(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2020년06월05일
(11) 등록번호 10-2119138
(24) 등록일자 2020년05월29일

(51) 국제특허분류(Int. Cl.)
G06T 3/40 (2006.01) *G06T 5/00* (2019.01)
(52) CPC특허분류
G06T 3/4015 (2013.01)
G06T 5/001 (2013.01)
(21) 출원번호 10-2018-0167800
(22) 출원일자 2018년12월21일
심사청구일자 2018년12월21일
(56) 선행기술조사문헌
Lebrun & Morel. A nonlocal Bayesian image denoising algorithm. SIAM Journal on Imaging Sciences, 2013년, pp. 1665-1688. 1부.*
Lee et al. Cost efffective color filter array demosaicing using spatial correlation. IEEE Trans. on Consumer Electronics, 2006년, pp. 547-554. 1부.*
Wang et al. Filter based Bayer pattern CFA demosaicking. CSSP, 2017년, pp. 2917-2940. 1부.*
*는 심사관에 의하여 인용된 문헌

(73) 특허권자
인천대학교 산학협력단
인천광역시 연수구 아카데미로 119 (송도동)
(72) 발명자
전광길
인천광역시 연수구 경원대로119번길 21, 114동 904호(동춘동, 연수2차풍림아파트)
(74) 대리인
특허법인충정

전체 청구항 수 : 총 6 항 심사관 : 김창원

(54) 발명의 명칭 **카메라를 위한 베이지안 기반 영상 복원 방법**

(57) 요 약

본 발명은 이미지에 대한 베이어(Bayer) 패턴을 생성하는 단계, 최적의 베이지안 추정치(Optimal Bayesian Estimator, OBE)를 산출하는 단계, 상기 베이어 패턴에 대하여, 상기 산출된 최적의 베이지안 추정치를 이용하여 그린 채널을 재건(Reconstruction)하는 단계, 상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건하는 단계 및 상기 재건된 그린 채널을 정제(Refinement)하는 단계를 포함하는 것을 특징으로 한다.

본 발명은 종래의 디모자이킹 방법과 비교하여, 고효율을 유지하면서 CPSNR, S-CIELAB, FSIM 및 지퍼 효과 측정을 개선할 수 있다.

대 표 도

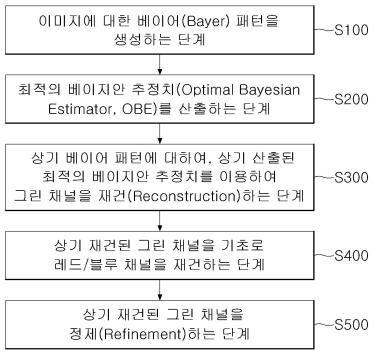

공지예외적용 : 있음

명 세 서

청구범위

청구항 1

이미지에 대한 베이어(Bayer) 패턴을 생성하는 단계;

최적의 베이지안 추정치(Optimal Bayesian Estimator, OBE)를 산출하는 단계;

상기 베이어 패턴에 대하여, 상기 산출된 최적의 베이지안 추정치를 이용하여 그린 채널을 재건(Reconstruction)하는 단계;

상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건하는 단계; 및

상기 재건된 그린 채널을 정제(Refinement)하는 단계를 포함하고,

상기 최적의 베이지안 추정치를 이용하여 재건된 그린 채널($\hat{\mathbf{y}}_G(\mathbf{k})$)은 하기 (수학식 2)로 표현되고, (수학식 3)을 기준으로 정해지는 것을 특징으로 하는 베이지안 기반 디모자이킹 방법.

(수학식 2)

$$\hat{\mathbf{y}}_G(\mathbf{k}) = \frac{\sum_{\mathbf{m}\in S_y} \tilde{\mathbf{y}}_G(\mathbf{k}+\mathbf{m})C(\mathbf{y})}{\sum_{\mathbf{m}\in S_y} C(\mathbf{y})}$$

$$\hat{\mathbf{y}}_G^H(\mathbf{k}) = \frac{\sum_{\mathbf{m}\in S_y^H} \tilde{\mathbf{y}}_G(\mathbf{k}+\mathbf{m})C(\mathbf{y})}{\sum_{\mathbf{m}\in S_y^H} C(\mathbf{y})}$$

$$\hat{\mathbf{y}}_G^V(\mathbf{k}) = \frac{\sum_{\mathbf{m}\in S_y^V} \tilde{\mathbf{y}}_G(\mathbf{k}+\mathbf{m})C(\mathbf{y})}{\sum_{\mathbf{m}\in S_y^V} C(\mathbf{y})}$$

(여기서, $\hat{\mathbf{y}}_G^H(\mathbf{k})$ 는 수평성분, $\hat{\mathbf{y}}_G^V(\mathbf{k})$ 는 수직 성분이고, S_y 는 크기가 $(2ws+1)\times(2ws+1)$ 인 색상 픽셀을 포함하는 영역, S_y^H , S_y^V 는 수평 및 수직방향으로 크기가 $1\times(2ws+1)$ 및 $(2ws+1)\times 1$ 인 주어진 색상 픽셀을 포함하는 영역,

$$C(\mathbf{y}) = \exp\left[\frac{-\|\mathbf{v}_G(\mathbf{k})-\mathbf{v}_G(\mathbf{k}+\mathbf{m})\|_1}{2\alpha}\right] + \mu\exp\left[\frac{-\|\mathbf{x}_R(\mathbf{k})-\mathbf{x}_R(\mathbf{k}+\mathbf{m})\|_1}{\alpha}\right]$$

이고, α 는 가중치 파라미터, μ 는 0,1, $\mathbf{v}_G(\mathbf{k})$ 와 $\mathbf{v}_G(\mathbf{k}+\mathbf{m})$ 는 센터의 레드 픽셀과 4 개의 인접한 그린 픽셀을 포함하는 패치 벡터임.)

(수학식 3)

$$\bar{\bar{\mathbf{y}}}_G(\mathbf{k}) = \begin{cases} \hat{\mathbf{y}}_G^H(\mathbf{k}), & \text{if } \delta(\mathbf{k}) > T_1 \\ \hat{\mathbf{y}}_G^V(\mathbf{k}), & \text{if } \delta(\mathbf{k}) < -T_1 \\ \hat{\mathbf{y}}_G(\mathbf{k}), & \text{otherwise} \end{cases},$$

$$\delta(\mathbf{k}) = \begin{cases} 1, & \text{if } \min(\mathbf{D}_H(\mathbf{k}), \mathbf{D}_V(\mathbf{k}), T_2) = \mathbf{D}_H(\mathbf{k}) \\ -1, & \text{if } \min(\mathbf{D}_H(\mathbf{k}), \mathbf{D}_V(\mathbf{k}), T_2) = \mathbf{D}_V(\mathbf{k}) \\ 0, & \text{otherwise} \end{cases},$$

$$\mathbf{D}_H = \mathbf{x} * \mathbf{f} + (\mathbf{x} - \hat{\mathbf{y}}_G^H) * \mathbf{f},$$

$$\mathbf{D}_V = \mathbf{x} * \mathbf{f}' + (\mathbf{x} - \hat{\mathbf{y}}_G^V) * \mathbf{f}',$$

(여기서, T 는 임계값, $\mathbf{D}_H$ 및 $\mathbf{D}_V$ 는 정규화된 파라미터임.)

청구항 2

제1항에 있어서,

상기 최적의 베이지안 추정치($\hat{\mathbf{y}}_{\mathrm{OBE}}$)는 하기 (수학식 1)로 표현되는 것을 특징으로 하는 베이지안 기반 디모자이킹 방법.

(수학식 1)

$$\hat{\mathbf{y}}_{\mathrm{OBE}} \approx \frac{\frac{1}{|S_y|}\sum_{\mathbf{m}\in S_y} \mathbf{y}(\mathbf{k}+\mathbf{m}) p[\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})]}{\frac{1}{|S_y|}\sum_{\mathbf{m}\in S_y} p[\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})]}.$$

(여기서 $\mathbf{x}(\mathbf{k}) = [\mathbf{x}_{\mathbf{R}}(\mathbf{k})\mathbf{x}_{\mathbf{G}}(\mathbf{k})\mathbf{x}_{\mathbf{B}}(\mathbf{k})]$ 로 모자이크 처리된 이미지이고, $\mathbf{y} = [\mathbf{y}_{\mathbf{R}}(\mathbf{k})\mathbf{y}_{\mathbf{G}}(\mathbf{k})\mathbf{y}_{\mathbf{B}}(\mathbf{k})]$ 로 원래의 컬러 이미지이며, $\mathbf{k} = (i, j) \in R^2$ 로 좌표 인덱스이고, S_y 는 보간된 픽셀을 중심으로 하는 로컬 이웃 영역임.)

청구항 3

삭제

청구항 4

이미지에 대한 베이어(Bayer) 패턴을 생성하는 단계;

최적의 베이지안 추정치(Optimal Bayesian Estimator, OBE)를 산출하는 단계;

상기 베이어 패턴에 대하여, 상기 산출된 최적의 베이지안 추정치를 이용하여 그린 채널을 재건(Reconstruction)하는 단계;

상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건하는 단계; 및

상기 재건된 그린 채널을 정제(Refinement)하는 단계를 포함하고,

상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건하는 과정은, 하기 (수학식 4)로 수행되는 것을 특징으

로 하는 베이지안 기반 디모자이킹 방법.

(수학식 4)

$$\bar{\mathbf{y}}_R(\mathbf{k}) = \bar{\mathbf{y}}_G(\mathbf{k}) + \frac{\sum_{\mathbf{m}\in S_y^{RB}} \Delta(\mathbf{k}+\mathbf{m}) C(\mathbf{y})}{\sum_{\mathbf{m}\in S_y^{RB}} C(\mathbf{y})},$$

$$\Delta(\mathbf{k}+\mathbf{m}) = \mathbf{x}_R(\mathbf{k}+\mathbf{m}) - \bar{\mathbf{y}}_G(\mathbf{k}+\mathbf{m}),$$

$$C(\mathbf{y}) = \exp\left[\frac{-\|\mathbf{v}_R(\mathbf{k}) - \mathbf{v}_R(\mathbf{k}+\mathbf{m})\|_1}{\beta}\right], + \mu \exp\left[\frac{-\|\bar{\mathbf{y}}_G(\mathbf{k}) - \bar{\mathbf{y}}_R(\mathbf{k}+\mathbf{m})\|_1}{\beta}\right],$$

$$\beta = \frac{\alpha}{2},$$

(여기서, $\mathbf{v}_R(\mathbf{k})$ 와 $\mathbf{v}_R(\mathbf{k}+\mathbf{m})$ 는 북서쪽, 북동쪽, 남서쪽 및 남동쪽에 위치한 4 개의 레드 픽셀을 포함하는 패치 벡터이고, S_y^{RB} 는 크기가 $(2ws+1)\times(2ws+1)$ 인 동일한 4 개의 레드 픽셀을 포함하는 영역, μ 는 0,1, α 는 가중치 파라미터임.)

청구항 5

제4항에 있어서,

상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건하는 과정은, 하기 (수학식 5)와 같은 과정이 추가적으로 수행되는 것을 특징으로 하는 베이지안 기반 디모자이킹 방법.

(수학식 5)

$$\bar{\mathbf{y}}_R(\mathbf{k}) = \bar{\mathbf{y}}_G(\mathbf{k}) + \frac{\sum_{\mathbf{m}\in S_y^{RG}} \Delta(\mathbf{k}+\mathbf{m}) C(\mathbf{y})}{\sum_{\mathbf{m}\in S_y^{RG}} C(\mathbf{y})},$$

$$\Delta(\mathbf{k}+\mathbf{m}) = \mathbf{x}_R(\mathbf{k}+\mathbf{m}) - \bar{\mathbf{y}}_G(\mathbf{k}+\mathbf{m}),$$

$$C(\mathbf{y}) = \exp\left[\frac{-\|\bar{\mathbf{y}}_G(\mathbf{k}) - \bar{\mathbf{y}}_R(\mathbf{k}+\mathbf{m})\|_1}{\beta}\right],$$

(여기서, S_y^{RG} 는 크기가 $(2ws+1)\times(2ws+1)$ 인 주어진 그린 픽셀 위아래의 두 개의 레드 픽셀을 포함하는 영역임.)

청구항 6

제1항에 있어서,

상기 재건된 그린 채널을 정제(Refinement)하는 과정은 하기 (수학식 6)으로 수행되는 것을 특징으로 하는 베이지안 기반 디모자이킹 방법.

(수학식 6)

$$\bar{\mathbf{y}}_R(\mathbf{k}) = \mathbf{x}_R(\mathbf{k}) + \kappa[\hat{\mathbf{y}}_G(\mathbf{k}) - \mathbf{x}_R(\mathbf{k})] + (1-\kappa)\frac{\sum_{[\mathbf{m}\in S(x)]}\Delta(\mathbf{k}+\mathbf{m})\hat{\mathbf{x}}_G(\mathbf{k}+\mathbf{m})}{\sum_{[\mathbf{m}\in S(x)]}\Delta(\mathbf{k}+\mathbf{m})},$$

$$\hat{\mathbf{x}}_G(\mathbf{k}+\mathbf{m}) = \mathbf{x}_G(\mathbf{k}+\mathbf{m}) - \bar{\mathbf{x}}_R(\mathbf{k}+\mathbf{m}),$$

$$\Delta(\mathbf{k}+\mathbf{m}) = \left\{ |\hat{\mathbf{y}}_G(\mathbf{k}) - \mathbf{x}_G(\mathbf{k}+\mathbf{m})| + \sum_{a\in\{0,2\}} |\mathbf{x}_R(\mathbf{k}+a\mathbf{m}) - \mathbf{x}_R[\mathbf{k}+(a+2)\mathbf{m}]| \right\}^{-1}$$

(여기서 κ 는 0.1로 가정된 가중치 파라미터임.)

청구항 7

제1항에 있어서,

상기 정제된 그린 채널을 기초로 상기 재건된 레드/블루 채널을 재차 정제하고, 상기 정제된 레드/블루 채널을 기초로 그린 채널을 정제하는 단계가 반복적으로 수행되는 것을 특징으로 하는 베이지안 기반 디모자이킹 방법.

발명의 설명

기 술 분 야

[0001] 본 발명은 카메라를 위한 베이지안 기반 영상 복원 방법에 관한 것으로, 더욱 상세하게는 베이지안 방법에 기반하여 카메라로 촬영된 풀칼라 이미지를 복원하는 디모자이킹 방법에 관한 것이다.

배 경 기 술

[0003] 단일 센서 디지털(SSD) 카메라 이미징 시스템에서는 비용을 줄이기 위해, 이미지를 등록할 때 레드(R), 그린(G), 블루(B)의 삼원색 중 단 하나의 값이 각 센서에 의해 등록되도록 카메라 렌즈가 컬러 필터 어레이(CFA: color filter array)에 덮힌다.

[0004] 일반적으로 R, G, 또는 B의 양을 정량화한 하나의 고정 비트 수(8 비트, 12 비트, 16 비트 등)가 하나의 픽셀에 저장된다. 이와 같이 픽셀은 단일 색상 정보 만을 가지므로 다른 두 색상 구성요소가 적용되어야 하는데, 이를 적용하는 과정을 디모자이킹(demosaicking)이라 한다.

[0005] 여기서 칼라 이미지 디모자이킹은, 풀-칼라(full-color) 이미지를 복원하기 위해, CFA 보간 처리가 각 픽셀 위치에서 다른 두 칼라 값을 산정하는 것을 말한다. 즉, 각 필셀 위치에서 단지 하나의 칼라 채널을 사용할 수 있기 때문에, 나머지 두 개의 누락되는 칼라 채널들은 이웃하여 존재하는 칼라 성분들의 스펙트럼 상관 관계를 이용하여 보간하는 것이다.

[0006] 도 1은 널리 이용되는 CFA인 베이어 패턴(Bayer pattern)의 예로서 7*7 베이어(Bayer) CFA 패턴을 나타낸 것이다.

[0007] 이러한 베이어 패턴에서 각 그룹은 9개의 픽셀을 가지며, 5개의 픽셀은 5개의 퀸쿤(quincunx) 방식으로 위치한 그린 픽셀이고 다른 4개의 픽셀은 레드 및 그린 픽셀이다.

[0008] 종래 Bayer 패턴을 기반으로 하는 다양한 디모자이킹 방법이 제안되었다. 이러한 방법들은 공간 또는 주파수 영역에서 세 가지 색상 평면 간의 색상 차이를 활용하여 풀 컬러 이미지를 얻도록 개발되었다.

[0009] 특히 적응 칼라 평면 보간법(adaptive color plane interpolation)은 에지 감지 보간법을 사용하는 초기 기법인데, 이 방법은 3 개의 예측 인자를 사용하고 그 다음에 색상 성분에 대해 라플라스식 2 차 미분과 그린 성분

에 대한 그래디언트 항을 사용하는 에지 분류기를 통해 그 중 하나를 선택하였다. 이러한 접근법을 기반으로 하는 추가적인 몇가지 방법이 제안된 바 있다.

[0010] 그러나 종래의 방법들은 단지 오브젝트의 경계에서만 견고하고, 엣지(edge)에 걸쳐서는 부정확한 결과가 발생하여, 추정 알고리즘의 정확도가 떨어지는 문제가 있었다.

발명의 내용

해결하려는 과제

[0012] 상기의 문제점을 해결하고자 본 발명은 포인트와 경로의 유사성을 고려한 하이브리드 방식의 베이지안 기반 디모자이킹 방법을 제공하는 것을 목적으로 한다.

과제의 해결 수단

[0014] 상기 기술적 과제를 해결하기 위하여 본 발명은 이미지에 대한 베이어(Bayer) 패턴을 생성하는 단계, 최적의 베이지안 추정치(Optimal Bayesian Estimator, OBE)를 산출하는 단계, 상기 베이어 패턴에 대하여, 상기 산출된 최적의 베이지안 추정치를 이용하여 그린 채널을 재건(Reconstruction)하는 단계, 상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건하는 단계 및 상기 재건된 그린 채널을 정제(Refinement)하는 단계를 포함하는 것을 특징으로 한다.

[0015] 또한 상기 최적의 베이지안 추정치($\hat{\mathbf{y}}_{\mathrm{OBE}}$)는 하기 (수학식 1)로 표현되는 것을 특징으로 한다.

[0016] 또한 상기 최적의 베이지안 추정치를 이용하여 재건된 그린 채널($\hat{\mathbf{y}}_G(\mathbf{k})$)은 하기 (수학식 2)로 표현되고, (수학식 3)을 기준으로 정해지는 것을 특징으로 한다.

[0017] 또한 상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건하는 과정은, 하기 (수학식 4)로 수행되는 것을 특징으로 한다.

[0018] 또한 상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건하는 과정은, 하기 (수학식 5)와 같은 과정이 추가적으로 수행되는 것을 특징으로 한다.

[0019] 또한 상기 재건된 그린 채널을 정제(Refinement)하는 과정은 하기 (수학식 6)으로 수행되는 것을 특징으로 한다.

[0020] 또한 상기 정제된 그린 채널을 기초로 상기 재건된 레드/블루 채널을 재차 정제하고, 상기 정제된 레드/블루 채널을 기초로 그린 채널을 정제하는 단계가 반복적으로 수행되는 것을 특징으로 한다.

발명의 효과

[0022] 본 발명의 실시 예들에 따른 베이지안 기반 디모자이킹 방법의 효과에 대해 설명하면 다음과 같다.

[0023] 본 발명은 종래의 디모자이킹 방법과 비교하여 고효율, 고성능을 유지하면서 CPSNR, S-CIELAB, FSIM 및 지퍼 효과 측정을 개선할 수 있다.

[0024] 또한 가우시안 및 푸아송 노이즈가 존재하는 이미지를 효율적으로 처리할 수 있다.

[0025] 다만, 본 발명의 실시 예들에 따른 베이지안 기반 디모자이킹 방법이 달성할 수 있는 효과는 이상에서 언급한 것들로 제한되지 않으며, 언급하지 않은 또 다른 효과들은 아래의 기재로부터 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 명확하게 이해될 수 있을 것이다.

도면의 간단한 설명

[0027] 본 발명에 관한 이해를 돕기 위해 상세한 설명의 일부로 포함되는, 첨부도면은 본 발명에 대한 실시예를 제공하고, 상세한 설명과 함께 본 발명의 기술적 사상을 설명한다.

도 1은 CFA인 베이어 패턴(Bayer pattern)의 예로서 7*7 베이어(Bayer) CFA 패턴을 나타낸 것이다.

도 2는 베이어(Bayer) CFA에서 저해상도(low resolution)영역을 관찰한 것이다.

도 3은 본 발명에 따른 베이지안 기반 디모자이킹 방법을 도시한 순서도이다.

도 4는 이미지 통계 모델(image statistic model)을 도시한 것이다.

도 5는 통계 모델(statistical model)과 경험적 히스토그램(empirical histogram)을 가우시안 분포와 라플라스 분포의 서로 다른 변수와 비교한 것이다.

도 6은 이웃한 지역의 픽셀 구조를 나타낸 것이다.

도 7은 디모자이킹을 수행하기 위한 테스트 이미지이다.

도 8 내지 도 10은 본 발명을 포함한 다양한 방법으로 수행된 디모자이킹된 이미지이다.

발명을 실시하기 위한 구체적인 내용

[0028] 본 명세서 및 특허청구범위에 사용된 용어나 단어는 통상적이거나 사전적인 의미로 한정하여 해석되어서는 아니되며, 발명자는 그 자신의 발명을 가장 최선의 방법으로 설명하기 위해서 용어의 개념을 적절하게 정의할 수 있다는 원칙에 입각하여, 본 발명의 기술적 사상에 부합되는 의미와 개념으로 해석되어야만 한다. 따라서 본 명세서에 기재된 실시예와 도면에 도시된 구성은 본 발명의 가장 바람직한 하나의 실시예에 불과할 뿐이고, 본 발명의 기술적 사상을 모두 대변하는 것은 아니므로, 본 출원시점에 있어서 이들을 대체할 수 있는 다양한 균등물과 변형예들이 있을 수 있음을 이해하여야 한다. 이하에서는, 첨부된 도면을 참조하여 본 발명의 실시예에 따른 베이지안 기반 디모자이킹 방법을 상세하게 설명하기로 한다.

[0030] 도 2는 베이어(Bayer) CFA에서 저해상도(low resolution)영역을 관찰한 것이고, 도 3은 본 발명에 따른 베이지안 기반 디모자이킹 방법을 도시한 순서도이다.

[0031] 디모자이킹 알고리즘은 모자이크 처리된 이미지에서 근본적인(underlying) 원본 트루 컬러 이미지를 복구한다. 본 발명은 알고리즘에 있어 이를 maximum a posteriori(MAP) 문제로 간주한다. MAP 문제를 명확히하기 위해 통계적 해석을 수행하고, 베이지안 기반의 방법을 이용하는 동기를 제시한다. MAP 문제는 누락 된 색상 픽셀과 그 인접 색상 픽셀 간의 잔여 값(residual value) 분포에 초점을 두고 있다. 포인트 와이즈(pointwise) 모델은 큰 스케일의 구조를 보존하고, 패치 위의 모델은 큰 검색 영역에서 기하학적 윤곽과 미세 스케일 구조를 제공한다. 본 발명은 pointwise 및 patchwise 모델을 검사한다. pointwise 모델은 대규모 구조를 보존하고, patchwise 모델은 큰 검색 영역에서 기하학적 개요 및 미세 스케일 구조를 제공한다. 복잡도 측면에서 pointwise 모델은 patchwise 모델보다 간단하고 효율적이다.

[0032] 본 발명은 포인트 및 패치 구조의 다른 장점을 활용하기 위해, 두 모델의 선형 조합(linear combination)으로 설계되는 적응형 하이브리드 모델을 제시하고, 매개 변수는 구조적 특징을 나타내는 표준 편차를 통해 적응적으로 조절되도록 한다. 본 발명은 누락된 그린 채널을 보간 한 후, 지역의 균일 한 색상 차이를 이용하여 레드/블루 채널을 추정한다. 이 후, 본 발명에 따른 디모자이킹 방법의 효과를 증명하고자 가우시안 및 푸 아송 잡음이 많은 이미지에 디 모자이크 알고리즘을 적용한다. 이하 본 발명에 따른 디모자이킹 방법을 상세히 설명한다.

[0033] 본 발명에 따른 베이지안 기반 디모자이킹 방법은 이미지에 대한 베이어(Bayer) 패턴을 생성하는 단계(S100), 최적의 베이지안 추정치(Optimal Bayesian Estimator, OBE)를 산출하는 단계(S200), 상기 베이어 패턴에 대하여, 상기 산출된 최적의 베이지안 추정치를 이용하여 그린 채널을 재건(Reconstruction)하는 단계(S300), 상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건하는 단계(S400) 및 상기 재건된 그린 채널을 정제(Refinement)하는 단계(S500)를 포함한다.

[0034] S100 단계에서는 이미지에서 디모자이킹을 수행하기 위한 베이어(Bayer) 패턴을 생성하는 단계이고, S200 단계는 최적의 베이지안 추정치를 산출하는 단계이다. 최적의 베이지안 추정치($\hat{\mathbf{y}}_{\mathrm{OBE}}$)를 산출하는 과정에 대하여 상세히 설명한다.

[0035] 모자이크 처리된 이미지를 $\mathbf{x}(\mathbf{k}) = [\mathbf{x}_{\mathbf{R}}(\mathbf{k})\mathbf{x}_{\mathbf{G}}(\mathbf{k})\mathbf{x}_{\mathbf{B}}(\mathbf{k})]$ 라 가정한다. 여기서 $\mathbf{k} = (i, j) \in R^2$ 는 이미지 좌표 인덱스이다.

[0036] 한편, 도 2에 도시된 바와 같이 진정한 원래의 컬러 이미지 $\mathbf{y} = [\mathbf{y}_{\mathbf{R}}(\mathbf{k})\mathbf{y}_{\mathbf{G}}(\mathbf{k})\mathbf{y}_{\mathbf{B}}(\mathbf{k})]$ 가 상기 $\mathbf{x}$와 매우 관련이 있다고 가정한다. 추정량 $\hat{\mathbf{y}}$ 는 모든 추정량 중에서 $E[L(\mathbf{y}, \hat{\mathbf{y}})|\mathbf{x}]$ 를 최소화하면 베이즈(bayes) 추정량으

로 간주될 수 있다. 이는 실질적으로 MAP 솔루션과 동일하다. $L(\mathbf{y},\widehat{\mathbf{y}})$ 은 추정값과 실제 값의 차이의 함수로 사용되는 손실 함수이다. 2차 손실함수 $L(\mathbf{y},\widehat{\mathbf{y}}) = \|\widehat{\mathbf{y}}-\mathbf{y}\|^2$ 는 신호 처리에 일반적으로 사용되는며, 함수이며, 여기서 $\lambda(\mathbf{y})$ 는 상수이다.

[0037] 최적의 베이지안 추정치(Optimal Bayesian estimator, OBE)($\widehat{\mathbf{y}}_{\mathrm{OBE}}$)는 $E[L(\mathbf{y},\widehat{\mathbf{y}})|\mathbf{x}]$ 를 하기 (수학식 1)과 같이 최소화함으로써 결정된다.

[0038] (수학식 1)

$$\widehat{\mathbf{y}}_{\mathrm{OBE}} = \arg\min_{\widehat{\mathbf{y}}} E[\|\widehat{\mathbf{y}}-\mathbf{y}\|^2|\mathbf{x}]$$

[0039]

[0040] 2차 손실함수의 가정에 기초하여, OBE는 하기 (수학식 2)와 같이 표현될 수 있다.

[0041] (수학식 2)

$$\widehat{\mathbf{y}}_{\mathrm{OBE}} = E[\mathbf{y}|\mathbf{x}] = \sum_{\mathbf{y}\in\Lambda}\mathbf{y}p(\mathbf{y}|\mathbf{x}) = \frac{\sum_{\mathbf{y}\in\Lambda}\mathbf{y}p(\mathbf{x}\mathbf{y})}{p(\mathbf{x})}$$

[0042]

[0043] 여기서 Λ 는 $\mathbf{y}\ (|\Lambda| = 256^n \text{ if } y(x)\in\{0,\ldots,255\})$ 의 모든 구성(all configuration)의 넓은 공간(large space)이다. 여기서 파라미터 n 은 데이터의 크기이다. 베이즈 법칙(Bayes rules)과 총 확률 법칙(law of total probability)을 사용함으로써 하기와 같은 식을 얻을 수 있다.

$$p(\mathbf{x},\mathbf{y}) = p(\mathbf{x}|\mathbf{y})p(\mathbf{y}), \quad p(\mathbf{x}) = \sum_{\mathbf{y}\in\Lambda}p(\mathbf{x}|\mathbf{y})(\mathbf{y})$$

[0044]

[0045] 이를 기초로 상기 (수학식 2)를 하기 (수학식 3)과 같이 수정할 수 있다.

[0046] (수학식 3)

$$\widehat{\mathbf{y}}_{\mathrm{OBE}} = \frac{\sum_{\mathbf{y}\in\Lambda}\mathbf{y}p(\mathbf{x}|\mathbf{y})(\mathbf{y})}{\sum_{\mathbf{y}\in\Lambda}p(\mathbf{x}|\mathbf{y})(\mathbf{y})}$$

[0047]

[0048] 수학식 (3)에서, 최적 추정치 $\widehat{\mathbf{y}}_{\mathrm{OBE}}$ 를 얻기 위해서, $\mathbf{x}|\mathbf{y}$ 의 분포와 사전 분포(prior distribution)로 알려진 $\mathbf{y}$ 의 분포를 결정한다. 분포를 유도하고자, 같은 위치에 존재하는 픽셀 대신 보간된 픽셀을 중심으로 한 로컬 이웃 영역(local neighbor region) S_y 에서 관측치(observation)를 사용할 필요가 있다. 로컬 영역 S_y 에서, $\mathbf{y}$ 의 사전분포는 균등 분포(uniform distribution)라 가정한다. 즉 $p(\mathbf{y}) = 1/|S_y|$ 이다.

[0049] 이 때, 국부적인 이웃 영역에서, 관찰이 유사한 구조를 가지고 있다고 가정한다. 최적 추정을 위해 하기 (수학식 4)와 같은 근사값을 사용한다.

[0050] (수학식 4)

$$\frac{1}{|S_y|}\sum_{\mathbf{m}\in S_y}\mathbf{y}(\mathbf{k}+\mathbf{m})p[\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})] \rightarrow \sum_{\mathbf{y}\in\Lambda}\mathbf{y}p(\mathbf{x}|\mathbf{y})p(\mathbf{y})$$

$$\frac{1}{|S_y|}\sum_{\mathbf{m}\in S_y}p[\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})] \rightarrow \sum_{\mathbf{y}\in\Lambda}p(\mathbf{x}|\mathbf{y})p(\mathbf{y}).$$

[0051]

[0052] 이를 이용하면, (수학식 3)은 하기 (수학식 5)와 같이 변경된다.

[0053] (수학식 5)

$$\hat{\mathbf{y}}_{\mathrm{OBE}} \approx \frac{\frac{1}{|S_y|}\sum_{\mathbf{m}\in S_y}\mathbf{y}(\mathbf{k}+\mathbf{m})p[\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})]}{\frac{1}{|S_y|}\sum_{\mathbf{m}\in S_y}p[\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})]}.$$

[0054]

[0055] 여기서 $\mathbf{k}+\mathbf{m}$ 은 정사각형 영역 $(2ws+1)\times(2ws+1)$ 내의 임의의 이웃 픽셀일 수 있다. 본 발명에서는 고효율(high efficiency)을 위해 $ws=1$ 를 선택한다. 이 때, 목표는 $\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})$ 의 분포를 찾는 것으로 변경된다.

[0056] 도 4는 이미지 통계 모델(image statistic model)을 도시한 것으로, (a)는 원본 이미지, (b)는 레드 컬러 채널에서 $p[\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})]$ 을, (c)는 그린 컬러 채널에서 $p[\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})]$ 을, (d)는 블루 컬러 채널에서 $p[\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})]$ 이다. 그리고 (e)는 레드 컬러 채널에서 $p[\mathbf{x}(\mathbf{k})-\mathbf{y}(\mathbf{k}+\mathbf{m})|\mathbf{y}(\mathbf{k}+\mathbf{m})]$ 을, (f)는 그린 컬러 채널에서의 $p[\mathbf{x}(\mathbf{k})-\mathbf{y}(\mathbf{k}+\mathbf{m})|\mathbf{y}(\mathbf{k}+\mathbf{m})]$, (g)는 블루 컬러 채널에서의 $p[\mathbf{x}(\mathbf{k})-\mathbf{y}(\mathbf{k}+\mathbf{m})|\mathbf{y}(\mathbf{k}+\mathbf{m})]$ 를 나타낸다.

[0057] 도 4의 (b) 내지 (d)를 참조하면, 3가지 색상 채널 모두가 명백한 통계적 특성을 가지고 있지 않음을 보여준다. 잔여 이미지(residual images)의 히스토그램을 기반으로 $\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})$ 대신 $\mathbf{x}(\mathbf{k})-\mathbf{y}(\mathbf{k}+\mathbf{m})|\mathbf{y}(\mathbf{k}+\mathbf{m})$ 의 분포를 유도한다.

[0058] 도 4의 (e) 내지 (g)를 참조하면, $\mathbf{x}(\mathbf{k})-\mathbf{y}(\mathbf{k}+\mathbf{m})|\mathbf{y}(\mathbf{k}+\mathbf{m})$ 가 명확한 통계적 특징을 가지고 있음을 알 수 있다. 가우시안(Gaussian)과 라플라시안(Laplacian)과 같은 두 가지 잘 알려진 배포판(distributions)은 이런 종류의 형식을 가지고 있다. 이 두 종류의 분포를 추후 다른 매개 변수와 비교한다. 라플라시안 분포는 가우스 분포 보다 통계적 특성에 더 적합하다. $\mathbf{x}(\mathbf{k})|\mathbf{y}(\mathbf{k}+\mathbf{m})$ 의 분포는 라플라시안 분포를 따른다.

[0059] (수학식 5)는 하기 (수학식 6)과 같이 수정될 수 있다.

[0060] (수학식 6)

$$\hat{\mathbf{y}}_G(\mathbf{k}) = \frac{\sum_{\mathbf{m}\in S_y}\tilde{\mathbf{y}}_G(\mathbf{k}+\mathbf{m})C(\mathbf{y})}{\sum_{\mathbf{m}\in S_y}C(\mathbf{y})}$$

[0061]

[0062] 여기서 $C(\mathbf{y})=\exp[-\|\mathbf{v}_G(\mathbf{k})-\mathbf{v}_G(\mathbf{k}+\mathbf{m})\|_1/\alpha]$ 이다. 가중치 파라미터 α 는 통계모델에서 중요한 역할을 수행한다.

[0063] 도 5는 통계 모델(statistical model)과 경험적 히스토그램(empirical histogram)을 가우시안 분포와 라플라스 분포의 서로 다른 변수와 비교한 것이다. (a)는 $f(x)=3.8\times10^{-5}\exp(-0.026x^2)$, (b)는 $f(x)=4.6\times10^{-5}\exp(-0.16|x|)$, (c)는 $f(x)=2.8\times10^{-5}\exp(-0.0081x^2)$, (d)는 $f(x)=4.2\times10^{-5}\exp(-0.137|x|)$, (e)는 $f(x)=1.7\times10^{-5}\exp(-0.0028x^2)$, (f)는 $f(x)=3\times10^{-5}\exp(-0.096|x|$ 이다.

[0064] 도 5의 좌측에 도시된 바와 같이, 상이한 가중치 파라미터 α 에서 매칭은 가변적 특징을 가진다. 도 5에서는 잔여 이미지(residual images)의 경험적 히스토그램을 나타내고, 경험적 히스토그램을 다양한 매개 변수의 이전 통계 모델과 비교하였다. 왼쪽 위부터 왼쪽 아래까지의 가중치 파라미터 α 는 0.35, 0.36 및 0.4 이다. 맨 위

는 α가 가장 작은 매개 변수를 나타내며, 0에서 양호한 매칭을 이루지만 꼬리에서는 실패한 것을 알 수 있다.

[0065] 아래쪽은 가장 큰 α를 가진 매개 변수를 나타내며 꼬리 부분에서는 양호한 일치를 이루지만 0 에서는 실패한다 도 5에서 너비(width)는 높이(height)보다 더 중요한 역할을 한다. 이는 잔차가 0 일 때, 픽셀은 평탄한 영역에 있는데 이 경우, 종래의 방법으로 재구성되기 쉽기 때문이다. 이미지 복구 측면에서, 에지(edge) 또는 텍스처(textures)와 같은 복잡한 영역, 즉 분포의 꼬리에 중점을 둔다.

[0066] 꼬리는 너비에 의해 제어된다. 경험적 히스토그램과의 최상의 매칭을 달성하기 위해, 적응성 가중치 파라미터를 상이한 픽셀 값에 할당해야 한다. 즉, 큰 잔여 값은 큰 가중치 매개 변수를 가져야하고 작은 잔여 값은 작은 값을 가져야한다. 따라서, 국소 영역에서 보간될 화소의 분산에 비례하는 적응 가중 파라미터를 설계한다. 이는 하기 (수학식 7)과 같이 설계될 수 있다.

[0067] (수학식 7)

$$\alpha = \lambda\sigma_m = \sum_{\mathbf{m}\in S_y} \frac{\lambda\|\mathbf{x}(\mathbf{k}+\mathbf{m}) - \bar{\mathbf{x}}\|}{|S_y|}$$

[0068]

[0069] 여기서 $\bar{\mathbf{x}}$는 $(2ws+1)\times(2ws+1)$ 크기의 국소 영역 S_y에서의 기대값이다. (수학식 6)을 통해, 칼라 이미지의 최적의 추정을 얻기위해, 원래 이미지 $\mathbf{y}(\mathbf{k}+\mathbf{m})$를 결정한다.

[0070] 원본 이미지는 부분적으로 알 수 없지만, 부분적으로 모자이크 처리된 이미지에 표시된다. 따라서 (수학식 6)에서 우리는 주어진 모자이크 처리된 컬러 픽셀값의 추정된 방향값으로 알려지지 않은 $\mathbf{y}(\mathbf{k}+\mathbf{m})$를 대입한다.

[0072] S300 단계에서는 상기 베이어 패턴에 대하여, S200 단계에서 산출된 최적의 베이지안 추정치를 이용하여 그린 채널을 재건(Reconstruction)한다.

[0073] 먼저 그린 채널을 재건(또는 복원)한 다음, 전체 그린 채널과 주어진 모

[0074] 자이크 색상 픽셀을 기반으로 레드/블루 채널을 재구성한다.

[0075] 도 1을 다시 참조하면, 주어진 레드/블루 픽셀에서 누락된 그린 픽셀이 북쪽, 남쪽, 서쪽 및 동쪽 방향에서 가장 가까운 4 개의 주어진 그린 픽셀로 둘러싸인 것을 알 수 있다. 누락된 그린 픽셀에는 여전히 레드/블루 픽셀이 존재한다. 따라서 누락된 그린 픽셀을 재구성하기 위해, 이러한 측면을 고려해야한다. 모자이크 처리된 이미지에는 모든 위치에 픽셀 값을 가진다는 특수한 특징이 있다.

[0076] 이러한 모자이킹 이미지의 특수한 속성에 기초하여, 상기 수학식 (6)의 4방향에서의 그린 픽셀을 직접 사용하는 대신, 하기 (수학식 8)과 같이 테일러 근사를 사용하여 근사된 4방향의 색상값을 주어진 색상 픽셀 값으로 제공할 수 있다.

[0077] (수학식 8)

$$\mathbf{y}_G(\mathbf{k}+\mathbf{m}) = \mathbf{x}_G(\mathbf{k}+\mathbf{m}) + \frac{\mathbf{x}_R(\mathbf{k}) - \mathbf{x}_R(\mathbf{k}+2\mathbf{m})}{2} + \frac{\mathbf{x}_R(\mathbf{k}+3\mathbf{m}) + \mathbf{x}_R(\mathbf{k}-\mathbf{m}) - 2\mathbf{x}_R(\mathbf{k}+\mathbf{m})}{8}$$

[0078]

[0079] 수학식 (6)에서 거리 $\|\mathbf{x}(\mathbf{k}) - \mathbf{y}(\mathbf{k}+\mathbf{m})\|$에 대한 두 후보자로 pointwise와 patchwise가 있다. patchwise 거리는 넓은 지역의 이미지의 구조를 보존하는 것을 목표로 한다. 작은 검색 영역에서 특히 이미지 복원 측면에서, pointwise 유사성은 대규모 구조를 처리하는데 중요한 역할을 한다. 누락된 색상 픽셀을 추정하려면 pointwise 와 patchwise의 거리를 모두 고려해야 한다. 따라서 본 발명은 하기 (수학식 9)와 같은 하이브리드 베이지안 추정(HBE)-BD 알고리즘을 이용한다.

[0080] (수학식 9)

$$C(\mathbf{y}) = \exp\left[\frac{-\|\mathbf{v}_G(\mathbf{k}) - \mathbf{v}_G(\mathbf{k}+\mathbf{m})\|_1}{2\alpha}\right] + \mu \exp\left[\frac{-\|\mathbf{x}_R(\mathbf{k}) - \mathbf{x}_R(\mathbf{k}+\mathbf{m})\|_1}{\alpha}\right]$$

[0081]

[0082] 여기서 $\mathbf{v}_G(\mathbf{k})$ 와 $\mathbf{v}_G(\mathbf{k}+\mathbf{m})$ 는 센터의 레드 픽셀과 4개의 인접한 그린 픽셀을 포함하는 패치 벡터(patch vectors)이다. 도 6은 이웃한 지역의 픽셀 구조를 나타낸 것으로, 인접한 지역 S_y가 나타나 있다. 이 알고리즘에서 μ 는 0.1이다. 도 6의 (a)에는 $1 \times (2ws+1)$ 크기를 가지는 수평 방향 컬러 픽셀을 포함하는 영역 S_y^H 가, (b)는 $(2ws+1) \times 1$ 크기를 가지는 수직 방향 컬러 픽셀을 포함하는 영역 S_y^V 가, (c)는 $(2ws+1) \times (2ws+1)$ 크기를 가지는 4개의 레드 픽셀을 포함하는 영역 S_y^{RB} 가 도시되어 있다.

[0083] 다양한 방향이나 질감과 같은 복잡한 특징이있는 이미지의 경우, (수학식 6)은 좋은 성능을 얻을 수 있다. 수평 및 수직 에지의 특수한 경우에 대해 우리는 주어진 픽셀을 수평 또는 수직 방향으로 적용하여 누락된 컬러 픽셀을 재구성해야 한다. 수평 및 수직 방향은 대부분의 이미지에 존재하며 한 이미지에서 큰 비율을 차지한다. 따라서 (수학식 6)을 수정하고 수평 및 수직 성분을 하기 (수학식 10)과 같이 채택하여 두 방향을 추정할 수 있다.

[0084] (수학식 10)

$$\hat{\mathbf{y}}_G^H(\mathbf{k}) = \frac{\sum_{\mathbf{m}\in S_y^H} \tilde{\mathbf{y}}_G(\mathbf{k}+\mathbf{m}) C(\mathbf{y})}{\sum_{\mathbf{m}\in S_y^H} C(\mathbf{y})}$$

$$\hat{\mathbf{y}}_G^V(\mathbf{k}) = \frac{\sum_{\mathbf{m}\in S_y^V} \tilde{\mathbf{y}}_G(\mathbf{k}+\mathbf{m}) C(\mathbf{y})}{\sum_{\mathbf{m}\in S_y^V} C(\mathbf{y})}$$

[0085]

[0086] 여기서 S_y^H 및 S_y^V 는 수평 및 수직방향으로 크기가 각각 $1 \times (2ws+1)$ 및 $(2ws+1) \times 1$ 인 주어진 색상 픽셀을 포함하는 영역이다. $C(\mathbf{y})$ 는 (수학식 9)에 기재되어 있다.

[0087] 이후, 방향을 구별하기 위해 하기 (수학식 11)과 같은 기준을 설정한다.

[0088] (수학식 11)

$$\bar{\bar{\mathbf{y}}}_G(\mathbf{k}) = \begin{cases} \hat{\mathbf{y}}_G^H(\mathbf{k}), & \text{if } \delta(\mathbf{k}) > T_1 \\ \hat{\mathbf{y}}_G^V(\mathbf{k}), & \text{if } \delta(\mathbf{k}) < -T_1 \\ \hat{\mathbf{y}}_G(\mathbf{k}), & \text{otherwise} \end{cases},$$

$$\delta(\mathbf{k}) = \begin{cases} 1, & \text{if } \min(\mathbf{D}_H(\mathbf{k}), \mathbf{D}_V(\mathbf{k}), T_2) = \mathbf{D}_H(\mathbf{k}) \\ -1, & \text{if } \min(\mathbf{D}_H(\mathbf{k}), \mathbf{D}_V(\mathbf{k}), T_2) = \mathbf{D}_V(\mathbf{k}) \\ 0, & \text{otherwise} \end{cases},$$

$$\mathbf{D}_H = \mathbf{x} * \mathbf{f} + (\mathbf{x} - \hat{\mathbf{y}}_G^H) * \mathbf{f},$$

$$\mathbf{D}_V = \mathbf{x} * \mathbf{f}' + (\mathbf{x} - \hat{\mathbf{y}}_G^V) * \mathbf{f}',$$

[0089]

[0090] 여기서 T 는 임계값이다. 그리고 $\mathbf{D}_H$ 및 $\mathbf{D}_V$ 는 정규화된 파라미터이다. 이를 통해 보간된 전체 그린 채널을 얻을 수 있다.

[0092] S400 단계에서는 상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건한다.

[0093] 앞서 S300 단계에서 그린 평면을 완전히 얻었으므로, 이를 기초로 레드/블루 픽셀을 블루/레드 또는 그린 위치에 채운다. 레드/블루 채널의 재구성에 있어, 색상 채널 간의 강한 상관관계 때문에 복원된 그린 색상 채널을 사용할 수 있다.

[0094] 도 1과 같이 주어진 블루 채널 위치에서 누락된 레드 픽셀을 재구성하기 위해, 주어진 네 개의 레드 픽셀이 주어진 블루 픽셀 주위에 위치한다. 이 때, 하기 (수학식 12)와 같이 재구성된 그린 픽셀을 기반으로하는 색상 차이를 이용한다.

[0095] (수학식 12)

$$\bar{\mathbf{y}}_R(\mathbf{k}) = \bar{\mathbf{y}}_G(\mathbf{k}) + \frac{\sum_{\mathbf{m} \in S_y^{RB}} \Delta(\mathbf{k}+\mathbf{m}) C(\mathbf{y})}{\sum_{\mathbf{m} \in S_y^{RB}} C(\mathbf{y})},$$

$$\Delta(\mathbf{k}+\mathbf{m}) = \mathbf{x}_R(\mathbf{k}+\mathbf{m}) - \bar{\mathbf{y}}_G(\mathbf{k}+\mathbf{m}),$$

$$C(\mathbf{y}) = \exp\left[\frac{-\|\mathbf{v}_R(\mathbf{k}) - \mathbf{v}_R(\mathbf{k}+\mathbf{m})\|_1}{\beta}\right], + \mu \exp\left[\frac{-\|\bar{\mathbf{y}}_G(\mathbf{k}) - \bar{\mathbf{y}}_R(\mathbf{k}+\mathbf{m})\|_1}{\beta}\right],$$

$$\beta = \frac{\alpha}{2},$$

[0096]

[0097] 여기서 $\mathbf{v}_R(\mathbf{k})$ 와 $\mathbf{v}_R(\mathbf{k}+\mathbf{m})$ 는 북서쪽, 북동쪽, 남서쪽 및 남동쪽에 위치한 4 개의 레드 픽셀을 포함하는 패치 벡터이고 S_y^{RB} 은 도 5의 (c)와 같이 크기가 $(2ws+1) \times (2ws+1)$ 인 동일한 4 개의 레드 픽셀을 포함한다.

[0098] 주어진 G 픽셀에서 누락된 레드/블루 픽셀에 대해, 도 1에 도시된 바와 같이 (수학식 13)이 적용된다.

[0099] (수학식 13)

$$\bar{\mathbf{y}}_R(\mathbf{k}) = \bar{\mathbf{y}}_G(\mathbf{k}) + \frac{\sum_{\mathbf{m}\in S_y^{RG}} \Delta(\mathbf{k}+\mathbf{m})C(\mathbf{y})}{\sum_{\mathbf{m}\in S_y^{RG}} C(\mathbf{y})},$$

$$\Delta(\mathbf{k}+\mathbf{m}) = \mathbf{x}_R(\mathbf{k}+\mathbf{m}) - \bar{\mathbf{y}}_G(\mathbf{k}+\mathbf{m}),$$

$$C(\mathbf{y}) = \exp\left[\frac{-\|\bar{\mathbf{y}}_G(\mathbf{k}) - \bar{\mathbf{y}}_R(\mathbf{k}+\mathbf{m})\|_1}{\beta}\right],$$

[0100]

[0101] 여기서 S_y^{RG} 는 주어진 그린 픽셀 위아래의 두 개의 레드 픽셀을 포함한다.

[0103] S500 단계에서는 재건된 그린 채널을 정제(Refinement)한다.

[0104] 주어진 레드 픽셀에서, 일단 그린 채널이 식 (11)을 사용하여 채워지면, 그린 채널은 하기 (수학식 14)와 같이 더 개선될 수 있다.

[0105] (수학식 14)

$$\bar{\mathbf{y}}_R(\mathbf{k}) = \mathbf{x}_R(\mathbf{k}) + \kappa[\hat{\mathbf{y}}_G(\mathbf{k}) - \mathbf{x}_R(\mathbf{k})] + (1-\kappa)\frac{\sum_{[\mathbf{m}\in S(x)]}\Delta(\mathbf{k}+\mathbf{m})\hat{\mathbf{x}}_G(\mathbf{k}+\mathbf{m})}{\sum_{[\mathbf{m}\in S(x)]}\Delta(\mathbf{k}+\mathbf{m})},$$

$$\hat{\mathbf{x}}_G(\mathbf{k}+\mathbf{m}) = \mathbf{x}_G(\mathbf{k}+\mathbf{m}) - \bar{\mathbf{x}}_R(\mathbf{k}+\mathbf{m}),$$

$$\Delta(\mathbf{k}+\mathbf{m}) = \left\{|\hat{\mathbf{y}}_G(\mathbf{k}) - \mathbf{x}_G(\mathbf{k}+\mathbf{m})| + \sum_{a\in\{0,2\}}|\mathbf{x}_R(\mathbf{k}+a\mathbf{m}) - \mathbf{x}_R[\mathbf{k}+(a+2)\mathbf{m}]|\right\}^{-1}$$

[0106]

[0107] 여기서 κ 는 0.1로 가정된 가중치 파라미터이다. 이후 S300 단계에서와 같이 수정된 그린 채널로 레드/블루 채널을 수정한다. 최적의 결과를 얻거나 정지 조건에 도달할 때까지 위 단계를 반복적으로 수정하여 그린 채널과 레드/블루 채널을 수정한다. 다시말해, 상기 정제된 그린 채널을 기초로 상기 재건된 레드/블루 채널을 재차 정제하고, 상기 정제된 레드/블루 채널을 기초로 그린 채널을 정제하는 단계를 반복적으로 수행한다.

[0108]

[0109] 도 7은 디모자이킹을 수행하기 위한 테스트 이미지이다.

[0110] 본 발명에 따른 디모자이킹 방법의 효과의 현저성을 비교하기 위해, 512 × 768 크기의 Kodak 데이터 세트(도 7의 (a))와 2개의 고주파수 이미지(도 7의 (b), (c))에 대해 시뮬레이션을 수행하였다. 이러한 테스트 이미지는 도 7에 도시되어 있다.

[0111] AFD, VCD, HOI, ESF, EDAEP, VDI, EDUSC 및 MLRI의 8 가지 방법이 비교대상으로 선정되었다. CPSNR, S-CIELAB $\triangle E^*$, FSIM 그리고 지퍼효과(Zipper Effect, ZE) 측면에서 객관적인 성능을 평가하였다. 그런 다음 Kodak 데이터 세트에 Gaussian 및 Poisson 노이즈를 적용하고 기존의 디모자이킹 방법과 비교하여 CPSNR 결과를 측정하였다. 시뮬레이션은 Intel Core 2 Duo CPU E8500@3.16 GHz에서 수행되었으며, 창 크기 ws 는 2로 설정하였다.

[0113] 1. 객관적인 성능 분석(Objective Performance Analysis)

[0114] 먼저 CPSNR로 측정한 객관적인 성과를 비교한다. 하기 표 1은 본 발명에따른 방법의 CPSNR 결과와 기존의 다른 방법들과의 결과를 비교한 것이다.

[0115] (표 1)

Table 1 CPSNR performance comparison on the Kodak images (the best performances are marked in bold).

Image	AFD	VCD	HOI	ESF	EDAEP	VDI	MLRI	BD	Rank
1	37.558	38.419	36.564	39.909	34.919	35.343	36.805	**40.676**	1
2	40.7	40.433	40.827	40.821	39.736	39.607	40.791	**41.565**	1
3	42.686	42.537	42.71	42.554	41.749	41.318	42.987	**43.517**	1
4	41.055	40.769	40.716	40.447	40.034	39.56	**41.49**	41.363	2
5	38.039	37.783	37.634	37.55	35.782	36.542	37.657	**38.68**	1
6	38.036	39.999	38.807	41.217	36.845	36.98	39.131	**41.386**	1
7	42.907	42.133	42.722	42.154	41.261	41.828	42.841	**43.223**	1
8	35.23	36.289	34.855	37.189	32.832	33.995	34.894	**37.631**	1
9	42.57	42.85	42.391	42.959	40.902	41.687	42.377	**43.439**	1
10	42.699	42.465	42.268	42.602	40.978	41.162	42.419	**43.154**	1
11	39.338	39.889	39.128	40.693	37.476	37.685	39.305	**40.926**	1
12	42.774	43.43	43.027	43.801	41.669	41.705	43.268	**44.277**	1
13	33.769	34.798	32.767	36.106	31.484	31.233	33.141	**36.326**	1
14	37.166	37.012	37.173	36.113	36.268	36.336	37.615	**37.898**	1
15	**39.839**	39.695	39.054	39.274	38.805	38.071	39.339	39.808	2
16	41.148	43.713	42.467	**44.772**	40.441	40.65	42.879	44.289	2
17	41.392	41.519	40.852	41.953	39.631	39.639	40.985	**42.107**	1
18	37.118	37.116	36.449	37.72	35.379	34.967	36.585	**37.86**	1
19	40	40.506	39.82	41.494	37.752	38.869	39.954	**41.684**	1
20	41.117	41.128	40.629	41.523	39.26	39.744	40.681	**41.752**	1
21	38.676	39.16	37.915	40.297	36.452	36.971	38.181	**40.375**	1
22	38.512	38.072	38.031	38.409	37.173	37.123	38.614	**38.965**	1
23	43.149	42.995	43.483	42.449	42.356	41.309	**43.81**	43.726	2
24	34.832	35.103	34.162	**35.342**	33.728	32.708	34.704	35.177	2
Avg.	39.596	39.909	39.352	40.306	38.039	38.126	39.602	**40.825**	1
Diff.	1.229	0.916	1.473	0.519	2.786	2.699	1.223		

[0116]

[0117] 기존의 다른 방법으로서 AFD, VCD, HOL, ESF, EDAEP, VDL 그리고 MLRI의 7 개의 방법이 선택되었다. 표 1에 나타난바와 같이, 본 발명에 따른 디모자이킹 방법은 평균 CPSNR이 가장 높았고, 다른 방법의 이득은 1.229 (AFD), 0.916 (VCD), 1.473 (HOI), 0.519 (ESF), 2.786 (EDAEP), 2.699 (VDI) 및 1.233 (MLRI)이다. 이미지 4, 15, 16, 23 및 24는 본 발명을 사용한 경우가 최상의 CPSNR을 나타내지는 않았지만, 여전히 두번째 순위를 기록하였다.

[0118] “Diff."는 BD와 해당 방법 간의 CPSNR 차이를 보여준다. "RANK"는 기존의 비교 방법과의 순위와 BD 방법의 순위를 나타내며, 가장 높은 수치는 굵게 표시 되었다. 시각적 성능 결과를 수치로 평가하기 위해, S-CIELAB $\triangle E^*$ 메트릭(metric)을 사용하였다. S-CIELAB $\triangle E^*$ 메트릭은 원본의 S-CIELAB 표현과 재구성된 이미지의 S-CIELAB 표현사이의 거리를 결정하기 위해 개발된 CIELAB $\triangle E^*$의 공간 형태이다. Kodak 데이터 세트의 S-CIELAB $\triangle E^*$ 측정에서 본 발명(BD 방법)은 하기 표 2에 나타나있다.

[0119] (표 2)

Table 2 S-CIELAB ΔE^* results on Kodak dataset for several demosaicking methods (the best performances are marked in bold).

Image	AFD	VCD	HOI	ESF	EDAEP	VDI	MLRI	BD	Rank
1	1.1989	1.1246	1.2505	0.9954	1.4736	1.368	1.2032	**0.9648**	1
2	0.6427	0.6818	0.6442	0.6634	0.7029	0.7283	0.6615	**0.6061**	1
3	0.4889	0.501	0.4916	0.5095	0.5243	0.5413	0.4706	**0.4632**	1
4	0.6721	0.6907	0.7003	0.7266	0.7285	0.7953	**0.6406**	0.6595	2
5	**1.0136**	1.0561	1.0641	1.2419	1.2706	1.1074	1.1107	1.0406	2
6	0.9571	0.8125	0.8515	**0.7413**	0.9889	0.9498	0.8347	0.755	2
7	0.5229	0.5942	0.5277	0.5838	0.6637	0.5641	0.5364	**0.5081**	1
8	1.4127	1.2863	1.4158	1.1904	1.8245	1.4773	1.4597	**1.1727**	1
9	0.582	0.5747	0.6007	0.5852	0.6529	0.6238	0.5772	**0.5485**	1
10	0.5367	0.5563	0.5715	0.569	0.6102	0.617	0.5554	**0.5327**	1
11	0.8032	0.763	0.7803	0.7223	0.9226	0.8587	0.7695	**0.7097**	1
12	0.5062	0.4779	0.4837	0.4655	0.5501	0.529	0.4794	**0.4405**	1
13	1.6959	1.6411	1.858	**1.4771**	2.0124	2.0417	1.8216	1.5482	2
14	1.0179	0.995	0.9873	1.0433	1.1376	1.0914	0.9364	**0.8894**	1
15	**0.6423**	0.6712	0.7007	0.7215	0.6907	0.7257	0.6829	0.6673	2
16	0.6983	0.5556	0.5979	**0.508**	0.7042	0.6892	0.5628	0.5828	4
17	0.5419	0.5529	0.564	0.5426	0.6409	0.6175	0.5713	**0.5365**	1
18	**1.0077**	1.0575	1.0694	1.0919	1.16	1.1466	1.0518	1.0563	3
19	0.7821	0.7746	0.8036	0.7357	0.9565	0.8466	0.7853	**0.7343**	1
20	0.5459	0.5621	0.5764	0.5553	0.6474	0.5785	0.675	**0.5458**	1
21	0.9291	0.9172	0.9886	**0.8606**	1.0905	1.0189	0.962	0.8917	2
22	0.9421	1.0344	0.9805	1.0229	1.0563	0.9952	**0.914**	0.9243	2
23	0.5009	0.528	0.4877	0.5596	0.5359	0.5439	**0.4709**	0.4872	2
24	**1.0181**	1.0775	1.0992	1.1017	1.1561	1.1183	1.143	1.1416	6
Avg.	0.8191	0.8119	0.8373	0.8006	0.9459	0.8989	0.8282	**0.767**	1
Diff.	0.0522	0.045	0.0703	0.0337	0.1789	0.1319	0.0612		

[0120]

[0121] 표 2에 나타난 바와 같이, 본 발명에 따른 디모자이킹 방법은 각각 0.0522, 0.0450, 0.0703, 0.0337, 0.1789, 0.1319 및 0.0612의 인자를 갖는 다른 모든 방법들(AFD, VCD, HOI, ESF, EDAEP, VDI, and MLRI)보다 평균적으로 높은 성능이 나타났다.

[0122] 본 발명에 따른 방법의 성능을 더 평가하기 위해 FSIM 인덱스라는 세번째 메트릭을 채택했다. 최상의 FSIM 결과는 1.0이지만, 더 작은 FSIM은 낮은 시각 품질을 나타낸다. 하기 표 3은 다양한 방법에 대한 Kodak 데이터 세트의 수치적인 FSIM 결과를 나타낸다.

[0123] (표 3)

Table 3 FSIM results on the Kodak dataset for several demosaicking methods (the best performances are marked in bold).

Image	AFD	VCD	HOI	ESF	EDAEP	VDI	MLRI	BD	Rank
1	0.9986	0.9987	0.998	0.999	0.9974	0.9975	0.9983	**0.9992**	1
2	0.9985	0.9984	0.9982	0.9984	0.9981	0.9976	0.9983	**0.9986**	1
3	0.9993	0.9992	0.9992	0.9992	0.9991	0.9986	0.9993	**0.9994**	1
4	0.9992	0.9992	0.9989	0.9992	0.9989	0.9986	0.9992	**0.9992**	1
5	0.9989	0.9988	0.9988	0.9988	0.9982	0.9985	0.9988	**0.9991**	1
6	0.9987	0.999	0.9987	0.9993	0.9982	0.9982	0.9989	**0.9993**	1
7	0.9995	0.9995	0.9995	0.9995	0.9993	0.9993	0.9995	**0.9996**	1
8	0.9978	0.9982	0.9975	0.9985	0.9963	0.9972	0.9977	**0.9987**	1
9	0.9992	0.9992	0.999	0.9993	0.9988	0.9988	0.9991	**0.9993**	1
10	0.9993	0.9992	0.9991	0.9993	0.9989	0.9988	0.9992	**0.9993**	1
11	0.9988	0.9989	0.9986	0.9991	0.9981	0.9981	0.9988	**0.9991**	1
12	0.9991	0.9991	0.999	0.9993	0.9987	0.9987	0.9991	**0.9993**	1
13	0.9974	0.9978	0.9962	0.9985	0.9954	0.9953	0.9969	**0.9987**	1
14	0.9987	0.9987	0.9985	0.9985	0.9983	0.9979	0.9987	**0.9989**	1
15	0.9986	0.9987	0.9978	0.9985	0.998	**0.9972**	0.9983	0.9984	4
16	0.999	0.9994	0.9991	0.9995	0.9988	0.9988	**0.9993**	0.9994	2
17	0.9993	0.9993	0.9991	**0.9994**	0.9989	0.999	0.9993	**0.9994**	1
18	0.9983	0.9982	0.9977	0.9986	0.9973	0.997	0.9978	**0.9986**	1
19	0.999	0.9991	0.9987	0.9992	0.9984	0.9986	0.999	**0.9993**	1
20	0.9991	0.999	0.9989	0.9991	0.9987	0.9987	0.9991	**0.9992**	1
21	0.9985	0.9986	0.9981	0.9989	0.9976	0.9978	0.9984	**0.9989**	1
22	0.9984	0.9982	0.9981	0.9983	0.9978	0.9978	0.9985	**0.9985**	1
23	0.9993	0.9993	0.9993	0.9992	0.9992	0.999	0.9994	**0.9994**	1
24	0.9975	0.9975	0.9968	0.9977	0.9966	0.9959	0.9973	**0.9976**	2
Avg.	0.9988	0.9988	0.9985	0.9989	0.9981	0.998	0.9987	**0.999**	1
Diff.	0.0003	0.0002	0.0006	0.0001	0.0009	0.001	0.0003		

[0124]

[0126] 본 발명에 따른 방법은 다른 방법들(AFD, VCD, HOI, ESF, EDAEP, VDI, and MLRI)보다 각각 평균 0.0003, 0.0002, 0.0006, 0.0001, 0.0009, 0.0010 및 0.0003 더 높다.

[0127] ZE는 디모자이킹(demosaicking)의 성가신 결함(artifact) 중 하나로, ZE의 결과는 ZE가 포함된 픽셀의 비율을 나타낸다. 숫자가 작을수록, ZE가 포함된 이미지가 줄어든다. 하기 표 4를 참조하면 본 발명에 따른 방법이 가장 작은 ZE를 생성했음을 보여준다.

[0128] (표 4)

Table 4 ZE results on the Kodak dataset for several demosaicking methods (the best performances are marked in bold).

Image	AFD	VCD	HOI	ESF	EDAEP	VDI	MLRI	BD	Rank
1	0.384	0.348	0.396	0.299	0.461	0.442	0.416	**0.276**	1
2	0.241	0.241	0.239	0.232	0.268	0.257	0.24	**0.214**	1
3	0.128	0.122	0.127	0.111	0.146	0.142	0.128	**0.106**	1
4	0.223	0.229	0.233	0.218	0.26	0.259	0.226	**0.209**	1
5	0.308	0.314	0.307	0.294	0.383	0.338	0.324	**0.278**	1
6	0.297	0.247	0.266	**0.206**	0.322	0.312	0.268	0.207	2
7	0.145	0.158	0.147	0.149	0.181	0.158	0.153	**0.134**	1
8	0.403	0.373	0.401	0.338	0.476	0.422	0.425	**0.326**	1
9	0.181	0.172	0.2	**0.16**	0.229	0.221	0.218	0.164	2
10	0.171	0.172	0.191	0.161	0.218	0.21	0.2	**0.16**	1
11	0.25	0.231	0.238	0.194	0.282	0.273	0.24	**0.193**	1
12	0.151	0.134	0.15	**0.114**	0.176	0.169	0.151	0.117	2
13	0.475	0.45	0.495	0.408	0.538	0.537	0.504	**0.397**	1
14	0.282	0.261	0.277	0.234	0.337	0.316	0.289	0.234	1
15	0.212	0.213	0.226	0.204	0.245	0.238	0.23	**0.203**	1
16	0.209	0.157	0.181	**0.128**	0.223	0.213	0.178	0.151	2
17	0.174	0.171	0.189	0.156	0.227	0.215	0.193	**0.153**	1
18	0.346	0.352	0.367	0.341	0.4	0.392	0.371	**0.334**	1
19	0.273	0.254	0.285	0.233	0.335	0.304	0.29	**0.231**	1
20	0.243	0.246	0.253	0.232	0.274	0.259	0.248	**0.231**	1
21	0.285	0.273	0.299	**0.244**	0.335	0.318	0.308	0.246	2
22	0.298	0.316	0.315	0.299	0.339	0.32	0.307	**0.286**	1
23	0.154	0.166	0.161	0.16	0.173	0.165	0.161	**0.151**	1
24	0.259	0.261	0.27	0.241	0.319	0.284	0.281	**0.237**	1
Avg.	0.254	0.244	0.259	0.223	0.298	0.282	0.265	**0.218**	1
Diff.	0.036	0.026	0.041	0.005	0.08	0.064	0.046		

[0129]

[0130] 본 발명에 따른 방법은 다른 방법(AFD, VCD, HOI, ESF, EDAEP, VDI 및 MLRI)보다 평균이 각각 0.036, 0.026, 0.041, 0.005, 0.080, 0.064 및 0.046 만큼 높았다.

[0132] 2. 시각적 성능 분석(Visual Performance Analysis)

[0133] 여기서는 본 발명에 따른 디모자이킹 방법과 기존 방법의 주관적인 성능을 비교한다.

[0134] 도 8 내지 도 10은 본 발명을 포함한 다양한 방법으로 수행된 디모자이킹된 이미지이다. 도 8 내지 10은 시각적 비교에서 재구성된 이미지와 주관적인 성능을 보여준다. 앨리어싱(Aliasing)은 신호 정보 손실 및 고주파 구성 요소의 잘못된 복원으로 인해 이미지 세부 정보 근처에서 발생된다. 따라서 이미지를 재구성함에 있어 중요한 초점은 이미지 가장자리의 품질이다.

[0135] 도 8은 Kodak #8의 확대/축소 디모자이킹 이미지를 보여준다. 도 8을 참조하면, 본 발명에 따른 디모자이킹 방법이 백색(white)을 재구성하는 경우, 더 나은 시각적 성능을 가지고 있음을 알 수 있다. 이러한 근거 중 하나는 다른 기존의 방법 결과는 주황색-청색의 결함이 나타난다는 사실이다. 예를 들어 VDI 방법은 도 7의 (g)에서 보여지는 좋은 시각 품질을 보여주나, 다른 주관적인 성능과 비교할 때 CPSNR과 같은 알고리즘보다 훨씬 품질이 떨어진다. 실제 VDI는 제안된 알고리즘보다 약 4dB 낮은 수치가 나타난다.

[0136] 고주파 영상에서 주관적 성능을 평가하기 위해 색반경 해상도 차트(color radial resolution chart)를 적용하였다. TE216 및 TE253 이미지에서 8 가지 방법을 테스트했으며 결과는 도 9 및 도 10에 도시되어 있다.

[0137] 본 발명에 따른 디모자이킹 방법은 고주파 영역에서 최상의 시각 품질을 제공하는 반면, 기존의 방법들은 주황색-보라색 결함이 나타났다. 실제 본 발명에 따른 방법과 기존의 방법으로 생성된 결과 이미지의 품질을 평가하기 위해 20 명의 관찰자를 모집하였다. 모든 관찰자에게 각 결과 이미지에 0 에서 10까지의 점수를 요청하였다. 결과 이미지가 원래 이미지와 동일하면 점수 10이 책정되며, 결과 이미지가 원본 이미지보다 나쁠 경우 낮은 점수가 책정되도록 하였다. 표 5는 20 명의 관찰자가 평가한 평균 점수를 보여준다. 하기 표 5를 참조하면, 본 발명에 따른 방법이 가장 우수한 평가를 받은 것을 알 수 있다.

[0138] (표 5)

Table 5 Subjective performance assessment by observers' evaluation.

Method	VCD	HOI	ESF	EDAEP	EDUSC	BD	Rank
Score	9.2098	9.2404	9.118	9.3016	9.3475	9.4546	1

[0139]

[0141] 3. 노이즈 상태에서의 성능 비교(Performance Comparison in the Noise Condition)

[0142] 센서에서 이미지를 가져오는 동안 노이즈가 발생할 수 있다. 본 발명에 따른 방법의 견고성(robustness)을 평가하기 위해 Gaussian 및 Poisson 노이즈를 적용하여 오염된(contaminated) Kodak 이미지에 대한 실험을 수행하였다. VCD, HOI, ESF, EDAEP, EDUSC 등 5 가지의 기존 방법을 비교에 사용하였다.

[0144] 3.1 가우시안 노이즈의 경우(Gaussian noise case)

[0145] 하기 표 6은 가우시안 잡음 조건에서의 CPSNR 결과를 보여준다.

[0146] (표 6)

Table 6 CPSNR results on the Kodak dataset with Gaussian noise ($\sigma = 10$, the best performances are marked in bold).

	VCD	HOI	ESF	EDAEP	EDUSC	BD	Rank
1	32.861	32.379	33.247	31.694	32.709	**33.328**	1
2	33.379	33.629	33.457	33.443	33.485	**33.755**	1
3	33.792	33.986	33.794	33.897	33.898	**34.071**	1
4	33.465	33.654	33.409	33.562	33.564	**33.658**	1
5	32.692	32.817	32.636	32.164	32.848	**33.116**	1
6	33.297	33.186	33.634	32.572	32.913	**33.666**	1
7	33.672	33.981	33.699	33.793	33.859	**33.981**	1
8	32.17	31.639	32.583	30.584	31.654	**32.731**	1
9	33.801	33.927	33.836	33.737	33.842	**34.045**	1
10	33.754	33.912	33.791	33.744	33.847	**34.036**	1
11	33.237	33.231	33.444	32.754	33.225	**33.587**	1
12	33.906	34.05	33.976	33.875	33.897	**34.198**	1
13	31.556	30.566	32.142	29.767	31.291	**32.151**	1
14	32.435	32.663	32.114	32.34	32.635	**32.876**	1
15	33.471	33.477	33.375	33.468	33.509	**33.658**	1
16	33.623	33.663	**33.992**	33.542	33.592	33.705	4
17	33.626	33.674	33.701	33.469	33.711	**33.905**	1
18	32.517	32.434	32.74	31.993	32.682	**32.907**	1
19	33.426	33.381	**33.555**	32.863	33.319	33.542	2
20	34.371	34.431	34.459	34.105	34.484	**34.644**	1
21	33.126	32.927	33.408	32.443	33.116	**33.421**	1
22	32.828	32.992	32.927	32.733	32.985	**33.261**	1
23	33.856	34.118	33.787	34.037	33.973	**34.135**	1
24	31.707	31.391	31.839	31.169	31.639	**31.85**	1
Avg.	33.199	33.18	33.314	32.823	33.195	**33.509**	1
Diff.	0.311	0.33	0.195	0.687	0.315		

[0147]

[0149] 본 발명은 ESF에 비해 0.195 dB의 이득을 제공하는 가장 높은 수치의 CPSNR이나타났다. 본 발명에 따른 방법은 가우스 노이즈 이미지에서 2가지 경우를(#16, #19) 제외하고는 가장 높은 CPSNR이 나타났다.

[0151] 3.2 포아송 노이즈의 경우(Poisson noise case)

[0152] 일부 잡음 제거 접근법에 있어, 잡음은 가우시안 분포라고 가정한다. 노이즈가 많은 이미지에서 본 발명의 성능을 검증하기 위해 Kodak 데이터 세트의 푸아송 노이즈 이미지를 이용하였다.

[0153] 하기 표 7은 포아송 노이즈 이미지의 디모자이크 알고리즘에 대한 CPSNR 결과를 나타낸다. 표 7을 참조하면 본 발명이 기존의 다른 방법보다 뛰어나며 ESF에 비해 0.441 dB 향상된 것을 알 수 있다.

[0154] (표 7)

Table 7 CPSNR results on the Kodak dataset with Poisson noise ($\sigma = 10$, the best performances are marked in bold).

	VCD	HOI	ESF	EDAEP	EDUSC	BD	Rank
1	37.946	36.255	39.257	34.703	37.37	**39.889**	1
2	39.905	40.282	40.249	39.304	40.04	**40.921**	1
3	41.447	41.64	41.481	40.877	41.637	**42.262**	1
4	40.044	40.047	39.789	39.459	40.098	**40.502**	1
5	37.441	37.333	37.238	35.582	37.674	**38.306**	1
6	39.202	38.223	40.226	36.453	37.502	**40.346**	1
7	41.041	41.569	41.076	40.438	41.61	**41.933**	1
8	35.94	34.591	36.775	32.679	34.784	**37.18**	1
9	41.388	41.104	41.471	39.988	41.221	**41.849**	1
10	41.184	41.104	41.303	40.102	41.282	**41.747**	1
11	39.297	38.641	40.006	37.154	38.921	**40.209**	1
12	41.512	41.35	41.803	40.359	41.055	**42.153**	1
13	34.569	32.631	35.814	31.388	33.961	**36.014**	1
14	36.68	36.845	35.857	36.019	37.052	**37.517**	1
15	39.134	38.587	38.751	38.356	38.899	**39.248**	1
16	42.265	41.384	**43.011**	39.742	40.302	42.51	2
17	40.807	40.259	41.17	39.194	40.922	**41.323**	1
18	36.853	36.255	37.45	35.219	37.133	**37.575**	1
19	39.662	39.145	40.478	37.326	39.335	**40.643**	1
20	40.159	39.785	40.455	38.637	40.338	**40.69**	1
21	38.541	37.47	39.521	36.127	38.317	**39.589**	1
22	37.593	37.582	37.905	36.812	37.885	**38.426**	1
23	41.737	42.174	41.332	41.335	41.866	**42.299**	1
24	34.861	33.973	**35.071**	33.559	34.546	34.93	2
Avg.	39.134	38.676	39.479	37.534	38.906	**39.919**	1
Diff.	0.786	1.243	0.441	2.385	1.013		

[0155]

[0156] 본 발명에 따른 방법은 가우시안 노이즈와 마찬가지로 2가지 경우를(#16, #24) 제외하고 가장 높은 CPSNR이 나타났다.

[0158] 4. 고주파 영역에서의 성능 테스트(Performance Test in a High-Frequency Area)

[0159] 고주파 이미지의 시각적 성능을 비교하기 위해 TE216 및 TE253 이라는 두 개의 고주파수 이미지를 채택하였다. 도 7의 (b)와 (c)에서 보여지는 두 이미지를 기초로 7가지 방법을 테스트하였다. 제안된 방법은 MLRI 방법을 따

르며, 주파에서 최상의 시각 품질을 제공한다. 도 9의 이미지에서 본 발명에 따른 방법이 두 번째로 높은 시각 품질이 나타났으며. 도 10의 이미지에서는 본 발명에 따른 방법이 가장 우수한 시각 품질이 나타났다.

[0160] 본 발명은 pointwise와 patchwise의 유사성을 고려하여 HBE를 이용한 디모자이킹 알고리즘을 제안하여, MAP 측정과 함께 디모자이킹 모델을 공식화하기 위해 베이지안 추정을 도입하였다. 실험을 통해 본 발명에 따른 디모자이킹 방법이 객관적, 주관적 성능 모두에서 기존의 방법들에 비해 우수한 성능을 가짐을 확인하였다.

[0162] 이상에서 본 발명의 대표적인 실시예들을 상세하게 설명하였으나, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자는 상술한 실시예에 대하여 본 발명의 범주에서 벗어나지 않는 한도 내에서 다양한 변형이 가능함을 이해할 것이다. 그러므로 본 발명의 권리범위는 설명된 실시예에 국한되어 정해져서는 안되며, 후술하는 특허청구범위뿐만 아니라 이 특허청구범위와 균등한 것들에 의해 정해져야 한다.

도면

도면1

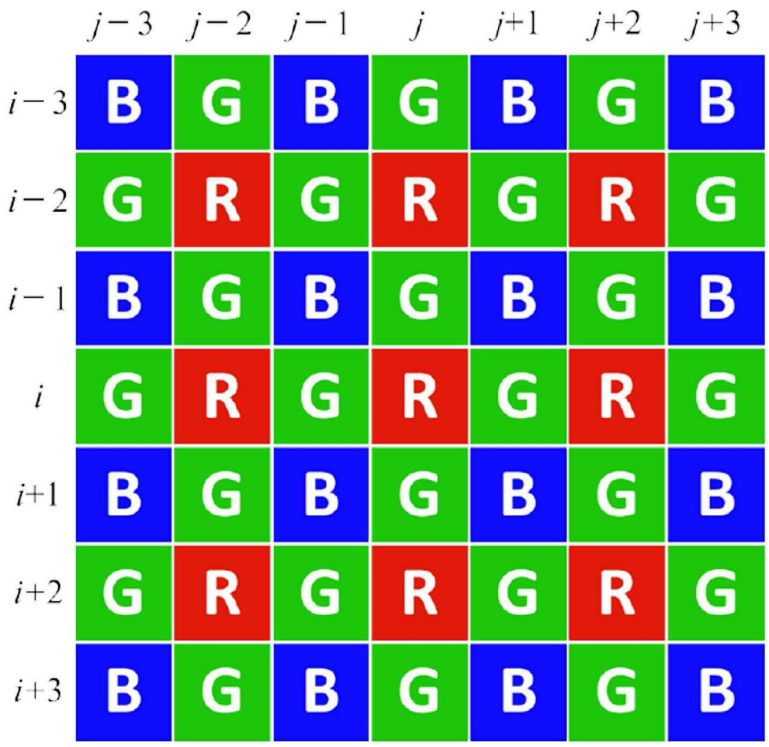

도면2

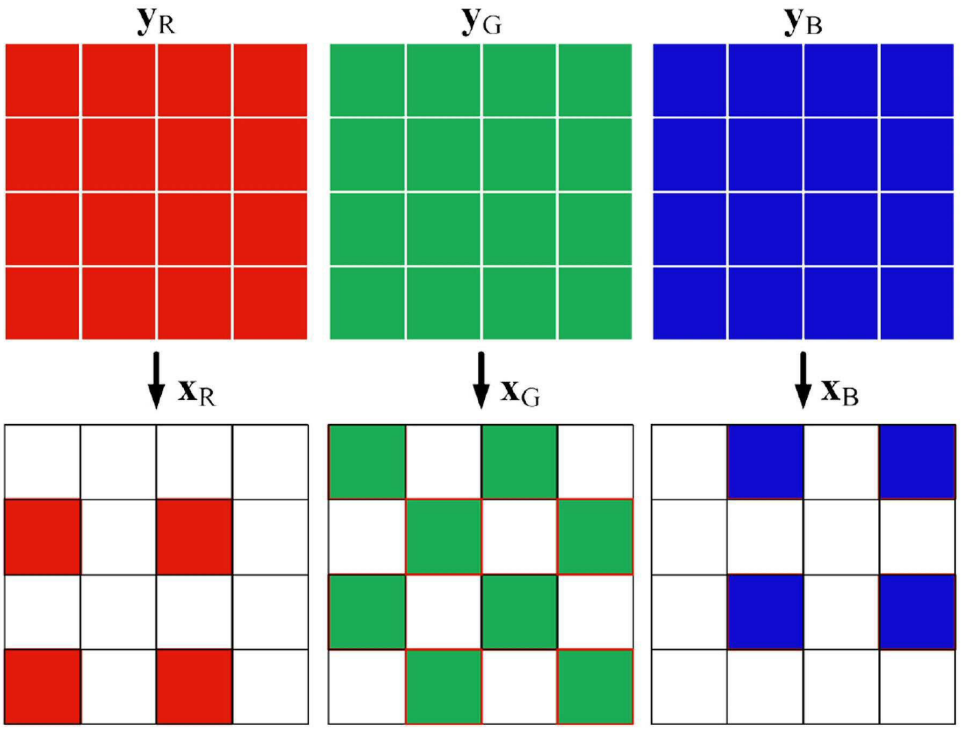
y_R
y_G
y_B
x_R
x_G
x_B

도면3

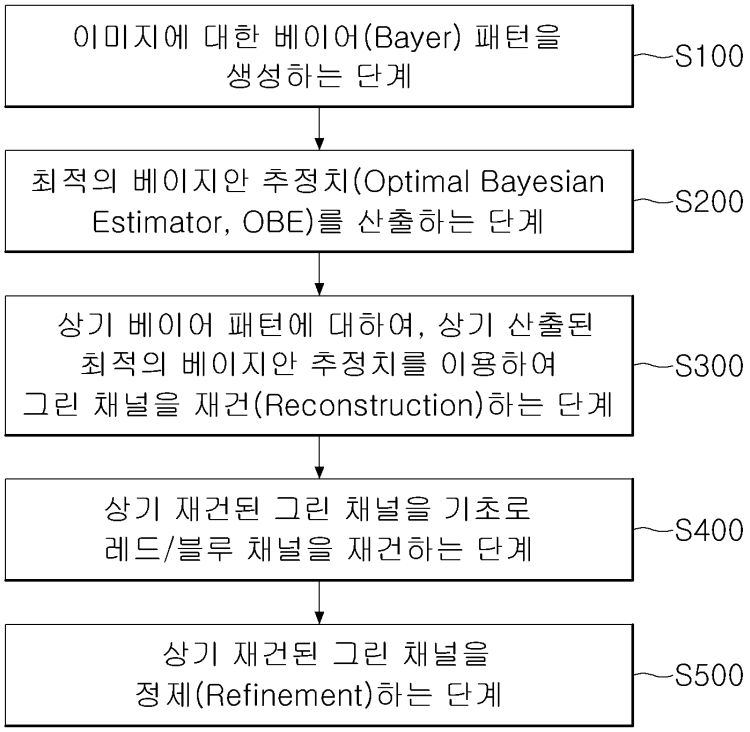
이미지에 대한 베이어(Bayer) 패턴을 생성하는 단계
S100
최적의 베이지안 추정치(Optimal Bayesian Estimator, OBE)를 산출하는 단계
S200
상기 베이어 패턴에 대하여, 상기 산출된 최적의 베이지안 추정치를 이용하여 그린 채널을 재건(Reconstruction)하는 단계
S300
상기 재건된 그린 채널을 기초로 레드/블루 채널을 재건하는 단계
S400
상기 재건된 그린 채널을 정제(Refinement)하는 단계
S500

도면4

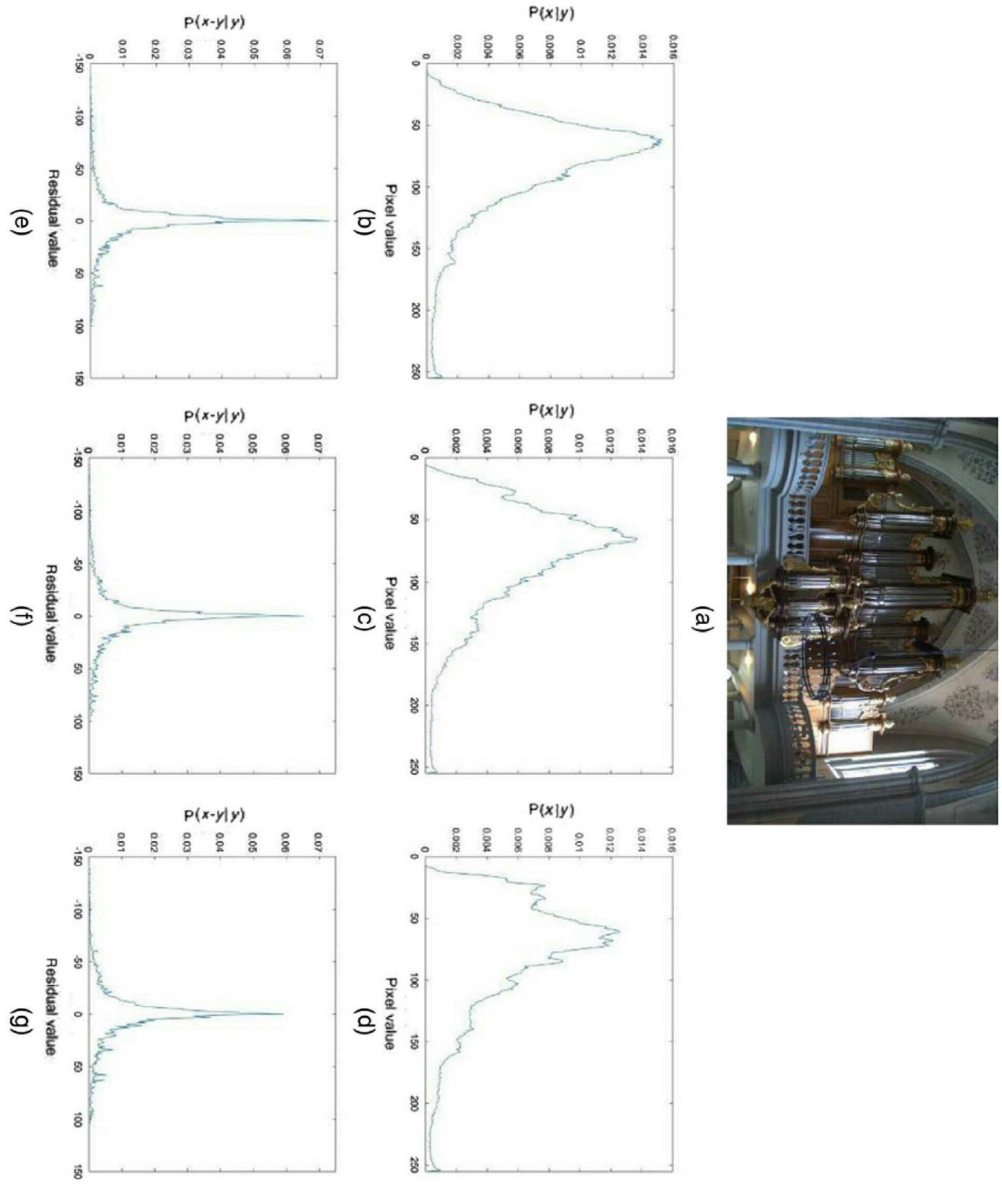
(a)
(b)
P(x|y)
Pixel value
(c)
P(x|y)
Pixel value
(d)
P(x|y)
Pixel value
(e)
P(x-y|y)
Residual value
(f)
P(x-y|y)
Residual value
(g)
P(x-y|y)
Residual value

도면5

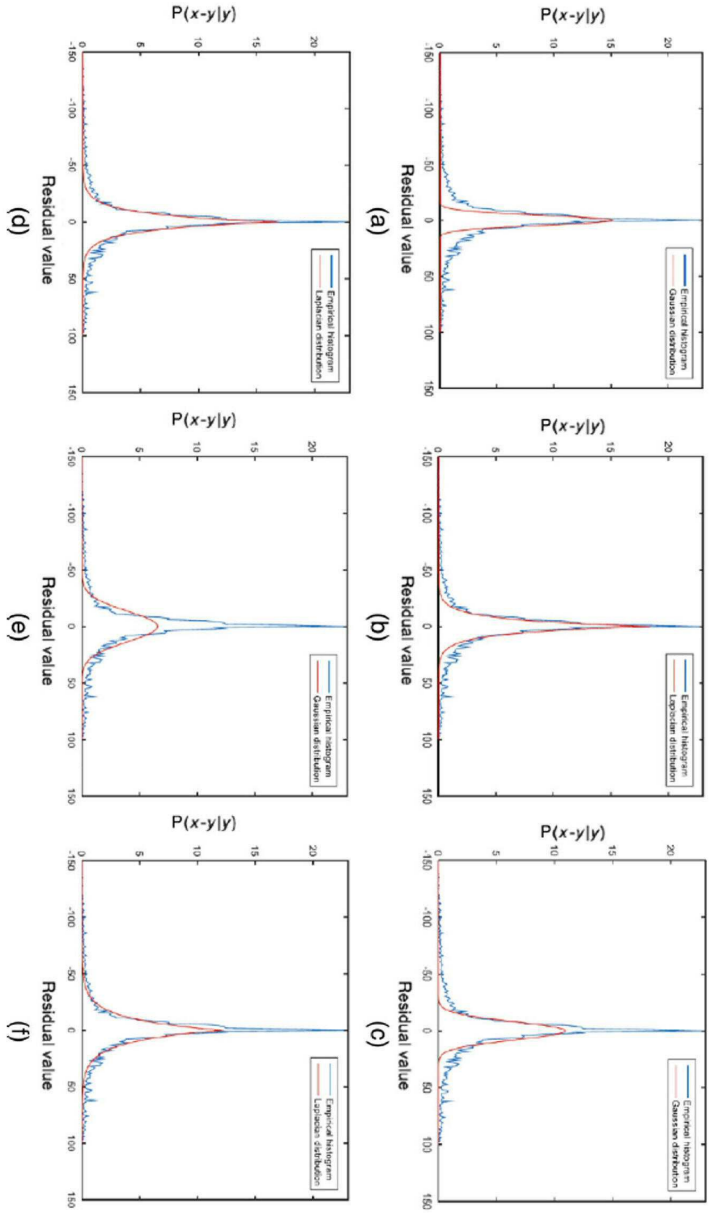
(a)
(b)
(c)
(d)
(e)
(f)
P(x-y|y)
Residual value
Empirical histogram
Gaussian distribution
Laplacian distribution

도면6

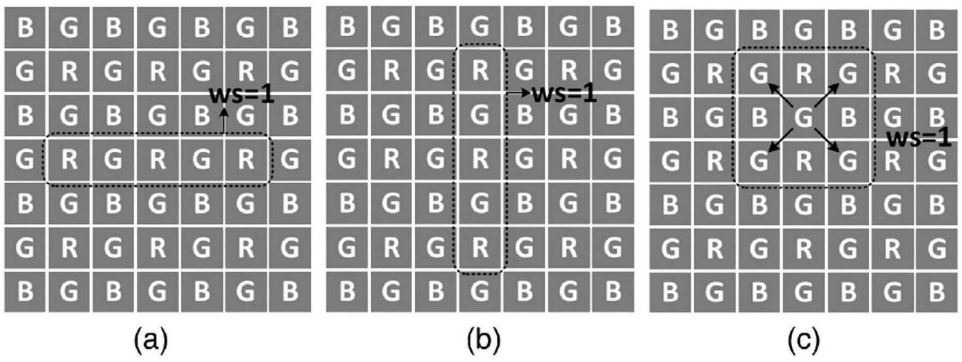
ws=1
ws=1
ws=1
(a)
(b)
(c)

도면7

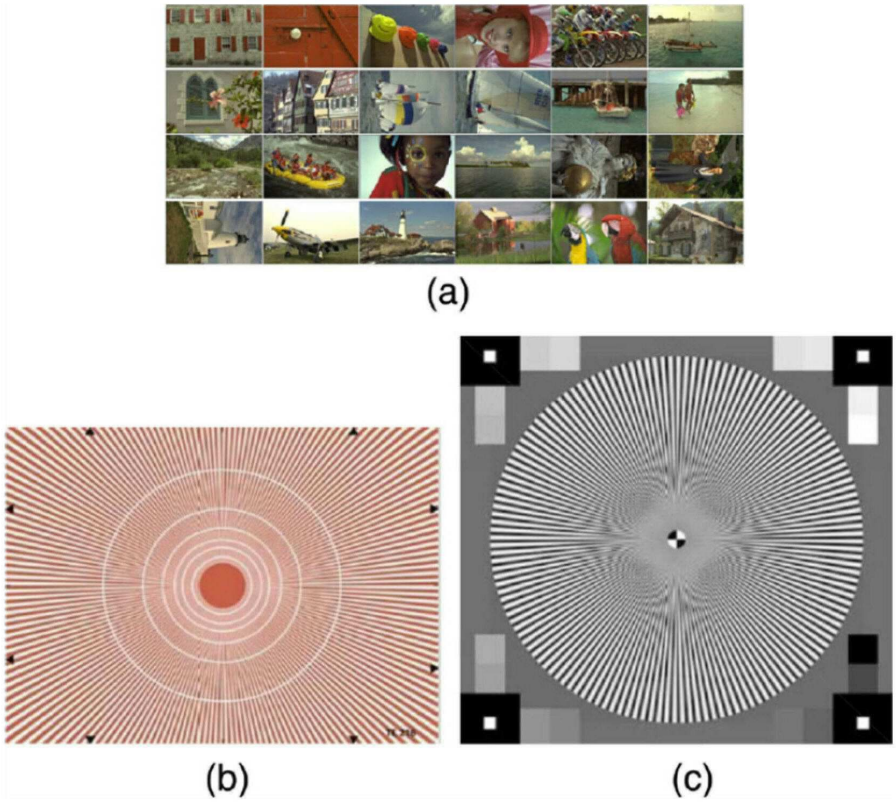

도면8

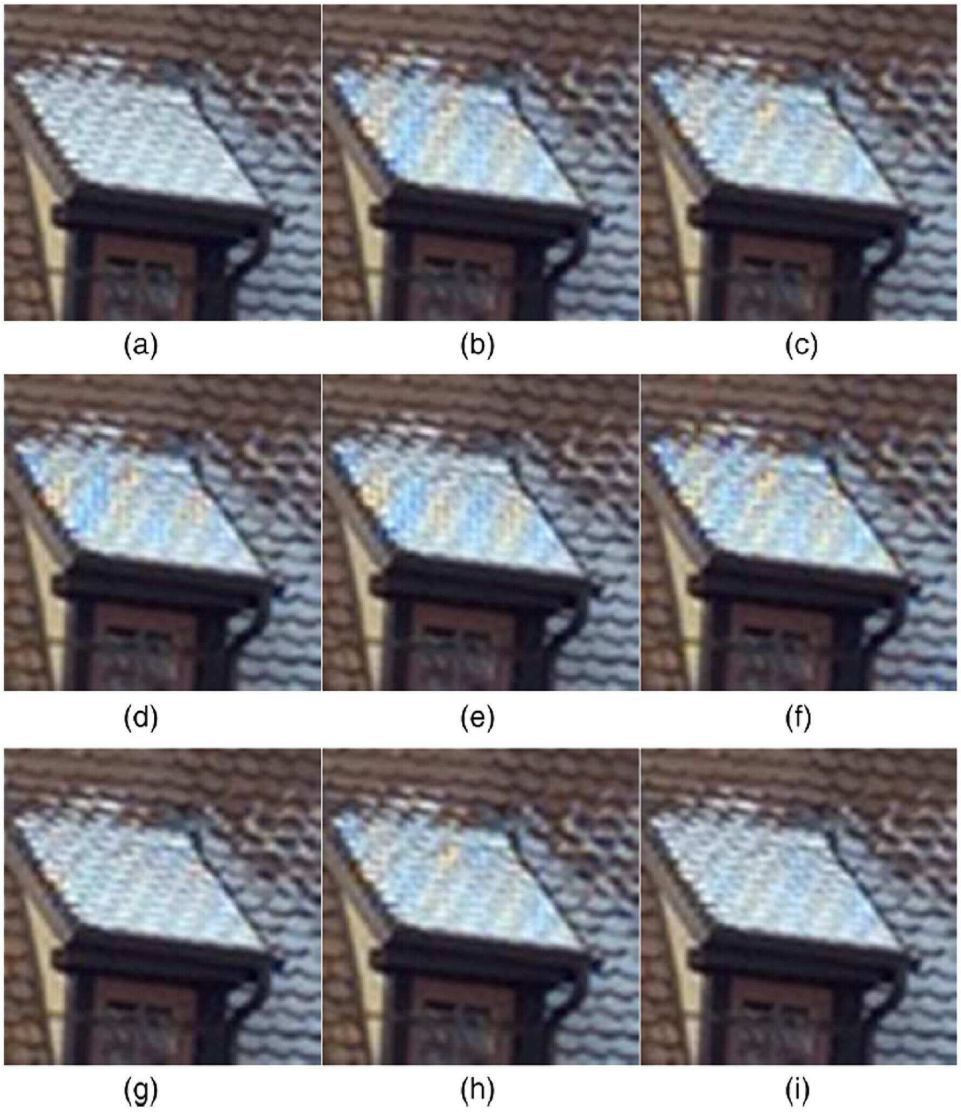

도면9

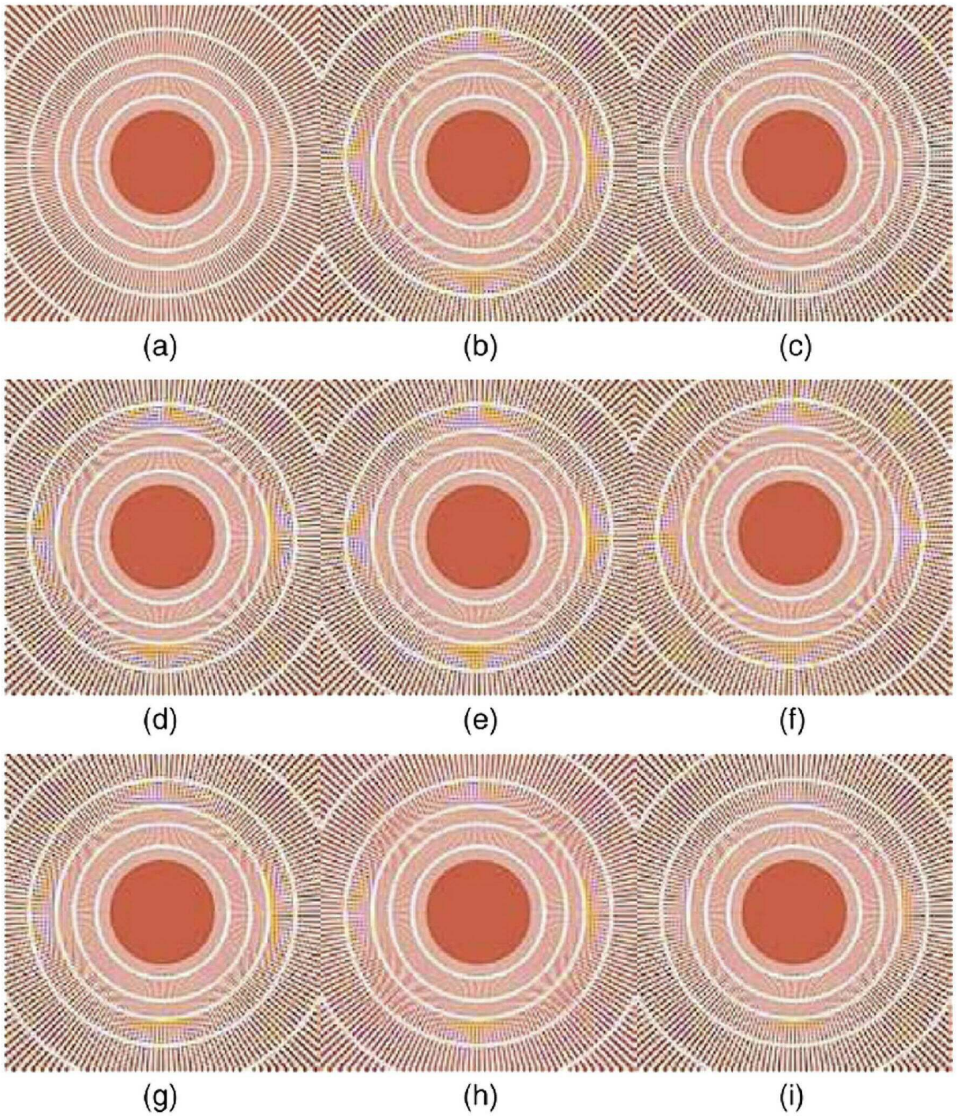

도면10

