도 영상을 이용하여 고주파 성분을 추론한 후 입력 영상에 대한 고해상도 영상을 복원해 내는 기술을 일컫는다 [7]. 이 중, 단일영상 기반 방식은 입력 저해상도 영상과 추정하고자 하는 고해상도 영상이 가지는 대응성 (correspondence) 학습을 위한 다수

의 저해상도와 고해상도 페어를 이용하여 추정한다. Table 1. 은 단일영상 기반 SR 알고리즘 수행에 필요한 영상들과 필요한 특징(feature) 세트를 정의하였다.

Table 1. Images, patches and feature sets notation

Images	Patch sets	Feature sets
L_s	$L_s = \{l_s^1, l_s^2, \dots, l_s^{N_s}\}$	$F_{L_s} = \{f_{L_s}^1, f_{L_s}^2, \dots, f_{L_s}^{N_s}\}$
\widehat{H}_s	$\widehat{H}_s = \{\widehat{h}_s^1, \widehat{h}_s^2, \dots, \widehat{h}_s^{N_s}\}$	$F_{\widehat{H}_s} = \{f_{\widehat{H}_s}^1, f_{\widehat{H}_s}^2, \dots, f_{\widehat{H}_s}^{N_s}\}$
L_t	$L_t = \{l_t^1, l_t^2, \dots, l_t^{N_t}\}$	$F_{L_t} = \{f_{L_t}^1, f_{L_t}^2, \dots, f_{L_t}^{N_t}\}$
H_t	$H_t = \{h_t^1, h_t^2, \dots, h_t^{N_t}\}$	$F_{H_t} = \{f_{H_t}^1, f_{H_t}^2, \dots, f_{H_t}^{N_t}\}$

Table 1.에서 L_s 는 입력 저 해상도 영상, \widehat{H}_s 는 복원되고자 하는 L_s 의 SR 영상이며, 학습을 위한 저해상도 및 고해상도 영상 페어를 각각 L_t 와 H_t 로 정의한다 (H_t 는 L_t 의 고해상도 영상). l_s^n , \widehat{h}_s^n , l_t^m 및 h_t^m 는 L_s , \widehat{H}_s , L_t 및 H_t 로부터 추출된 영상 패치들을 나타내며 N_s 와 N_t 는 영상 L_s 와 L_t 로부터 추출된 패치의 개수이다. ($1 \leq n \leq N_s$, $1 \leq m \leq N_t$) F_{L_s} , $F_{\widehat{H}_s}$, F_{L_t} 및 F_{H_t} 는 영상패치 l_s^n , \widehat{h}_s^n , l_t^m 및 h_t^m 로부터 추출된 feature들을 원소로 가지는 벡터를 나타낸다. l_s^n 과 \widehat{h}_s^n 는 유사한 로컬 형태를 가지기 때문에 l_s^n 과 \widehat{h}_s^n 패치로부터 추출된 feature는 feature 공간에서 서로 근접하여 위치하게 되며, 이는 $f_{L_s}^n$ 와 특징 $f_{L_t}^m$ 가 서로 근접해 있다면 $f_{H_t}^m$ 역시 $f_{\widehat{H}_s}^n$ 와 근접한다고 말할 수 있다. 따라서 단일 영상기반 SR 기법은 feature 공간에서 $f_{L_s}^n$ 와 F_{L_t} 원소들 간의 거리를 계산하여 가장 근접한 $f_{L_t}^m$ 을 찾고, 그 feature가 추출된 패치 l_t^m 의 고해상도 페어 h_t^m 을 선택하는 방식으로 일반화될 수 있다. Feature 공간에서 $f_{L_s}^n$ 와 가장 근접한 $f_{L_t}^m$ 을 추출하는 방식으로 k -Nearest Neighborhood (k -NN)을 활용하며, l_2 -norm을 이용하여 feature 공간에서 $f_{L_s}^n$ 와 근접한 k 개의 feature 들을 F_{L_t} 로부터 추출해내고 그에 해당하는 학습패치를 L_t 로부터 선택하여 $L_t^k = \{\tilde{l}_t^1, \tilde{l}_t^2, \dots, \tilde{l}_t^k\}$ 과 같이 정의한다. k -NN에 의해 추출된 저해상도 학습 패치 L_t^k 를 기반으로 하여 그에 해당되는 고해상도 패치 페어 $H_t^k = \{\tilde{h}_t^1, \tilde{h}_t^2, \dots, \tilde{h}_t^k\}$ 를 H_t 로부터 선택한 후 그 결과를 최적으로 통합하기 위하여 가중치 벡터 $\Gamma_n = \{\gamma_n^1, \gamma_n^2, \dots, \gamma_n^k\}^T$ 를 식 (12)와 같이 계산한다.

$$\min_{\Gamma_n} (\epsilon_n) = \min_{\Gamma_n} \|l_{svcc}^n - \sum_{k=1}^K \gamma_k \tilde{l}_{tvec}^k\|^2, \Gamma_n^T \Gamma_n = 1 \quad (12)$$

$$\Pi_n = (l_{svcc}^n \mathbf{1}^T - L_{tvec}^k)^T (l_{svcc}^n \mathbf{1}^T - L_{tvec}^k), \Gamma_n = \frac{\Pi_n^{-1} \mathbf{1}}{\mathbf{1}^T \Pi_n^{-1} \mathbf{1}}$$

식 (12)에서 l_{svcc}^n 와 \tilde{l}_{tvec}^k 는 각각 $p^2 \times 1$ 차원으로 벡터화된 l_s^n 와 \tilde{l}_t^k 이고 (p 는 패치 사이즈), $\mathbf{1}$ 은 $k \times 1$ unit 열벡터를 나타낸다. L_{tvec}^k 의 각 열은 $\tilde{l}_{tvec}^1, \tilde{l}_{tvec}^2, \dots, \tilde{l}_{tvec}^k$ 이며 $p^2 \times k$ 차원을 가진다. 식 (12)의 Γ_n 와 학습 패치 \tilde{h}_t^k 에 의해 \widehat{h}_s^n 는 식 (13)과 같이 구해진다.

$$\widehat{h}_s^n = \sum_{k=1}^K \gamma_k^k \tilde{h}_t^k \quad (13)$$

식 (13)에 의해 구해진 각 \widehat{h}_s^n 는 유사한 방식으로 복원된 주변 패치 \widehat{h}_s^{n-1} 및 \widehat{h}_s^{n+1} 와의 인과성을 고려하여 공간적으로 중첩되어 최종 \widehat{H}_s 를 생성한다.

2. Super Resolution Multi-scale Kalman Smoothing(SR-MKS) algorithm

제안하는 SR-MKS 알고리즘은 융합하고자 하는 finest 스케일 영상에 data missing 영역이 존재할 경우 이를 보상하기 위하여 coarse 스케일 영상으로 부터 고해상도 영상을 복원하고 그 영상을 MKS 융합 프레임워크의 새로운 입력으로 포함시키는 것이다. 추가적인 고 해상도 영상이 finest 스케일에 포함됨에 따라 두 개 이상의 동일 해상도 영상을 해당 스케일에서 융합시킬 수 있는 벡터 방식의 (vector valued) MKS[15] 방식이 적용된다. SR에 의해 생성된 영상은 finest 스케일 영상의 data missing 영역에 고 주파수 성분을 가지는 새로운 정보를 제공함으로써 MKS 수행 시 finest 스케일 융합결과에서 나타나는 blocky 왜곡을 효과적으로 경감시킬 수 있다. SR 영상을 생성하기 위하여 III. 3절의 MKS 알고리즘을 통하여 얻어진 coarse 스케일에서의 융합결과를 L_s 으로 사용하고, 이는 MKS의 최적 융합결과가 SR 생성에 반영될 수 있다는 측면에서 성능향상을 위한 유리한 접근 방식이다.

3. Implementation of SR-MKS

Fig. 6.은 제안 방식의 구현 및 성능검증을 위하여 사용된 영상을 나타낸다. 각 영상은 Australia Finke River 주변지역을 공간해상도 20m의 (a) ERS와 공간해상도 5m의 (b) TOPSAR 센서를 활용하여 취득한 영상이다. Fig. 6. (a)와 (b)의 노란박스로 표시된 영역은 각각 MKS와 SR-MKS 알고리즘의 입력 영상으로 사용되는 되는 coarse 스케일 영상 (256×256)과 finest 스케일 영상 (1024×1024)을 나타낸다. 또한, Fig. 6. (b)에서 흰색 박스로 표현된 8개의 영역들은 IV. 1절에 설명된 SR 알고리즘 수행을 위하여 추출된 고 해상도 학습 영상 (H_t)을 나타낸다.




Fig. 6. (a) ERS image, and (b) TOPSAR image. The regions represented by yellow boxes in (a) and (b) are extracted and used as coarse scale (256 x 256 in 9th scale) and finest scale (1024 x 1024 in 11th scale) inputs of MKS and SR-MKS algorithms

SR을 위하여 III. 3 절의 MKS로부터 coarse 스케일 융합결과를 얻고, 이를 Table 1.의 L_s 로 정의하여 5×5 크기의 l_s^n 를 추출하였다. 주변 패치들 간의 연관성을 고려하여 각 l_s^n 는 주변 패치 l_s^{n-1} 및 l_s^{n+1} 와 4픽셀을 공간적으로 중첩하여 추출 하였다. 학습을 위한 고해상도 학습 패치 h_i^n 는 H_i 로부터 16픽셀을 중첩하여 추출하였고, 각 h_i^n 를 2단계 다운샘플링 하여 저 해상도 학습 패치 l_i^n 를 생성하였다. Feature 공간에서 $f_{L_s}^n$ 와 가장 근접한 $f_{L_t}^n$ 을 추출하기 위하여 l_s^n 와 l_t^n 의 1차 및 2차 그래디언트를 계산하여 2×1 차원의 $f_{L_s}^n$ 와 $f_{L_t}^n$ 를 생성하였다. $k=4$ 인 k -NN을 적용하고, 식 (12)를 통하여 얻어진 최적의 가중치 벡터 T_n 를 식 (13)에 적용하여 최종 SR영상을 생성하였다.

4. Simulation results

Fig. 7. 은 제안된 융합방식의 성능검증을 위하여 사용된 finest 스케일 영상과 SR 복원 영상을 나타낸다. 결과의 정량적 비교를 위하여 data missing이 없는 finest 스케일 영상에서 Fig. 8. (b)와 같이 5개의 영역 A, B, C, D, E를 임의의 data missing 영역으로 지정하였고, 해당 영역에서의 융합결과에 대한 RMSE를 식 (15)와 같이 계산하였다.

$$RMSE = \sqrt{\frac{1}{MN} \sum_{i,j} (x_{CT}(i,j) - \hat{x}(i,j))^2} \quad (15)$$

식 (15)에서 $x_{CT}(i,j)$ 는 finest 스케일 영상의 ground truth 값이며, $\hat{x}(i,j)$ 는 기존 MKS 방식과 제안된 SR-MKS를 적용한 융합결과이다. Fig. 7. (a)는 SR을 위한 입력영상 L_s , (b)는 임의의 data missing 영역이 포함된 finest 스케일 영상, (c)는 SR 방식을 적용하여 data missing 영역을 복원한 결과를 나타낸다. 본 시뮬레이션에서 coarse 와 finest 스케일 영상은 각각 9번째 와 11번째 스케일에 위치하며, 11번째 스케일에는 data missing 된 finest 스케일 영상과 SR에 의해 생성된 고해상도 영상이 위치한다.




Fig. 7. (a) The MKS result at coarse scale, (b) finest scale input with data missing regions in A,B,C,D and E, and (c) auxiliary high resolution (11th scale) input achieved by SR for the data missing regions in A,B,C,D and E

Fig. 8.은 기존 MKS와 제안한 SR-MKS 방식을 활용하여 얻어진 finest 스케일 (11th 스케일)에서의 영상융합 결과를 나타내었다. 기존 MKS 방식을 적용할 경우, Fig. 8. (a)와 같이 융합결과의 data missing 지역 (A, B, C, D, E)에서 계단형태의 blocky 왜곡이 나타났으며, SR-MKS를 적용함으로써 이와 같은 왜곡현상을 효과적으로 억제시킬 수 있었다. 이는 새롭게 생성된 SR 영상이 data missing 영역에 고해상도 영상정보를 제공해 줌으로써 융합결과의 개선에 기여한 결과이다. 시뮬레이션 결과의 정량적 비교를 위하여 각 data missing 영역의 융합 결과 RMSE 값을 Table 2.에 비교 요약하였다. 모든 영역에 대하여 SR-MKS 결과가 기존 방식대비 개선되었음을 알 수 있다. 본 시뮬레이션을 통하여 제안된 SR-MKS 방식은 시각적 뿐만 아니라 정량적인 성능 측정 (RMSE) 측면에서도 평균 0.62가 감소되는 개선 결과를 제공함을 확인할 수 있다.




Fig. 8. Multi-resolution image fusion results at the finest scale(11th scale). The fusion results using (a) standard MKS in chapter III.3, and (b) proposed SR-MKS methods

Table 2. RMSE of fusion results at data missing regions

	RMSE using MKS	RMSE using SR-MKS
Area A	2.5	1.8
Area B	1.9	1.5
Area C	2.1	1.8
Area D	2.7	2.0
Area E	3.1	2.1

Fig. 9는 Fig. 6. (b)의 우측 상단 지역에 존재하는 data missing 영역을 추출하여 제안한 SR-MKS방식을 적용한 융합결과를 나타내었다. 이 경우 역시 SR-MKS를 통한 융합결과는 기존 방식대비 개선된 결과를 보여줌을 확인하였다.




Fig. 9. 3D perspective views of fusion results using (a) standard MKS and (b) proposed SR-MKS methods. The image data sets being used are extracted from pixel missing region (upper right region) in Fig. 6. (b)

V. Conclusions

본 논문에서는 Markov 쿼드트리 구조의 MKS 방식에서 발생하는 blocky 왜곡현상을 보완하기 위하여 단일영상 Super Resolution (SR)을 MKS 융합 프레임워크에 적용한 새로운 방식의 SR-MKS 알고리즘을 제안하였다. SR을 통하여 새로운 고 해상도 영상을 생성하여 트리구조에 포함시켜 융합함으로써 기존 MKS 알고리즘이 가지고 있던 blocky 왜곡 문제를 경감시킬 수 있었다. 실제 센서에 의해 측정된 영상을 이용한 시뮬레이션을 통하여 제안된 방식은 기존 방식 대비 시각적 뿐 아니라 정량적인 성능(RMSE) 측면에서도 평균 0.62가 감소되는 개선 결과를 보여주었다.

본 연구에서는 다중 스케일 방식을 픽셀 intensity와 같이 동일 modality를 가지는 다 해상도 영상융합에 적용하였고, 향후 후속 연구 방향으로 측정 데이터의 modality가 다른 이중 정보를 포함한 영상융합분야에 제안한 SR-MKS 방식을 적용하는 연구를 진행할 예정이다.

REFERENCES

[1] G. Pajares, and J.M de la Cruz, "A wavelet-based image

fusion tutorial," Pattern Recognition, Vol. 37, Issue 9, pp. 1855-1872, Sep. 2004.

- [2] M. M. Daniel and A. S. Willsky, "A multiresolution methodology for signal-level fusion and data assimilation with applications to remote sensing," Proc. IEEE, Vol. 85, pp. 164-180, Jan. 1997.
- [3] W. Irving, W. Karl, and A. Willsky, "A Theory for Multiscale Stochastic Realization," 33rd Conference on Decision and Control, Vol. 1, pp. 655-662, Jan. 1994.
- [4] H. E. Rauch, C. T. Striebel, and F. Tung, "Maximum likelihood estimates of linear dynamic systems," AIAA Journal, Vol. 3, No. 8, pp. 1445-1450, Aug. 1965.
- [5] K. Chou, A. Willsky, and R. Nikoukhah, "Multiscale systems, Kalman filters, and Riccati equations," IEEE Transactions on Automatic Control, Vol. 39, pp. 479-492, Mar. 1994.
- [6] S.M Kay, "Fundamentals of Statistical Signal Processing: Estimation Theory," Prentice Hall, Upper Saddle River, NJ, 1993.
- [7] L. Yue, et al., "A locally adaptive L1-L2 norm for multi-frame super-resolution of images with mixed noise and outliers," Signal Processing, Vol. 105, Nu. pp. 156-174, 2014.
- [8] Q. Zhou, and A.-X. Zhu, "The recent advancement in digital terrain analysis and modeling," International Journal of Geographical Information Science, Vol. 27, No.7, pp. 1269-1271, 2013.
- [9] M.R. Luetngen, W.C. Karl, and A. Willsky, "Multiscale Representations of Markov Random Fields," IEEE Trans. Signal Processing, Vol. 41, pp. 3377-3395, Dec. 1993.
- [10] A.S. Willsky, "Multiresolution Markov models for signal and image processing," Proceedings of the IEEE, Vol. 90, No. 8, p.p 1396-1458, Aug. 2002.
- [11] W. Fieguth, W. C. Karl, and A. S. Willsky, "Multiscale Stochastic Processing of Topex/Poseidon Oceanographic Altimetry," IEEE Trans. Image Proc., Vol. 9, pp. 456-468, Mar. 2000.
- [12] K. Chou, A. Willsky, and R. Nikoukhah, "Multiscale systems, Kalman filters, and Riccati equations," IEEE Transactions on Automatic Control, Vol. 39, No. 3, pp.479-492, Mar. 1994.
- [13] K.C. Slatton, M.M. Crawford, and B.L. Evans, "Fusing interferometric radar and laser altimeter data to estimate surface topography and vegetation heights," IEEE Transactions on Geoscience and Remote Sensing, Vol. 39, pp. 2470-2482, 2001.
- [14] H. Zebker, S. Madsen, and J. Martin, "The TOPSAR interferometric radar topographic mapping instrument," IEEE Transactions on Geoscience and Remote Sensing, Vol. 30, pp. 933-940, 1992.

- [15] H. Jhee, S. Cheung, and K.C Slatton, "Efficient observational updating for fusion of incomplete image data," In Proceedings of the IEEE International Geoscience and Remote Sensing Symposium, Vol. 4, pp. 2807-2810, Jul. 2005.
- [16] S. Todorovic, and M.C. Nechyba, "Interpretation of complex scenes using dynamic tree-structure Bayesian networks," Computer Vision and Image Understanding, Vol. 106 No.1, p.71-84, Apr. 2007.

Authors



Hojin Jhee received the B.S. degree in Electronic Engineering from Dongguk University, Seoul, Korea, in 1997 and the Ph.D degree in Electrical and Computer Engineering from University of Florida, Gainesville, Florida, U.S.A in

2010. Dr. Jhee is currently research engineer at LIG Nex1 in Korea. His research interests include statistical signal processing, image processing and applications of machine vision domain.



Chulhee Jang received the B.S., and M.S. degrees in Computer Science and Engineering from INHA University, Korea, in 2011, 2013 respectively. Mr. Jang joined the LIG Nex1 company in 2013. He is currently research engineer

of detecting and tracking system. He is interested in Constraint Satisfaction Problem, object detecting and tracking system.



Sanghun Jin received the B.S., and M.S. degrees in Electronics from Kyungpook National University, Korea, in 1993, 1995 respectively. Mr. Jin joined LIG Nex1 company in 2000. He is currently working on search and tracking system.

He is interested in image processing, developing search and tracking system based on infrared and visual camera.



Yonghee Hong received the B.S., and M.S. degrees in Computer Science and Engineering from Soongsil University, Seoul, Korea, in 2009 and 2011, respectively. Mr. Hong joined LIG Nex1 company in 2011. He is currently

working on infrared camera. He is interested in image processing, developing infrared camera.