(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0102134
(43) 공개일자 2023년07월07일

(51) 국제특허분류(Int. Cl.)
G06T 5/50 (2006.01) *G06T 3/40* (2006.01)
(52) CPC특허분류
G06T 5/50 (2023.01)
G06T 3/4076 (2013.01)
(21) 출원번호 10-2021-0192023
(22) 출원일자 2021년12월30일
심사청구일자 2021년12월30일

(71) 출원인
인천대학교 산학협력단
인천광역시 연수구 아카데미로 119 (송도동)
(72) 발명자
전광길
인천광역시 연수구 해송로 70, 209동 805호(송도동, 송도웰카운티2단지)
(74) 대리인
특허법인충정

전체 청구항 수 : 총 12 항

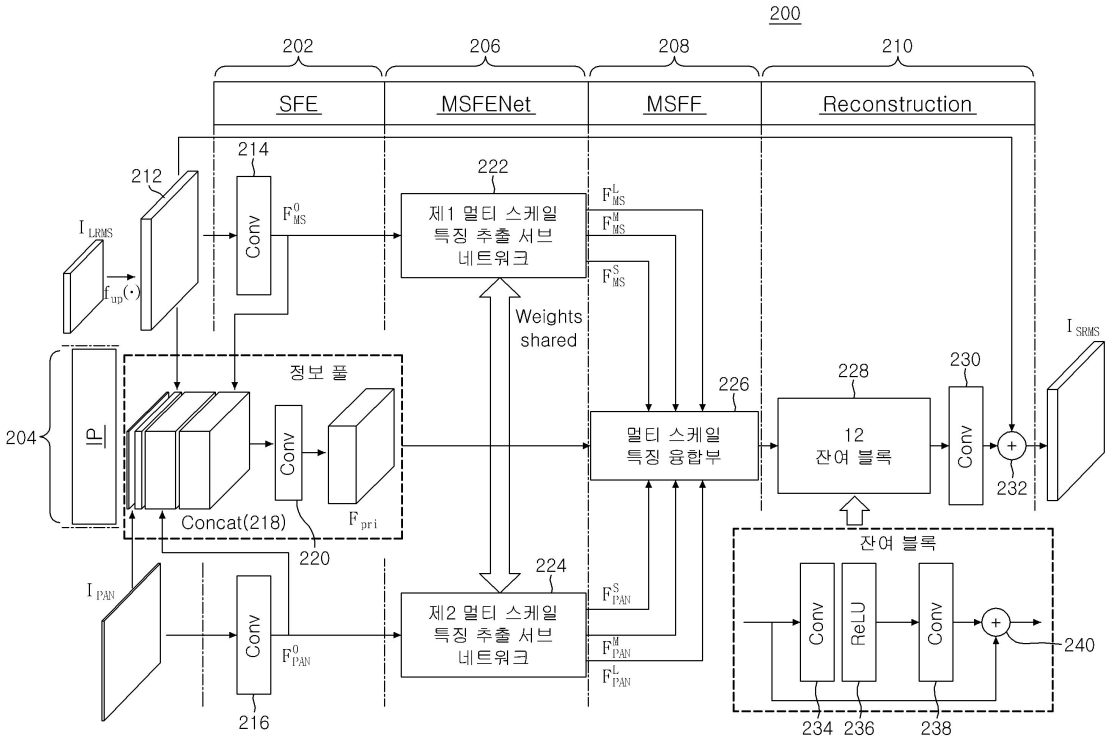
(54) 발명의 명칭 **딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법**

(57) 요 약

본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치는, 업샘플링된 저해상도 멀티 스펙트럼 이미지와 팬크로마틱 이미지로부터 각각 얕은 특징을 추출하는 얕은 특징 추출부; 상기 팬크로마틱 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지

(뒷면에 계속)

대 표 도



의 얕은 특징 및 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 원시 정보 특징을 생성하는 정보 풀(Information Pool); 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징에 기반하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 제1 멀티 스케일 특징 추출 서브 네트워크; 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 제2 멀티 스케일 특징 추출 서브 네트워크; 상기 원시 정보 특징, 상기 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징, 및 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징들을 융합하는 멀티 스케일 특징 융합부; 및 상기 융합된 특징 및 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지에 기반하여 고해상도 멀티 스펙트럼 이미지를 재구성하는 재구성부를 포함한다.

(52) CPC특허분류

G06T 2207/20221 (2013.01)

명 세 서

청구범위

청구항 1

업샘플링된 저해상도 멀티 스펙트럼 이미지와 팬크로마틱 이미지로부터 각각 얕은 특징을 추출하는 얕은 특징 추출부;

상기 팬크로마틱 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징 및 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 원시 정보 특징을 생성하는 정보 풀(Information Pool);

상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징에 기반하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 제1 멀티 스케일 특징 추출 서브 네트워크;

상기 팬크로마틱 이미지의 얕은 특징에 기반하여 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 제2 멀티 스케일 특징 추출 서브 네트워크;

상기 원시 정보 특징, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징, 및 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징들을 융합하는 멀티 스케일 특징 융합부; 및

상기 융합된 특징 및 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지에 기반하여 고해상도 멀티 스펙트럼 이미지를 재구성하는 재구성부를 포함하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치.

청구항 2

청구항 1에 있어서,

상기 얕은 특징 추출부는,

상기 업샘플링된 저해상도 멀티 스펙트럼 이미지에 대해 컨벌루션 연산을 수행하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징을 출력하는 제1 컨벌루션 레이어; 및

상기 팬크로마틱 이미지에 대해 컨벌루션 연산을 수행하여 상기 팬크로마틱 이미지의 얕은 특징을 출력하는 제2 컨벌루션 레이어를 포함하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치.

청구항 3

청구항 1에 있어서,

상기 정보 풀(Information Pool)은,

상기 팬크로마틱 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징 및 상기 팬크로마틱 이미지의 얕은 특징을 연결하는 연결부; 및

상기 연결부의 출력에 대해 컨벌루션 연산을 수행하여 상기 원시 정보 특징을 출력하는 제3 컨벌루션 레이어를 포함하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치.

청구항 4

청구항 1에 있어서,

상기 제1 멀티 스케일 특징 추출 서브 네트워크는,

상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징의 공간 해상도를 낮추고 특징 맵들의 특징 채널들을 늘리는 제1 인코더; 및

상기 제1 인코더의 출력에 기반하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들

스케일 특징 및 라지 스케일 특징을 생성하는 제1 디코더를 포함하고,

상기 제2 멀티 스케일 특징 추출 서브 네트워크는,

상기 팬크로마틱 이미지의 얕은 특징의 공간 해상도를 낮추고 특징 맵들의 특징 채널들을 늘리는 제2 인코더; 및

상기 제2 인코더의 출력에 기반하여 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 제2 디코더를 포함하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치.

청구항 5

청구항 4에 있어서,

상기 제1 멀티 스케일 특징 추출 서브 네트워크와 상기 제2 멀티 스케일 특징 추출 서브 네트워크는 컨벌루션 레이어에서 사용되는 가중치를 공유하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치.

청구항 6

청구항 1에 있어서,

상기 멀티 스케일 특징 융합부는,

상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징과 상기 팬크로마틱 이미지의 스몰 스케일 특징을 융합하여 융합된 스몰 스케일 특징을 출력하는 스몰 스케일 특징 융합부;

상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 미들 스케일 특징과 상기 팬크로마틱 이미지의 미들 스케일 특징을 융합하여 융합된 미들 스케일 특징을 출력하는 미들 스케일 특징 융합부; 및

상기 융합된 스몰 스케일 특징, 상기 융합된 미들 스케일 특징, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 라지 스케일 특징, 상기 팬크로마틱 이미지의 라지 스케일 특징 및 상기 원시 정보 특징을 융합하여 최종 융합된 특징을 출력하는 포괄적 특징 융합부를 포함하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치.

청구항 7

(A) 얕은 특징 추출부가, 업샘플링된 저해상도 멀티 스펙트럼 이미지와 팬크로마틱 이미지로부터 각각 얕은 특징을 추출하는 단계;

(B) 정보 풀(Information Pool)이, 상기 팬크로마틱 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징 및 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 원시 정보 특징을 생성하는 단계;

(C) 제1 멀티 스케일 특징 추출 서브 네트워크가, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징에 기반하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 단계;

(D) 제2 멀티 스케일 특징 추출 서브 네트워크가, 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 단계;

(E) 멀티 스케일 특징 융합부가, 상기 원시 정보 특징, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징, 및 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징들을 융합하는 단계; 및

(F) 재구성부가, 상기 융합된 특징 및 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지에 기반하여 고해상도 멀티 스펙트럼 이미지를 재구성하는 단계를 포함하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법.

청구항 8

청구항 7에 있어서,

상기 단계 (A)는,

상기 업샘플링된 저해상도 멀티 스펙트럼 이미지에 대해 컨벌루션 연산을 수행하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징을 출력하는 단계; 및

상기 팬크로마틱 이미지에 대해 컨벌루션 연산을 수행하여 상기 팬크로마틱 이미지의 얕은 특징을 출력하는 단계를 포함하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법.

청구항 9

청구항 7에 있어서,

상기 단계 (B)는,

(B-1) 상기 팬크로마틱 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징 및 상기 팬크로마틱 이미지의 얕은 특징을 연결하는 단계; 및

(B-2) 상기 단계 (B-1)의 출력에 대해 컨벌루션 연산을 수행하여 상기 원시 정보 특징을 출력하는 단계를 포함하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법.

청구항 10

청구항 7에 있어서,

상기 단계 (C)는,

(C-1) 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징의 공간 해상도를 낮추고 특징 맵들의 특징 채널들을 늘리는 단계; 및

(C-2) 상기 단계 (C-1)의 출력에 기반하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 단계를 포함하고,

상기 단계 (D)는,

(D-1) 상기 팬크로마틱 이미지의 얕은 특징의 공간 해상도를 낮추고 특징 맵들의 특징 채널들을 늘리는 단계; 및

(D-2) 상기 단계 (D-1)의 출력에 기반하여 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 단계를 포함하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법.

청구항 11

청구항 10에 있어서,

상기 단계 (C)와 상기 단계 (D)는 컨벌루션 레이어에서 사용되는 가중치를 공유하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치.

청구항 12

청구항 7에 있어서,

상기 단계 (E)는,

상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징과 상기 팬크로마틱 이미지의 스몰 스케일 특징을 융합하여 융합된 스몰 스케일 특징을 출력하는 단계;

상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 미들 스케일 특징과 상기 팬크로마틱 이미지의 미들 스케일 특징을 융합하여 융합된 미들 스케일 특징을 출력하는 단계; 및

상기 융합된 스몰 스케일 특징, 상기 융합된 미들 스케일 특징, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 라지 스케일 특징, 상기 팬크로마틱 이미지의 라지 스케일 특징 및 상기 원시 정보 특징을 융합하여 최종 융합된 특징을 출력하는 단계를 포함하는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법.

발명의 설명

기 술 분 야

[0001] 본 발명은 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법에 관한 것이다.

배 경 기 술

[0002] 원격 감지는 지구를 이해하고 인간-지구 통신을 지원하는 기본 도구이다. 원격 감지 기술의 중요한 분야인 멀티 스펙트럼(MS) 이미징은 실시간 모니터링 및 감시 분야에 널리 적용된다. 그러나 센서와 대역폭의 한계로 인해 단일 센서를 사용하여 높은 공간 해상도의 멀티 스펙트럼 이미지를 얻는 것은 특히 어렵다.

[0003] 일반적으로 이러한 문제를 해결하기 위해 광원격탐사위성은 멀티 센서를 장착하여 멀티 대역의 저해상도 멀티 스펙트럼(LRMS: low-resolution multi-spectral) 이미지와 단일 대역의 고해상도(HR: high resolution) 팬크로마틱 이미지를 동시에 획득한다. 팬 샤프닝 기법은 저해상도 멀티 스펙트럼 이미지와 고해상도 팬크로마틱 이미지의 보완적 정보를 융합하여 고해상도 멀티 스펙트럼 이미지를 재구성하는 기술로서, 그 공간 해상도는 팬크로마틱 이미지와 동일하다.

[0004] 실시간 원격 감지 커뮤니티에서는 이미지 분류, 이미지 분할 및 이미지 감지와 같은 다양한 작업이 붐을 이루고 있다. 일반적으로 이러한 작업은 고해상도 원격 감지 이미지를 입력으로 사용하는 것을 선호한다. 왜냐하면, 입력 이미지가 더 높은 해상도를 가질수록 후속 프로세스 및 분석을 위해 더 많은 정보를 제공할 것이기 때문이다. 반대로 해상도가 낮은 이미지는 저해상도 이미지에서 제한되는 객체의 구조와 픽셀 간의 관계에 민감하기 때문에 이러한 작업의 수행에 방해가 되기 쉽다. 도 1에서 볼 수 있듯이 원격 감지 이미지 융합(팬 샤프닝)은 원격 감지 이미지 처리에 매우 중요하며, 스펙트럼 영역 및 공간 영역 모두에서 고해상도 이미지를 제공하여 후속 작업의 정확도를 높인다.

[0005] 지난 수십 년 동안 연구자들은 팬 샤프닝 기술에 많은 관심을 기울이고 다양한 의미 있는 방법을 제안했다. 기존 팬 샤프닝 방법은 실제로 기존 알고리즘과 딥 러닝 기반 방법의 두 가지 범주로 나눌 수 있다. 기존 알고리즘과 관련하여 구성 요소 대체(CS: component substitution) 접근 방식, 멀티 해상도 분석(MRA: multi-resolution analysis) 접근 방식 및 모델 기반 최적화(model-based optimization) 접근 방식의 세 가지 분기로 더 분류할 수 있다.

[0006] CS 접근 방식의 경우 일반적으로 멀티 스펙트럼 이미지를 적절한 영역으로 변환한다. 여기서 멀티 스펙트럼 이미지의 공간 구성 요소는 고해상도 팬크로마틱 이미지로 대체된다. 그런 다음 해당 역변환을 통해 팬 샤프닝된 이미지가 달성된다. 강도-색조 포화 기법(HIS: intensity-hue-saturation), 주성분 분석(PCA: principal component analysis), 브로베이(Brovey) 변환(BT) 및 그램-슈미트(Gram-Schmidt) 변환은 종종 CS에 통합된다. 이러한 방법은 간단하고 빠르며 팬크로마틱 이미지에서 직접 공간 정보를 얻는 경향이 있지만 스펙트럼 왜곡이 있다. MRA 방법의 경우 주로 이산 웨이블릿 변환(DWT), 라플라시안 피라미드(LP), a trous 웨이블릿 변환(ATWT)을 통합하여 팬크로마틱 이미지를 분해하고 고주파 정보를 추출하고 LRMS로 주입한다. 이러한 방법은 더 나은 스펙트럼 일관성을 얻을 수 있지만 더 심각한 공간 왜곡을 초래할 수 있다.

[0007] 최근 딥 러닝의 상당한 발전과 함께 CNN(Convolutional Neural Networks)은 팬 샤프닝 커뮤니티에서 많은 주목을 받아 성능과 효율성 모두에서 현저한 개선을 달성했다. 팬 샤프닝과 단일 이미지 초해상도(SISR) 모두 향상된 고해상도(HR) 이미지를 재구성하는 것을 목표로 하기 때문에 팬 샤프닝은 어느 정도 초해상도 관련 작업이다. 주요 차이점은 전자는 주로 고해상도의 팬크로마틱 이미지에서 공간적 디테일을 추출하는 반면 후자는 해당 저해상도(LR) 이미지에서 디테일을 추출한다는 것이다. 따라서 기존의 많은 딥 러닝 기반 팬 샤프닝 접근법은 SISR 방법에 의해 계몽되었다.

[0008] 일반적으로 실제 적용에서는 실시간 및 효과적인 팬 새프닝 방법이 선호된다. 그래픽 처리 장치(GPU)의 급속한 발전으로 대부분의 딥 러닝 기반 팬 샤프닝 방법은 실시간 요구 사항을 충족할 수 있다. 그러나 실시간 응용의 조건에서 더 선명한 이미지를 획득함과 동시에 스펙트럼 왜곡을 줄일 수 있는 원격 감지를 위한 실시간 이미지 융합 장치 및 방법이 요구된다.

선행기술문헌

특허문헌

[0009] (특허문헌 0001) KR 10-1132272 B1

발명의 내용

해결하려는 과제

[0010] 본 발명이 해결하고자 하는 과제는 가중치 공유 인코더-디코더 구조에 의해 추출된 팬크로마틱 이미지 및 멀티 스펙트럼 이미지의 레이어적 보완 특징을 최대한 활용할 수 있고, 더 큰 수용 필드를 가능하게 하여 멀티 스펙트럼 이미지 및 해당 팬크로마틱 이미지의 멀티 스케일 보완 컨텍스트 정보를 유용하게 획득할 수 있는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법을 제공하는 것이다.

[0011] 본 발명이 해결하고자 하는 다른 과제는 거친-미세(coarse-to-fine) 전략을 네트워크에 통합하여 단계적으로 멀티 스케일 특징을 획득함으로써 다양한 스케일의 특징을 모두 풍부하게 추출할 수 있는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법을 제공하는 것이다.

[0012] 본 발명이 해결하고자 하는 또 다른 과제는, 후속 특징 융합을 위한 기본 정보를 보존하기 위해 정보 풀을 구축함으로써 네트워크의 표현 능력을 향상시킬 뿐만 아니라 기울기 역전파(gradient back-propagation)에도 도움이 될 수 있는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법을 제공하는 것이다.

[0013] 본 발명이 해결하고자 하는 또 다른 과제는, 스펙트럼 왜곡을 현저히 줄일 수 있으면서 동시에 선명한 고해상도 이미지를 획득할 수 있는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법을 제공하는 것이다.

과제의 해결 수단

[0014] 상기 과제를 해결하기 위한 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치는,

[0015] 업샘플링된 저해상도 멀티 스펙트럼 이미지와 팬크로마틱 이미지로부터 각각 얕은 특징을 추출하는 얕은 특징 추출부;

[0016] 상기 팬크로마틱 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징 및 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 원시 정보 특징을 생성하는 정보 풀(Information Pool);

[0017] 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징에 기반하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 제1 멀티 스케일 특징 추출 서브 네트워크;

[0018] 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 제2 멀티 스케일 특징 추출 서브 네트워크;

[0019] 상기 원시 정보 특징, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징, 및 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징들을 융합하는 멀티 스케일 특징 융합부; 및

[0020] 상기 융합된 특징 및 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지에 기반하여 고해상도 멀티 스펙트럼 이미지를 재구성하는 재구성부를 포함한다.

[0021] 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치에 있어서, 상기 얕은 특징 추출부는,

[0022] 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지에 대해 컨벌루션 연산을 수행하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징을 출력하는 제1 컨벌루션 레이어; 및

[0023] 상기 팬크로마틱 이미지에 대해 컨벌루션 연산을 수행하여 상기 팬크로마틱 이미지의 얕은 특징을 출력하는 제2 컨벌루션 레이어를 포함할 수 있다.

[0024] 또한, 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치에 있어서, 상기

정보 풀(Information Pool)은,

[0025] 상기 팬크로마틱 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징 및 상기 팬크로마틱 이미지의 얕은 특징을 연결하는 연결부; 및

[0026] 상기 연결부의 출력에 대해 컨벌루션 연산을 수행하여 상기 원시 정보 특징을 출력하는 제3 컨벌루션 레이어를 포함할 수 있다.

[0027] 또한, 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치에 있어서, 상기 제1 멀티 스케일 특징 추출 서브 네트워크는,

[0028] 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징의 공간 해상도를 낮추고 특징 맵들의 특징 채널들을 늘리는 제1 인코더; 및

[0029] 상기 제1 인코더의 출력에 기반하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 제1 디코더를 포함하고,

[0030] 상기 제2 멀티 스케일 특징 추출 서브 네트워크는,

[0031] 상기 팬크로마틱 이미지의 얕은 특징의 공간 해상도를 낮추고 특징 맵들의 특징 채널들을 늘리는 제2 인코더; 및

[0032] 상기 제2 인코더의 출력에 기반하여 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 제2 디코더를 포함할 수 있다.

[0033] 또한, 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치에 있어서, 상기 제1 멀티 스케일 특징 추출 서브 네트워크와 상기 제2 멀티 스케일 특징 추출 서브 네트워크는 컨벌루션 레이어에서 사용되는 가중치를 공유할 수 있다.

[0034] 또한, 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치에 있어서, 상기 멀티 스케일 특징 융합부는,

[0035] 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징과 상기 팬크로마틱 이미지의 스몰 스케일 특징을 융합하여 융합된 스몰 스케일 특징을 출력하는 스몰 스케일 특징 융합부;

[0036] 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 미들 스케일 특징과 상기 팬크로마틱 이미지의 미들 스케일 특징을 융합하여 융합된 미들 스케일 특징을 출력하는 미들 스케일 특징 융합부; 및

[0037] 상기 융합된 스몰 스케일 특징, 상기 융합된 미들 스케일 특징, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 라지 스케일 특징, 상기 팬크로마틱 이미지의 라지 스케일 특징 및 상기 원시 정보 특징을 융합하여 최종 융합된 특징을 출력하는 포괄적 특징 융합부를 포함할 수 있다.

[0038] 상기 과제를 해결하기 위한 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법은,

[0039] (A) 얕은 특징 추출부가, 업샘플링된 저해상도 멀티 스펙트럼 이미지와 팬크로마틱 이미지로부터 각각 얕은 특징을 추출하는 단계;

[0040] (B) 정보 풀(Information Pool)이, 상기 팬크로마틱 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징 및 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 원시 정보 특징을 생성하는 단계;

[0041] (C) 제1 멀티 스케일 특징 추출 서브 네트워크가, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징에 기반하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 단계;

[0042] (D) 제2 멀티 스케일 특징 추출 서브 네트워크가, 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 단계;

[0043] (E) 멀티 스케일 특징 융합부가, 상기 원시 정보 특징, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징, 및 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징들을 융합하는 단계; 및

[0044] (F) 재구성부가, 상기 융합된 특징 및 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지에 기반하여 고해상도 멀티 스펙트럼 이미지를 재구성하는 단계를 포함한다.

[0045] 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법에 있어서, 상기 단계 (A)는,

[0046] 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지에 대해 컨벌루션 연산을 수행하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징을 출력하는 단계; 및

[0047] 상기 팬크로마틱 이미지에 대해 컨벌루션 연산을 수행하여 상기 팬크로마틱 이미지의 얕은 특징을 출력하는 단계를 포함할 수 있다.

[0048] 또한, 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법에 있어서, 상기 단계 (B)는,

[0049] (B-1) 상기 팬크로마틱 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징 및 상기 팬크로마틱 이미지의 얕은 특징을 연결하는 단계; 및

[0050] (B-2) 상기 단계 (B-1)의 출력에 대해 컨벌루션 연산을 수행하여 상기 원시 정보 특징을 출력하는 단계를 포함할 수 있다.

[0051] 또한, 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법에 있어서, 상기 단계 (C)는,

[0052] (C-1) 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징의 공간 해상도를 낮추고 특징 맵들의 특징 채널들을 늘리는 단계; 및

[0053] (C-2) 상기 단계 (C-1)의 출력에 기반하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 단계를 포함하고,

[0054] 상기 단계 (D)는,

[0055] (D-1) 상기 팬크로마틱 이미지의 얕은 특징의 공간 해상도를 낮추고 특징 맵들의 특징 채널들을 늘리는 단계; 및

[0056] (D-2) 상기 단계 (D-1)의 출력에 기반하여 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하는 단계를 포함할 수 있다.

[0057] 또한, 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법에 있어서, 상기 단계 (C)와 상기 단계 (D)는 컨벌루션 레이어에서 사용되는 가중치를 공유할 수 있다.

[0058] 또한, 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법에 있어서, 상기 단계 (E)는,

[0059] 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징과 상기 팬크로마틱 이미지의 스몰 스케일 특징을 융합하여 융합된 스몰 스케일 특징을 출력하는 단계;

[0060] 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 미들 스케일 특징과 상기 팬크로마틱 이미지의 미들 스케일 특징을 융합하여 융합된 미들 스케일 특징을 출력하는 단계; 및

[0061] 상기 융합된 스몰 스케일 특징, 상기 융합된 미들 스케일 특징, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 라지 스케일 특징, 상기 팬크로마틱 이미지의 라지 스케일 특징 및 상기 원시 정보 특징을 융합하여 최종 융합된 특징을 출력하는 단계를 포함할 수 있다.

발명의 효과

[0062] 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법에 의하면, 가중치 공유 인코더-디코더 구조에 의해 추출된 팬크로마틱 이미지 및 멀티 스펙트럼 이미지의 레이어적 보완 특징을 최대한 활용할 수 있고, 더 큰 수용 필드를 가능하게 하여 멀티 스펙트럼 이미지 및 해당 팬크로마틱 이미지의 멀티 스케일 보완 컨텍스트 정보를 유용하게 획득할 수 있다.

[0063] 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법에 의하면, 거

친-미세(coarse-to-fine) 전략을 네트워크에 통합하여 단계적으로 멀티 스케일 특징을 획득함으로써 다양한 스케일의 특징을 모두 풍부하게 추출할 수 있다.

[0064] 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법에 의하면, 후속 특징 융합을 위한 기본 정보를 보존하기 위해 정보 풀을 구축함으로써 네트워크의 표현 능력을 향상시킬 뿐만 아니라 기울기 역전파(gradient back-propagation)에도 도움이 될 수 있다.

[0065] 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법에 의하면, 스펙트럼 왜곡을 현저히 줄일 수 있으면서 동시에 선명한 고해상도 이미지를 획득할 수 있는, 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법을 제공하는 것이다.

도면의 간단한 설명

[0066] 도 1은 원격 감지 커뮤니티에서의 팬-샤프닝의 중요한 역할을 설명하기 위한 도면.

도 2는 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치를 도시한 도면.

도 3은 멀티 스펙트럼 경로의 제1 멀티 스케일 특징 추출 서브 네트워크의 구조를 도시한 도면.

도 4는 멀티 스케일 특징 융합부의 구조를 도시한 도면.

도 5는 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 방법의 흐름도를 도시한 도면.

도 6a는 표 4에 대응하는 절제 실험의 손실 곡선을 도시한 도면.

도 6b는 표 5에 대응하는 단일 스케일 융합 및 멀티 스케일 융합의 손실 곡선을 도시한 도면.

도 7은 퀵버드(QuickBird) 데이터셋에 대한 상이한 팬-샤프닝 방법들의 비주얼 결과를 도시한 도면.

도 8은 IKONOS 데이터셋에 대한 상이한 팬-샤프닝 방법들의 비주얼 결과를 도시한 도면.

도 9는 Pleiades 데이터셋에 대한 상이한 팬-샤프닝 방법들의 비주얼 결과를 도시한 도면.

발명을 실시하기 위한 구체적인 내용

[0067] 본 발명의 목적, 특정한 장점들 및 신규한 특징들은 첨부된 도면들과 연관되어지는 이하의 상세한 설명과 바람직한 실시예들로부터 더욱 명백해질 것이다.

[0068] 이에 앞서 본 명세서 및 청구범위에 사용된 용어나 단어는 통상적이고 사전적인 의미로 해석되어서는 아니되며, 발명자가 그 자신의 발명을 가장 최선의 방법으로 설명하기 위해 용어의 개념을 적절하게 정의할 수 있는 원칙에 입각하여 본 발명의 기술적 사상에 부합되는 의미와 개념으로 해석되어야 한다.

[0069] 본 명세서에서 각 도면의 구성요소들에 참조번호를 부가함에 있어서, 동일한 구성 요소들에 한해서는 비록 다른 도면상에 표시되더라도 가능한 한 동일한 번호를 가지도록 하고 있음에 유의하여야 한다.

[0070] 또한, "제1", "제2", "일면", "타면" 등의 용어는, 하나의 구성요소를 다른 구성요소로부터 구별하기 위해 사용되는 것으로, 구성요소가 상기 용어들에 의해 제한되는 것은 아니다.

[0071] 이하, 본 발명을 설명함에 있어, 본 발명의 요지를 불필요하게 흐릴 수 있는 관련된 공지 기술에 대한 상세한 설명은 생략한다.

[0072] 이하, 첨부된 도면을 참조하여 본 발명의 바람직한 실시형태를 상세히 설명하기로 한다.

[0073] 실시간 모니터링 및 감시는 더 나은 분석을 위해 높은 공간 해상도의 멀티 스펙트럼(MS: multi-spectral) 이미지가 널리 요구되는 원격 감지 분야에서 중요한 역할을 한다. 그러나 센서와 대역폭의 한계로 인해 고해상도 멀티 스펙트럼 이미지를 직접 얻을 수 없다. 이러한 문제를 완화하기 위한 필수적인 방법으로 팬 샤프닝(pan-sharpening)은 저해상도 멀티 스펙트럼 이미지와 고해상도 팬크로마틱(PAN: panchromatic) 이미지의 보완 정보를 융합하여 고해상도 멀티 스펙트럼 이미지를 재구성하는 것을 목표로 한다.

[0074] 대부분의 이전 딥러닝 기반 방법은 GPU(그래픽 처리 장치)의 도움으로 실시간 요구 사항을 충족할 수 있다. 그러나 그들은 유리한 레이어적 정보를 완전히 활용하지 않아 성능 향상을 위한 큰 여지를 남겨두지 않는다.

[0075] 본 발명에서는 실시간 구현의 요구사항을 충족함과 동시에 보다 효과적인 성능을 달성하기 위해 팬크로마틱 이미지 및 멀티 스펙트럼 이미지의 레이어적 보완 특징을 최대한 활용하는 멀티 스케일 융합 네트워크(Multi-Scale fusion network)를 제안한다. 구체적으로, 팬크로마틱 이미지와 멀티 스펙트럼 이미지의 멀티 스케일 특징을 개별적으로 효과적으로 추출하기 위해 인코더-디코더 구조와 거친-미세(coarse-to-fine) 전략을 도입한다.

[0076] 한편, 원시 정보를 보존하기 위해 정보 풀을 채택하고 있다. 그런 다음 멀티 스케일 특징 융합부가 디코더와 정보 풀의 멀티 스케일 특징을 융합하기 위해 적용된다. 마지막으로 융합된 특징을 활용하여 고해상도 멀티 스펙트럼 이미지를 재구성한다. 광범위한 실험은 본 발명에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법이 정량적 메트릭 및 시각적 품질 측면에서 다른 방법에 비해 유리한 성능을 달성한다는 것을 보여준다. 게다가, 실행 시간에 대한 결과는 본 발명에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법이 실시간 성능을 달성할 수 있음을 나타낸다.

[0077] 구체적으로, 가중치 공유 인코더-디코더 구조와 거친-미세(Coarse-to-Fine) 전략을 도입하여 팬크로마틱 이미지와 멀티 스펙트럼 이미지의 멀티 스케일 특징을 각각 효과적으로 추출한다. 인코더-디코더 구조는 네트워크가 더 큰 수용 필드를 얻을 수 있도록 하여 멀티 스펙트럼 이미지와 해당 팬크로마틱 이미지의 멀티 스케일 보완적 컨텍스트 정보를 캡처하는 데 유용하다.

[0078] 디코더 단계의 경우, 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법에서는 멀티 스케일 특징들을 점진적으로 디코딩하여 단계적으로 더 미세한 세부 사항을 얻기 위해 거친 대 미세 전략을 통합한다. 이러한 방식으로 스몰-스케일 특징 뿐만 아니라 미들-스케일 및 라지-스케일 특징도 풍부하게 추출하여 더 나은 후속 융합을 만든다. 또한 원시 정보를 보존하기 위하여 정보 풀을 채택한다.

[0079] 이 정보 풀에서는 업샘플링된 멀티 스펙트럼 이미지인 팬크로마틱 이미지와 얕은 특징(단일 컨볼루션 레이어를 통해 얻은 특징)을 연결하여 컨볼루션 레이어에 공급하여 원시 정보를 예약한다. 정보 풀의 직관적인 동기는 특징 재사용과 메모리 메커니즘이며, 이는 원시 공간 및 스펙트럼 정보를 포함하는 얕은 특징이 팬 샤프닝의 성능을 높이는 데 도움이 된다는 것을 의미한다.

[0080] 한편, 후속 특징 융합에 적용되는 정보 풀의 스킵 연결도 기울기 역전파에 이점이 있다. 그런 다음 멀티 스케일 특징 융합 모듈을 적용하여 디코더와 정보 풀에서 각각 멀티 스케일 특징과 원시 정보를 융합한다. 마지막으로 융합된 특징을 사용하여 여러 잔여 블록을 통해 고해상도 멀티 스펙트럼 이미지를 재구성한다. 스펙트럼 정보를 보존하기 위해 업샘플링된 멀티 스펙트럼 이미지에 대한 전역 잔여 학습이 채택되었다는 점은 언급할 가치가 있다. 실험 결과는 제안한 멀티 스케일 융합 네트워크(MSFN)의 우수성을 보여준다.

[0081] 다음에서는 개요 아키텍처 및 수학적 표현을 포함하여 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법에서 제안된 멀티 스케일 융합 네트워크(MSFN)의 프레임워크를 설명한다. 그런 다음 두 가지 특수 모듈에 대해 자세히 설명한다. 그 후, 실시간 구현에 대해 설명할 것이다. 마지막으로 손실 함수가 도입된다.

[0083] **네트워크 프레임워크**

[0084] 도 2와 같이 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치(200)는 크게 얕은 특징 추출부(202)(SFE: Shallow Feature Extraction), 멀티 스케일 특징 추출 네트워크(206)(MSFENet: Multiscale Feature Extraction Net), 정보 풀(204)(IP: Information Pool), 멀티 스케일 특징 융합부(208)(MSFF: Multi-Scale Feature fusion) 및 재구성부(210)의 5개 부분으로 구성된다.

[0085] 얕은 특징 추출부(202)는, 업샘플링된 저해상도 멀티 스펙트럼 이미지(212)와 팬크로마틱 이미지로부터 각각 얕은 특징을 추출하고, 정보 풀(Information Pool)(204)은, 상기 팬크로마틱 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징 및 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 원시 정보 특징을 생성하며, 제1 멀티 스케일 특징 추출 서브 네트워크(222)는 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징에 기반하여 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하고, 제2 멀티 스케일 특징 추출 서브 네트워크(224)는 상기 팬크로마틱 이미지의 얕은 특징에 기반하여 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징을 생성하며, 멀티 스케일 특징 융합부(226)은 상기 원시 정보 특징, 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징,

및 상기 팬크로마틱 이미지의 스몰 스케일 특징, 미들 스케일 특징 및 라지 스케일 특징들을 융합하고, 재구성부(210)는 상기 융합된 특징 및 상기 업샘플링된 저해상도 멀티 스펙트럼 이미지에 기반하여 고해상도 멀티 스펙트럼 이미지를 재구성한다.

[0086] I_{LRMS} 및 I_{PAN}을 각각 저해상도 멀티 스펙트럼 이미지 및 팬크로마틱 이미지 입력으로 표시한다. I_{SRMS}는 MSFN의 출력을 나타낸다. 특히 SFE 부분의 경우 I_{LRMS} 및 I_{PAN}이 별도로 처리된다. 대응하는 I_{PAN}과 업샘플링된 I_{LRMS}로부터 각각 얕은 특징들 F_{PAN}^{0}와 F_{MS}^{0}를 추출하기 위하여 단지 하나의 컨볼루션 레이어만 적용된다.

수학식 1

[0087] $$F_{\mathrm{PAN}}^{0}=H_{\mathrm{SFE_PAN}}(I_{\mathrm{PAN}})$$

수학식 2

[0088] $$F_{\mathrm{MS}}^{0}=H_{\mathrm{SFE_MS}}(f_{\mathrm{up}}(I_{\mathrm{LRMS}}))$$

[0089] 여기서 $H_{\mathrm{SFE_PAN}}(\cdot)$와 $H_{\mathrm{SFE_MS}}(\cdot)$는 각각 팬크로마틱 경로와 멀티 스케일 경로의 컨볼루션 연산을 나타낸다. $f_{\mathrm{up}}(\cdot)$은 쌍삼차 업샘플링 연산을 나타낸다. 그런 다음 얕은 특징들 F_{PAN}^{0}와 F_{MS}^{0}는 멀티 스케일 특징들을 추가로 추출하기 위해 멀티 스케일 특징 추출 네트워크(206)(MSFENet)에 공급되고 원시 정보 보존을 위해 정보 풀(204)(IP)에 공급된다.

[0090] 멀티 스케일 특징 추출 네트워크(206)(MSFENet)의 경우 동일한 아키텍처와 공유 가중치를 가진 두 개의 서브 네트워크인 제1 멀티 스케일 특징 추출 네트워크(222)와 제2 멀티 스케일 특징 추출 네트워크(224)를 사용하여 각각 팬크로마틱 이미지 및 멀티 스펙트럼 이미지의 멀티 스케일 정보를 캡처한다.

[0091] 각 서브 네트워크는 인코더-디코더 구조와 효과적인 멀티 스케일 특징 추출을 위한 거친-미세 전략을 통합한다. 멀티 스케일 특징 추출 네트워크(206)(MSFENet)에 대한 자세한 내용은 추후 설명될 것이다. 각 서브 네트워크는 얕은 특징 추출부(202)(SFE)의 얕은 특징을 입력으로 사용하고 하기와 같이 공식화될 수 있는 세 가지 출력: $F_{\cdot}^{S}$, $F_{\cdot}^{M}$, $F_{\cdot}^{L}$을 생성한다.

수학식 3

[0092] $$F_{\mathrm{PAN}}^{S},F_{\mathrm{PAN}}^{M},F_{\mathrm{PAN}}^{L}=H_{\mathrm{MSFENet_PAN}}(F_{\mathrm{PAN}}^{0})$$

수학식 4

[0093] $$F_{\mathrm{MS}}^{S},F_{\mathrm{MS}}^{M},F_{\mathrm{MS}}^{L}=H_{\mathrm{MSFENet_MS}}(F_{\mathrm{MS}}^{0})$$

[0094] 여기서 $H_{\mathrm{MSFENet_PAN}}(\cdot)$과 $H_{\mathrm{MSFENet_MS}}(\cdot)$는 각각 팬크로마틱에 대한 서브 네트워크와 멀티 스케일에 대한 서브 네트워크의 합성 함수를 나타낸다. $F_{\cdot}^{S}$, $F_{\cdot}^{M}$, $F_{\cdot}^{L}$은 각각 스몰 스케일(small scale), 미들 스케일

(middle scale) 및 라지(large scale) 스케일 특징을 나타낸다. 본 발명에서 스케일은 특징 맵의 해상도를 나타낸다. 스몰 스케일 특징들은 거친(대략적인) 정보가 포함된 저해상도 특징 맵을 나타내고, 라지 스케일 특징들은 정제된 정보가 포함된 고해상도 특징 맵을 나타낸다. 이러한 멀티 스케일 특징들은 보완 정보 융합을 위해 멀티 스케일 특징 융합부(226)(MSFF)로 전달된다.

[0095] 정보 풀(204)(IP)과 관련하여 원시 정보를 보존하는 것은 간단하지만 유용한 모듈이다. 정보 풀(204)의 직관적인 동기는 특징 재사용과 메모리 메커니즘이며, 이는 원시 공간 및 스펙트럼 정보를 포함하는 얕은 특징이 팬샤프닝의 성능을 높이는 데 도움이 된다는 것을 의미한다. 도 2와 같이 정보 풀(204)은 팬크로마틱 이미지, 업샘플링된 멀티 스펙트럼 이미지, 얕은 특징들 F_{PAN}^{0}, F_{MS}^{0}를 입력으로 연결하고, 입력을 단일 컨볼루션 레이어로 처리하여 원시 정보를 갖는 출력 특징들을 생성할 것이다. 이 부분은 다음과 같이 나타낼 수 있다.

수학식 5

[0096] $$F_{\mathrm{pri}} = H_{\mathrm{IP}}([I_{\mathrm{PAN}}, f_{\mathrm{up}}(I_{\mathrm{LRMS}}), F_{\mathrm{PAN}}^{0}, F_{\mathrm{MS}}^{0}])$$

[0097] 여기서 F_{pri}는 원시 정보를 나타낸다. F_{pri}는 스킵 연결을 통해 후속 특징 융합을 위해 멀티 스케일 특징 융합부(226)(MSFF)로 전송된다. 따라서 그것은 기울기 역전파에도 이점이 있다. $H_{\mathrm{IP}}(\cdot)$와 $[\cdot]$는 각각 정보 풀(204)(IP)에서의 컨벌루션 레이어 및 연결(concatenation) 연산을 나타낸다. $f_{\mathrm{up}}(\cdot)$은 쌍삼차 업샘플링 연산을 나타낸다.

[0098] 결과적으로 멀티 스케일 특징 추출 네트워크(206)(MSFENet)의 멀티 스케일 특징과 정보 풀(204)(IP)의 원시 정보는 보완 정보 융합을 위해 멀티 스케일 특징 융합부(226)(MSFF)에서 활용되어 다음과 같은 융합된 특징을 생성한다:

수학식 6

[0099] $$F_{\mathrm{fused}} = H_{\mathrm{MSFF}}(F_{\mathrm{PAN}}^{S}, F_{\mathrm{MS}}^{S}, F_{\mathrm{PAN}}^{M}, F_{\mathrm{MS}}^{M}, F_{\mathrm{PAN}}^{L}, F_{\mathrm{MS}}^{L}, F_{\mathrm{pri}})$$

[0100] 여기서 $H_{\mathrm{MSFF}}(\cdot)$는 멀티 스케일 특징 융합부(226)(MSFF)의 특징을 나타낸다. 멀티 스케일 특징 융합부(226)(MSFF)에 대한 자세한 내용은 추후 설명될 것이다.

[0101] 그런 다음 정보 특징 F_{fused}는 재구성부(210)의 입력으로 사용된다. 재구성부(210)는 K개의 잔여 블록(228)과 꼬리에 있는 단일 컨볼루션 레이어(230) 및 제1 가산기(232)로 구성된다. 공정한 비교를 위해 매개변수의 수를 TFNet과 거의 같게 하기 위해 K를 12로 설정했다. 잔여 블록은 ResNet에서 처음 제안되었으며 다양한 컴퓨터 비전 작업에서 지배적인 역할을 했다.

[0102] 잔여 블록 채택에 대해서, Ledig et al.은 SISR를 위해 SRResNet 및 SRGAN을 제안했다. 그러나 오리지널 잔여 블록의 배치 정규화(BN: batch normalization)는 특징 값들의 다양성을 변경하므로 이미지 복원 작업에 적합하지 않다. 따라서 Lim et al.은 잔여 블록에서 BN 층을 제거하여 만족스러운 성능을 얻었다. 따라서 Lim et al.에서와 같은 잔여 블록을 적용한다. 잔여 블록의 세부 사항은 도 2에 나와 있다. 잔여 블록(228)과 단일 컨볼루션 레이어(230)를 통해 잔차 이미지 I_{res}가 생성된다.

수학식 7

[0103] $$I_{\mathrm{res}} = H_{\mathrm{re}}(F_{\mathrm{fused}})$$

[0104] 여기서 $H_{re}()$는 재구성부(210)의 중첩 함수를 나타낸다. 따라서 최종 팬-샤프닝된 I_{SRMS}는 업샘플링된 멀티 스펙트럼 이미지의 전역 잔여 학습에 의해 얻을 수 있다.

수학식 8

[0105] $$I_{SRMS} = I_{res} + f_{up}(I_{LRMS})$$

[0106] 여기서 $f_{up}(\cdot)$은 쌍삼차 업샘플링 연산을 나타낸다.

[0107] 표 1은 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치(MSFN)의 세부 파라미터 설정을 보여준다.

표 1

SFE	MS path		PAN path	
	Conv(4, 32, 3, 1, 1)		Conv(1, 32, 3, 1, 1)	
MSFENet	ReLU()		ReLU()	
Encoder	Conv(32, 32, 3, 1, 1)		Conv(32, 32, 3, 1, 1)	
	ReLU()		ReLU()	
	Conv(32, 64, 3, 2, 1)		Conv(32, 64, 3, 2, 1)	
	ReLU()		ReLU()	
	Conv(64, 128, 3, 2, 1)		Conv(64, 128, 3, 2, 1)	
	ReLU()		ReLU()	
Decoder	4 residual blocks	Conv(128, 128, 3, 1, 1)	4 residual blocks	Conv(128, 128, 3, 1, 1)
		ReLU()		ReLU()
		Conv(128, 128, 3, 1, 1)		Conv(128, 128, 3, 1, 1)
	Conv(128, 128, 3, 1, 1)		Conv(128, 128, 3, 1, 1)	
	Deconv(128, 64, 3, 2, 1, 1)		Deconv(128, 64, 3, 2, 1, 1)	
	ReLU()		ReLU()	
	2 residual blocks	Conv(64, 64, 3, 1, 1)	2 residual blocks	Conv(64, 64, 3, 1, 1)
		ReLU()		ReLU()
		Conv(64, 64, 3, 1, 1)		Conv(64, 64, 3, 1, 1)
	Conv(64, 64, 3, 1, 1)		Conv(64, 64, 3, 1, 1)	
	Deconv(64, 32, 3, 2, 1, 1)		Deconv(64, 32, 3, 2, 1, 1)	
	ReLU()		ReLU()	
	1 residual block	Conv(32, 32, 3, 1, 1)	1 residual block	Conv(32, 32, 3, 1, 1)
		ReLU()		ReLU()
		Conv(32, 32, 3, 1, 1)		Conv(32, 32, 3, 1, 1)
	Conv(32, 32, 3, 1, 1)		Conv(32, 32, 3, 1, 1)	
IP	Conv(69, 32, 3, 1, 1)			
MSFF				
SSFFB	Conv(256, 32, 1, 1, 0)			
	ReLU()			
	Deconv(32, 32, 8, 4, 2, 0)			
MSFFB	Conv(128, 32, 1, 1, 0)			
	ReLU()			
	Deconv(32, 32, 3, 2, 1, 1)			
CFFB	Conv(160, 32, 1, 1, 0)			
Reconstruction	12 residual blocks	Conv(32, 32, 3, 1, 1)		
		ReLU()		
		Conv(32, 32, 3, 1, 1)		
	Conv(32, 4, 3, 1, 1)			

[0108] Conv(C_{in}, C_{out}, k, s, p) represents the convolutional layer with C_{in} input channels, C_{out} output channels, kernel_size = k, stride = s and padding = p. Deconv(C_{in}, C_{out}, k, s, p, op) represents the deconvolutional layer where op denotes output_padding

[0109] **멀티 스케일 특징 추출 네트워크(206)**

[0110] 멀티 스케일 특징 추출 네트워크(206)(MSFENet: Multi-Scale Feature Extraction Net)와 관련하여 동일한 아키텍처와 공유 가중치를 가진 두 개의 서브 네트워크인 제1 멀티 스케일 특징 추출 서브 네트워크(222)와 제2 멀티 스케일 특징 추출 서브 네트워크(224)를 사용하여 각각 멀티 스펙트럼 이미지와 팬크로마틱 이미지의 멀티 스케일 정보를 캡처한다.

[0111] 도 3과 같이, 각각의 서브 네트워크(222, 224)는 인코더-디코더 구조를 도입한다. 두 개의 서브 네트워크가 정확히 동일하므로 여기에서 멀티 스펙트럼 경로의 제1 멀티 스케일 특징 추출 서브 네트워크(222)를 예로 들어

보겠다.

[0112] 입력은 F_{MS}^{0} 이고, 반면에 대응하는 출력들은 F_{MS}^{S}, F_{MS}^{M}, F_{MS}^{L} 이고, 각각 멀티 스펙트럼 이미지의 멀티 스케일 특징들을 지칭한다. 인코더 단에서, 초기에 컨벌루션 레이어를 사용하여 로우-레벨 특징을 추출한다.

수학식 9

[0113] $$F_{\mathrm{MS}}^{1} = H_{encoder_1}(F_{\mathrm{MS}}^{0})$$

[0114] $H_{\mathrm{encoder_1}}(\cdot)$ 는 스트라이드가 1인 컨벌루션 레이어를 나타낸다. F_{MS}^{1} 는 스킵 연결 및 추가적인 인코딩을 위해 사용될 것이다. 그 다음 스트라이드가 2인 컨벌루션 레이어를 적용하여 공간 해상도를 절반으로 낮추고 입력 특징 맵들의 특징 채널들을 2배로 늘린다.

수학식 10

[0115] $$F_{\mathrm{MS}}^{2} = H_{\mathrm{encoder_2}}(F_{\mathrm{MS}}^{1})$$

[0116] $H_{\mathrm{encoder_2}}(\cdot)$ 는 방금 언급된 컨벌루션 연산을 나타낸다. F_{MS}^{2} 는 스킵 연결 및 추가 인코딩을 위해 사용될 것이다. 후속적으로, 스트라이드가 2인 컨벌루션 레이어를 적용하여 두번째 다운샘플링 프로세스를 수행한다.

수학식 11

[0117] $$F_{\mathrm{MS}}^{3} = H_{\mathrm{encoder_3}}(F_{\mathrm{MS}}^{2})$$

[0118] $H_{\mathrm{encoder_3}}(\cdot)$ 는 $H_{\mathrm{encoder_2}}(\cdot)$ 와 유사한 컨벌루션 연산을 나타낸다. 공간 크기를 절반으로 줄이고 F_{MS}^{2}의 특징 채널들을 2배로 늘리는, F_{MS}^{3} 는 스킵 연결 및 추가 인코딩을 위해 사용될 것이다.

[0119] 디코더는 주로 스몰 스케일 특징 추출부(310)(SSFEM: small-scale feature extraction module), 미들 스케일 특징 추출부(314)(MSFEM: middle-scale feature extraction module) 그리고 라지 스케일 특징 추출부(318)(LSFEM: large-scale feature extraction module)의 세 부분으로 구성된다.

[0120] 스몰 스케일 특징 추출부(310)(SSFEM)는 4개의 잔여 블록(328)과 꼬리에 있는 컨벌루션 레이어(330)로 구성된다. 필터의 수는 F_{MS}^{3} 의 특징 채널들과 같다. 또한 마지막 컨벌루션 레이어의 출력에 F_{MS}^{3}를 로컬 잔여 학습으로 추가하여, 메모리를 유지하고 정보 흐름에 이점을 줄 수 있다. 이 부분은 다음과 같이 설명할 수 있다.

수학식 12

[0121] $$F_{\mathrm{MS}}^{0} = H_{\mathrm{SFE_MS}}(f_{\mathrm{up}}(I_{\mathrm{LRMS}}))$$

[0122] $H_{\mathrm{S}}^{4}(\cdot)$, $H_{\mathrm{S}}^{3}(\cdot)$, $H_{\mathrm{S}}^{2}(\cdot)$ 및 $H_{\mathrm{S}}^{1}(\cdot)$ 는 스몰 스케일 특징 추출부(310)(SSFEM)에서 4개의 잔여 블록들의 특징들을 나타낸다. $H_{\mathrm{S}}^{\mathrm{lc}}(\cdot)$ 는 마지막 컨벌루션 레이어(330)의 연산을 나타낸다. F_{MS}^{S}는 추출된 스몰 스케일 특징을 나타

낸다.

[0123] 미들 스케일 특징 추출부(312)(MSFEM)에서, 입력 F_{MS}^{S}는 먼저 스트라이드가 2인 디컨벌루션 레이어(332)에 의해 처리되어, F_{MS}^{S}의 공간 크기가 두 배이고 특징 채널이 절반인 특징 맵을 생성한다. 그런 다음 꼬리에 두 개의 잔여 블록(324)과 컨볼루션 레이어(336)를 적용한다. 또한, 스킵 연결을 위해 F_{MS}^{2}가 미들 스케일 특징 추출부(312)(MSFEM)의 출력에 가산된다. 프로세스는 다음과 같이 공식화할 수 있다.

수학식 13

[0124] $$F_{\mathrm{MS}}^{M}=H_{\mathrm{M}}^{\mathrm{lc}}(H_{\mathrm{M}}^{2}(H_{\mathrm{M}}^{1}(H_{\mathrm{M}}^{\mathrm{dec}}(F_{\mathrm{MS}}^{S}))))+F_{\mathrm{MS}}^{2}$$

[0125] $H_{\mathrm{M}}^{2}(\cdot)$과 $H_{\mathrm{M}}^{1}(\cdot)$은 M미들 스케일 특징 추출부(312)(MSFEM)에서의 두 잔여 블록들(334)의 특징들을 나타낸다. $H_{\mathrm{M}}^{dec}(\cdot)$와 $H_{M}^{\mathrm{lc}}(\cdot)$는 각각 첫번째 디컨벌루션 레이어(332)와 마지막 컨벌루션 레이어(334)의 연산을 나타낸다. F_{MS}^{M}는 추출된 미들 스케일 특징을 나타낸다.

[0126] 라지 스케일 특징 추출부(318)(LSFEM)의 경우, 시작 부분에 스트라이드가 2인 디컨벌루션 레이어(338), 중간에 잔여 블록(340), 꼬리 부분에 컨벌루션 레이어(342)로 구성된다. 초기에, 라지 스케일 특징 추출부(318)(LSFEM)의 입력, F_{MS}^{M}는 디컨벌루션 레이어(338)에서 처리된다. 이 레이어(338)를 통해 F_{MS}^{M}의 두 배의 공간 해상도와 절반의 채널을 가진 특징 맵을 얻는다.

[0127] 후속적으로, 이들 특징 맵들은 잔여 블록(340)과 컨볼루션 레이어(342)에 입력되어 출력을 생성한다. 또한, 잔여 학습을 활용하기 위해, 스킵 연결을 위한 출력에 F_{MS}^{1}를 가산한다. 이러한 방식으로, 라지 스케일 특징 F_{MS}^{L}가 획득된다. 이 부분은 다음과 같이 공식화할 수 있다.

수학식 14

[0128] $$F_{\mathrm{MS}}^{L}=H_{\mathrm{L}}^{\mathrm{lc}}(H_{\mathrm{L}}^{1}(H_{\mathrm{L}}^{\mathrm{dec}}(F_{\mathrm{MS}}^{M})))+F_{\mathrm{MS}}^{1}$$

[0129] $H_{\mathrm{L}}^{\mathrm{dec}}(\cdot)$은 라지 스케일 특징 추출부(318)(LSFEM)에서 초기 디컨벌루션 레이어(328)의 특징을 나타낸다. $H_{L}^{1}(\cdot)$ 및 $H_{\mathrm{L}}^{\mathrm{lc}}(\cdot)$은 각각 중간의 잔여 블록(340) 및 마지막 컨벌루션 레이어(342)의 연산을 나타낸다.

[0130] 디코더 단계에서, 멀티 스케일 특징을 점진적으로 디코딩하여, 단계적으로 더 미세한 세부 사항을 얻기 위해 거친 대 미세(coarse-to-fine) 전략을 통합한다. 구체적으로, 4개의 잔여 블록들은 스몰 스케일 특징을 위해 사용되는 반면, 2개의 잔여 블록들은 미들 스케일 특징을 위해 사용되며 하나의 잔여 블록은 미들 스케일 특징을 위해 사용된다. 따라서 스몰 스케일 특징 뿐만 아니라 미들 스케일 특징 및 라지 스케일 특징도 풍부하게 추출하여 더 나은 후속 융합을 제공한다. 상이한 스케일의 특징 추출을 위해 4, 2, 1의 잔여 블록을 유지한다는 점은 언급할 가치가 있다.

[0131] 이러한 방식으로, 제1 멀티 스케일 특징 추출 서브 네트워크(222)의 3가지 멀티 스케일 출력, 즉 F_{MS}^{S}, F_{MS}^{M} 및 F_{MS}^{L}가 획득된다. 마찬가지로 팬크로마틱 경로의 제2 멀티 스케일 특징 추출 서브 네트워크(224)는 F_{PAN}^{S},

F^{M}_{PAN} 및 F^{L}_{PAN}을 생성한다. 후속적으로, 이들 6개의 출력은 추가 보완 정보 융합을 위해 멀티 스케일 특징 융합부(208, 226)(MSFF)에 제공될 것이다.

[0133] **멀티 스케일 특징 융합부(208, 226)**

[0134] 멀티 스케일 특징 추출 네트워크(206)(MSFENet)의 멀티 스케일 특징과 정보 풀(204)(IP)의 원시 정보는 보완 정보 융합을 위해 멀티 스케일 특징 융합부(206, 208)(MSFF: multi-scale feature fusion)에서 처리된다.

[0135] 도 4에서 볼 수 있듯이, 멀티 스케일 특징 융합부(206, 208)(MSFF)는 주로 스몰 스케일 특징 융합부(400)(SSFFB: small-scale features fusion block), 미들 스케일 특징 융합부(402)(MSFFB: middle-scale features fusion block) 및 포괄적 특징 융합부(404)(CFFB: comprehensive features fusion block)의 세 부분으로 구성된다.

[0136] 스몰 스케일 특징 융합부(400)(SSFFB)의 경우, 커널 크기가 1인(kernel_size=1) 컨벌루션 레이어(408)와 스트라이드(stride)가 4인 디컨벌루션 레이어(410)로 구성된다. 연결부(406)에 의해 F^{S}_{MS}와 F^{S}_{PAN}가 연결되어 컨벌루션 레이어(408)의 입력으로 사용된다. 그런 다음 스몰 스케일 특징들이 저해상도(LR: low resolution) 공간에 융합되어, 계산 부담이 크게 줄어든다. 마지막으로 융합된 특징은 추가 융합을 위해 디컨벌루션 레이어(410)에 의해 스케일 인자 x4로 업샘플링된다. 이 프로세스는 다음과 같이 나타낼 수 있다.

수학식 15

[0137] $$F^{S}_{\mathrm{fused}} = H^{\mathrm{dec}}_{\mathrm{S}}(H^{c}_{\mathrm{S}}([F^{S}_{\mathrm{MS}}, F^{S}_{\mathrm{PAN}}]))$$

[0138] 여기서 $[\cdot]$는 연결 동작을 나타낸다. $H^{c}_{\mathrm{S}}(\cdot)$와 $H^{\mathrm{dec}}_{\mathrm{S}}(\cdot)$는 각각 연결된 특징을 압축하기 위한 1×1 컨벌루션 레이어(408)와 스트라이드가 4인 디컨벌루션 레이어(410)를 나타낸다. F^{S}_{fused}는 스몰 스케일의 융합된 특징을 나타낸다.

[0139] 마찬가지로, 미들 스케일 특징 융합부(402)(MSFFB)는 F^{M}_{MS}와 F^{M}_{PAN}의 연결을 입력으로 사용하고 1×1 컨볼루션 레이어(414)를 사용하여 중간 해상도(MR: medium-resolution) 공간에서 미들 스케일 특징들을 융합한다. 후속적으로, 융합된 특징은 추가 융합을 위해 스트라이드가 2인 디컨벌루션 레이어(416))를 사용하여 업샘플링된다. 이 부분은 다음과 같이 설명할 수 있다.

수학식 16

[0140] $$F^{M}_{\mathrm{fused}} = H^{\mathrm{dec}}_{\mathrm{M}}(H^{c}_{\mathrm{M}}([F^{M}_{\mathrm{MS}}, F^{M}_{\mathrm{PAN}}]))$$

[0141] 여기서 $[\cdot]$는 연결 동작을 나타낸다. $H^{c}_{\mathrm{M}}(\cdot)$과 $H^{dec}_{\mathrm{M}}(\cdot)$은 각각 1×1 컨벌루션 레이어(414)와 스트라이드가 2인 디컨벌루션 레이어(416)를 나타낸다. F^{M}_{fused}는 미들 스케일의 융합된 특징을 나타낸다.

[0142] 마지막으로, F^{S}_{fused}, F^{M}_{fused}, F^{L}_{MS}, F^{L}_{PAN} 및 F_{pri}는 연결되어 종합적인 정보, 즉, 멀티 스케일 보완 정보 및 원시 정보를 융합하기 위하여 1×1 컨볼루션 레이어를 나타내는 종합 특징 융합부(404)(CFFB)에 제공된다. 이 마지막 융합된 특징은 다음과 같이 공식화될 수 있다.

수학식 17

[0143] $$F_{\text{fused}} = (H^{c}_{\text{CFFB}}([F^{S}_{\text{fused}}, F^{M}_{\text{fused}}, F^{L}_{\text{MS}}, F^{L}_{\text{PAN}}, F_{pri}]))$$

[0144] 여기서 $[\cdot]$는 연결 동작을 나타낸다. $H^{c}_{\text{CFFB}}(\cdot)$는 종합 특징 융합부(404)(CFFB)에서 1×1 컨볼루션 레이어(420)를 나타낸다.

[0146] **실시간 구현**

[0147] 매개변수와 계산 복잡도는 실제 응용과 실시간 처리의 두 가지 필수 요소이다. 따라서 본 발명에서는 실시간 구현을 위한 두 가지 조치가 있다. 한편, 두 개의 인코더-디코더의 가중치, 즉 멀티 스케일 특징 추출 네트워크(206)(MSFENet)의 두 개의 서브 네트워크인 제1 멀티 스케일 특징 추출 서브 네트워크(222)와 제2 멀티 스케일 특징 추출 서브 네트워크(224)의 가중치는 매개변수를 줄이기 위해 공유된다. 반면에 더 적은 수의 계산을 위해 스몰 스케일 특징은 저해상도(LR) 공간에 융합되고 미들 스케일 특징은 중간 해상도(MR) 공간에 융합된다.

[0149] **가중치 공유 인코더-디코더 구조**

[0150] 멀티 스케일 특징 추출 네트워크(206)(MSFENet)에서는 동일한 인코더-디코더 아키텍처를 가진 두 개의 서브 네트워크를 사용하여 멀티 스펙트럼 이미지와 해당 팬크로마틱 이미지의 멀티 스케일 보완 컨텍스트 정보를 캡처한다. 인코더-디코더 아키텍처는 더 큰 수용 필드를 가능하게 하여 효과적인 멀티 스케일 특징 추출에 도움이 된다. 그러나 인코더-디코더 아키텍처는 또한 엄청난 양의 매개변수를 발생시킨다. 유리한 성능을 위해 인코더-디코더 아키텍처를 활용하고 적당한 크기의 네트워크를 유지하기 위해 두 개의 인코더-디코더가 동일한 가중치를 공유하므로 멀티 스케일 특징 추출 네트워크(206)(MSFENet)의 매개변수가 절반으로 줄어든다.

[0152] **스몰 스케일 특징을 위한 저해상도 공간에서의 융합 및 미들 스케일 특징을 위한 중간 해상도 공간에서의 융합**

[0153] 보완 스몰 스케일 특징(F^{S}_{MS}와 F^{S}_{PAN}) 또는 미들 스케일 특징(F^{M}_{MS}와 F^{M}_{PAN})으로부터 융합된 특징을 획득하기 위한 주된 2가지 방법이 존재한다. 첫번째 방법은 도 3에 도시된 파이프라인, 연결부(Concat), 컨벌루션 레이어(Conv) 및 디컨벌루션 레이어(Deconv)를 채택하는 것이고, 반면에 두 번째 방법은 디컨벌루션 레이어(Deconv), 연결부(Concat) 및 컨벌루션 레이어(Conv)의 또 다른 파이프라인을 채택한다.

[0154] 전자는 저해상도(LR) 또는 중간 해상도(MR) 공간에서 보완적인 특징을 융합하고 후자는 고해상도(HR) 공간에서 융합한다. 분명히 전자는 공간 해상도가 증가함에 따라 계산 비용이 커지고 저해상도(LR) 또는 중간 해상도(MR) 공간의 특징 맵들의 공간 해상도가 고해상도(HR) 공간보다 낮기 때문에, 계산 복잡성이 더 작다.

[0156] **손실 함수**

[0157] 네트워크 아키텍처 외에도 손실 함수는 팬 샤프닝의 성능에 영향을 미치는 또 다른 중요한 요소이다. L_2 손실 함수는 기존의 SISR 및 팬 샤프닝 태스크에서 일반적으로 적용된다. 그럼에도 불구하고 L_2 손실 함수가 로컬 최소값에 빠질 가능성이 더 높아 예기치 않은 아티팩트가 발생한다. 따라서 본 발명에서는 네트워크를 최적화하기 위해 L_1 손실 함수를 채택하여 더 나은 휘도와 색상을 보존할 수 있고, L_2 손실 함수보다 더 빠르게 수렴한다.

[0158] 훈련 세트는 $D = \{I^{(i)}_{\text{LRMS}}, I^{(i)}_{\text{PAN}}, I^{(i)}_{\text{HRMS}}\}$와 같이 표시되는데, $I^{(i)}_{\text{LRMS}}$와 $I^{(i)}_{\text{PAN}}$은 각각 저해상도 멀티 스펙트럼 이미지와 팬크로마틱 이미지를 나타낸다. $I^{(i)}_{\text{HRMS}}$는 대응하는 그라운드-트루스(ground truth) 고해상도 멀티 스펙트럼 이미지를 나타낸다. 따라서, 본 발명에 의한 멀티 스펙트럼 융합 네트워크의 손실 함수는 다음과 같이

나타낼 수 있다.

수학식 18

$$L(\theta) = \frac{1}{N}\sum_{i=1}^{N}\left\| I_{\mathrm{HRMS}}^{(i)} - N_{\mathrm{MSFN}}(I_{\mathrm{LRMS}}^{(i)}, I_{\mathrm{PAN}}^{(i)}; \theta)\right\|_1$$

[0159]

[0160] N, $N_{\mathrm{MSFN}}(\cdot)$ 및 θ는 각각 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치(MSFN)의 훈련 샘플의 수(크기), 함수 및 매개변수들을 나타낸다.

[0162] **실험 결과**

[0163] **데이터셋**

[0164] 본 발명의 일 실시예에 의한 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치 및 방법의 우수성을 입증하기 위해 QuickBird, IKONOS, Spot-6 및 Pleiades의 네 가지 데이터 세트에 대한 실험을 구현한다. 이러한 위성의 스펙트럼 파장 및 공간 해상도 특징은 표 2에 요약되어 있다. 고해상도 멀티 스펙트럼 이미지가 실제로 팬 샤프닝 데이터셋에 존재하지 않는다는 점을 고려하여 실험 시뮬레이션을 위해 Wald의 프로토콜을 따른다. 특히, 스케일 인자 ×4로 멀티 스펙트럼 이미지 및 팬크로마틱 이미지를 모두 다운샘플링한다. 이러한 방식으로 다운샘플링된 멀티스펙트럼 이미지 및 팬크로마틱 이미지를 네트워크 입력으로 활용하고 원본 멀티 스펙트럼 이미지를 네트워크 훈련 및 방법 평가를 위한 참조로 사용할 수 있다.

표 2

[0165]

Satellite	Spectral wavelength (nm)					Spatial resolution (m)	
	PAN	Blue	Green	Red	Nir	PAN	MS
QuickBird	450–900	450–520	520–600	630–690	760–900	0.6	2.4
IKONOS	526–929	445–516	506–595	632–698	757–853	0.82	3.28
Spot-6	450–750	455–525	530–590	625–695	760–890	1.5	6
Pleiades	480—830	430–550	490–610	600–720	750–950	0.5	2

[0167] **구현 세부 사항**

[0168] 앞에서 언급된 4개의 데이터 세트는 별도로 실험을 구현하는 데 사용된다. 각 데이터 세트에 대해 업샘플링된 저해상도 멀티스펙트럼(LRMS)/팬크로마틱/고해상도 멀티 스펙트럼(HRMS) 이미지 쌍은 초기에 256×256 크기로 추출된다. 그런 다음 훈련/테스트를 위해 90/10%로 분할된다. 게다가, 데이터 증대는 무작위 자르기, 회전 및 뒤집기를 포함하여 각 훈련 세트에 채택된다. 훈련 단계에서 미니 배치 크기는 8로 설정되고 각 패치 쌍은 훈련 이미지 쌍에서 무작위로 64×64로 잘린다. 각 실험의 훈련 과정은 1000 에포크(Epoch)가 소요된다. 네트워크를 최적화하기 위해 Adam을 적용한다. 초기 학습률은 0.0001로 설정되고 매 200 에포크마다 0.5 팩터로 감소한다. 모든 딥 러닝 기반 실험은 GTX1080Ti GPU가 탑재된 데스크탑의 파이토치(Pytorch)에서 구현된다. 기존 방법의 실험은 4.2GHz Intel i7-7700K CPU가 장착된 MATLAB R2018a에서 수행된다.

[0170] **절제(Ablation) 연구**

[0171] 정보 풀(IP), CTF(Coarse-to-Fine) 전략(CTF) 및 멀티 스케일 융합(MSF)의 효율성을 검증하기 위해 5가지 네트워크의 성능을 분석한다: 기준선(IP, CTF 및 MSF 없음), IP 없는 MSFN, CTF 없는 MSFN, MSF 없는 MSFN 및 제안된 MSFN. 모든 절제 실험은 퀵버드(QuickBird) 데이터 세트에서 수행된다. 절제 실험 결과 및 해당 손실 곡선은

각각 표 3 및 도 6a에 나와 있다.

표 3

MSF	CTF	IP	CC ↑	ERGAS ↓	Q_4 ↑	SAM ↓	RASE ↓	RMSE ↓
×	×	×	0.9572	1.1036	0.9560	0.0259	4.4156	11.3174
✓	✓	×	0.9594	1.0661	0.9582	0.0253	4.2256	10.8223
✓	×	✓	0.9598	1.0594	0.9586	0.0252	4.2035	10.7650
×	✓	✓	0.9588	1.0748	0.9573	0.0255	4.2716	10.9434
✓	✓	✓	**0.9603**	**1.0514**	**0.9590**	**0.0250**	**4.1715**	**10.6821**

The best performance is shown in bold

[0172]

[0174] **정보 풀(204)(IP).**

[0175] 정보 풀(204)(IP)은 단순하지만 기본 정보를 보존하는 데 도움이 되는 모듈이며, 반면에 그래디언트 역전파(back-propagation)에 유용하다. 직관적인 동기는 특징 재사용과 메모리 메커니즘이며, 이는 원시 공간 및 스펙트럼 정보를 포함하는 얕은 특징이 팬 샤프닝의 성능을 향상시킬 가능성이 있음을 의미한다. 표 3에서 보는 바와 같이 두 번째 행과 마지막 행에 있는 결과는 정보 풀(204)(IP)의 효율성을 보여준다.

[0177] **거친-미세(CTF: Coarse-to-fine) 전략**

[0178] MSFENet의 디코더 단계에 대해 본 발명에서는 멀티 스케일 특징을 점진적으로 디코딩하여 단계적으로 더 미세한 세부 사항을 얻는 거친-미세 전략을 통합한다. 구체적으로, 4개의 잔여 블록은 소규모 특징에 사용되는 반면, 2개의 잔여 블록은 미들 스케일 특징에, 1개의 잔여 블록은 라지 스케일 특징에 사용된다. 이러한 방식으로 스몰 스케일 특징뿐만 아니라 미들 스케일 특징 및 라지 스케일 특징도 풍부하게 추출하여 더 나은 후속 융합을 만든다. CTF의 효율성을 입증하기 위해 MSFEM 및 LSFEM에서 잔여 블록을 제거하고 7개의 잔여 블록을 모두 SSFEM으로 병합한다. 표 3에서 보는 바와 같이 CTF가 없는 네트워크의 성능은 MSFN보다 열등하여 CTF의 장점을 나타낸다.

[0180] **멀티 스케일 융합(MSF: Multi-scale fusion)**

[0181] MSF는 팬크로마틱 및 멀티 스펙트럼 이미지의 레이어적 보완 특징을 최대한 활용하는 데 필수적인 부분이다. MSF의 절제 연구를 위해 MSF 대신 단일 규모 융합을 적용한다. 특히, 라지 스케일 특징 F^L_{MS}와 F^L_{PAN}을 융합하여 보완 정보를 획득하고, 표 3의 네 번째 행에 결과를 생성한다. 단일 스케일 융합과 멀티 스케일 융합 사이의 추가 비교를 위해, 스몰 스케일 융합과 미들 스케일 융합 각각을 가지고 2개의 단일 스케일 유합 실험을 수행하였다. 스몰 스케일 융합은 스몰 스케일 특징인 F^S_{MS}와 F^S_{PAN}만을 융합하는 것을 의미하고, 미들 스케일 융합은 미들 스케일 특징인 F^M_{MS}와 F^M_{PAN}만을 융합하는 것을 의미한다. 비교 결과는 표 4에 표시되고, 해당 손실 곡선은 도 6b에 표시된다. 멀티 스케일 융합이 실제로 단일 스케일 융합보다 성능이 우수하다는 것은 분명하며, 이는 MSF의 효율성을 보여준다. 전반적으로 모든 IP, CTF 및 MSF는 팬 샤프닝의 더 나은 성능에 유리하다.

표 4

	CC ↑	ERGAS ↓	Q_4 ↑	SAM ↓	RASE ↓	RMSE ↓
Single-scale fusion						
Small-scale fusion	0.9582	1.0806	0.9567	0.0256	4.2950	11.0046
Middle-scale fusion	0.9585	1.0800	0.9571	0.0256	4.2877	10.9827
Large-scale fusion	0.9588	1.0748	0.9573	0.0255	4.2716	10.9434
Multi-scale fusion	**0.9603**	**1.0514**	**0.9590**	**0.0250**	**4.1715**	**10.6821**

[0182]

[0184] **다른 방법과의 비교**

[0185] **정량적 평가 및 시각적 성능**

[0186] 본 발명에 의한 MSFN의 효과를 확인하기 위해 Indusion, MMP, AWLP, GS, PNN, DiCNN1, PanNet, ECNN, DRPNN, BIEDN 및 TFNet을 포함하여, 4가지 전통적인 방법과 여러 딥 러닝 기반 방법을 본 발명의 방법과 비교한다. 정량적 평가를 위해 본 실험에서 널리 사용되는 6가지 지표가 채택되었다: 상관 계수(CC), 상대 전역 차원 합성 오차(ERGAS), 범용 이미지 품질 지수의 4밴드 확장(Q_4), 스펙트럼 각도 매퍼(SAM), 상대 평균 스펙트럼 오차(RASE) 및 RMSE(제곱 평균 오차). 앞에서 언급된 4개의 데이터 세트에 대한 객관적인 정량적 결과는 각각 표 5, 6, 7 및 8에 나열되어 있다. 각 데이터 세트에 대해 해당 테스트 이미지에 대한 결과를 평균화하여 최종 결과를 계산한다.

표 5

Method	CC ↑	ERGAS ↓	Q_4 ↑	SAM ↓	RASE ↓	RMSE ↓
Indusion [19]	0.8472	2.2567	0.8379	0.0476	9.0814	23.3507
MMP [18]	0.8852	1.9259	0.8659	0.0425	7.9260	20.3837
AWLP [29]	0.8295	2.5248	0.7702	0.0548	10.2561	26.2513
GS [23]	0.8843	2.1710	0.8212	0.0475	8.9362	22.9340
PNN [28]	0.9296	1.4200	0.9263	0.0323	5.9468	15.3316
DiCNN1 [15]	0.9321	1.4111	0.9281	0.0321	5.9018	15.2131
PanNet [47]	0.9232	1.4855	0.9213	0.0335	6.1915	15.9811
ECNN [13]	0.9343	1.3867	0.9309	0.0313	5.8218	15.0075
DRPNN [45]	0.9445	1.2371	0.9429	0.0292	4.9741	12.7422
BIEDN [26]	0.9359	1.3744	0.9321	0.0309	5.7327	14.7724
TFNet [27]	*0.9540*	*1.1409*	*0.9523*	*0.0268*	*4.5558*	*11.6897*
MSFN (Ours)	**0.9603**	**1.0514**	**0.9590**	**0.0250**	**4.1715**	**10.6821**

The best performance is shown in bold, and the second best performance is shown in italic shape

[0187]

표 6

Method	CC ↑	ERGAS ↓	Q_4 ↑	SAM ↓	RASE ↓	RMSE ↓
Indusion [19]	0.8795	3.4358	0.8631	0.0773	14.3933	45.5049
MMP [18]	0.9075	2.9947	0.9004	0.0715	12.4730	39.5354
AWLP [29]	0.8617	3.9161	0.8288	0.0792	15.7896	49.5278
GS [23]	0.8884	3.6414	0.8345	0.0808	15.5066	50.6687
PNN [28]	0.9271	2.6695	0.9234	0.0577	11.1968	35.3801
DiCNN1 [15]	0.9267	2.6729	0.9227	0.0576	11.2101	35.3623
PanNet [47]	0.9259	2.6956	0.9229	0.0591	11.3411	35.7500
ECNN [13]	0.9301	2.5919	0.9269	0.0562	10.8987	34.3059
DRPNN [45]	0.9411	2.2931	0.9393	0.0532	9.5183	29.9604
BIEDN [26]	0.9320	2.5606	0.9284	0.0568	10.7881	33.9918
TFNet [27]	*0.9483*	*2.1659*	*0.9463*	*0.0507*	*8.9266*	*28.1966*
MSFN (Ours)	**0.9537**	**2.0269**	**0.9520**	**0.0476**	**8.3507**	**26.2889**

The best performance is shown in bold, and the second best performance is shown in italic shape

[0188]

표 7

Method	CC ↑	ERGAS ↓	Q_4 ↑	SAM ↓	RASE ↓	RMSE ↓
Indusion [19]	0.9133	3.6399	0.9128	0.0684	16.8852	39.6835
MMP [18]	0.9478	2.7360	0.9445	0.0560	11.9565	28.0880
AWLP [29]	0.9370	2.7015	0.9183	0.0561	12.2196	29.0540
GS [23]	0.9137	3.5897	0.9054	0.0734	16.6123	38.7832
PNN [28]	0.9876	1.3144	0.9875	0.0351	6.4758	15.2498
DiCNN1 [15]	0.9873	1.3422	0.9872	0.0358	6.6030	15.5609
PanNet [47]	0.9875	1.3245	0.9873	0.0356	6.4980	15.3350
ECNN [13]	0.9884	1.2662	0.9883	0.0336	6.2064	14.6162
DRPNN [45]	0.9896	1.1833	0.9895	0.0311	*5.7223*	*13.4671*
BIEDN [26]	0.9891	1.2309	0.9889	0.0321	6.0003	14.1322
TFNet [27]	*0.9898*	*1.1828*	*0.9897*	*0.0309*	5.7565	13.5491
MSFN (Ours)	**0.9906**	**1.1372**	**0.9905**	**0.0297**	**5.5246**	**12.9917**

The best performance is shown in bold, and the second best performance is shown in italic shape

[0189]

표 8

Method	CC ↑	ERGAS ↓	Q_4 ↑	SAM ↓	RASE ↓	RMSE ↓
Indusion [19]	0.9228	4.2221	0.9221	0.0634	18.4791	109.6234
MMP [18]	0.9484	3.4470	0.9477	0.0563	14.6737	87.2424
AWLP [29]	0.9418	3.9679	0.9298	0.0521	16.4055	97.2002
GS [23]	0.9399	3.7514	0.9342	0.0614	16.3020	96.6394
PNN [28]	0.9828	1.9202	0.9827	0.0395	8.2972	49.2551
DiCNN1 [15]	0.9810	2.0495	0.9807	0.0397	8.8571	52.5451
PanNet [47]	0.9825	1.9514	0.9824	0.0417	8.4793	50.3741
ECNN [13]	0.9866	1.6946	0.9865	0.0362	7.3709	43.8347
DRPNN [45]	0.9935	1.1619	0.9935	0.0295	*5.1272*	*30.4186*
BIEDN [26]	0.9862	1.7422	0.9859	0.0467	7.9415	46.7854
TFNet [27]	*0.9936*	*1.1590*	*0.9936*	*0.0292*	5.1512	30.5663
MSFN (Ours)	**0.9943**	**1.0972**	**0.9942**	**0.0274**	**4.8725**	**28.9379**

The best performance is shown in **bold**, and the second best performance is shown in italic shape

[0190]

[0191] 이들 표에서 볼 수 있듯이 본 발명에 의한 MSFN은 모든 객관적인 평가 지표에 대한 모든 비교 팬 샤프닝 방법 중 최고의 성능을 달성함을 알 수 있다. 이러한 정량적 결과는 공간 세부 사항을 복구하는 데 성공할 뿐만 아니라 스펙트럼 정보를 보존하는 동시에 본 발명의 MSFN의 우수성을 보여준다.

[0192] 객관적인 결과 외에도 여러 시각적 비교 결과를 제공한다. 도 7 내지 도 9는 각각 QuickBird, IKONOS 및 Pleiades의 이들 주관적인 결과를 보여준다. 멀티 스펙트럼 이미지의 처음 세 밴드는 시각적 비교를 위해 선택된다. 더 나은 육안 검사를 위한 차이점을 강조하기 위해 해당 잔여 이미지도 제공한다. 잔여 이미지는 팬 샤프닝된 이미지와 참조 이미지의 차이를 나타낸다. 분명히 차이가 작을수록 더 나은 재구성을 얻을 수 있다. 도 7의 확대된 영역에서 전통적인 방법이 명확한 공간 정보를 얻는 경향이 있지만 스펙트럼 왜곡을 겪는 반면, 대부분의 딥 러닝 기반 방법이 더 부드러운 공간 세부 정보를 얻는 경향이 있음을 쉽게 알 수 있다. 본 발명에 의한 방법만이 스펙트럼 및 공간 영역 모두에서 만족스러운 보존을 달성하며, 특히 확대 영역에서 세 개의 검은 점을 주목하는 것이 분명하다. 잔여 이미지는 본 발명에 의한 방법이 참조 이미지에 비해 공간 및 스펙트럼 왜곡이 가장 적다는 것을 추가로 증명한다. 도 8에서 볼 수 있듯이 Indusion, AWLP 및 GS와 같은 전통적인 방법은 특히 녹지와 협곡을 관찰하는 데 심각한 스펙트럼 왜곡을 도입하는 대가로 공간 세부 사항을 눈에 띄게 향상시킨다. PNN, DiCNN1, ECNN 및 DRPNN과 같은 일부 딥 러닝 기반 방법에서도 동일한 현상이 나타나다. 반대로 MMP와 PanNet은 스펙트럼 왜곡이 적지만 더 부드러운 공간 디테일을 회복한다.

[0193] 대조적으로, TFNet과 본 발명에 의한 방법은 만족스러운 스펙트럼 및 공간 보존을 얻는다. 추가 관찰을 위해, 본 발명에 의한 방법은 도 8의 확대된 영역과 해당 잔여 이미지에서 볼 수 있듯이 협곡과 녹색 지면의 더 선명한 모양을 얻는 동시에 스펙트럼 왜곡을 줄인다.

[0194] 도 9에서 볼 수 있듯이 전통적인 방법은 공간 세부 사항을 인상적으로 개선하지만 그와 동시에 특히 AWLP 및 GS의 경우 스펙트럼 왜곡이 눈에 띄게 나타난다. 딥러닝 기반 방법이 더 만족스러운 재구성을 달성할 가능성이 높다. 그러나 PNN, DiCNN1, PanNet 및 ECNN은 잔여 이미지에 따라 복잡한 텍스처 영역에서 아티팩트가 발생하는 경향이 있다. 대조적으로 DRPNN, TFNet 및 본 발명에 의한 방법은 더 나은 결과를 생성한다. 추가 관찰을 위해 본 발명에 의한 방법은 스펙트럼 왜곡 없이 배수로의 가장 선명한 직선 윤곽을 생성하고 참조 이미지와 더 유사하다. 위에서 언급한 비교는 본 발명에 의한 MSFN의 우수성을 보여준다. 요약하면, 본 발명에 의한 방법은 정량적 메트릭과 시각적 품질 측면에서 우수한 성능을 달성한다.

[0196] **비모수 테스트**

[0197] 정량적 메트릭 및 시각적 품질 외에도 다양한 방법을 비교하는 데 강력한 것으로 입증된 일부 비모수 통계 테스트를 수행한다. Friedman, Aligned Friedman 및 Quade를 포함하여 널리 적용되는 세 가지 비모수 테스트가 통계적 유의성 테스트를 위해 본 실험에서 사용된다. 각 테스트에 대해 모든 방법의 평균 순위는 CC 지표 측면에서 서로 다른 데이터 세트에 대한 성능에 따라 계산된다.

[0198] Friedman, Aligned Friedman 및 Quade 비모수 테스트의 결과는 각각 표 9, 10 및 11에 나열되어 있다. 순위 번호가 작을수록 더 좋은 방법이다. 이 표에서 볼 수 있듯이 본 발명에 의한 MSFN은 모든 비교 팬 샤프닝 방법에 대해 최상의 성능을 달성한다. 세 가지 비모수 테스트 모두 본 발명에 의한 방법의 우수성을 보여준다.

표 9

Method	Ranking
Indusion [19]	11.5
MMP [18]	9.0
AWLP [29]	11.0
GS [23]	10.5
PNN [28]	6.25
DiCNN1 [15]	7.25
PanNet [47]	7.5
ECNN [13]	4.75
DRPNN [45]	3.0
BIEDN [26]	4.25
TFNet [27]	2.0
MSFN (Ours)	1.0

[0199]

표 10

Method	Ranking
Indusion [19]	44.25
MMP [18]	34.5
AWLP [29]	43.25
GS [23]	40.0
PNN [28]	23.25
DiCNN1 [15]	24.5
PanNet [47]	26.5
ECNN [13]	19.5
DRPNN [45]	8.5
BIEDN [26]	17.5
TFNet [27]	7.0
MSFN (Ours)	5.25

[0200]

표 11

Method	Ranking
Indusion [19]	11.3
MMP [18]	9.0
AWLP [29]	11.4
GS [23]	10.3
PNN [28]	6.4
DiCNN1 [15]	6.9
PanNet [47]	7.7
ECNN [13]	4.9
DRPNN [45]	3.0
BIEDN [26]	4.1
TFNet [27]	2.0
MSFN (Ours)	1.0

[0201]

[0203] **실시간 평가**

[0204] 시간 평가의 경우, 1024×1024 크기의 업샘플링된 LRMS 및 팬크로마틱 이미지 쌍을 이러한 학습된 모델에 직접 공급하여 팬 샤프닝된 이미지를 생성한다. 서로 다른 데이터셋에 대한 각 방법의 결과는 표 12에 나와 있다. 결과는 본 발명에 의한 방법이 0.0068초 안에 하나의 이미지를 생성하여 실시간 성능을 달성할 수 있음을 나타낸다. 본 발명에 의한 방법은 BIEDN을 제외한 다른 딥 러닝 기반 방법보다 팬 샤프닝 이미지를 재구성하는 데 더 많은 시간이 걸린다는 점에 주목할 가치가 있다. 이는 본 발명에 의한 방법의 목적이 실시간 애플리케이션의 조건에서 가능한 한 성능을 향상시키는 것이기 때문에 합리적이다. 앞에서 언급했듯이 MSFN은 모든 비교 팬 샤프닝 방법 중 최고의 성능을 달성한다. 따라서 본 발명에 의한 방법은 실시간 구현의 요구 사항을 충족함과 동시에 보다 효과적인 성능을 달성할 수 있다.

표 12

[0205]

Method	QuickBird	IKONOS	Spot-6	Pleiades	Average
Indusion [19]	0.3141	0.3125	0.3208	0.3105	0.3145
MMP [18]	1.7571	1.7584	1.7476	1.7544	1.7544
AWLP [29]	0.2643	0.2655	0.2640	0.2674	0.2653
GS [23]	0.2596	0.2581	0.2572	0.2614	0.2591
PNN [28]	0.0006	0.0009	0.0010	0.0009	0.0009
DiCNN1 [15]	0.0010	0.0010	0.0008	0.0010	0.0010
PanNet [47]	0.0017	0.0020	0.0017	0.0017	0.0018
ECNN [13]	0.0008	0.0007	0.0009	0.0009	0.0008
DRPNN [45]	0.0015	0.0015	0.0013	0.0016	0.0015
BIEDN [26]	0.0433	0.0421	0.0418	0.0441	0.0428
TFNet [27]	0.0029	0.0023	0.0028	0.0022	0.0026
MSFN (Ours)	0.0072	0.0066	0.0068	0.0066	0.0068

[0207] **결론 및 향후 과제**

[0208] 실시간 구현의 요구 사항을 충족하고 동시에 보다 효과적인 성능을 달성하기 위해 본 발명에서는 팬크로마틱 및 멀티 스펙트럼 이미지의 계층적인 보완 특징들을 최대한 활용할 수 있는 팬 샤프닝 작업을 위한 멀티 스케일 융합 네트워크(MSFN)를 제안한다. 제안된 MSFN에서는 팬크로마틱 이미지와 멀티 스펙트럼 이미지의 멀티 스케일 특징들을 개별적으로 효과적으로 추출하기 위하여, 인코더-디코더 구조 및 거친-미세 전략을 도입한다. 한편, 원시 정보를 보존하기 위해 정보 풀을 채택하여, 기울기 역전파에도 이점을 제공한다.

[0209] 또한, 멀티 스케일 융합 모듈은 디코더와 정보 풀로부터의 멀티 스케일 특징을 융합하기 위해 적용되어, 계층적 보완공간 및 스펙트럼 정보를 최대한 활용한다. 광범위한 실험은 팬 샤프닝 방법을 위해 본 발명의 방법의 우수성을 보여준다.

[0210] 이상 본 발명을 구체적인 실시예를 통하여 상세하게 설명하였으나, 이는 본 발명을 구체적으로 설명하기 위한 것으로, 본 발명은 이에 한정되지 않으며, 본 발명의 기술적 사상 내에서 당 분야의 통상의 지식을 가진 자에 의해 그 변형이나 개량이 가능함은 명백하다고 할 것이다.

[0211] 본 발명의 단순한 변형 내지 변경은 모두 본 발명의 영역에 속하는 것으로, 본 발명의 구체적인 보호 범위는 첨부된 청구범위에 의하여 명확해질 것이다.

부호의 설명

[0212] 200 : 딥러닝에 기반한 원격 감지를 위한 실시간 이미지 융합 장치

202 : 얕은 특징 추출부 204 : 정보 풀

206 : 멀티 스케일 특징 추출 네트워크 208 : 멀티 스케일 특징 융합부

210 : 재구성부

212 : 업샘플링된 저해상도 멀티 스펙트럼 이미지

214, 216, 220, 230, 234, 238 : 컨벌루션 레이어

218 : 연결부

222 : 제1 멀티 스케일 특징 추출 서브 네트워크

224 : 제2 멀티 스케일 특징 추출 서브 네트워크

226 : 멀티 스케일 특징 융합부 228 : 잔여 블록

232, 240 : 가산기 236 : ReLU

300 : 인코더 302 : 디코더

304, 306, 308, 330, 336, 342 : 컨벌루션 레이어

310, 322 : 스몰 스케일 특징 추출부 312, 316, 320 : 가산기

314, 324 : 미들 스케일 특징 추출부

318, 326 : 라지 스케일 특징 추출부 328, 334, 340 : 잔여 블록

332, 338 : 디컨벌루션 레이어 400 : 스몰 스케일 특징 융합부

402 : 미들 스케일 특징 융합부 404 : 종합 특징 융합부

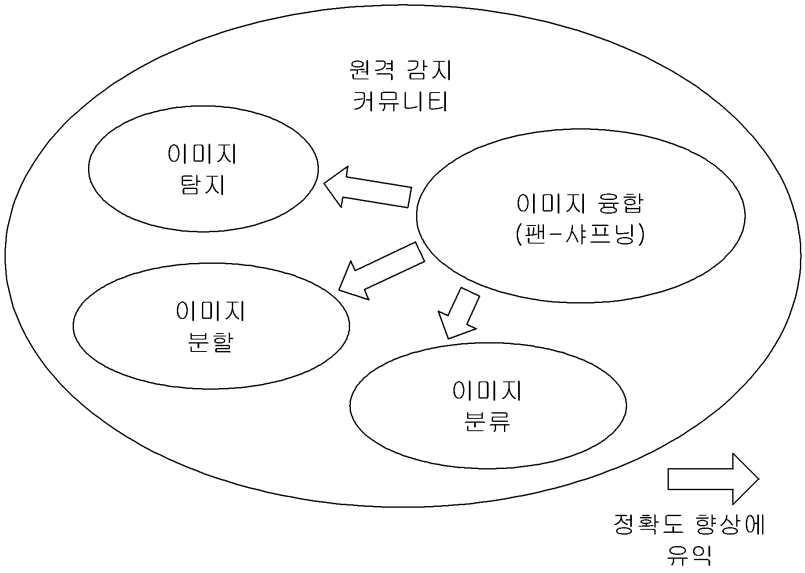
406, 412, 418 : 연결부

408, 414, 420 : 컨벌루션 레이어

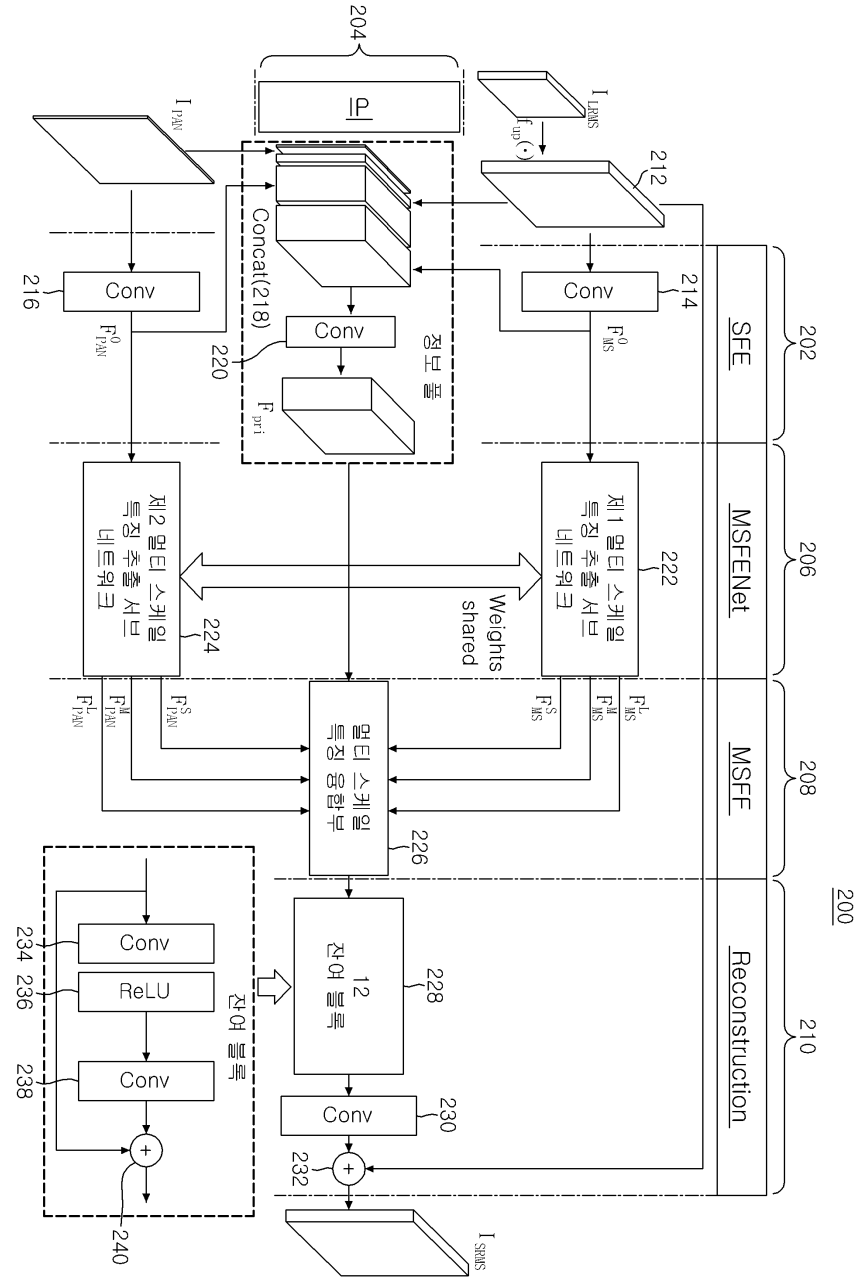
410, 416 : 디컨벌루션 레이어

도면

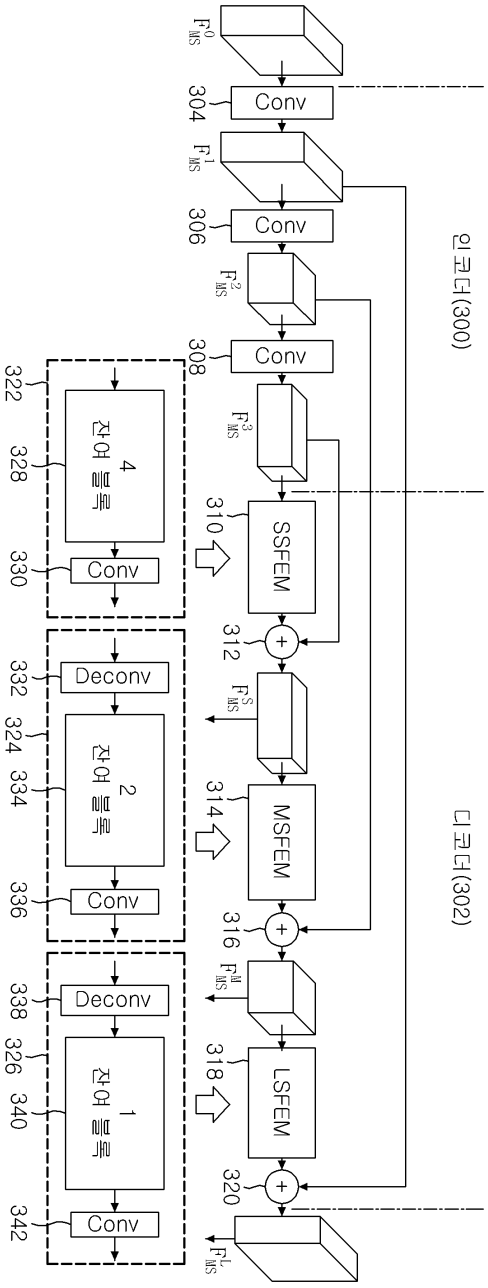
도면1



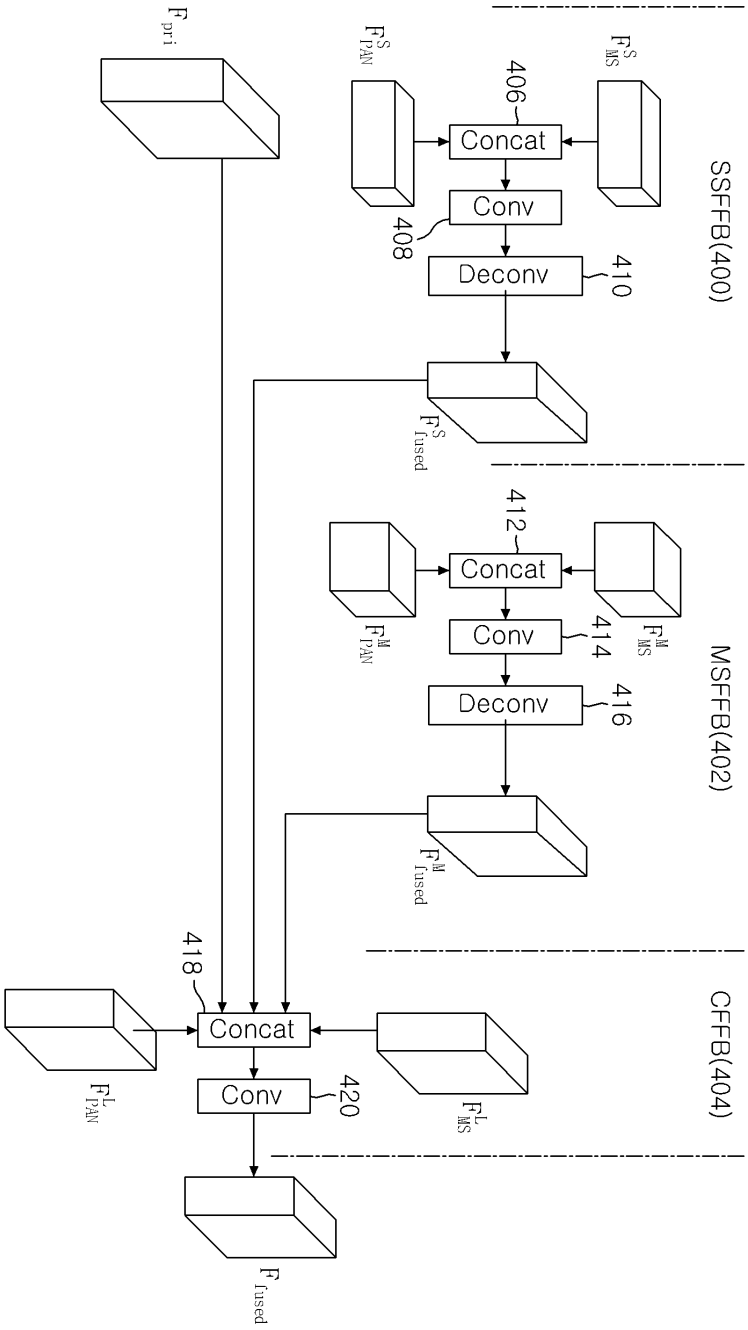
도면2


204
I PAN
I LRMS
f up(·)
212
Concat(218)
Conv
216
Conv
214
Conv
220
정보 풀
F pri
F 0 PAN
F 0 MS
SFE
202
MSFENet
206
제2 멀티 스케일 특징 추출 서브 네트워크
224
Weights shared
제1 멀티 스케일 특징 추출 서브 네트워크
222
F L PAN
F M PAN
F S PAN
F S MS
F M MS
F L MS
멀티 스케일 특징 융합부
226
MSFF
208
200
Conv
ReLU
Conv
234
236
238
잔여 블록
12 잔여 블록
228
Conv
230
232
240
I SRMS
Reconstruction
210

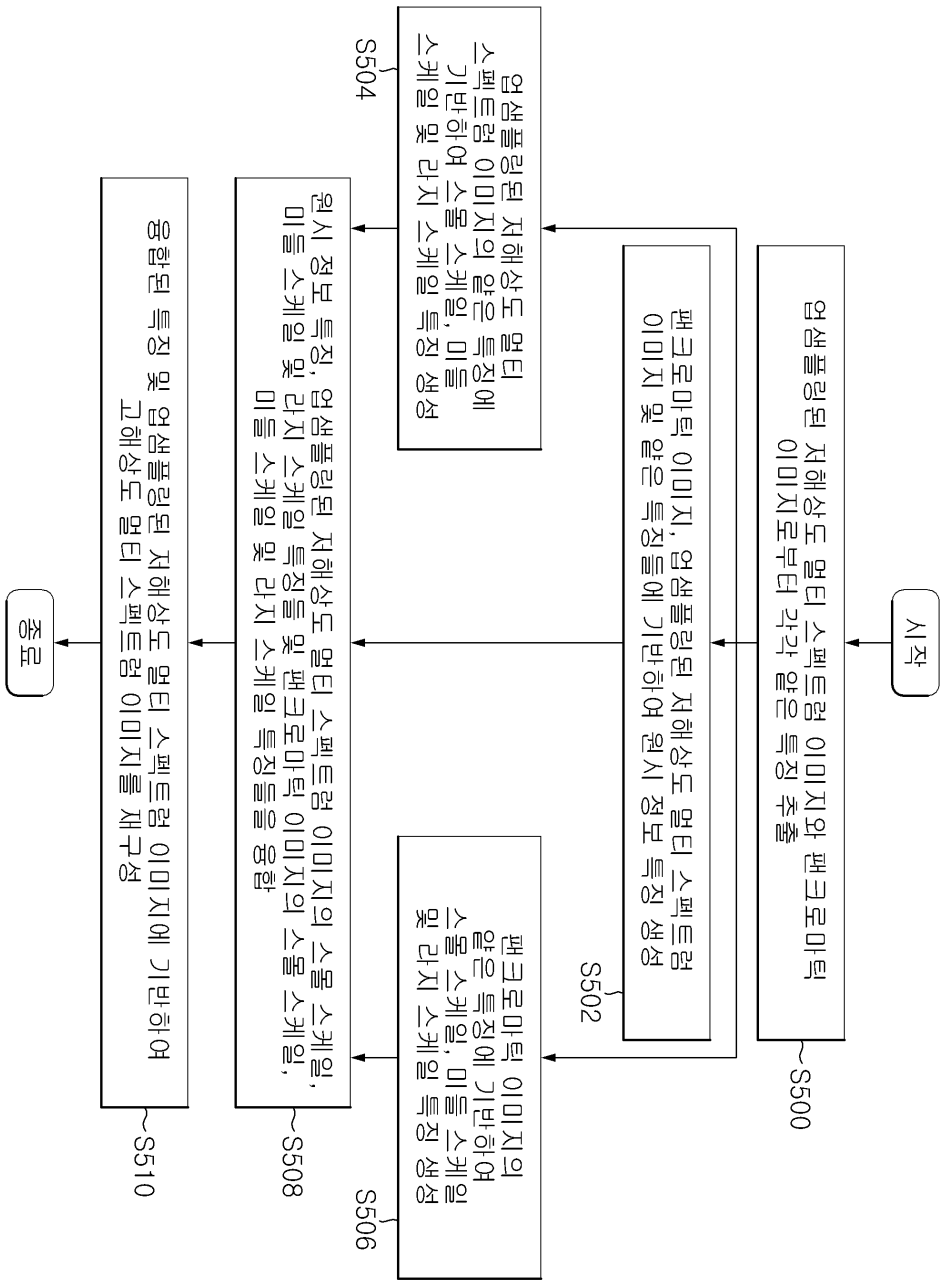
도면3


인코더(300)
디코더(302)
Conv
304
306
308
SSFEM
310
312
MSFEM
314
316
LSFEM
318
320
Deconv
322
4 잔여 블록
328
330
Deconv
332
324
2 잔여 블록
334
336
Deconv
338
326
1 잔여 블록
340
342

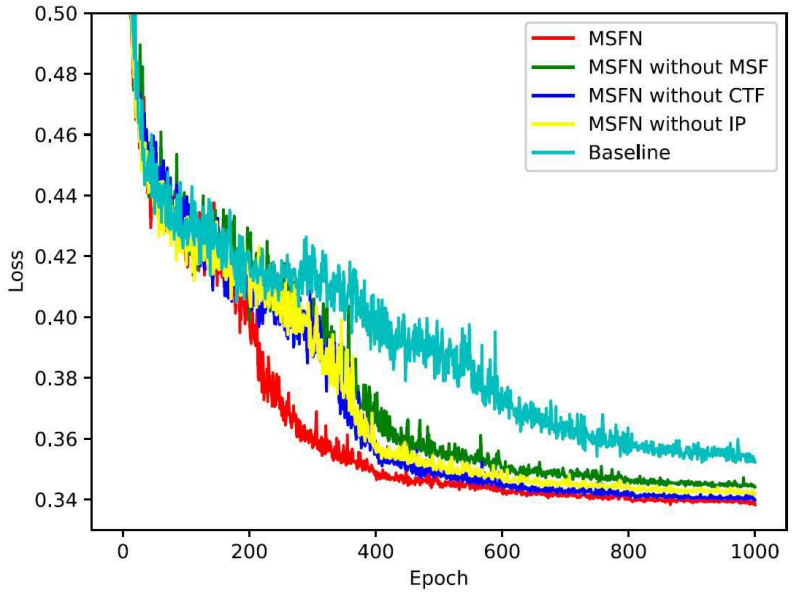
도면4


F pri
F S PAN
F S MS
406
Concat
Conv
408
Deconv
410
SSFFB(400)
F S fused
412
Concat
F M PAN
F M MS
414
Conv
Deconv
416
MSFFB(402)
F M fused
418
Concat
F L PAN
F L MS
Conv
420
CFFB(404)
F fused

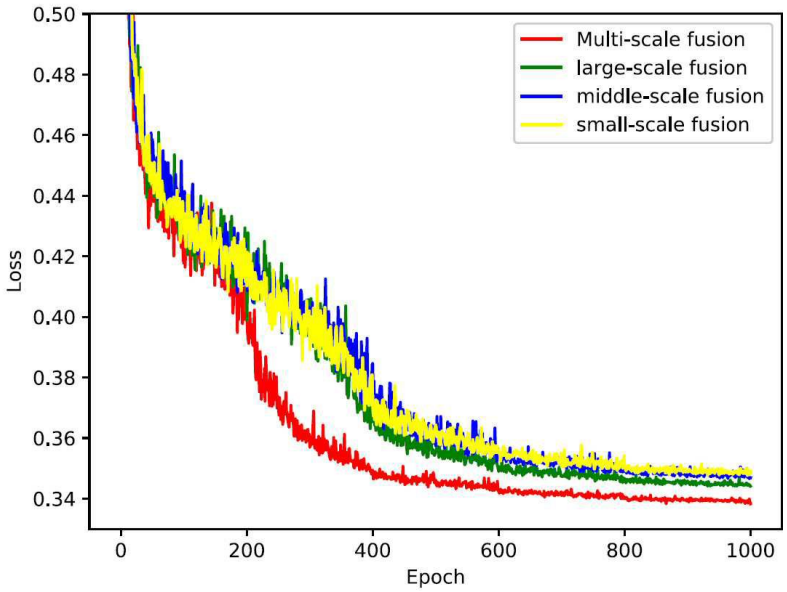
도면5


시작
업샘플링된 저해상도 멀티 스펙트럼 이미지와 팬크로마틱 이미지로부터 각각 얕은 특징 추출
S500
팬크로마틱 이미지, 업샘플링된 저해상도 멀티 스펙트럼 이미지 및 얕은 특징들에 기반하여 원시 정보 특징 생성
S502
업샘플링된 저해상도 멀티 스펙트럼 이미지의 얕은 특징에 기반하여 스몰 스케일, 미들 스케일 및 라지 스케일 특징 생성
S504
팬크로마틱 이미지의 얕은 특징에 기반하여 스몰 스케일, 미들 스케일 및 라지 스케일 특징 생성
S506
원시 정보 특징, 업샘플링된 저해상도 멀티 스펙트럼 이미지의 스몰 스케일, 미들 스케일 및 라지 스케일 특징들 및 팬크로마틱 이미지의 스몰 스케일, 미들 스케일 및 라지 스케일 특징들을 융합
S508
융합된 특징 및 업샘플링된 저해상도 멀티 스펙트럼 이미지에 기반하여 고해상도 멀티 스펙트럼 이미지를 재구성
S510
종료

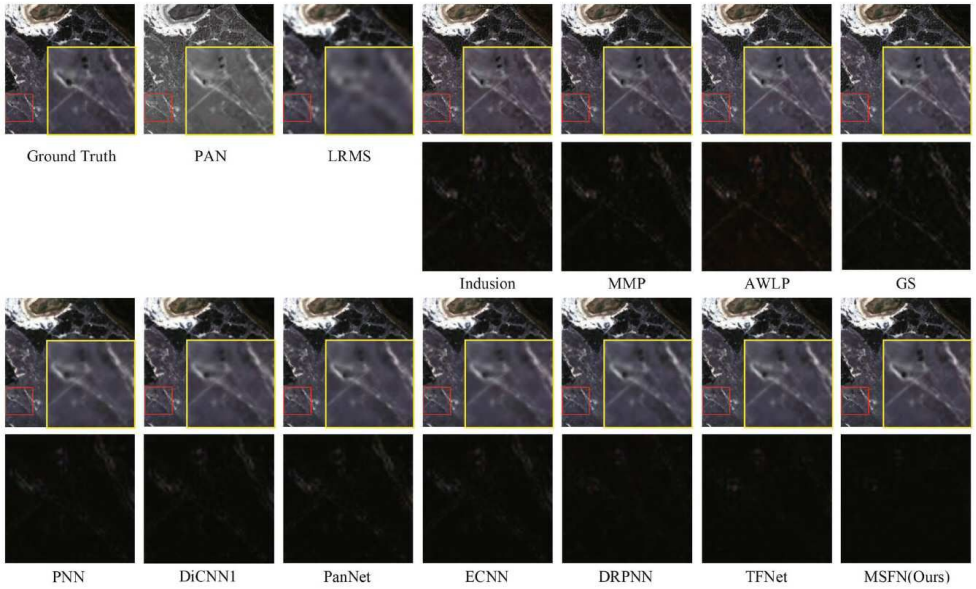
도면6a


MSFN
MSFN without MSF
MSFN without CTF
MSFN without IP
Baseline
Loss
Epoch
0.50
0.48
0.46
0.44
0.42
0.40
0.38
0.36
0.34
0
200
400
600
800
1000

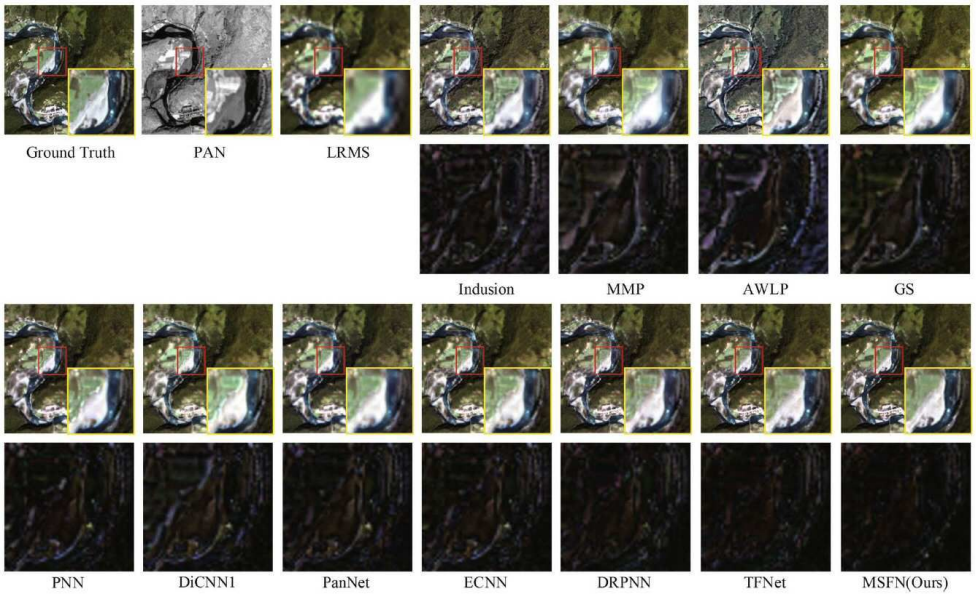
도면6b


Multi-scale fusion
large-scale fusion
middle-scale fusion
small-scale fusion
Loss
Epoch
0.50
0.48
0.46
0.44
0.42
0.40
0.38
0.36
0.34
0
200
400
600
800
1000

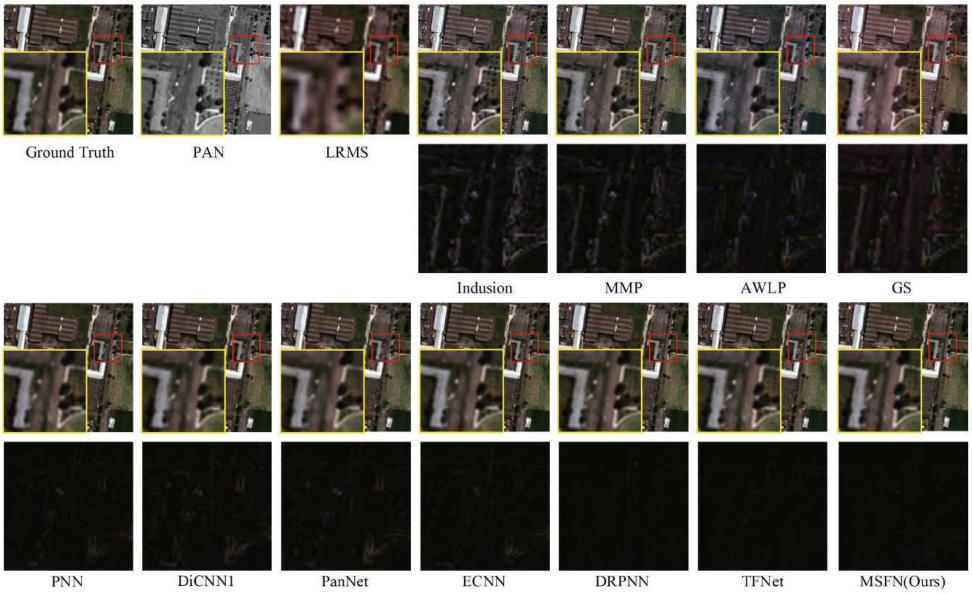
도면7


Ground Truth
PAN
LRMS
Indusion
MMP
AWLP
GS
PNN
DiCNN1
PanNet
ECNN
DRPNN
TFNet
MSFN(Ours)

도면8


Ground Truth
PAN
LRMS
Indusion
MMP
AWLP
GS
PNN
DiCNN1
PanNet
ECNN
DRPNN
TFNet
MSFN(Ours)

도면9


Ground Truth
PAN
LRMS
Indusion
MMP
AWLP
GS
PNN
DiCNN1
PanNet
ECNN
DRPNN
TFNet
MSFN(Ours)