



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2016년08월31일
(11) 등록번호 10-1652265
(24) 등록일자 2016년08월24일

(51) 국제특허분류(Int. Cl.)

HO4N 7/01 (2006.01)

(52) CPC특허분류

HO4N 7/012 (2013.01)

HO4N 7/0115 (2013.01)

(21) 출원번호 10-2015-0149643

(22) 출원일자 2015년10월27일

심사청구일자 2015년10월27일

(56) 선행기술조사문헌

Jin Wang, Gwanggil Jeon, Jechang Jeong, Opt.
Eng. 51(4), 2012.05.02.

기술이전 희망 : 기술양도

(73) 특허권자

인천대학교 산학협력단

인천광역시 연수구 아카데미로 119 (송도동)

(72) 발명자

전광길

인천광역시 연수구 경원대로119번길 21, 114동
904호 (동춘동, 풍림2차아파트)

(74) 대리인

특허법인충정

전체 청구항 수 : 총 5 항


심사관 : 김희주

(54) 발명의 명칭 최대 귀납 기반 인트라 필드 디인터레이싱 방법

(57) 요약

본 발명의 실시예에 따른 최대 귀납 기반 인트라 필드 디인터레이싱 방법은, 컴퓨터 시스템의 디인터레이싱 방법에 있어서, 인터레이스된 이미지에 대해 포인트 와이즈 추정자를 산출하는 단계와, 상기 인터레이스된 이미지에 대해 패치 와이즈 추정자를 산출하는 단계와, 상기 포인트 와이즈 및 패치 와이즈 추정자를 기반으로 하이브리드 추정자(패치-와이즈 추정자)를 산출하는 단계 및 상기 하이브리드 추정자를 이용하여 상기 인터레이스된 이미지에 대해 디인터레이싱을 실행하는 단계를 포함한다.

대표도 - 도4



(52) CPC특허분류

H04N 7/0137 (2013.01)

H04N 7/0142 (2013.01)

공지예외적용 : 있음

명세서

청구범위

청구항 1

컴퓨터 시스템의 디인터레이싱 방법에 있어서,

인터레이스된 이미지에 대해 포인트 와이즈 추정자를 산출하는 단계;

상기 인터레이스된 이미지에 대해 패치 와이즈 추정자를 산출하는 단계;

상기 포인트 와이즈 및 패치 와이즈 추정자를 기반으로 하이브리드 추정자(패치-와이즈 추정자)를 산출하는 단계; 및

상기 하이브리드 추정자를 이용하여 상기 인터레이스된 이미지에 대해 디인터레이싱을 실행하는 단계;를 포함하고,

포인트 와이즈 추정자 $(PoE) \hat{y}_{PoE}$ 는,

$$\hat{y}_{PoE}(i,j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+1, n+j) p(\hat{y}_o(i,j) | y(m+1, n+j))}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) p(\hat{y}_o(i,j) | y(m+1, n+j))}$$

이고 여기서, x 는 상기 인터레이스된 크기(1/2 X width X height)의 저해상도 이미지이고, y 는 실제 원본 고해상도 이미지이며,

$y(i,j) = x(\frac{i+1}{2}, j)$ 이고, $i=2d-1, d=1, \dots, height/2$ 이며, $\hat{y}_o$ 는 저해상도 이미지

$\hat{y}_o(i,j) = y(i,j), i=2d-1, d=1, \dots, height/2$ 의 재생성된 이미지이며, $y = \hat{y}_o + \varepsilon$, 여기서 ε 는 추정 에러

$$p(y) = \frac{1}{|S_y|} \quad i=2d, d=1, 2, \dots, \frac{height}{2}$$

고, 인 것을 특징으로 하는, 최대 귀납 기반 인트라 필드 디인터레이싱 방법.

청구항 2

삭제

청구항 3

컴퓨터 시스템의 디인터레이싱 방법에 있어서,

인터레이스된 이미지에 대해 포인트 와이즈 추정자를 산출하는 단계;

상기 인터레이스된 이미지에 대해 패치 와이즈 추정자를 산출하는 단계;

상기 포인트 와이즈 및 패치 와이즈 추정자를 기반으로 하이브리드 추정자(패치-와이즈 추정자)를 산출하는 단계; 및

상기 하이브리드 추정자를 이용하여 상기 인터레이스된 이미지에 대해 디인터레이싱을 실행하는 단계;를 포함하고,

상기 패치 와이즈 추정자(PaE)는

$$\widehat{y_{PaE}}(i,j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+1, n+j) p(v(N_{i,j}) | v(N_{m+i, n+j}))}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) p(v(N_{i,j}) | v(N_{m+i, n+j}))} \quad \text{이고,} \quad \text{여기서}$$

$$i=2d, v(N_{i,j}) = \{ \widehat{y_o}(i+s, j+t), (s,t) \in N_{i,j} \} \quad \text{와} \quad v(N_{m+i, n+j}) = \{ y(m+i+2s, n+j+2t), (s,t) \in N_{i,j} \}$$

은 벡터화된 픽셀 부분들인 것을 특징으로 하는, 최대 귀납 기반 인트라 필드 디인터레이싱 방법.

청구항 4

컴퓨터 시스템의 디인터레이싱 방법에 있어서,

인터레이스된 이미지에 대해 포인트 와이즈 추정자를 산출하는 단계;

상기 인터레이스된 이미지에 대해 패치 와이즈 추정자를 산출하는 단계;

상기 포인트 와이즈 및 패치 와이즈 추정자를 기반으로 하이브리드 추정자(패치-와이즈 추정자)를 산출하는 단계; 및

상기 하이브리드 추정자를 이용하여 상기 인터레이스된 이미지에 대해 디인터레이싱을 실행하는 단계;를 포함하고,

하이브리드 추정자(패치-와이즈 추정자)는,

$$\widehat{y_{HE}^C}(i,j) = \widehat{y_{PaE}^C}(i,j) + \mu^C \cdot \widehat{y_{PoE}^C}(i,j) \quad \text{이고, 여기서 } i = 2d \text{이고 } C \text{는 } G \text{나 } L \text{ 둘 중의 하나이고,}$$

μ^C 은 규칙화 요소인 것을 특징으로 하는, 최대 귀납 기반 인트라 필드 디인터레이싱 방법.

청구항 5

제4항에 있어서, 상기 하이브리드 추정자의 가우시안 분포는,

$$\widehat{y_{HE}^G}(i,j) = \widehat{y_{PaE}^G}(i,j) + \mu^G \widehat{y_{PoE}^G}(i,j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+i, n+j) \exp(\Psi_G)}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) \exp(\Psi_G)} \quad \text{이고,} \quad \text{여기서}$$

$$\Psi_G = - \frac{\mu^G (\widehat{y_o}(i,j) - \widehat{y_o}(m+i, n+j))^2 + \sum_{(s,t) \in N_{i,j}} (\widehat{y_o}(i+s, j+t) - \widehat{y_o}(m+i+2s, n+j+t))^2}{2}$$

여기서 $i=2d$, η 는 스케일 인자이고, η^G 은 정규화 요소인 것을 특징으로 하는, 최대 귀납 기반 인트라 필드 디인터레이싱 방법.

청구항 6

제4항에 있어서, 상기 하이브리드 추정자의 라플라시안 분포는,

$$\widehat{y_{HE}}(i,j) = \widehat{y_{PaE}}(i,j) + \mu^L \widehat{y_{PoE}}(i,j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+i, n+j) \exp(\Psi_L)}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) \exp(\Psi_L)}$$

$$\Psi_L = - \frac{\mu^L \left| \widehat{y_o}(i,j) - \widehat{y_o}(m+i, n+j) \right| + \sum_{(s,t) \in N_{ij}} \left| \widehat{y_o}(i+s, j+t) - \widehat{y_o}(m+i+2s, n+j+t) \right|}{\eta}$$

이고, 여기서,

여기서 $i=2d$, η 는 스케일 인자이고, η^L 은 정규화 요소인 것을 특징으로 하는, 최대 귀납 기반 인트라 필드 디인터레이싱 방법.

발명의 설명

기술 분야

[0001] 본 발명은 최대 귀납 기반 인트라 필드 디인터레이싱 방법에 관한 것으로, 특히 포인트 와이즈(point-wise) 접근과 패치 와이즈(patch-wise) 접근의 선형적 조합인 하이브리드 접근을 제안함으로써, 서로의 단점을 보완한 최대 귀납 기반 인트라 필드 디인터레이싱 방법에 관한 것이다.

배경 기술

[0002] 인터레이싱 스캔 포맷은 대역폭을 줄이기 위해, 비디오 신호에 제안되어 왔다. 현재의 고해상도 디스플레이에서, 인터레이스된 신호의 중요한 단점은 에지 깜빡임과 행간 깜빡임과 필드 알리아싱이다. 특히 HDTV와 PC에서의 최근 진보에서 몇몇 디인터레이싱 기법은 인공 결점을 제거하기 위해 발표되어 왔다.

[0003] 디인터레이싱은 수직 샘플링 비율 상향 변환 문제를 가지고 있다. 왜냐하면 텔레비전에서 신호 처리는 실제 장면의 시간과 공간적인 샘플링 처리이기 때문이다. 샘플링 이론에 근거하여, 모든 원본 빈도 구성들이 샘플링 비율 상향 전환에 의해 재생성될 수 있도록, Nyquist 샘플링 비율 뒤에 있는 빈도들을 제거하기 위해, 샘플링 절차 이전에 필터가 적용되어야 한다. 하지만, 그러한 필터를 설계하는 것은, 실제 시스템을 위해서는 실현 가능한 것이 아니다. 더욱이, 원본 프레임에서 모든 빈도 구성들을 재생성 하는 것은 불가능하다. 따라서 디인터레이싱은, 기준 스펙트럼을 유지하면서 가능한 많이 알리아싱 인공 결점을 억제하기 위한 절차이다.

[0004] 기존 디인터레이싱 알고리즘은 인트라 필드나 인터 필드 디인터레이싱 기법들로 구분될 수 있다. 인트라 필드 기법은 인터레이스된 이미지에 수행되며, 인터 필드 기법은 다른 시간대의 수많은 인터레이스된 이미지들에 수행된다. 인트라 필드 기법은 정지 이미지 영역에서 잘 동작한다. 하지만, 그들은 움직이는 물체를 가진 영역에서는 효과가 적으며, 움직이는 물체가 프레임에서 프레임으로 일반적으로 디인터레이스 되지 않는다면 심한 깜빡임 인공 결점이 나타날 수 있다.

[0005] 인터 필드 모션 적응적 및 모션 보상 디인터레이싱 기법은 진보된 기법이며, 정확한 움직임 정보가 제공된 움직이는 물체에 대해, 더 나은 성능을 달성한다. 하지만, 모션 보상 기법은 높은 정확도의 움직임 정보를 요구하며, 이 정확한 정보를 얻기 위해서는, 하드웨어 복잡도가 크게 증가될 수 있다. 따라서 이 움직임 정보는 많은 제품들, 특히 소프트웨어 어플리케이션에서는 실현 가능성이 없다. 반면, 인트라 필드 기법은 그들의 단순성으로 인해 널리 적용되고 있다.

[0006] 몇몇 인트라 필드 디인터레이싱 기법은 다른 정도의 복잡도와 성능으로 발표되어 왔다. 예를 들면, 라인 평균(LA) 기법은 상하 픽셀들의 평균값으로 픽셀을 보간하는 단순한 기법이다. LA는 그것의 단순성으로 널리 이용되어 왔다. 하지만, 이미지가 보간되기 전에 반으로 줄어든 수직 해상도는 디인터레이스된 이미지의 품질을 저하시킨다. 이 문제를 경감시키기 위해, ELA(edge-based line-average) 기법이 제안되었다. 이 기법은, 인터레이스

된 이미지의 두 인접한 선 사이의 손실 픽셀을 디인터레이스 하기 위해 에지 방향의 상관관계를 이용한다. 하지만 이 기법은 높은 공간 빈도 지역에서 결점이 있는 가시 품질을 생성하며, 부정확하게 결정된 에지 방향은 품질의 악화를 유발할 수 있다. ELA에 기반한 다양한 해법들이 이러한 결점들을 줄이기 위해 제안되었다. 예를 들면, efficient ELA (EELA) 기법은 공간적인 상관관계를 효율적으로 얻기 위해, 측정치 P , Q , V 를 제안했다. Park은 에지 방향을 정확히 감지하기 위해, 차이점과 에지 패턴을 함께 사용하는 새로운 NEDD(edge dependent deinterlacing)기법을 제안했다. 수평 에지 패턴에 의존하는 LCID(low complex interpolation method for deinterlacing) 기법이 발표되었다. LCID 기법은 대각선, 반대각선, 수직, 수평의 4개의 단순화된 방향적 차이점들을 채택했다. EMD(edge map-based deinterlacing) 기법은 소벨 마스크(Sobel mask)로 디인터레이스 될 수 있도록, 손실 픽셀의 에지 방향을 추정하며, 결정된 에지 방향에서의 어떤 두 개의 픽셀들 사이의 평균값들인, 디인터레이스 된 픽셀 후보로 추정된 에지 방향에 따라 보간을 수행한다. ECA(edge-based correlation adaptive) 기법은 보간된 픽셀과 이웃 픽셀 사이의 밀접성과 유사성을 함께 고려한다. ECA와 EAD는 모두, 보간 결과를 향상시키기 위한 ELA 요소의 가중치가 부여된 합을 사용함으로써 개선된다.

발명의 내용

해결하려는 과제

[0007] 본 발명의 목적은 포인트 와이즈(point-wise) 접근과 패치 와이즈(patch-wise) 접근을 선형적으로 조합하여 서로의 단점을 보완함으로써 최적의 하이브리드 디인터레이싱 방법을 제공하는데 있다.

과제의 해결 수단

[0008] 상기한 기술적 과제를 달성하기 위한 본 발명의 실시예에 따른 최대 귀납 기반 인트라 필드 디인터레이싱 방법은, 컴퓨터 시스템의 디인터레이싱 방법에 있어서, 인터레이스된 이미지에 대해 포인트 와이즈 추정자를 산출하는 단계와, 상기 인터레이스된 이미지에 대해 패치 와이즈 추정자를 산출하는 단계와, 상기 포인트 와이즈 및 패치 와이즈 추정자를 기반으로 하이브리드 추정자(패치-와이즈 추정자)를 산출하는 단계 및 상기 하이브리드 추정자를 이용하여 상기 인터레이스된 이미지에 대해 디인터레이싱을 실행하는 단계를 포함한다.

발명의 효과

[0009] 본 발명의 실시예에 따른 디인터레이싱 방법은 포인트 와이즈(point-wise) 접근과 패치 와이즈(patch-wise) 접근의 선형적 조합인 하이브리드 접근을 제안함으로써, 서로의 단점을 보완하며, 이러한 하이브리드 알고리즘은 좋은 성능과 높은 효율성을 달성시켜 준다.

도면의 간단한 설명

[0010] 도 1은 리서치 S_x 영역의 사이즈를 도시하는 도면이다.

도 2는 포인트 와이즈 접근을 위한 통계학적 모델을 도시하는 그래프이다.

도 3은 $l=1$ 일 때, 이웃 N_x 및 N_y 의 구조를 도시하는 도면이다.

도 4는 패치 와이즈 접근을 위한 통계학적 모델을 도시하는 그래프이다.

도 5는 성능 평가에 이용되는 테스트 이미지의 스냅샷을 도시한다.

도 6은 성능 측정 방법을 도시한다.

도 7은 이웃 $N(i, j)$ 의 사이즈 l 에 대한 평균 PNSR 결과를 도시하는 그래프이다.

도 8은 S_y 리서치 영역의 사이즈 k 에 대한 평균 PSNR 결과를 도시하는 그래프이다.

도 9는 디인터레이싱 기반 하이브리드 가우시안의 필터링 인자 γ 의 계산을 도시하는 그래프이다.(MAPHG)

도 10은 디인터레이싱 기반 하이브리드 라플라시안의 필터링 인자 η 의 계산을 도시하는 그래프이다.(MAPHG)

도 11은 MAPHG의 정규화 인자 μ^G 에 대한 평균 PSNR 결과를 도시하는 그래프이다.

도 12는 MAPHL의 정규화 인자 μ^L 에 대한 평균 PSNR 결과를 도시하는 그래프이다.

도 13의 (a)는 원본 이미지, (b)는 원본 부분 이미지, (c)는 LA, (d)는 ELA, (e)는 EELA, (f)는 LCID, (g)는 NEDD, (h)는 ECA, (i)는 EAD 및 (j)는 MAPHL을 도시한다.

도 14의 (a)는 원본 이미지, (b)는 원본 부분 이미지, (c)는 LA, (d)는 ELA, (e)는 EELA, (f)는 LCID, (g)는 NEDD, (h)는 ECA, (i)는 EAD 및 (j)는 MAPHL을 도시한다.

도 15는 6개의 Bayesian 기반 디인터레이싱 접근들 사이의 PSNR 비교를 도시하는 표.

도 16은 각 이미지를 디인터레이싱하는데 드는 CPU 시간을 도시하는 표.

도 17은 BAYESIAM 기반 디인터레이싱 알고리즘을 이용한 디인터레이스된 이미지의 SSIM 메트릭을 나타내는 표.

도 18은 제안된 MAPHL 및 종래의 알고리즘을 이용한 여섯 개의 디인터레이스된 이미지에 대한 PSNR(DB) 메트릭을 나타내는 표.

도 19는 제안된 MAPHL 및 종래의 알고리즘을 이용한 각 이미지를 디인터레이싱하는데 드는 CPU 시간을 나타내는 표.

도 20은 제안된 MAPHL 및 종래의 알고리즘을 이용한 여섯 개의 디인터레이스된 이미지에 대한 SSIM 메트릭을 나타내는 표.

발명을 실시하기 위한 구체적인 내용

- [0011] 본 발명을 충분히 이해하기 위해서 본 발명의 바람직한 실시예를 첨부 도면을 참조하여 설명한다. 본 발명의 실시예는 여러 가지 형태로 변형될 수 있으며, 본 발명의 범위가 아래에서 상세히 설명하는 실시예로 한정되는 것으로 해석되어서는 안 된다. 본 실시예는 당업계에서 평균적인 지식을 가진 자에게 본 발명을 보다 완전하게 설명하기 위하여 제공 되는 것이다. 따라서 도면에서의 요소의 형상 등은 보다 명확한 설명을 강조하기 위해서 과장되어 표현될 수 있다. 각 도면에서 동일한 부재는 동일한 참조부호로 도시한 경우가 있음을 유의하여야 한다. 또한, 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 공지 기능 및 구성에 대한 상세한 기술은 생략된다.
- [0013] 이 발명에서, 우리는 최대 귀납 (MAP) 기반 디인터레이싱 알고리즘을 제안한다. 디인터레이싱 알고리즘은 인터레이스된 이미지로부터 원본 실제 이미지를 복구하는 것이다. 우리는 이 기법을 MAP 문제로서 공식화 한다. MAP 문제를 해결하기 위해, 우리는 몇몇의 통계적인 정의를 조사해야 한다. 이를 위해, 우리는 MAP 문제를 명확히 하기 위해, 통계적인 해석과 Bayesian 이론을 제공한다. 그리고 MAP 문제는 손실 픽셀과 이웃 픽셀 사이의 잔여 값의 분포에 집중한다. 우선, 분포가 Gaussian이나 Laplacian 둘 중의 하나로 가정되는, point-wise 모델을 연구한다. 실적인 그래프와 비교하여, Laplacian 분포는 좋은 적합성을 달성한다. 하지만 이 point-wise 접근은 몇 가지 단점이 있다. (1) 손실 픽셀을 추정하기 위해 사용되는 몇몇의 알려지지 않은 픽셀들(우리는 손실 픽셀과 이웃 픽셀 사이의 관련성을 알기를 원한다) (2) 그것은 지리적 요약과 미세 스케일 구조를 무시한다. 그리고, 우리는 두 이웃들(손실 픽셀의 이웃과 그 이웃 픽셀의 이웃들) 사이의 연관성을 고려하는 patch-wise 모델을 연구한다. 이들 이웃들에서 사용되는 모든 값들은 원본 실제 이미지로부터 주어진다. patch-wise 접근의 분석에 의해, 우리는 point-wise 접근보다 손실 픽셀의 더 좋은 추정을 얻는다. 반면, point-wise 접근은, 디인터레이싱 알고리즘계의 또 다른 심각한 문제인, 큰 스케일 구조를 보존할 수 있다. 결국, 우리는 point-wise 접근과 patch-wise 접근의 선형적 조합인 하이브리드 접근을 제안하며, 이는 서로의 단점을 보완한다. 우리가 제안한 하이브리드 알고리즘은 좋은 성능과 높은 효율성을 달성시켜 준다.
- [0014] 발명의 나머지는 다음과 같이 구성된다. 섹션2에서 우리는 제안된 알고리즘을 묘사한다. 섹션3에서 몇 가지 실험 결과와 대응하는 토론이 제공된다. 마지막으로 섹션4에서 결론이 주어진다.

- [0016] 2. 제안된 알고리즘

[0017] A. 포인트 와이즈(Point-Wise) 기반 디인테레이싱

[0018] 본 발명의 디인테레이스 알고리즘을 위해, 인터레이스된 크기($1/2 \times \text{width} \times \text{height}$)의 저해상도 이미지 x 가 주어지고, 이 저해상도 이미지는 원본 이미지의 홀수열이다. 실제 원본 고해상도 이미지가 y 라고 가정하며, 이 이

미지의 크기는 ($\text{width} \times \text{height}$)이며, 이미지 x 와 $y(i,j)=x(\frac{i+1}{2},j)$ 으로 관계를 가진다. 여기서

$i=2d-1, d=1, \dots, \text{height}/2$ 이다. 높은 해상도의 이미지 $\hat{y}_o$ 가 크기($\text{width} \times \text{height}$)를 가지며, 이

는 주어진 저해상도 이미지 $\hat{y}_o(i,j)=y(i,j), i=2d-1, d=1, \dots, \text{height}/2$ 의 재생성된 이미지이다. 그리고

$y=\hat{y}_o+\varepsilon$, 여기서 ε 는 추정 에러이고, 이는 추가적인 노이즈로 간주될 수 있으며 이는 독립적

이다. 추정치 $\hat{y}$ 는, 만약 모든 추정치들 사이에서 $E[L(y,\hat{y})|\hat{y}_o]$ 을 최소화 할 수 있다면, 최적

추정치로 볼 수 있으며, 이는 MAP 해결과 같다. 여기에서 $L(y,\hat{y})$ 는 추정된 값과 실제값 사이의 차이

점의 몇몇 함수로서 이용되는 손실 함수이다. 이차 손실 함수 $L(y,\hat{y})=\lambda(y) \|\hat{y}-y\|^2$ 는 보통 신호 처리

에 사용되며, $\lambda(y)$ 는 상수값이다. 그리고 최적 추정 $(OE)\hat{y}_{OE}$ 는 다음 수학적 식 1로서

$E[L(y,\hat{y})|\hat{y}_o]$ 을 최소화한다.

수학적 식 1

$$\hat{y}_{OE} = \arg \min_{\hat{y}} E[\lambda(y) \|\hat{y}-y\|^2 | \hat{y}_o]$$

[0019]

[0020] 이차 손실 함수 추정에 근거하여, 최적의 추정치는

수학적 식 2

$$\hat{y}_{OE} = \frac{E[\lambda(y)y | \hat{y}_o]}{E[\lambda(y) | \hat{y}_o]} = \frac{\sum_{y \in \Lambda} \lambda(y)y p(y | \hat{y}_o)}{\sum_{y \in \Lambda} \lambda(y)p(y | \hat{y}_o)}$$

[0021]

[0022]

여기서 Λ 은 $y(|\Lambda|=256 \text{ if } y \in 0, \dots, 255)$ 의 모든 설정의 큰 영역이다. Bayes 규칙을 사용하여, 다음을 얻을 수 있다.

수학식 3

$$\hat{y}_{OE} = \frac{\sum_{y \in \Lambda} \lambda(y) y p(\hat{y}_o | \hat{y}_o) p(y)}{\sum_{y \in \Lambda} \lambda(y) p(y | \hat{y}_o) p(y)}$$

[0023]

수학식 3으로부터, 최적 추정치 $\hat{y}_{OE}$ 을 얻기 위해, $\hat{y}_o | y$ 의 분포를 알기를 원한다. 그리고 y의 분포는

사전 분포로 알려져 있다. $p(\hat{y}_o | y)$ 의 확률 밀도 함수 (PDF)가 알려져 있지 않다고 가정해 보라. 그러나, 도 1에 도시된 바와 같이 사이즈 $2k \times (2k + 1)$ 을 가지는 집합 $\{y(2i-k, j-k), y(2i-k, j-k+1), \dots, y(2i+k, j+k)\}$ (여기서, $k=1, 2, \dots$)를 가진다. 그리고 이것은

손실 픽셀 $(2i, j)$ 에서의 중앙에 위치한 이웃 영역 S_y 에 있으며, 주어진 저해상도 이미지로부터 온다. 이웃

영역 S_y 에서, y의 사전 분포는 균일 분포로 가정된다. 예를 들면 $p(y) = \frac{1}{|S_y|}$. 그러면, $\hat{y}_{OE}$

를 위한 적절한 포인트 와이즈(point-wise) 추정치 $(PoE) \hat{y}_{PoE}$ 를 가지며, 이는 아래에 있는 수학식 4로

$$i=2d, d=1, 2, \dots, \frac{height}{2}$$

서 손실 픽셀을 추정한다. 여기서, 이다. 수학식 4에서

$y(m+i, n+j) = \hat{y}_o(m+i, n+j)$ 를 쉽게 찾아낼 수 있다.

수학식 4

$$\hat{y}_{PoE}(i, j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+1, n+j) p(\hat{y}_o(i, j) | y(m+i, n+j))}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) p(\hat{y}_o(i, j) | y(m+i, n+j))}$$

[0025]

[0026]

$\hat{y}_o(2d,j)$ 이 알려지지 않기 때문에, 우리는 수직 방향

$\hat{y}_o(2d,j) = (\hat{y}_o(2d-1,j) + \hat{y}_o(2d+1,j))/2$ 에 있는 두개의 가장 근접한 픽셀들의 평균값을 주어진 사전 지식으로 활용한다. 우리는 손실 픽셀과 그 이웃 픽셀들 사이의 나머지가 독립적이라 가정한다. 그러

면 수학적 4는 수학적 5로 재구성될 수 있다. 수학적 5를 사용하면서, 추정 $\hat{y}_{PoE}$ 을 계산할 수

$p(\hat{y}_o(i,j) - \hat{y}_o(m+i, n+j))$ 있으며, 제공된 PDF 은 알려져 있다. 우리는 두 개의 분포를 사용한다 : Gaussian 분포와 Laplacian 분포.

[0027]

도 2(a)는 Gaussian 분포와 실증적인 그래프의 곡선 매칭을 보여준다. 또한, 도 2(a)는 나머지 값들이 0에 가까워질 때, 실증적인 그래프와 Gaussian 분포 사이에 명확한 오차가 있다는 것을 보여준다. 반면, 도 2(b)는 Laplacian 분포가 실증적인 그래프에 잘 맞는다는 것을 보여준다. 만약 PDF가 Gaussian 분포라면 수학적 5는 수

학적 6으로 다시 쓰여질 수 있으며, 여기서 $i = 2d$ 이고, α_1 은 스케일 인자이다.

[0028]

만약 PDF가 Laplacian이라면 수학적 5는 수학적 7로 바뀔 수 있고, 여기서 $i = 2d$ 이고, β_1 은 스케일 인자이다.

[0030]

B. 패치 와이즈(Patch-wise) 기반 디인터레이싱

[0031]

위의 포인트 와이즈(point-wise) 기반 디인터레이싱은 두 가지 큰 결점이 있다.

[0032]

1) 짝수 열 $\hat{y}_o$ 이 알려지지 않았고, 우리는 귀납적(선) 추정으로 이웃 픽셀들의 평균을 채택했다.

[0033]

2) 큰 검색 영역 S_y 에서, 그것은 점의 유사성만 고려하고, 지리적 설정은 무시한다.

[0034]

이들 결점을 극복하기 위해, 우리는 패치 와이즈(patch-wise) 기반 디인터레이싱을 제안한다. 패치 와이즈(patch-wise) 기법에서, 우리는 추정된 손실 픽셀과 그것의 이웃 픽셀들 사이의 나머지 값들 대신, 알려진 나머지 이웃을 활용한다. 첫 째, 손실 픽셀과 주어진 픽셀들의 이웃은 도 3에 도시된 바와 같이 모두 알려져 있다. 둘 째, 그것은, 픽셀들이 손실 픽셀과 유사한 이웃을 가진다는 사실을 고려하고, 손실 픽셀의 추정을 통해 관련 없는 이웃들을 제거할 수 있다.

[0035]

patch-wise 추정자 (PaE)는 다음 페이지에서 보여지듯이, 수학적 9로서 공식화 될 수 있다. 여기서

$$i=2d, v(N_{ij}) = \{ \hat{y}_o(i+s, j+t), (s,t) \in N_{ij} \}$$

와

$$v(N_{m+i, n+j}) = \{ y(m+i+2s, n+j+2t), (s,t) \in N_{ij} \}$$

은 벡터화된 픽셀 부분들이다.

수학식 5

$$y_{PoE}(i,j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+1, n+j) p(\widehat{y_o}(i,j) - \widehat{y_o}(m+i, n+j))}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) p(\widehat{y_o}(i,j) - \widehat{y_o}(m+i, n+j))}$$

[0036]

수학식 6

$$y_{PoE}^G(i,j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+1, n+j) \exp(-\frac{(\widehat{y_o}(i,j) - \widehat{y_o}(m+i, n+j))^2}{\alpha_1^2})}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) \exp(-\frac{(\widehat{y_o}(i,j) - \widehat{y_o}(m+i, n+j))^2}{\alpha_1^2})}$$

[0037]

수학식 7

$$y_{PoE}^I(i,j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+1, n+j) \exp(-\frac{|\widehat{y_o}(i,j) - \widehat{y_o}(m+i, n+j)|}{\beta_1})}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) \exp(-\frac{|\widehat{y_o}(i,j) - \widehat{y_o}(m+i, n+j)|}{\beta_1})}$$

[0038]

[0039]

픽수 열에서 보간된 픽셀 $N_{i,j}$ 의 이웃은 하나의 윈도우에서 주어진 픽셀 부분의 홀수 열이다. 그리고 홀수 열에서 주어진 픽셀 $N_{m+i, n+j}$ 의 이웃은 도 3에서 보듯이 하나의 윈도우에서 주어진 픽셀 부분의 홀수 열

이다. 이들 두 이웃의 크기는 $(2l+1) \times 2l, l=1, 2, \dots$ 과 같다. 우리는 모든 픽셀들이 같은 분포를 가진다고 가정하며, 그러면 patch 벡터의 PDF는 다음과 같이 쓰여질 수 있다.

수학식 8

$$p(v(N_{i,j})|v(N_{m+i, n+j})) = \prod_{(s,t) \in N_{i,j}} p(\widehat{y_o}(i+s, j+t)|y(m+i+2s, n+j+2t))$$

[0040]

[0041]

수학식 8에서의 모든 값들은 홀수 열에서의 주어진 픽셀들이다. 그리고 우리는 다음의 수학식 10을 얻기 위해, 더 나아가 수학식 8을 수학식 9로 교환할 수 있다.

수학식 9

$$\widehat{y_{PaE}(i,j)} = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+1, n+j) p(v(N_{i,j}) | v(N_{m+i, n+j}))}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) p(v(N_{i,j}) | v(N_{m+i, n+j}))}$$

[0042]

수학식 10

$$\begin{aligned} \widehat{y_{PaE}(i,j)} &= \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+1, n+j) \prod_{(s,t) \in N_{i,j}} \Omega_1}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) \prod_{(s,t) \in N_{i,j}} \Omega_1} \\ &= \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+1, n+j) \prod_{(s,t) \in N_{i,j}} \Omega_2}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) \prod_{(s,t) \in N_{i,j}} \Omega_2} \end{aligned}$$

[0043]

$$\Omega_1 = p(\widehat{y_o}(i+s, j+t) | \widehat{y_o}(m+i+2s, n+j+2t))$$

$$\Omega_2 = p(\widehat{y_o}(i+s, j+t) | -\widehat{y_o}(m+i+2s, n+j+2t))$$

[0044]

여기서, Ω_2 이며, $i = 2d$ 이다. 수학식 10으로부터,

보간된 픽셀을 추정하기 위해서는 PDF Ω_2 으로의 유도가 필요하다는 것을 알아냈다.

[0046]

몇몇 자연 이미지들의 나머지의 실증적 그래프는 Gaussian 분포와 Laplacian 분포로 비교되며, 이는 도 4(a)와

$$\widehat{y_o}(i+s, j+t) - \widehat{y_o}(m+i+2s, n+j+2t)$$

(b)에서 각각 볼 수 있다. 도 4에서, 이 나머지는 $\widehat{y_o}(i+s, j+t) - \widehat{y_o}(m+i+2s, n+j+2t)$ 에 의해

계산되며, 우리는 $s = -1, t = 0$ 를 예제로 선택할 수 있다. 도 2와 도 4를 비교하면서, 우리는 patch-wise 매칭이 0 주위의 point-wise 매칭보다 실증적 그래프와 더욱 잘 맞는다는 결론을 낼 수 있다. point-wise 기법은 0주위에서는 나쁜 매칭을 나타낸다. 그리고 patch-wise 기법은 도 2와 도 4에서 보듯이, 이 약점을 개선한다. 그다음, 우리는 Gaussian과 Laplacian 분포를 수학식 10으로 교체하여, 수학식 11과 수학식 12를 얻는다.

수학식 11

$$\widehat{y_{PaE}^G(i,j)} = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+1, n+j) \exp(\Phi_G)}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) \exp(\Phi_G)}$$

[0047]

$$\Phi_G = \frac{-\sum_{(s,t) \in N_{ij}} (\hat{y}_o(i+s, j+t) - \hat{y}_o(m+i, n+j+2t))^2}{\alpha_2^2}$$

[0048] 여기서, 이다.

수학식 12

$$\hat{y}_{PaE}^L(i, j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+i, n+j) \exp(\Phi_L)}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) \exp(\Phi_L)}$$

[0049]

$$\Phi_L = -\frac{\sum_{(s,t) \in N_{ij}} (\hat{y}_o(i+s, j+t) - \hat{y}_o(m+i+2s, n+j+2t))}{\beta_2}$$

[0050] 여기서, 이다. 여기서 $i=2d$,

α_2, β_2 는 스케일 인자이다.

[0052] C. Hybrid Estimator 기반 디인테레이싱

[0053] patch-wise 추정자 기반 디인테레이싱은 이미지들의 구조에 대한 보존을 설명한다. 반면, 작은 검색 영역에서는, 특히 이미지 디인테레이싱 문제에 있어서는, point-wise 유사성은 여전히 중요한 역할을 하고 있다.

[0054] 즉, point-wise와 patch-wise 추정자는 둘 다, 손실 픽셀 복원을 위한 노력이다. 따라서 우리는 hybrid estimator (HE) 기반 디인테레이싱 알고리즘을 다음과 같이 제안한다.

수학식 13

$$\hat{y}_{HE}^C(i, j) = \hat{y}_{PaE}^C(i, j) + \mu^C \cdot \hat{y}_{PoE}^C(i, j)$$

[0055]

[0056] 여기서 $i = 2d$ 이고 C 는 G 나 L 둘 중의 하나이고, μ^C 은 규칙화 요소이다.

[0057] Gaussian 분포를 위해서는 수학식 14를 얻기 위해, 수학식 6과 수학식 11을 조합하고, Laplacian 분포를 위해서는 수학식 15를 얻기 위해 수학식 7과 수학식 12를 조합한다.

수학식 14

$$\hat{y}_{HE}^G(i, j) = \hat{y}_{PaE}^G(i, j) + \mu^G \hat{y}_{PoE}^G(i, j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+i, n+j) \exp(\Psi_G)}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) \exp(\Psi_G)}$$

[0058]

[0059] 여기서,

$$\Psi_G = - \frac{\mu^G (\hat{y}_o(i,j) - \hat{y}_o(m+i, n+j))^2 + \sum_{(s,t) \in N_{ij}} (\hat{y}_o(i+s, j+t) - \hat{y}_o(m+i+2s, n+j+t))^2}{\eta^G}$$

[0060]

[0061] 여기서 $i=2d$, η 는 스케일 인자이고, η^G 은 정규화 요소이다.

수학식 15

$$\hat{y}_{HE}^T(i,j) = \hat{y}_{PaE}^T(i,j) + \mu^L \hat{y}_{PoE}^T(i,j) = \frac{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) y(m+i, n+j) \exp(\Psi_L)}{\frac{1}{|S_y|} \sum_{(m,n) \in S_y} \lambda(y) \exp(\Psi_L)}$$

[0062]

[0063] 여기서,

$$\Psi_L = - \frac{\mu^L |\hat{y}_o(i,j) - \hat{y}_o(m+i, n+j)| + \sum_{(s,t) \in N_{ij}} |\hat{y}_o(i+s, j+t) - \hat{y}_o(m+i+2s, n+j+t)|}{\eta^L}$$

[0064]

[0065] 여기서 $i=2d$, η 는 스케일 인자이고, η^L 은 정규화 요소이다.

[0067] 3. 실험 결과

[0068] 인터레이스된 이미지에 대해, 제안된 기법의 성능을, 진보적인 변환 문제로 입증하기 위해, 우리는 이 섹션에서 몇몇의 모의실험 결과를 제공한다. 모의실험 연구는, 기존 알고리즘 LA, ELA, EELA, NEDD, LCID, ECA, EAD와 비교하여 차별성을 확인하기 위해, 도 5에 있는 표준 테스트 이미지[25]로 수행되었다. 우리 실험은 Intel Core 2 Duo CPU E8500@3.16GHz에서 수행되었다. 우리는 peak signal-to-noise ratio (PSNR)이라 불리는 잘 알려진 상이성 기준을 채택한다. 여기서 org와 rec는 각각 원본과 재생성된 이미지이다.

수학식 16

$$MSE(org, rec) = \sum_{i=1}^{width} \sum_{j=1}^{height} \frac{(org(i,j) - rec(i,j))^2}{width \times height}$$

[0069]

수학식 17

$$PSNR(org,rec)=10\log_{10}\frac{255^2}{MSE(org,rec)}$$

[0070]

[0071]

우리는 도 5에 있는 이미지들이 원본으로 주어진 이미지라 가정한다. 모든 테스트 이미지들은, 도 6에서의 시스템에 따라, 원본 크기에서 수직적으로 인터레이스 된 크기로 변환되고, 재생성된 이미지들은 원본 이미지와 비교된다. 우리는 성능 확인을 위해서 언급한 6가지 디인터레이싱 알고리즘을 통해, 객관적이고 주관적으로 보여준다 : MAP 기반 point-wise Gaussian 기반 디인터레이싱 (MAPPoG), MAP 기반 point-wise Laplacian 기반 디인터레이싱 (MAPPoL), MAP 기반 patch-wise Gaussian Bayesian 기반 디인터레이싱 (MAPPaG), MAP 기반 hybrid Gaussian 기반 디인터레이싱 (MAPHG), MAP 기반 hybrid Laplacian 기반 디인터레이싱 (MAPHL).

[0073]

A. 최적 인자의 테스트와 튜닝

[0074]

이 섹션에서, 관심있는 중심 인자들은, hybrid MAPHG를 위한 스케일 인자 γ , MAPHL을 위한 스케일 인자 η , MAPHG를 위한 정규화 요소 μ^G , MAPHL을 위한 정규화 요소 μ^L , 이웃 $N(i, j)$ 의 크기에 관련된

인자 1 , 검색 영역 S_y 의 크기와 관련된 인자 k 이다. 각각의 실험에서, 우리는 하나의 인자는 변화시키고,

나머지 인자들은 디폴트 값들, $\gamma=100, \eta=100, \mu^G=1, \mu^L=1, k=1, l=1$ 로 고정시킨다. 최적 인자를 찾기 위해, 우리는 24개의 Kodak 휘도 채널[26]과 18개의 McM [27] 이미지들을 연습 집합으로 사용했다.

[0075]

도 7은 이웃 $N(i, j)$ 의 다른 크기 l 에 대한 디인터레이스 된 이미지들의 평균 PSNR을 보여준다. 만약 l 이 너무 크다면, 이웃의 유사성에 대한 확률은 떨어지게 된다. 그리고 따라서 우리는 l 의 값을 1에서 10까지만 다양화한다.

[0077]

우리는 이웃의 크기를 늘리는 것이 PSNR을 감소시킨다는 것을 관찰한다. 이것은 6개의 가장 가까운 픽셀들이 손실 픽셀과 가장 강한 관계를 가진다는 것을 의미하며, 또한 더 큰 이웃은 확률의 예측을 불안정하게 한다. 이 발명에서는 $l = 1$ 이 최적의 크기로 선택된다.

[0078]

도 8은 검색 영역 S_y 의 다른 크기 k 에 대한 디인터레이스 된 이미지들의 평균 PSNR을 보여준다. 첫 째, 우리는 k 를 1에서 10까지 설정한다. 이상적으로, 검색 영역 S_y 의 크기 k 가 클수록, 더 신뢰성 있는 분포를 보여준다. 하지만, 도 8에서 볼 수 있듯이, 검색 영역의 크기 k 는 디인터레이싱 기법에서는 PSNR에 영향을 주지 않는다. 말하자면, 검색 영역에서의 더 많은 데이터는 더 높은 PSNR을 주지 못하지만, 더 높은 연산 복잡도만 야기시킬 뿐이다. 따라서 우리는 좋은 성능과 필요없는 연산을 없애기 위해, k 를 1로 설정한다.

[0079]

도 9 및 도 10은 MAPPaG를 위한 스케일 인자 γ 과 MAPPaL을 위한 스케일 인자 η 의 PSNR의 조정을 보여준다. 인자 γ 은 1에서 200의 범위이며, 인자 η 은 1에서 200의 범위이다. 도 9 및 도 10에서 볼 수 있

듯이, 인자 γ 과 η 은 제안된 알고리즘에서 아주 중요한 역할을 하며, 다른 인자 γ 과 η 은 PSNR

결과에 있어서, 아주 큰 차이를 발생시킨다. 그것은 인자 γ 과 η 이 아주 클 때, 다른 이웃은 모든 유사

한 가중치들을 가지기 때문이다. 반면, 인자 γ 과 η 이 아주 작으면, 가중치는 더욱 민감해 진다.

[0081] 우리는 도 9 및 도 10으로부터, $\gamma = 126$ 과 $\eta = 149$ 가 최고의 PSNR이라는 것을 관찰한다.

[0082] 도 11 및 도 12는 MAPHG를 위한 정규화 요소 μ^G 과 MAPHL을 위한 정규화 요소 μ^L 의 튜닝을 묘사한다. 하이브리드 모델에 대해, poin-wise와 patch-wise 측정은 둘 다, 성능에 영향을 줄 것이다. 따라서, 적절한 μ^G 과 μ^L 가 요구된다. 도 11 및 도 12에서 보듯이, $\mu^G = 3.1$ 과 $\mu^L = 3.4$ 가 이 발명에서 선택된다.

[0084] B. Point-wise와 Patch-wise에서의 유효성과 하이브리드 접근

[0085] 테이블(1)은 6개의 Bayesian 기반 디인터레이싱 접근들 사이의 PSNR 비교를 보여준다. 그것은 Laplacian Bayesian 기반 접근이, 대응하는 Gaussian Bayesian 기반 접근과 비교해서, 더 높은 PSNR을 가진다는 것으로 보여진다. 더욱이 일반적으로, patch-wise 접근들이 point-wise 접근들보다 더 낮고, 한편, 하이브리드 접근들이 point-wise와 patch-wise 접근들 보다 더 낮다. MAPHL 기법은 PSNR에 따라 최고의 성능을 가진다. CPU 시간의 관점에서, 이들 6가지 방법들은, 테이블(2)에서 보듯이, 모두 아주 적은 CPU 시간을 소모한다. point-wise 기법들은, 그것의 단순성 때문에, patch-wise와 하이브리드 기법들과 비교하여, 절반보다 더 많은 시간을 절감한다.

[0087] 반면, point-wise 접근들은 PSNR의 개선을 아주 적게 확장할 뿐이다. 하이브리드 접근 MAPHL은 적은 CPU 시간으로 최고의 PSNR을 달성한다.

[0088] 주관적인 품질을 평가하기 위해, 우리는, 주관적인 이미지 품질 측정에 널리 사용되는 측정중의 하나인, structural similarity(SSIM) 측정[28]을 적용한다. SSIM 측정은, 대조와 휘도로 일반화 된, 픽셀 강도의 지역 패턴들을 비교한다. 특히, 우리는 원본 이미지(org)와 재생성된 이미지(rec) 사이의 유사성을 SSIM으로 측정할 수 있다.

[0090] SSIM 측도는 이미지들에서, 구조의 손실을 얻는 것에 집중한다. 사람의 시각 시스템이 가시 장면으로부터 구조적인 정보를 추출하는데 더욱 적응이 되어있기 때문에, 구조적 유사성의 측정은 포착된 주관적 품질의 좋은 추정을 제공한다. SSIM 인덱스는 다음과 같이 보여질 수 있다.

수학식 18

$$SSIM(org,rec)=\frac{(2\mu_O\mu_R+T_1)(2\sigma_{OR}+T_2)}{(\mu_O^2+\mu_R^2+T_1)(\sigma_O^2+\sigma_R^2+T_2)}$$

[0091]

[0092] 여기서 σ_{OR} 은 두 지역 영역들 org와 rec의 공분산을 나타내며, μ_O (or σ_O) 와 μ_R (or σ_R) 은

특정 지역 영역의 평균(이나 표준편차)를 나타낸다. 두 상수 T_1, T_2 은 $v_O^2 + v_R^2$ 가 0에 접근할 때, 불안정성을 회피하기 위해 사용된다. 전체 이미지 품질을 평가하기 위해, mean SSIM (MSSIM) 인덱스가 적용되며, 그것은 다음과 같다.

수학식 19

$$MSSIM(org, rec) = \frac{1}{L} \sum_{l=1}^L SSIM(org, rec)$$

[0093]

[0094]

여기서 L은 이미지들의 지역 영역들의 개수이다. 우리는 v_O 이 v_R 과 같고, σ_O 가 σ_R 과 같을 때, SSIM이 가장 큰 값 1임을 발견한다. 수학식 18에 있는 모든 인자들이 음수가 아니기에, SSIM은 또한 음수가 아니다. 따라서 SSIM의 범위는 0에서 1이다. 만약 SSIM이 1에 근접하면, 재생성된 이미지는 원본 이미지와 더욱 유사하며, 반대로 마찬가지로이다. MSSIM이 SSIM의 평균이기 때문에, MSSIM은 SSIM과 같은 속성들을 가지고 있다. 6개의 Bayesian 기반 알고리즘들의 MSSIM 결과는 테이블(3)에서 비교된다. 각각의 이미지에 대해, 제안된 MAPHL은 다른 Bayesian 기법들과 비교하여, 최고의 MSSIM 결과를 생성한다. 이것은 우리의 제안된 알고리즘이 주관적 결과 뿐만 아니라 객관적 결과도 뛰어난 성능을 가짐을 의미한다.

[0096]

C. 기존 기법들과 함께 객관적 성능 분석

[0097]

우리는 테이블(4)와 테이블(5)에서, 제안된 MAPHL과 기존의 기법들의 PSNR과 CPU 시간으로 측정된 객관적인 성능을 나타낸다. 테이블(4)로부터, 우리는 기존 기법들인, LA, ELA, EELA, LCID, NEDD, ECA, EAD와 각각 비교하여, 제안된 MAPHL 알고리즘이 최고의 PSNR을 나타내고, 평균 PSNR의 개선이 0.839, 1.174, 0.976, 0.673, 0.933, 1.418 dB(데시벨) 까지 이르는 것을 관찰한다.

[0099]

테이블(5)로부터, EELA, LCID, NEDD, ECA와 비교하여, MAPHL이 CPU 시간을 59%, 25%, 97%, 67%까지 줄인다는 것을 명백히 알 수 있다.

[0101]

우리의 제안된 알고리즘은 PSNR을 개선하고, 동시간 대비 높은 효율을 보여준다. 비록 제안된 알고리즘이 기존 기법들과 비교하여 CPU 시간을 줄이지만, LA 기법보다는 CPU 시간이 여전히 길다. LA는 수직 방향으로, 단지 상하 픽셀의 평균을 구하는 가장 단순한 기법이며, 짧은 시간 대비 아주 나쁜 가시 품질을 가진다. 제안된 알고리즘은 LA보다 더 복잡하지만, 방향 정보를 선택하기 위한 조정 가능한 기법을 사용하며, 더욱 뛰어난 가시 성능 및 PSNR을 가지며, 시간을 더 많이 소요한다. 향후 연구에서, 우리는 제안된 알고리즘의 복잡도를 줄이는 방법에 대해 연구할 것이며, 좋은 성능을 지킬 것이다.

[0103]

D. 기존 기법들과 함께 주관적 성능 분석

[0104]

가시 효과의 관점에서 결과 이미지들의 주관적 성능 평가를 위해, 우리는 또한 도 13에서는 "Im3"의 인지된 이미지 품질의 부분을 보여주고, 도 14에서는 Im4"의 인지된 이미지 품질의 부분을 보여준다. 도 13에서, 모든 다른 기법들보다, 제안된 알고리즘이 꽃잎의 세부묘사에서 더 뛰어난 가시 품질을 보여준다는 것은 명백하다. 비록 LA가 높은 PSNR 값을 가지더라도, 도 13(c)에서 볼 수 있듯이, LA는 꽃잎의 가장자리가 확실히 뾰족뾰족한 이미지를 생성한다. ELA, EELA, LCID, NEDD, ECA, EAD 기법들은 LA보다 더 큰 PSNR을 가지지 않거나, 더 나쁘다. 반면 그들은 도 13의 (d)~(h)에서 보듯이, LA와 비교하여 각각 가시 품질을 개선한다. 대조적으로 우리의 제안된 MAPHL 기법은, 도 13(i)에서 보듯이, 다른 기법들보다 훨씬 더 좋은 가시 품질을 발생시키는 이미지로 조정될 수 있다. "Im4"를 사용하는 수평 예지에서의 가시 성능은 도 14에서 볼 수 있다. 기존 기법들로 디인터레이스 된 이미지가 인공 결점을 포함한다는 것은 명백하다. 하지만, 우리의 제안된 MAPHL 알고리즘으로 디인터레이스 된 이미지는 상태가 좋고, 강력한 지리적 균형을 가지는 부드러운 예지들을 포함한다. 따라서 우리의 제안된 MAPHL 알고리즘에서 현저한 개선이 보이는 것은 명백하다. MSSIM 결과는 테이블(4)에서 비교된다. 각각의 이미지에서, 제안된 MAPHL은 다른 기존 기법들과 비교하여 최고의 MSSIM 결과를 생성한다. 이것은 우리의 제안

된 기법이 객관적 결과 뿐만 아니라, 주관적 결과에서도 더욱 뛰어난 성능을 보여준다는 것을 암시한다.


4. 결론

MAP 기반 디인테레이싱 알고리즘이 이 발명에서 제안된다. 기존 기법들은, 픽셀들의 연관성과 함께, 제한된 숫자의 후보 에지 방향들로 이상적인 방향의 감지를 시도한다. 하지만 후보 에지 방향의 제한은 가시 품질을 떨어뜨리고 복잡성을 증가시킨다. 우리의 제안된 기법은, 이미지 특징을 통계적인 정의로 공식화 하고, 그 결과 좋은 가시 품질과 높은 효율성을 얻을 수 있기에, 객관적 및 주관적인 관점에서 뛰어난 성능을 보여준다. 추가적으로, 우리는 PSNR을 고려한 최적의 인자들을 찾는다. 이 기법의 가장 큰 공헌은, 우리가 이 기법을 통해, 좋은 가시 품질과 매우 짧은 CPU 소비 시간 뿐만 아니라, 더 높은 PSNR을 얻을 수 있다는 것이다.


이상에서 설명된 본 발명의 실시 예는 예시적인 것에 불과하며, 본 발명이 속한 기술분야의 통상의 지식을 가진 자라면 이로부터 다양한 변형 및 균등한 타 실시예가 가능하다는 점을 잘 알 수 있을 것이다. 그러므로 본 발명은 상기의 상세한 설명에서 언급되는 형태로만 한정되는 것은 아님을 잘 이해할 수 있을 것이다. 따라서 본 발명의 진정한 기술적 보호 범위는 첨부된 특허청구범위의 기술적 사상에 의해 정해져야 할 것이다. 또한, 본 발명은 첨부된 청구범위에 의해 정의되는 본 발명의 정신과 그 범위 내에 있는 모든 변형물과 균등물 및 대체물을 포함하는 것으로 이해되어야 한다.

도면


도면1



도면2




(a)




(b)

도면4




(a)




(b)


도면5




도면6




도면7




도면8




도면9




도면10




도면11




도면12



도면13



도면14



도면15

TABLE I
PSNR (DB) METRIC FOR SIX DEINTERLACED IMAGES USING SIX
BAYESIAN-BASED DEINTERLACING ALGORITHMS

Method	Im1	Im2	Im3	Im4	Im5	Im6	Average
MAPPoG	36.056	33.711	37.516	44.377	45.316	47.967	40.824
MAPPoL	36.223	33.704	37.599	44.476	45.363	48.055	40.903
MAPPaG	36.112	33.834	38.155	44.515	45.411	48.241	41.045
MAPPaL	36.443	33.845	38.619	44.615	45.492	48.341	41.226
MAPHG	36.589	33.826	38.423	44.539	45.426	48.262	41.178
MAPHL	37.022	33.828	39.038	44.669	45.507	48.372	41.406

도면16

TABLE II
CPU TIME (S) TO DEINTERLACE EACH IMAGE USING SIX BAYESIAN-BASED
DEINTERLACING ALGORITHMS

Method	Im1	Im2	Im3	Im4	Im5	Im6	Average
MAPPoG	0.078	0.078	0.062	0.483	0.483	0.483	0.278
MAPPoL	0.062	0.062	0.062	0.468	0.468	0.468	0.265
MAPPaG	0.172	0.172	0.172	1.263	1.341	1.263	0.730
MAPPaL	0.172	0.172	0.172	1.263	1.263	1.263	0.718
MAPHG	0.187	0.172	0.172	1.388	1.342	1.388	0.775
MAPHL	0.172	0.172	0.172	1.295	1.326	1.295	0.739

도면17

TABLE III
SSIM METRIC FOR SIX DEINTERLACED IMAGES USING SIX BAYESIAN-BASED
DEINTERLACING ALGORITHMS

Method	Im1	Im2	Im3	Im4	Im5	Im6	Average
MAPPoG	0.9818	0.9175	0.9771	0.9779	0.9776	0.9893	0.9702
MAPPoL	0.9828	0.9184	0.9780	0.9780	0.9776	0.9893	0.9707
MAPPaG	0.9817	0.9180	0.9775	0.9779	0.9777	0.9894	0.9704
MAPPaL	0.9830	0.9182	0.9781	0.9781	0.9778	0.9894	0.9708
MAPHG	0.9827	0.9181	0.9779	0.9780	0.9777	0.9894	0.9706
MAPHL	0.9842	0.9189	0.9801	0.9782	0.9778	0.9894	0.9714

도면18

TABLE IV
PSNR (DB) METRIC FOR SIX DEINTERLACED IMAGES USING PROPOSED
MAPHL AND CONVENTIONAL ALGORITHMS

Method	Im1	Im2	Im3	Im4	Im5	Im6	Average
LA	35.923	33.572	37.333	44.088	44.790	47.575	40.567
ELA	35.683	33.219	37.034	43.566	44.545	47.346	40.232
EELA	36.044	33.328	37.463	43.744	44.598	47.401	40.430
LCID	36.191	33.555	37.682	44.213	44.976	47.782	40.733
NEDD	36.072	33.338	37.353	43.928	44.642	47.506	40.473
ECA	34.544	33.489	35.815	43.813	44.716	47.551	39.988
EAD	35.716	33.658	36.068	43.734	44.275	46.957	40.068
MAPHL	37.022	33.828	39.038	44.669	45.507	48.372	41.406

도면19

TABLE V
CPU TIME (s) TO DEINTERLACE EACH IMAGE USING PROPOSED MAPHL
AND CONVENTIONAL ALGORITHMS

Method	Im1	Im2	Im3	Im4	Im5	Im6	Average
LA	0.015	0.021	0.015	0.062	0.078	0.062	0.042
ELA	0.218	0.202	0.218	1.741	1.732	0.218	0.722
EELA	0.249	0.265	0.249	1.918	1.918	1.908	1.085
LCID	0.203	0.265	0.218	1.809	1.700	1.700	0.983
NEDD	4.929	4.929	4.742	38.829	38.939	38.906	21.879
ECA	0.780	0.768	0.780	3.721	3.703	3.703	2.243
EAD	0.086	0.079	0.079	0.571	0.574	0.575	0.327
MAPHL	0.172	0.172	0.172	1.295	1.326	1.295	0.739

도면20

TABLE VI
SSIM METRIC FOR SIX DEINTERLACED IMAGES USING PROPOSED MAPHL
AND CONVENTIONAL ALGORITHMS

Method	Im1	Im2	Im3	Im4	Im5	Im6	Average
LA	0.9839	0.9185	0.9791	0.9753	0.9739	0.9878	0.9697
ELA	0.9790	0.9073	0.9716	0.9727	0.9733	0.9872	0.9652
EELA	0.9816	0.9117	0.9759	0.9738	0.9735	0.9874	0.9673
LCID	0.9833	0.9168	0.9791	0.9768	0.9754	0.9885	0.9670
NEDD	0.9831	0.9135	0.9786	0.9741	0.9730	0.9875	0.9683
ECA	0.9765	0.9107	0.9711	0.9755	0.9734	0.9880	0.9659
EAD	0.9828	0.9185	0.9770	0.9779	0.9777	0.9893	0.9705
MAPHL	0.9842	0.9189	0.9801	0.9782	0.9778	0.9894	0.9714