



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2022-0005846
(43) 공개일자 2022년01월14일

(51) 국제특허분류(Int. Cl.)
G06T 3/40 (2006.01) G06N 3/04 (2006.01)
G06N 3/08 (2006.01)
(52) CPC특허분류
G06T 3/4053 (2013.01)
G06N 3/04 (2013.01)
(21) 출원번호 10-2020-0083513
(22) 출원일자 2020년07월07일
심사청구일자 2020년07월07일

(71) 출원인
인천대학교 산학협력단
인천광역시 연수구 아카데미로 119 (송도동)
(72) 발명자
전광길
인천광역시 연수구 해송로 70, 209동 805호(송도동, 송도웹카운티2단지)
(74) 대리인
특허법인충정


전체 청구항 수 : 총 9 항

(54) 발명의 명칭 인공지능을 이용한 영상 확대 및 해상도 향상 장치 및 방법

(57) 요약

다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치 및 방법은 이전 시간 단계에서 피드백 연결되어 수신된 이미지의 하이 레벨 특징을 이용하여 이미지의 로우 레벨 특징을 정제하고, 정제된 로우 레벨 특징을 학습하여 하이 레벨 특징을 개선하며, 이에 따라 초고해상도 이미지를 재구성함으로써 저해상도 이미지의 손상을 회복하여 초고해상도 이미지의 해상도를 향상할 수 있는 효과가 있다.

대표도



(52) CPC특허분류

G06N 3/08 (2013.01)

G06T 3/4046 (2013.01)

G06T 2207/20084 (2013.01)

명세서

청구범위

청구항 1

각 시간 단계마다 원본 저해상도 이미지를 초고해상도 이미지로 재구성하는 게이트 피드백 모듈(Multiple Gated Feedback Module, GFM)과, 잔여 밀도 블록(Residual Dense Block, RDB)으로 서로 번갈아 가면서 순차적으로 연결하는 게이트 다중 피드백 네트워크이고,

상기 각각의 GFM은 이전 시간 단계에서 상기 각각의 RDB의 출력을 피드백 연결되어 복수의 하이 레벨 특징을 수신하고, 상기 하이 레벨 특징을 이용하여 입력되는 입력 이미지의 로우 레벨 특징을 정제하고, 상기 각각의 RDB은 상기 GFM으로부터 상기 정제된 로우 레벨 특징을 입력받아 계층적 특징을 학습하여 하이 레벨 특징을 출력하는 것을 특징으로 하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치.

청구항 2

제1항에 있어서,

상기 최초의 GFM은 입력 이미지에 대하여 하나 이상의 컨볼루션 레이어를 적용하여 로우 레벨 특징($F_{L,0}^t$)을 추출하는 로우 레벨 특징 추출 블록의 출력단에 연결되는 것을 특징으로 하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치.

청구항 3

제1항에 있어서,

상기 마지막의 RDB의 출력인 하이 레벨 특징($F_{L,B}^t$)을 입력받아 디컨볼루션 레이어(Deconvolutional Layer)와 컨볼루션 레이어(Convolutional Layer)를 통과한 제1 이미지와, 보관된 저해상도 이미지(I_{LR})를 결합하여 초고해상도 이미지 I_{SR}^t 를 재구성하여 출력하는 재구성 블록에 연결되는 것을 특징으로 하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치.

청구항 4

제1항에 있어서,

상기 각각의 GFM은 이전 시간 단계에서 상기 각각의 RDB의 출력을 피드백 연결되어 복수의 하이 레벨 특징을 수신하고, 상기 수신한 복수의 하이 레벨 특징으로부터 하이 레벨 정보를 적응적으로 선택하는 게이트 유닛; 및
상기 각각의 RDB로부터 하이 레벨 특징을 입력받고, 상기 하이 레벨 특징을 이용하여 입력되는 입력 이미지의 로우 레벨 특징을 정제하고, 상기 정제된 로우 레벨 특징을 상기 RDB로 전송하는 리파인먼트 유닛을 포함하는 것을 특징으로 하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치.

청구항 5

제3항에 있어서,

초기 시간 단계에서는 상기 최초의 GFM에 연결되어 입력 이미지에 대하여 하나 이상의 컨볼루션 레이어를 적용하여 로우 레벨 특징($F_{L,0}^t$)을 추출하는 로우 레벨 특징 추출 블록과, 순차적으로 복수개 연결된 각각의 RDB와, 상기 재구성 블록으로 이루어져 있고,

상기 초기 시간 단계 이후의 t시간 단계에서는 상기 로우 레벨 특징 추출 블록, 서로 번갈아 가면서 순차적으로 연결하는 상기 GFM과 상기 RDB, 상기 재구성 블록으로 이루어져 있는 것을 특징으로 하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치.

청구항 6

t시간 단계와 T시간 단계마다 원본 저해상도 이미지를 초고해상도 이미지로 재구성하는 게이트 피드백 모듈(Multiple Gated Feedback Module, GFM)과, 잔여 밀도 블록(Residual Dense Block, RDB)으로 서로 번갈아 가면서 순차적으로 연결하는 게이트 다중 피드백 네트워크이고,

t시간 단계에서, 이전 시간 단계의 각각의 제1 RDB의 출력을 피드백 연결된 제1 GFM은 상기 복수의 제1 하이 레벨 특징을 수신하고, 상기 제1 하이 레벨 특징을 이용하여 입력되는 제1 입력 이미지의 제1 로우 레벨 특징을 정제하는 단계;

제1 RDB는 상기 정제된 제1 로우 레벨 특징을 입력받아 계층적 특징을 학습하여 제1 하이 레벨 특징을 출력하는 단계; 및

상기 제1 하이 레벨 특징을 디컨볼루션 레이어(Deconvolutional Layer)와 컨볼루션 레이어(Convolutional Layer)를 통과한 제1 이미지와, 보간된 저해상도 이미지(I_{LR})를 결합하여 제1 초고해상도 이미지 I_{SR}^t 를 재구성하여 출력하는 단계를 포함하는 것을 특징으로 하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 방법.

청구항 7

제6항에 있어서,

T시간 단계에서, 상기 t시간 단계의 각각의 제2 RDB의 출력을 피드백 연결된 제2 GFM은 복수의 제2 하이 레벨 특징을 수신하고, 상기 제2 하이 레벨 특징을 이용하여 입력되는 제2 입력 이미지의 제2 로우 레벨 특징을 정제하는 단계;

제2 RDB는 상기 정제된 제2 로우 레벨 특징을 입력받아 계층적 특징을 학습하여 제2 하이 레벨 특징을 출력하는 단계; 및

상기 제2 하이 레벨 특징을 디컨볼루션 레이어(Deconvolutional Layer)와 컨볼루션 레이어(Convolutional Layer)를 통과한 제2 이미지와, 보간된 저해상도 이미지(I_{LR})를 결합하여 제2 초고해상도 이미지 I_{SR}^t 를 재구성하여 출력하는 단계를 포함하는 것을 특징으로 하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 방법.

청구항 8

제6항에 있어서,

상기 제1 로우 레벨 특징을 정제하는 단계는,

상기 최초의 제1 GFM은 입력 이미지에 대하여 하나 이상의 컨볼루션 레이어를 적용하여 로우 레벨 특징($F_{L,0}^t$)을 입력받는 단계를 포함하는 것을 특징으로 하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 방법.

청구항 9

제7항에 있어서,

상기 제2 로우 레벨 특징을 정제하는 단계는,

상기 최초의 제2 GFM은 입력 이미지에 대하여 하나 이상의 컨볼루션 레이어를 적용하여 로우 레벨 특징($F_{L,0}^t$)을 입력받는 단계를 포함하는 것을 특징으로 하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 방법.

발명의 설명

기술 분야

본 발명은 영상 확대 및 해상도 향상 장치에 관한 것으로서, 더욱 상세하게는 이전 시간 단계에서 피드백 연결

되어 수신된 이미지의 하이 레벨 특징을 이용하여 이미지의 로우 레벨 특징을 정제하고, 정제된 로우 레벨 특징을 학습하여 하이 레벨 특징을 개선하며, 이에 따라 초고해상도 이미지를 재구성하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치 및 방법에 관한 것이다.

배경 기술

- [0002] 최근 SR(Super Resolution)의 진보는 더 나은 재구성 성능을 달성하기 위해서 딥 러닝의 힘을 탐구했다. 그러나 인간 시각 시스템에 일반적으로 존재하는 피드백 메커니즘은 기존의 딥 러닝 기반 이미지 SR 방법에서 완전히 활용되지 않고 있다.
- [0003] SR(Super Resolution)은 저해상도(LR) 이미지에서 고해상도(HR) 이미지를 재구성하는 것을 목표로 하는 저수준 컴퓨터 비전 작업이다.
- [0004] SR은 여러 개의 HR 이미지가 동일한 LR 이미지를 생성 할 수 있기 때문에 여러 문제가 발생할 수 있는데, 이러한 문제를 해결하기 위해서 보간 기반 방법, 재구성 기반 방법 및 학습 기반 방법을 포함한 수많은 이미지 SR 방법이 제안되었다.
- [0005] SR에 적용되는 딥 러닝은 이미지 SR을 포함한 다양한 컴퓨터 비전 작업에서 탁월한 성능을 보여주었고, 네트워크가 깊어질 때마다 최적화의 어려움을 극복하기 위해서 스킵 연결(Skip Connection)이 사용되었다.
- [0006] 최근 연구에 따르면, 이미지 SR을 현저하게 개선하기 위해 다양한 종류의 스킵 연결을 채택한다. 이러한 네트워크 아키텍처의 건너 뛰기 연결은 상향식으로 계층 구조 기능을 사용하거나 결합한다. 따라서, 하위 레벨 기능은 작은 수용 필드의 제한으로 인해 충분한 컨텍스트 정보가 없는 이전 계층의 정보만 수신할 수 있다.
- [0007] 이러한 하위 수준 기능은 다음 계층에서 재사용되므로 네트워크의 재구성 능력을 더욱 제한하는 문제점을 발생한다.
- [0008] 그러나 이러한 종래의 SR에 적용된 방법들은 연결 건너 뛰기를 통해 신경망이 더 깊어지고, 이에 따라 매개 변수가 더 증가하며, 대용량 네트워크의 경우, 거대한 스토리지 리소스를 차지하여 오버피팅(Overfitting) 문제로 어려움을 겪게 된다.

선행기술문헌

특허문헌

- [0009] (특허문헌 0001) 한국 공개특허번호 제10-2019-0039958호

발명의 내용

해결하려는 과제

- [0010] 이와 같은 문제점을 해결하기 위하여, 본 발명은 이전 시간 단계에서 피드백 연결되어 수신된 이미지의 하이 레벨 특징을 이용하여 이미지의 로우 레벨 특징을 정제하고, 정제된 로우 레벨 특징을 학습하여 하이 레벨 특징을 개선하며, 이에 따라 초고해상도 이미지를 재구성하는 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치 및 방법을 제공하는데 그 목적이 있다.

과제의 해결 수단

- [0011] 상기 목적을 달성하기 위한 본 발명의 특징에 따른 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치는,
- [0012] 각 시간 단계마다 원본 저해상도 이미지를 초고해상도 이미지로 재구성하는 게이트 피드백 모듈(Multiple Gated Feedback Module, GFM)과, 잔여 밀도 블록(Residual Dense Block, RDB)으로 서로 번갈아 가면서 순차적으로 연결하는 게이트 다중 피드백 네트워크이고,
- [0013] 상기 각각의 GFM은 이전 시간 단계에서 상기 각각의 RDB의 출력을 피드백 연결되어 복수의 하이 레벨 특징을 수신하고, 상기 하이 레벨 특징을 이용하여 입력되는 입력 이미지의 로우 레벨 특징을 정제하고, 상기 각각의 RDB은 상기 GFM으로부터 상기 정제된 로우 레벨 특징을 입력받아 계층적 특징을 학습하여 하이 레벨 특징을 출력하

는 것을 특징으로 한다.

- [0015] 본 발명의 특징에 따른 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 방법은,
- [0016] t 시간 단계와 T 시간 단계마다 원본 저해상도 이미지를 초고해상도 이미지로 재구성하는 게이트 피드백 모듈(Multiple Gated Feedback Module, GFM)과, 잔여 밀도 블록(Residual Dense Block, RDB)으로 서로 번갈아 가면서 순차적으로 연결하는 게이트 다중 피드백 네트워크이고,
- [0017] t 시간 단계에서, 이전 시간 단계의 각각의 제1 RDB의 출력을 피드백 연결된 제1 GFM은 상기 복수의 제1 하이 레벨 특징을 수신하고, 상기 제1 하이 레벨 특징을 이용하여 입력되는 제1 입력 이미지의 제1 로우 레벨 특징을 정제하는 단계;
- [0018] 제1 RDB는 상기 정제된 제1 로우 레벨 특징을 입력받아 계층적 특징을 학습하여 제1 하이 레벨 특징을 출력하는 단계; 및
- [0019] 상기 제1 하이 레벨 특징을 디컨볼루션 레이어(Deconvolutional Layer)와 컨볼루션 레이어(Convolutional Layer)를 통과한 제1 이미지와, 보간된 저해상도 이미지(I_{LR})를 결합하여 제1 초고해상도 이미지 I_{SR}^t 를 재구성하여 출력하는 단계를 포함하는 것을 특징으로 한다.

발명의 효과

- [0020] 전술한 구성에 의하여, 본 발명은 저해상도 이미지의 정제하여 저해상도 이미지의 손상을 회복하며, 이에 따라 초고해상도 이미지의 해상도를 향상할 수 있는 효과가 있다.

도면의 간단한 설명

- [0021] 도 1은 본 발명의 실시예에 따른 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치의 구성을 나타낸 도면이다.
- 도 2는 본 발명의 실시예에 따른 게이트 피드백 모듈의 내부 구성을 간략하게 나타낸 도면이다.
- 도 3은 본 발명의 실시예에 따른 잔여 밀도 블록의 내부 구성을 간략하게 나타낸 도면이다.
- 도 4는 본 발명의 실시예에 따른 재구성 블록의 내부 구성을 간략하게 나타낸 도면이다.

발명을 실시하기 위한 구체적인 내용

- [0022] 명세서 전체에서, 어떤 부분이 어떤 구성요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있는 것을 의미한다.
- [0023] 피드백 시스템은 반복적인 방식으로 출력을 입력으로 전파하는 것이다.
- [0024] 본 발명의 게이트 다중 피드백 네트워크(Gated Multiple Feedback Network for Image SR)는 언롤링(Unrolling) T 시간 단계의 컨볼루션 반복 신경망 네트워크로 설계되고, 각 시간 단계에서 서브 네트워크는 독립적인 컨볼루션 신경망으로 간주되어 원본 LR 이미지를 SR(Super Resolution) 이미지로 재구성하는 것을 목적으로 한다.
- [0025] 본 발명은 정교하게 설계된 게이트 피드백 모듈에서 하이 레벨 특징 중 중복 정보를 제거하고, 선택한 하이 레벨 정보로 로우 레벨 특징을 정제할 수 있다.
- [0026] 도 1은 본 발명의 실시예에 따른 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치의 구성을 나타낸 도면이고, 도 2는 본 발명의 실시예에 따른 게이트 피드백 모듈의 내부 구성을 간략하게 나타낸 도면이고, 도 3은 본 발명의 실시예에 따른 잔여 밀도 블록의 내부 구성을 간략하게 나타낸 도면이며, 도 4는 본 발명의 실시예에 따른 재구성 블록의 내부 구성을 간략하게 나타낸 도면이다.
- [0027] 도 1에 도시된 바와 같이, 다중 피드백 네트워크를 이용한 영상 확대 및 해상도 향상 장치(100)는 주로 4개의 부분으로 구성되고, 4개의 부분은 로우 레벨 특징 추출 블록(110), 게이트 피드백 모듈(Multiple Gated Feedback Module, GFM)(120), 잔여 밀도 블록(Residual Dense Blocks, RDB)(130) 및 재구성 블록(Reconstruction Block, RB)(140)을 포함한다.

- [0028] 이러한 4 부분의 매개 변수는 시간이 지남에 따라 공유된다. 인접한 시간 단계에서 서브 네트워크 사이의 통신은 다수의 피드백 연결 그룹에 의해 달성된다.
- [0029] 초기 시간 단계, t 시간 단계, T 시간 단계마다 확대 및 해상도 향상 장치(100)가 각각 구성된다.
- [0030] 초기 시간 단계에서는 로우 레벨 특징 추출 블록(110)과, 잔여 밀도 블록(130)가 순차적으로 복수개 연결하고, 재구성 블록(140)으로 이루어져 있다.
- [0031] t 시간 단계에서는 로우 레벨 특징 추출 블록(110)과, 게이트 피드백 모듈(120) 및 잔여 밀도 블록(130)으로 서로 번갈아 가면서 순차적으로 연결하며, 재구성 블록(140)으로 이루어져 있다.
- [0032] T 시간 단계에서는 로우 레벨 특징 추출 블록(110)과, 게이트 피드백 모듈(120) 및 잔여 밀도 블록(130)으로 서로 번갈아 가면서 순차적으로 연결하며, 재구성 블록(140)으로 이루어져 있다.
- [0033] 본 발명은 각 시간 단계마다 원본 저해상도 이미지를 초고해상도 이미지로 재구성하며, 각 시간 단계마다 초고해상도 이미지의 화질이 점차 개선된다.

- [0035] 각각의 GFM(120)은 이전 시간 단계에서 각각의 RDB(130)의 출력을 피드백 연결되어 복수의 하이 레벨 특징을 수신하고, 하이 레벨 특징을 이용하여 입력되는 입력 이미지의 로우 레벨 특징을 정제한다.
- [0036] t 번째 시간 단계에서 게이트 다중 피드백 네트워크(GMFN)의 입력 이미지로서 I_{LR} 이 주어지면, 로우 레벨 특징 추출 블록(110)은 초기 로우 레벨 특징($F_{L,0}^t$)을 추출하기 위해서 2개의 컨볼루션 레이어를 적용한다. 제1 레이어와 제2 레이어는 3×3 크기와 1×1 크기의 컨볼루션 커널들을 각각 보유한다. 초기 로우 레벨 특징($F_{L,0}^t$)은 하기의 수학식 1에 의해 추출된다.

수학식 1

[0037]
$$F_{L,0}^t = H_{LFEB}(I_{LR})$$

- [0038] 여기서, $H_{LFEB}(\cdot)$ 는 초기 로우 레벨 특징 추출 블록의 함수를 나타낸다.

- [0039] 이후에, 추출된 초기 로우 레벨 특징($F_{L,0}^t$)은 복수의 잔여 밀도 블록(RDBs)에 공급되어 계층적 특징을 학습한다.

- [0040] 더 많은 다중 잔여 밀도 블록(RDB)(130)을 쌓으면 서브 네트워크에서 보다 다양한 수준의 수용 필드를 제공하여 추출된 특징의 더 나은 계층 구조를 형성한다.

- [0041] 이러한 풍부한 계층적 특징은 로우 레벨 특징을 개선하는데 도움이 된다. 각 개량된 프로세스는 하나의 피드백 연결 그룹이 있는 하나의 RDB(130) 앞에 배치된 GFM(120)에 의해 수행된다.

- [0042] 잔여 밀도 블록(130)은 각 시간 단계에서 B RDB(130)를 순차적으로 연결되면, LR 공간에서의 최종 하이 레벨 특징($F_{L,B}^t$)은 하기의 수학식 2에 의해 얻어질 수 있다.

수학식 2

[0043]
$$F_{L,B}^t = H_{GFM-RDB}(F_{L,0}^t)$$

- [0044] 여기서, $H_{GFM-RDB}(\cdot)$ 은 B RDB와 M GFM의 연산을 결합한 함수를 나타낸다. 특히, 이전 시간 단계에서

제공한 높은 수준의 정보가 없기 때문에 첫 번째 단계에서 RDB 앞에 GFM가 없다(도 1 참조).

[0045] 각각의 RDB(130)는 복수의 컨볼루션 레이어를 구성하여 정제된 로우 레벨 특징을 입력받아 계층적 특징을 학습하여 하이 레벨 특징을 출력한다.

[0046] 재구성 블록(140)은 마지막의 RDB(130)의 출력인 하이 레벨 특징($F_{L,B}^t$)을 입력받아 디컨볼루션 레이어(Deconvolutional Layer)와 컨볼루션 레이어(Convolutional Layer)를 통과한 제1 이미지와, 보간된 저해상도 이미지(I_{LR})를 결합하여 초고해상도 이미지 I_{SR}^t 를 재구성하여 출력한다.

[0047] 재구성 블록(140)에서 추출된 하이 레벨 특징($F_{L,B}^t$)은 디컨볼루션 레이어(Deconvolutional Layer)에 의해 업스케일된다.

[0048] 그런 다음 3×3 크기의 컨볼루션 레이어는 업스케일된 특징을 사용하여 잔여 이미지(Residual Image)를 복구한다.

[0049] 마지막으로, 복구된 잔여 이미지는 보간된 LR 이미지와 결합되어 t번째 시간 단계에서 SR 이미지인 I_{SR}^t 를 재구성한다. 재구성 블록(140)의 수학적 공식은 다음의 수학적 식 3과 같이 표현될 수 있다.

수학적 식 3

$$I_{SR}^t = H_{RB}(F_{L,B}^t, I_{LR}) = H_{UF}(F_{L,B}^t) + H_{\uparrow}(I_{LR})$$

[0051] 여기서, $H_{RB}(\cdot)$, $H_{UF}(\cdot)$ and $H_{\uparrow}(\cdot)$ 는 각각 재구성 블록, 디컨볼루션 레이어 및 컨볼루션 레이어, 보간된 커널의 함수를 각각 나타낸다.

[0052] 본 발명에서 제안된 GMFN에서 T 시간 단계가 전개되면, T SR 이미지를 완전히 획득한다.

[0053] 마찬가지로 각 서브 네트워크의 재구성 대상으로 T HR 이미지가 있다. 본 발명은 GMFN을 최적화하기 위해서 L1 손실 함수를 채택한다.

[0054] 손실 기능은 다음의 수학적 식 4와 같이 공식화 할 수 있다.

수학적 식 4

$$\mathcal{L}(\Theta) = \frac{1}{T} \sum_{t=1}^T \|I_{HR}^t - I_{SR}^t\|_1$$

[0056] 여기서, Θ 는 GMFN의 파라미터 세트, I_{HR}^t 는 t번째 시간 단계에서 타겟 HR 이미지를 나타낸다.

[0058] 각각의 게이트 피드백 모듈(Gated Feedback Module, GFM)(120)은 이전 시간 단계로부터 새로운 루트로 보내진 복수의 하이 레벨 특징들을 이용하여 얇은 레이어들로부터 추출된 로우 레벨 특징을 정제하는데 사용된다.

[0059] 도 2에 도시된 바와 같이, 하나의 게이트 피드백 모듈(120)은 게이트 유닛(Gate Unit)(121) 및 리파인먼트 유닛(Refinement Unit)(122)으로 구성된다.

[0060] 게이트 유닛(121)은 복수의 하이 레벨 특징들로부터 유용한 하이 레벨 정보를 적응적으로 선택한다.

[0061] 게이트 유닛(121)은 이전 시간 단계에서 각각의 RDB(130)의 출력을 피드백 연결되어 복수의 하이 레벨 특징을

수신하고, 수신한 복수의 하이 레벨 특징로부터 하이 레벨 정보를 적응적으로 선택한다.

[0062] 리파인먼트 유닛(122)은 게이트 유닛(122)에서 선택된 하이 레벨 정보를 사용하여 로우 레벨 특징들을 정제하고, 정제된 로우 레벨 특징을 RDB(130)로 전송한다.

[0063] 리파인먼트 유닛(122)은 각각의 RDB(130)로부터 하이 레벨 특징을 입력받고, 하이 레벨 특징을 이용하여 입력되는 입력 이미지의 로우 레벨 특징을 정제하고, 정제된 로우 레벨 특징을 RDB(130)로 전송한다.

[0065] GFM(120)의 배치는 정제할 특징들의 수준에 따라 결정된다. 다중 캐스케이드(Cascaded)된 RDBs 간의 상대적 계층 관계에 따르면, 로우 레벨 특징을 정제할 필요가 있을 때, 다중 얕은(Shallow) RDB(130)의 입력을 선택하고, 새로운 루트로 보내지는 하이 레벨 특징들로서 다중 딥(Deep) RDBs의 출력을 선택한다.

[0066] 가장 깊은 RDBs는 LR 공간에서 가장 대표적인 정보를 추출할 수 있기 때문에 초기 로우 레벨 특징의 개선 프로세스를 용이하게 한다. 본 발명은 복수의 그룹의 피드백 연결을 사용하여 가장 깊은 RDBs로부터 가장 얕은 RDBs까지 다중 하이 레벨 특징을 전달한다. 각 피드백 연결 그룹은 하나의 GFM(120)에 의해 처리된다.

[0067] $\mathbf{S}_M = \{1, 2, \dots, M-1, M\}$ 는 가장 얕은 M RDB의 선택된 인덱스 세트에 설정되고, 이의 입력은 로우 레벨 특징들로 간주된다.

[0068] $\mathbf{D}_N = \{N, N+1, \dots, B-1, B\}$ 는 가장 깊은 B - N + 1 RDBs의 선택된 인덱스 세트에 사용된다.

[0069] t번째 시간 단계에서, b번째 RDB $F_{L,b}^t$ 의 출력은 하기의 수학식 5를 통해 얻을 수 있다.

수학식 5

$$F_{L,b}^t = \begin{cases} H_{RDB,b} \left(H_{RU,b} \left(\left[F_{H,b}^t, F_{L,b-1}^t \right] \right) \right), & \text{if } b \in \mathbf{S}_M \text{ and } t > 1 \\ H_{RDB,b} \left(F_{L,b-1}^t \right), & \text{otherwise,} \end{cases}$$

[0071] 여기서, $H_{RDB,b}(\cdot)$ and $H_{RU,b}(\cdot)$ 는 각각 b번째 GFM에서 b번째 RDB 및 리파인먼트 유닛의 함수들을 나타낸다.

[0072] $\left[F_{H,b}^t, F_{L,b-1}^t \right]$ 는 $F_{H,b}^t$ and $F_{L,b-1}^t$ 의 연결을 나타낸다.

[0073] $F_{H,b}^t$ 는 b번째 GFM으로 전달되는 다중 하이 레벨 특징들로부터 선택된 하이 레벨 정보를 나타낸다.

[0074] 이러한 하이 레벨 특징은 가장 깊은 RDBs로부터 추출되고, 하나의 피드백 연결 그룹에 의해 전달된다. 따라서, 선택된 하이 레벨 정보($F_{H,b}^t$)는 하기의 수학식 6에 의해 획득될 수 있다.

수학식 6

$$F_{H,b}^t = \begin{cases} H_{GU,b} \left(\left[F_{L,N}^{t-1}, \dots, F_{L,B}^{t-1} \right] \right), & \text{if } b < N, \\ H_{GU,b} \left(\left[F_{L,b}^{t-1}, \dots, F_{L,B}^{t-1} \right] \right), & \text{otherwise,} \end{cases}$$

[0075]

[0076] 여기서, $H_{GU,b}(\cdot)$ 는 b 번째 GFM에서 게이트 유닛의 함수를 나타낸다. 다중 캐스케이드(Cascaded)된 RDBs 간의 상대 계층 관계를 기반으로 하고, 수학식 6은 b번째 GFM이 이전 시간 단계로부터 인덱스가 b보다 크거나 같은 RDB의 출력을 수신함을 나타낸다.

[0077] 매개 변수 및 계산 효율을 위해서, 본 발명은 b번째 GFM(120)에서 게이트 유닛(121)과 리파인먼트 유닛(122)으로 두 개의 1×1 크기의 컨볼루션 레이어들을 사용한다.

[0078] 수학식 5와 수학식 6에 따르면, 각 시간 단계(제1 시간 단계를 제외함)에서의 GFM의 수 및 인접한 시간 단계들 사이의 피드백 연결 그룹의 수는 M과 동일하고, 각 그룹의 피드백 연결의 그룹들 수는 N의 값에 의해 결정된다.

[0079] 따라서, 본 발명은 선택된 인덱스 세트들인 SM 및 DN에서의 m 및 n 값을 조정하여 개선해야 하는 로우 레벨 특징들이 얼마나 많은지, 새로운 루트로 보내져야 하는 하이 레벨 특징들이 얼마나 많은지 각각 제어할 수 있다.

[0080] 전술한 피드백 연결들은 피드백 구성에서 특별한 경우이다. 더 상세하게 살펴보면, 본 발명은 $N = B$ 를 쉽게 설정하여 단일 대 단일($M = 1$) 또는 단일 대 다중($M \neq 1$) 피드백 연결을 달성 할 수 있으며, 최상위 레벨 기능을 가장 얇은 RDB로 다시 라우팅한다.

[0081] 그러나 본 발명은 서로 다른 수용 필드에서 캡처된 모든 하이 레벨 정보가 SR 이미지를 재구성하는데 중요하다고 주장한다.

[0082] 본 발명은 $N \neq B$ 를 설정하여 다중 대 단일($M = 1$) 및 다중 대 다중($M \neq 1$) 피드백 방식을 달성한다. 피드백 방식은 하이 레벨 특징들을 활용하여 로우 레벨 특징을 개선한다.

[0083] 이상에서 본 발명의 실시예는 장치 및/또는 방법을 통해서만 구현이 되는 것은 아니며, 본 발명의 실시예의 구성에 대응하는 기능을 실현하기 위한 프로그램, 그 프로그램이 기록된 기록 매체 등을 통해 구현될 수도 있으며, 이러한 구현은 앞서 설명한 실시예의 기재로부터 본 발명이 속하는 기술분야의 전문가라면 쉽게 구현할 수 있는 것이다.

[0084] 이상에서 본 발명의 실시예에 대하여 상세하게 설명하였지만 본 발명의 권리범위는 이에 한정되는 것은 아니고 다음의 청구범위에서 정의하고 있는 본 발명의 기본 개념을 이용한 당업자의 여러 변형 및 개량 형태 또한 본 발명의 권리범위에 속하는 것이다.

부호의 설명

[0085] 100: 영상 확대 및 해상도 향상 장치

110: 로우 레벨 특징 추출 블록

120: 게이트 피드백 모듈

121: 게이트 유닛


122: 리파인먼트 유닛

130: 잔여 밀도 블록


140: 재구성 블록

도면


도면1



도면2



도면3



도면4

