

논문 2011-48SP-1-7

일차원 패치 학습을 이용한 고속 내용 기반 보간 기법

(Fast Content Adaptive Interpolation Algorithm Using One-Dimensional Patch-Based Learning)

강 영 육*, 정 신 철*, 송 병 철**

(Young Uk Kang, Shin-Cheol Jeong, and Byung Cheol Song)

요약

본 논문은 저해상도 입력 영상을 고해상도 영상으로 복원하는 고속 학습기반 보간 기법을 제안한다. 일반적인 학습기반 초고해상도 기법은 여러 종류의 저해상도 영상과 고해상도 영상의 상관성을 통해 고주파 정보를 사전에 학습하고, 합성 단계에서 학습한 정보를 이용해 임의의 저해상도 영상을 고해상도 영상으로 복원한다. 이런 기존 학습기반 초고해상도 기법은 방대한 양의 학습된 정보를 메모리에 저장해야만 하는 단점이 있을 뿐만 아니라, 이차원 블록 단위 경합 과정을 거쳐야 하기 때문에 상당한 연산량이 요구된다. 이러한 문제점을 보완하기 위해 본 논문은 일차원 패치 단위 학습을 통해 학습 정보 저장용 메모리 크기 및 연산량을 크게 줄이는 기법을 제안한다. 실험 결과에 따르면, 제안한 기법은 전통적인 bicubic 보간 기법보다 평균 0.7dB 정도 높은 PSNR을 보이며, SSIM도 평균 0.01 이상 향상되는 결과를 보인다.

Abstract

This paper proposes a fast learning-based interpolation algorithm to up-scale an input low-resolution image into a high-resolution image. In conventional learning-based super-resolution, a certain relationship between low-resolution and high-resolution images is learned from various training images and a specific high frequency synthesis information is derived. And then, an arbitrary low resolution image can be super-resolved using the high frequency synthesis information. However, such super-resolution algorithms require heavy memory space to store huge synthesis information as well as significant computation due to two-dimensional matching process. In order to mitigate this problem, this paper presents one-dimensional patch-based learning and synthesis. So, we can noticeably reduce memory cost and computational complexity. Simulation results show that the proposed algorithm provides higher PSNR and SSIM of about 0.7dB and 0.01 on average, respectively than conventional bicubic interpolation algorithm.

Keywords : Learning, super-resolution, one-dimensional patch, directional interpolation.

I. 서 론

최근 디스플레이의 대화면화 및 고 해상도화 추세에 따라 저해상도 영상을 고화질의 고해상도 영상으로 변환하기 위한 스케일링 (scaling) 혹은 보간 (interpolation) 기법의 중요성이 점차 증가하고 있다. 가장 전형적인 스케일링 기법으로 bilinear, bi-cubic 보

간법 등 선형 방식들이 있다. 이러한 선형 기법들은 비교적 적은 연산량을 갖지만, 에지의 특성을 잘 살리지 못하는 단점이 있다. 이런 문제점을 해결하기 위한 방식으로서 NEDI (new edge directional interpolation)^[1]와 같은 에지 방향성을 고려한 비선형 기법들이 개발되었다^[1~3]. NEDI는 저해상도 영상의 현재 화소와 대각 방향에 위치한 화소와의 상관관계가 고해상도 영상에서도 유사하다고 가정에 기반한다.

상기의 기법들은 간단한 구조를 가지고 있지만, blurring, jagging, ringing과 같은 artifact가 발생하는 단점이 있다. 이러한 문제점을 해결하기 위한 방법 중

* 학생회원, ** 평생회원 인하대학교 전자공학부
(School of Electronic Engineering, Inha University)
※ 이 논문은 인하대학교의 지원에 의하여 연구되었음.
접수일자: 2010년5월27일, 수정완료일: 2010년8월30일

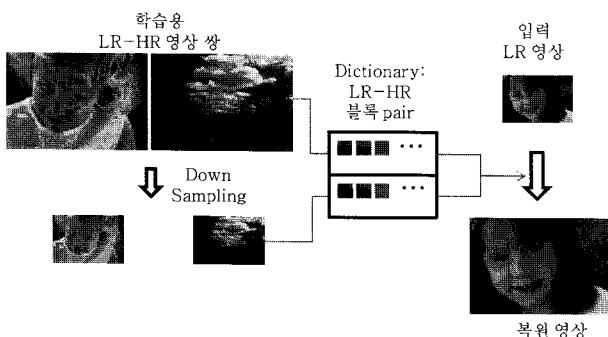


그림 1. 전형적인 학습 기반 SR

Fig. 1. Typical learning-based SR algorithm.

하나로 초 고해상도 (super-resolution; SR) 영상 복원 기법이 주목받고 있다. 전형적인 SR은 여러 장의 저해상도 영상들을 정합하여 하나의 고해상도 영상을 복원해내는 기법을 말한다.^[4~6] 이런 전형적인 SR은 움직임 보상 기반 정합 때문에 방대한 연산량이 필요하다. 그래서, 그림 1과 같은 학습 기반 SR 기법들이 대안으로 주목받고 있다. 이러한 기법들은 다양한 고해상도 영상과 그에 대응하는 저해상도 영상으로부터 블록 단위 고주파 정보를 추출하여 소위 dictionary에 저장하고, 입력 저해상도 영상 내 각 블록에 대한 고해상도 정보를 미리 학습된 dictionary로부터 찾아 합성한다. 상기 학습 기반 SR 기법은 기존의 선형 보간 기법들보다 좋은 화질을 보이지만, dictionary 구현 시 메모리 크기가 매우 방대하다. 또한, 유사한 블록을 찾기 위해 상당한 정합 연산이 요구된다.

본 논문은 일차원 패치 기반의 학습을 통해 dictionary를 간소화하고 동시에 정합 연산량을 크게 줄

인 고속 학습 기반 보간 기법을 제안한다. 기존 기법들은 이차원 패치 기반의 학습을 수행하는 반면, 제안한 기법은 일차원 패치에 기반하여 유사한 패치들을 K-means clustering으로 묶는 방식으로 학습 단계에서 dictionary 크기를 1/1000 이하로 줄일 수 있다. 더불어, 합성 단계에서 정합 연산이 크게 줄기 때문에 제안한 학습 기반 영상 보간 기법은 실시간 처리가 가능하고 하드웨어 구현에도 적합하다. 실험을 통해 제안한 기법이 종래 학습 기반 SR 기법보다 PSNR은 물론 화질도 우수함을 보인다.

본 논문의 구성은 다음과 같다. II장은 제안한 기법을 기술하며, III장은 실험 결과를 보인다. 마지막으로 IV장에서 결론을 맺는다.

II. 제안 기법

1. 1D Content Adaptive Interpolation (1DCAI)

가. 학습 단계

그림 2와 같이 제안된 기법은 학습 (learning) 단계와 고해상도 영상 합성 (synthesis) 단계로 나눌 수 있다. 학습 단계에서는 고해상도 (high resolution; HR) 영상과 그 영상을 저 대역 통과 필터를 이용해 blurring 및 sub-sampling한 저 해상도 (low resolution; LR) 영상의 복수 쌍들을 이용하여 dictionary를 생성한다. 합성 단계에서는 전 단계에서 생성한 dictionary를 이용해서 각 입력 LR 영상에 대한 HR 영상을 복원한다.

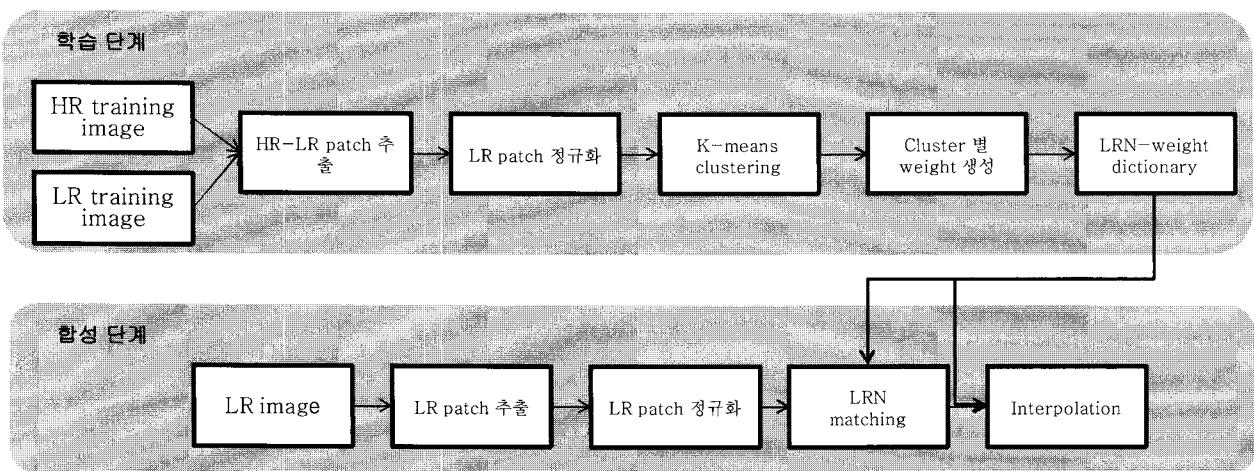


그림 2. 제안한 기법

Fig. 2. The proposed algorithm.

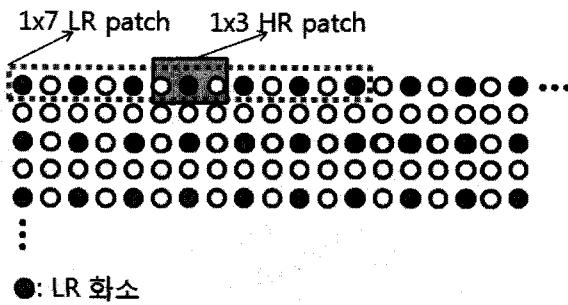


그림 3. LR-HR 패치 쌍 추출

Fig. 3. Extraction of a LR-HR patch pair.

(1) HR-LR patch pair 추출

먼저 복수의 HR 영상과 LR 영상 쌍들에서 그림 3과 같이 HR-LR 패치 쌍들을 추출한다. 그림에서 각 원은 HR 화소 위치를 의미하며, 유색 원은 1:2 보간을 가정할 때 LR 화소 위치를 의미한다. 여기서 기준 방식의 패치들은 2차원인 반면, 우리는 1차원 패치들을 추출함에 주목할 필요가 있다. 이는 기존의 선형 보간 방법과 유사하게 수평 방향으로 보간을 수행한 후 순차적으로 수직 방향 보간을 수행하기 위함이다. 그래서, 제안한 기법을 본 논문에서는 1차원 내용 기반 보간 (one-dimensional content adaptive interpolation) 즉, 1DCAI라고 명명한다. 결국 1DCAI는 적은 연산으로도 2차원 보간 효과를 거둘 수 있다.

만족할 만한 화질 성능을 내기 위해 HR 기준 2화소 간격으로 충분한 수의 패치 쌍들을 추출한다. 수평 방향은 물론 수직 방향으로도 LR-HR 패치 쌍을 추출한다. 본 논문에서는 그림 3과 같이 패치 쌍의 한 예로 LR 패치의 크기는 1x7이며, 중심의 HR 패치 크기는 1x3이라고 가정한다.

모든 추출된 LR-HR 패치 쌍들 중 t 번째 쌍의 HR 패치와 LR 패치를 각각 HR_t , LR_t 라 하자. 먼저 LR_t 는 정규화 과정을 거친다. LR_t 내 화소들의 평균을 μ , 표준 편차를 σ 라 할 때, LR_t 내의 각 화소 값 x 의 정규화 결과는 다음과 같다.

$$x' = \frac{x - \mu}{\sigma} \quad (1)$$

정규화 된 LR_t 패치를 LRN_t 이라고 하자.

(2) Dictionary 생성

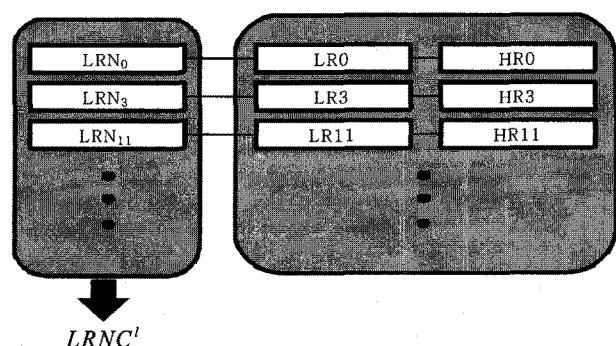
[5]과 같은 기존의 학습 기반 SR은 dictionary 크기

가 매우 크다는 단점이 있다. 그래서 우리는 K -means clustering을 이용해 유사한 패치 쌍들을 하나의 cluster로 묶음으로써 dictionary의 크기를 줄임과 동시에 정합 연산량도 줄인다. 제안 기법에서는 수평 방향 패치 쌍들과 수직 방향 패치 쌍들을 별도로 clustering한다. 따라서, 최종적으로 수평 방향 dictionary와 수직 방향 dictionary 각 독립적으로 생성된다. Clustering 과정을 좀 더 상세하게 살펴본다.

먼저 총 M 개의 LR-HR 패치 쌍들이 추출되었다고 하자. 일반적으로 M 은 수 만에서 수십만에 이를 정도로 방대하기 때문에, dictionary에 저장할 패치 쌍들의 수를 대폭 줄일 필요가 있다. 그래서, M 개의 패치 쌍들에 LRN을 기준으로 한 K -means clustering을 적용하여, LR 특성이 유사한 패치 쌍들끼리 모아, M 보다 훨씬 작은 L 개의 cluster들로 분류한다. LRN 기준의 clustering이라는 하지만, 쌍 단위로 묶임에 주목하라. 즉, 각 cluster에는 한 개 이상의 LRN-LR-HR 패치 쌍들이 포함된다. 그림 4는 l 번째 cluster의 예를 보여준다. 정규화 된 0번째, 3번째, 11번째 LRN 패치가 유사하다면 하나의 cluster로 묶일 수 있다. 해당 cluster로 분류된 LRN들의 중심값 (평균값)이 그 cluster를 대표하는 인덱스로 사용된다. l 번째 cluster의 index를 $LRNC^l$ 이라고 하자.

다음으로는 각 cluster를 대표하는 고주파 합성 정보를 생성한다. 본 논문에서는 고주파 합성 정보를 LR-HR 패치 쌍의 관계로부터 추출한다. 예를 들어, 특정 LR-HR 패치 쌍의 관계는 다음 식 (2)로 표현이 가능하다.

$$I_H(i) = \sum_{x=0}^{N-1} w_{ix} I_L(x) \quad (2)$$

그림 4. l 번째 cluster의 예Fig. 4. An example of the l -th cluster.

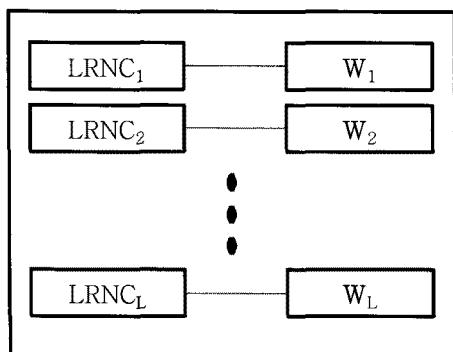


그림 5. Dictionary에 저장되는 고주파 합성 정보
Fig. 5. The high frequency synthesis information to be stored in the dictionary.

식 (2)에서 $I_H(\cdot)$ 과 $I_L(\cdot)$ 은 각각 1차원 HR 패치와 LR 패치를 의미한다. 또한 i 는 HR 패치 내 화소의 위치를 나타내고, x 는 LR 패치 내 화소 위치를 나타낸다. 이 때, w_{ix} 는 i 번째 HR화소를 보간하기 위한 x 번째 가중치를 의미한다. 결국 dictionary에는 그림 5와 같이 각 cluster를 대표하는 인덱싱용 LRNC와 그에 대응하는 가중치 정보가 쌍으로 저장된다.

나. 고 해상도 영상 합성 단계

본 논문은 1차원 패치 학습을 통해 얻어진 dictionary를 이용하여 영상을 합성하는 방식을 제안한다. 즉, 2차원 영상을 수평 방향의 복원과 수직 방향의 복원으로 나누어 보간한다. 설명의 편의를 위해 본 절에서는 수평 방향에 대한 영상 합성 과정만을 기술한다.

먼저, 입력 LR 영상 내 수평 방향 1차원 패치들을 추출하여 정규화한다. 각 정규화된 입력 LR patch LRN_{Input} 와 dictionary 내 모든 LR 패치들 (LRNC) 사이에 정합 (matching)을 수행한다. 정합을 통해 LRN_{Input} 와 가장 유사한 LR 패치를 찾고, 이에 대응되는 가중치 정보를 이용하여 HR 패치를 합성한다. 단계별 상세한 내용은 다음과 같다.

(1) 입력 저 해상도 영상에 대한 patch 추출

LR 영상이 입력되면 학습 단계와 동일한 방식으로 LR 패치들을 이웃한 패치와 적절히 중첩하면서 추출한다. 본 논문에서는 LR 기준 1화소 간격으로 추출한다. 수평 방향 보간 시 수평 방향으로 1차원 패치를 추출하고, 수직 방향으로 복원 시 수직 방향으로 1차원적인 패치를 추출한다. 정합 과정에서 dictionary 내 LRNC 패치들과 비교를 위해 각 LR 패치는 정규화된다.

(2) 정합

LRN_{Input} 과 dictionary에 존재하는 L 개의 LRNC들 간 distance를 계산하여 최소의 거리를 갖는 후보를 찾는다. 정합을 위한 거리를 계산하는 방법으로는 L_1 -norm이나 L_2 -norm과 같은 널리 알려진 거리 계산 방법을 포함하여 다양한 방법들을 선택할 수 있다. 본 논문에서는 L_2 -norm 거리를 사용하였다.

(3) 복원

만약 정합을 통해 찾아진 최적의 후보가 l 번째 cluster라면, dictionary 내의 l 번째 가중치 정보 (W_l)를 이용하여 HR patch를 합성한다. 해당 가중치 정보와 LRN_{Input} 을 이용하여 식 (2)로부터 HR 패치를 합성한다. 그런데, 평탄한 영역에서는 상기 합성 방식에 의한 효과가 미미하거나 오히려 불필요한 고주파를 생성해서 artifact로 보일 수 있다. 그래서, 본 논문에서는 각 LR 패치의 분산이 특정 문턱값보다 작으면 상기 합성 대신 bi-cubic을 적용한다.

한편, LR 패치가 중첩되어 있으므로 HR 패치도 중첩이 되기 때문에, 겹치는 부분에서는 평균을 통해 HR 값을 결정한다.

2. 2D 스케일링으로의 적용

본 논문은 1DCAI를 이용하여 2차원 영상을 보간하는 두 가지 방법을 제안한다. 첫째는 기존의 선형 보간 방식처럼 동일한 1DCAI를 수평, 수직 순차적으로 적용하는 방식이며, 둘째는 수평 방향에 대해서만 1DCAI를 적용하고 수직 방향에 대해서는 소위 directional interpolation을 수행하는 방식이다. 첫 번째 방식은 매우 단순하므로 본 논문에서는 두 번째 방법을 자세히 기술한다.

두 번째 방식의 장점은 dictionary의 크기를 더 줄일 수 있고, 대각선 방향에서 발생할 수 있는 계단 무늬 artifact를 줄일 수 있다는 것이다. 첫 번째 방식은 수평 방향의 dictionary와 수직 방향의 dictionary가 별도로 있어야 하지만 두 번째 방식은 수평 방향으로만 1DCAI를 적용하므로 dictionary 크기를 첫 번째 방법 대비 1/2로 줄일 수 있다. 또한, 첫 번째 방법은 철저히 1차원 중심이기 때문에 대각 방향의 에지에 취약한 측면이 있다. 그러나 두 번째 방법은 수직 방향의 보간 시 2차원 정보를 고려한 directional interpolation을 수행하므로 이 문제점을 상당 부분 해결한다.

가. Directional interpolation

수평 방향으로 1DCAI를 적용하여 얻어진 영상은 마치 비월주사 (interlaced) 필드 영상과 유사하다. 기존에 비월 주사 필드를 순차주사 (progressive) 프레임으로 변환해주는 많은 기술들이 개발된 바 있다^[7~10]. 이런 기술을 de-interlacing이라고 하는데, 가장 널리 알려져 있는 de-interlacing 기술이 에지 방향을 고려한 directional interpolation이다.

(1) 에지 기반 라인 평균 방식

가장 간단한 directional interpolation이 ELA (edge-based line-average)이다. 그림 6에서 $X(i)$ 는 보간될 수평 line 내 i 번째 화소를, U 와 L 은 각각 X 의 위와 아래에 존재하는 기 수평 방향 보간된 참조 HR line이다. 식 (3)에서 $C(k)$ 는 방향성 상관도를 나타낸다.

$$C(k) = \frac{1}{k} \sum_{k=-n, -1, 0, 1, \dots, n} |U(i+k) - L(i+k)|, \quad (3)$$

$C(k)$ 가 최소가 되는 방향을 찾고, 결정된 방향으로 보간을 수행한다. ELA 방법은 비교적 연산량이 적고 방향성 검출에 오류가 없을 때 좋은 성능을 제공하지만, 고주파 성분이 많은 영역에서는 방향성을 잘못 검출함으로 인해 보간 어러가 발생하고 좋지 않은 화질을 보이는 경우가 종종 발생한다.

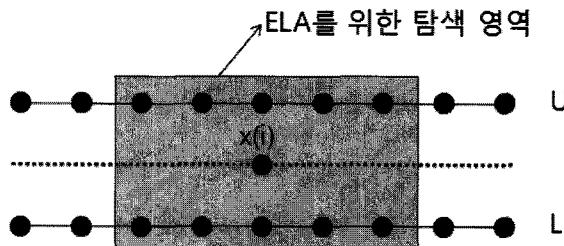


그림 6. ELA를 위한 탐색 영역
Fig. 6. The search window for ELA.

(2) Direction-Oriented Interpolation (DOI)

ELA보다 방향성 검출 성능이 좋은 directional interpolation 기법으로 DOI가 있다^[9]. DOI 기법은 3x2 블록 단위로 에지의 방향성을 검출한다. DOI 기법은 손실 퍽셀을 보간하기 위해 2개의 상위 참조 라인과 2개의 하위 참조 라인을 사용한다. 또한, 2개의 공간 방향 벡터 (spatial direction vector; SDV)가 보간을 위해 사용된다. 그림 7에서 U_1 와 U_0 , L_1 와 L_0 는 각각 상위, 하위 참조 라인을 나타낸다. SDV와 보간될 $X(i)$ 화소

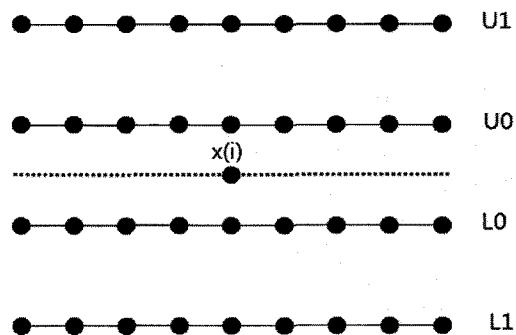


그림 7. DOI를 위한 상하 참조 라인

Fig. 7. Reference lines for DOI.

값은 다음 식들에 의해 구해진다.

$$S_U(k) = \sum_{j=-1}^1 (|U_0(i+j) - U_1(i+j+k)|^2 + |L_0(i+j) - U_0(i+j+k)|^2) \quad (4)$$

$$S_L(k) = \sum_{j=-1}^1 (|U_0(i+j) - L_0(i+j+k)|^2 + |L_0(i+j) - U_1(i+j+k)|^2) \quad (5)$$

$$sdv_U = \arg \min \{S_U(k)\}, -R \leq k \leq R \quad (6)$$

$$sdv_L = \arg \min \{S_L(k)\}, -R \leq k \leq R \quad (7)$$

$$i_U = \frac{sdv_U}{2}, \quad i_L = \frac{sdv_L}{2} \quad (8)$$

$$X(i) = \frac{U_0(i+i_U) + L_0(i+i_L)}{2} \quad (9)$$

DOI는 ELA보다는 좋은 성능을 보이지만, 연산량이 많다는 단점이 있다.

(3) Novel Intra De-interlacing (NID)

[10]에서는 DOI의 연산량을 줄이면서도 성능을 유지 시킬 수 있는 directional interpolation 방법을 제안하였다. 그레이디언트 (gradient)를 이용하여 영역 특성을 분석하여, 보간 위치 별로 다음과 같이 네 가지 카테고리로 분류한다.

- 평坦하거나 수직 에지를 갖는 영역
- 수직 방향성을 균일하게 갖는 에지 영역
- 수평 방향성을 갖는 에지 영역
- 에지 특성이 복잡한 텍스쳐 영역

상기 분류 결과를 바탕으로 영역별로 LA, ELA, DOI 등을 적절히 적용함으로써, 연산량도 줄이면서 좋은 화질을 유지한다.

나. Directional interpolation을 이용한 보간

수평 방향에 대해 1DCAI를 적용하고, 수직 방향의 보간은 상기 언급한 [10]의 NID에 기반한 directional interpolation을 수행한다.

III. 실험 결과

1. 실험 조건

1DCAI를 반복 적용하는 방법 (proposed 1)과 1DCAI와 directional interpolation을 혼합 적용하는 방법 (proposed 2) 등 제안 기법들을 bilinear interpolation, bi-cubic, NEDI^[1], Fan's^[6]과 비교하였다. 실험 영상으로는 500x332 영상 3장, 512x512 영상 3 장, 1280x720 영상 3장 등 총 9장 영상들을 사용하였다. 대부분의 영상은 MPEG 및 JPEG test-용이며, 500x332 영상들은 <http://www.thedigital-picture.com/Gallery/>에서 다운로드하였다. 본 논문에서는 2배 스케일링에 대해 성능 평가를 하였다. 필터 계수가 [22 0 -52 0 159 256 159 0 -52 0 22]/512인 저대역 통과 필터로 HR 영상을 수직, 수평 방향으로 각각 필터링하였고, 필터링된 영상을 2:1 서브 샘플링하여 LR 영상을 얻었다.

제안하는 기법과 Fan 기법의 학습을 위해 실험 영상에 포함되지 않은 5장의 512x512 영상들 (*Bridge, Couple, Woman, Village, Car*)과 3장의 1280x720 영상들 (*City, Jet, Ship*)을 사용하였다. Fan 방법 및 제안 기법 모두 M 은 200,000이다. 제안한 기법에서 LR 및 HR 패치 크기는 각각 1x3과 1x7이며, dictionary 크기 L 은 256이다. 성능 평가를 위한 화질 척도로는 PSNR 및 SSIM^[11~12]을 사용하였다.

2. 실험 결과

그림 8과 그림 9는 스케일링된 *Bee* 영상 및 *Butterfly* 영상의 일부를 도시한 것이다. 제안 기법들이 기존 기법들보다 우수한 화질을 보임을 알 수 있다. 특히, proposed 2는 proposed 1에 비해 설명도는 다소 떨어지지만 대각선 에지 부근에서 jagging 없이 깨끗한 화질을 보인다. 표 1과 표 2에서 각각 PSNR과 SSIM 결과를 비교하였다. 제안 기법들이 기존 기법보다 PSNR은

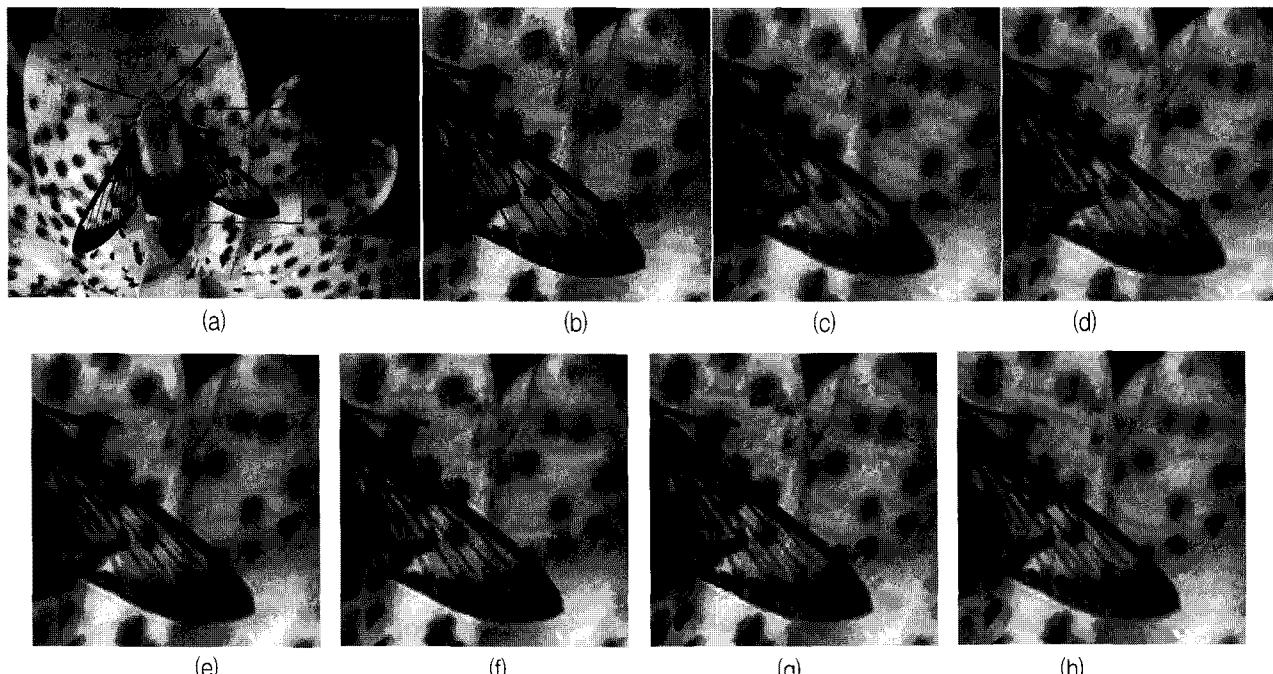


그림 8. *Bee* 영상에 대한 복원 결과 (a) 원 영상 (b) 원 영상 내 박스 영역 (c) bilinear (d) bi-cubic (e) NEDI (f) Fan's (g) proposed 1 (h) proposed 2

Fig. 8. The reconstructed images for *bee* (a) original (b) a box region in the original (c) bilinear (d) bi-cubic (e) NEDI (f) Fan's (g) proposed 1 (h) proposed 2.

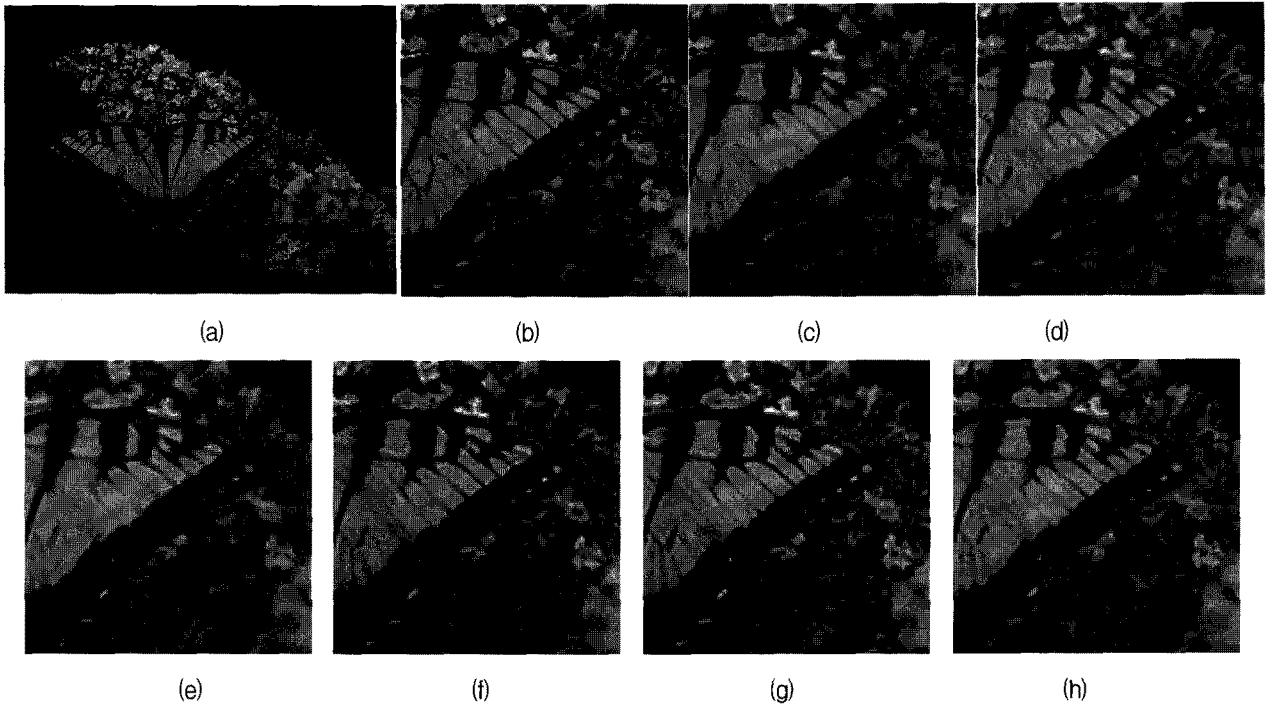


그림 9. *Butterfly* 영상에 대한 복원 결과 (a) 원영상 (b) 원 영상 내 박스 영역 (c) bilinear (d) bi-cubic (e) NEDI (f) Fan's (g) proposed 1 (h) proposed 2

Fig. 9. The reconstructed images for *Butterfly* (a) original (b) a box region in the original (c) bilinear (d) bi-cubic (e) NEDI (f) Fan's (g) proposed 1 (h) proposed 2.

표 1. PSNR 비교

Table 1. The PSNR comparison.

		Bilinear	Bi-cubic	NEDI	Fan's algorithm	Proposed 1	Proposed 2
720P	<i>Night</i>	30.86	32.28	30.66	32.36	33.36	31.78
	<i>Parkrun</i>	24.13	25.11	23.77	24.91	25.50	24.81
	<i>Shields</i>	29.77	31.07	29.55	30.94	31.50	30.58
512P	<i>Lena</i>	33.17	34.82	33.60	34.97	35.41	34.99
	<i>Baboon</i>	24.49	25.07	24.52	24.98	25.26	24.82
	<i>Barbara</i>	24.83	25.11	24.42	25.13	25.34	25.13
332P	<i>Bee</i>	28.73	29.84	29.18	30.32	30.70	30.02
	<i>Flower</i>	33.35	35.04	34.10	35.90	36.56	35.31
	<i>Butterfly</i>	27.25	28.67	26.98	28.69	29.56	28.28
평균		28.51	29.67	28.53	29.80	30.35	29.52

물론 우수한 SSIM 결과를 보임을 알 수 있다. Proposed 1은 전형적인 학습 기반 SR인 Fan 기법 대비 평균 약 0.6dB정도 PSNR이 좋다. Proposed 2는 proposed 1에 비해 PSNR은 다소 떨어지지만, directional interpolation 효과로 인해 주관적 화질은 비

교 우위에 있음을 확인하였다 (그림 8, 9 참조).

표 3에서 여러 알고리즘들의 메모리 크기 및 연산 시간을 비교하였다. 예를 들어 proposed 1의 dictionary 크기를 살펴보자. LR 패치의 크기가 1×7 이고, HR 패치의 크기가 1×3 이므로, 인덱스용 LRNC와 가중치들을

표 2. SSIM 비교
Table 2. The SSIM comparison.

		Bilinear	Bi-cubic	NEDI	Fan's algorithm	Proposed 1	Proposed 2
720P	<i>Night</i>	0.9200	0.9370	0.9123	0.9360	0.9480	0.9329
	<i>Parkrun</i>	0.7920	0.8363	0.7727	0.8320	0.8560	0.825
	<i>Shields</i>	0.8780	0.9021	0.8683	0.8990	0.9128	0.8948
512P	<i>Lena</i>	0.9130	0.9280	0.9114	0.9260	0.9318	0.9273
	<i>Baboon</i>	0.7160	0.7598	0.7158	0.7600	0.7817	0.7456
	<i>Barbara</i>	0.7790	0.8001	0.7848	0.8020	0.8160	0.8026
332P	<i>Bee</i>	0.9010	0.9175	0.8972	0.9190	0.9274	0.9172
	<i>Flower</i>	0.9550	0.9669	0.9551	0.9690	0.9718	0.9656
	<i>Butterfly</i>	0.9210	0.9404	0.9114	0.9410	0.9508	0.9365
평균		0.8639	0.8876	0.8588	0.8871	0.8996	0.8830

표 3. 메모리 사용량 및 실행 시간 비교
Table 3. Comparison of memory sizes and running times.

	메모리 사용량	Running Time
Fan's algorithm	20MB	216min
Proposed1	14KB	4.08sec
Proposed2	7KB	1.03sec

저장하기 위해서는 $2x(7+3x7)x256\text{byte}$ 즉, 14Kbyte의 메모리 크기가 요구된다. Fan 방법은 M 이 20만이므로 약 20Mbyte에 이르는 메모리가 필요하다. 따라서, proposed 1은 Fan 방법 대비 1/1000이상으로 메모리 크기를 줄일 수 있다. Proposed 2의 경우 수평 방향 dictionary만 있으면 되기 때문에 추가적으로 메모리 크기를 1/2로 줄일 수 있다. 즉, 7Kbyte의 메모리만 있으면 된다. 실행 시간은 Intel CPU Duo2 내장 PC에서 측정하였다. 표 3의 수치들은 720P 영상 한 장을 보간하는데 걸리는 시간이다. Proposed 2의 경우 1초 정도로 Fan 기법 대비 획기적으로 빨라짐을 알 수 있었다.

IV. 결 론

본 논문은 종래의 학습 기반 SR의 방대한 저장 공간 및 연산량을 줄이기 위해 1차원 패치를 바탕으로 학습 및 영상 합성을 수행하는 기법들을 제안한다. 첫 번째 방법은 수평 방향과 수직 방향을 분리하여 각 방향에

대해 독립적으로 1차원 패치 기반 dictionary를 이용해 보간하는 방법이다. 두 번째 방법은 수직 방향의 보간을 directional interpolation으로 대체하여 추가적으로 메모리를 줄이고, 대각선 방향 화질 열화를 방지할 수 있는 방식이다. 실험 결과를 통해 제안 기법들이 적은 연산량에도 불구하고 객관적 화질은 물론 주관적 화질 측면에서 기존의 보간 기법들보다 우수함을 확인하였다. 제안한 보간 기법은 디지털 카메라나 평판 디지털 텔레비전같이 고해상도 스케일링을 요구하는 제품에 적용 가능하다.

참 고 문 헌

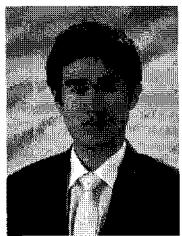
- [1] X. Li and M. Orchard, "New edge directed interpolation," *IEEE Trans. Image processing*, vol. 10, no. 10, pp. 1520–1527, Oct. 2001.
- [2] 신정호, 정정훈, 백준기, "정최화된 영상복원을 이용한 공간 적응적 영상보간," 전자공학회논문지 제35권 SP편, 11호, 1578~1584쪽, 1998년 11월.
- [3] 정신철, 송병철, "영역별 특성을 고려한 적응적 영상 보간 방법," 전자공학회논문지 제46권 SP편, 5호, 111~119쪽, 2009년 9월.
- [4] M. Zhao, M. Bosma, and G. de Haan, "Making the best of legacy video on modern displays," *J. Soc. Inf. Display*, vol. 15, no. 1, pp. 49–60, 2007.
- [5] W. Freeman, T. Jones, and E. Pasztor, "Example-based super-resolution," *IEEE Computer Graphics and Applications*, vol. 40, no. 1, pp. 23–47, 2000.

- [6] W. Fan and D. Yeung, "Image hallucination using neighbor embedding over visual primitive manifolds," *IEEE Proc. CVPR*, 2007.
- [7] G. de Haan and E. B. Bellers, "Deinterlacing- an overview," *Proc. of the IEEE*, vol. 86, no. 9, pp. 1839-1857, Sep. 1998.
- [8] Tao Chen, Hong Ren Wu, and Zheng Hua Yu, "Efficient de-interlacing algorithm using edge-based line average interpolation," *Optical Engineering*, vol. 39, no. 8, pp. 2101-2105, Aug. 2000.
- [9] H. Yoo and J. Jeong, "Direction-oriented interpolation and its application to de-interlacing," *IEEE Trans. Consumer Electronics*, vol. 48, no. 4, pp. 954-962, Nov. 2002.
- [10] W. Kim, S. Jin, and J. Jeong, "Novel intra deinterlacing algorithm using content adaptive interpolation," *IEEE Trans. Consumer Electronics*, vol. 53, no. 3, pp. 1036-1043, Aug. 2007.
- [11] Z.Wang, "The SSIM index for image quality assessment," <http://www.cns.nyu.edu/~lcv/ssim/>.
- [12] Z Wang, AC Bovik, HR Sheikh, "Image quality assessment: from error visibility to structural similarity," *IEEE Trans. Image Processing*, vol. 13, no. 4, pp. 1-14, April 2004.

저 자 소 개



강 영 융(학생회원)
 2010년 인하대학교 전자공학부
 졸업 (학사).
 2010년 ~ 현재 인하대학교
 전자공학부 석사과정
 <주관심분야: 영상 신호처리, 화
 질 개선>



정 신 철(학생회원)
 2009년 인하대학교 전자공학부
 졸업 (학사).
 2009년 ~ 현재 인하대학교
 전자공학부 석사과정
 <주관심분야: 영상 신호처리, 화
 질 개선>



송 병 철(평생회원)
 1994년 한국과학기술원 전기 및
 전자공학과 졸업 (학사).
 1996년 한국과학기술원 전기 및
 전자공학과 졸업 (석사).
 2001년 한국과학기술원 전기 및
 전자공학과 졸업
 (공학박사).
 2001년 ~ 2008년 삼성전자 디지털미디어연구소
 책임연구원
 2008년 ~ 현재 인하대학교 전자공학부 교수
 <주관심분야: 영상 신호처리, 영상시스템/SoC>