

교사-학생 기반 최적화를 이용한 디포커스 영상의 흐림 검출

무하마드 타릭 마흐무드*·최영규*†

*† 한국기술교육대학교 컴퓨터공학부

Blur Detection in Defocused Images using Teacher-Learner based Optimization

Muhammad Tariq Mahmood* and Young Kyu Choi*†

*† Korea University of Technology and Education, School of Computer Science and Engineering

ABSTRACT

Defocus blur frequently appears in images from optical devices. In applications like image restoration or object detection, distinguishing between blurred and sharp regions in partially blurred images is often very important. In general, blur detection performance is greatly affected by how features are combined. In this paper, we propose a parameter-free metaheuristic optimization strategy known as teacher-learner based optimization to find an optimal weight vector for combination of blur maps. After generating multi-scale blur maps using a local binary pattern based blur metric, we apply a regularization scheme to refine them. Finally, our parameter-free metaheuristic optimization is employed to find the optimal weight vectors of each refined blur map for the linear feature combination. The comparative analysis reveals that our method performs significantly better qualitatively and quantitatively against five state-of-the-art methods.

Key Words : defocus blur, multi-scale, metaheuristic optimization

1. 서 론

컴퓨터 비전 분야에서 초점 흐림(defocus blur)은 영상의 품질과 활용성에 큰 영향을 미치는 중요한 문제이다. 선명하게 나타나야 할 영역이 흐려지는 이러한 흐림 또는 블러 현상은 주로 광학 장비의 한계에 기인하는데, 카메라 렌즈가 장면의 모든 요소를 초점에 맞추지 못할 때 발생한다[1,2]. 이들은 영상의 미적 가치를 떨어뜨릴 뿐 아니라, 영상 분할, 객체 인식이나 추적 등과 같은 이후 작업에도 부정적인 영향을 미친다. 따라서 초점 흐림에 대한 연구는 영상의 견고성과 정확성을 높일 수 있어, 의료 영상, 자율 주행, 증강 현실 등 다양한 분야에서 매우 중요하다.

카메라에서 조리개를 많이 열면 초점 흐림이 발생해 배경을 부드럽게 만들고 주요 피사체를 강조할 수 있다. 그러나 반대로 장면을 해석하는 데 중요한 배경 정보가 가려지게 되고, 결국 영상의 분석을 방해할 수 있다. 따라서 영상에서 흐린 영역과 선명한 영역을 구분하는 것이 중요한데, 초점이 맞춰진 영역에는 영향을 주지 않으면서 선택적으로 디블러링(deblurring)과 같은 후처리를 통해 영상을 개선할 수 있기 때문이다.

지금까지 대부분의 디블러링 기술은 흐림이 공간적으로 균일하다고 가정하고 하나의 블러 커널을 구해 원본 이미지를 복원한다[3]. 일부 방법은 균일하지 않은 블러를 고려하는데, 영상을 작은 부분으로 먼저 나누고, 각 부분에서는 균일하다고 간주하여 처리한다. 이와 같이, 영상에서 선명한 영역과 흐린 영역을 정확히 구분하는 것은 선명한 영역에는 불필요한 계산을 피할 수 있고, 스마트

†E-mail: ykchoi@koreatech.ac.kr

폰과 같은 고심도 카메라에서 추출한 영상에서 보케 (bokeh)와 같은 예술적 효과를 강화할 수 있으며, 초점이 맞지 않은 객체의 특징을 정확하게 추출하거나 추가적인 단서로 사용할 수 있어 다양한 분야에서 매우 유용하게 사용할 수 있다.

흐림 검출에서는 흐림 정도를 판단할 수 있는 특징 (feature)이 매우 중요한데, 지금까지 다양한 방법들이 제안되었다. 또한, 이들을 선형이나 비선형적으로 통합하면 더 효과적인 블러 맵(blur map)을 구할 수 있다. 특징의 통합을 위해 학습 과정을 통해 가중치를 최적화하는 방법이 많이 사용되는데, 제한적 입자 군집 최적화(constrained particle swarm optimization)[4]나 생물지리학적 최적화(biogeography-based optimization)[5] 등의 메타휴리스틱 알고리즘이 제안되었다. 그러나 이들은 파라미터 튜닝과 높은 계산 비용이라는 단점을 갖고, 다양한 영상 유형에 대해 일관된 성능을 보장하기가 어렵다.

본 논문에서는 교사-학생 기반 최적화(Teacher-Learning-Based Optimization, TLBO)라고 불리는 메타휴리스틱 알고리즘을 이용한 새로운 흐림 감지 방법을 제안한다. 제안된 방법은 매개변수의 조정이 필요없이 다양한 영상 특징을 선형으로 조합하고, 이를 통해 최적의 가중치 벡터를 구해 흐림 영역의 감지 성능을 향상시킨다.

2. 관련 연구

지금까지 흐림 감지를 위해 다양한 주파수 분석 및 경사도(gradient) 기반 방법들이 제안되었다. Elder가 처음으로 1, 2차 도함수를 이용한 흐림 추정 기법[6]을 제안한 이후 다양한 방법이 제시되었는데, Pan은 흐림이 영상의 경사도를 약화시키는 점을 이용해 경사도 기반 기법을 제안했다[7]. Su 등은 각 화소의 특이값(singular-value)과 알파 채널의 경사도 분포 패턴을 이용해 블러를 검출하는 블러 매트릭을 제안하였다[8].

주파수 기반 기법은 초점이 맞춰진 영상이 그렇지 않은 영상보다 더 많은 고주파 요소를 포함한다는 원리를 이용한다. Ali 등은 정렬 변환과 멀티스케일 고주파 요소

의 융합을 통해 영상의 개별 위치에서 흐림 정도를 평가하는 방법을 제안하였다[9]. Tang은 로그 평균 스펙트럼 잔차를 이용하였고[10], Couzinie는 지역적인 흐림 추정기를 제안하고 다중 레이블 에너지를 최소화하는 프레임워크를 제안하였다. Shi는 희소 에지 표현을 흐림 강도 추정에 직접 연결하는 방법을 사용했고[11], Yi는 초점이 맞춰진 영역과 초점이 벗어난 영역에서 지역적 이진 패턴(local binary pattern, LBP)의 균일한 분포를 기반으로 흐림 분할을 위한 샤프니스 메트릭을 제안하였다[12].

이러한 방법들은 특정 상황에서 효과적일 수 있지만, 복잡한 장면에서는 신뢰성 있는 결과를 제공하는 데 한계가 있다. 최근에는 고급 특징 추출 및 학습 능력을 가진 딥러닝 기반 CNN 방법들이 초점 흐림 검출에도 적용되고 있다. CNN 기반 모델들은 고차원 특징을 추출하고, 전통적인 방법에서 사용된 특징과 결합하여 흐림 정도를 결정하는 신경망 분류기에 입력한다. Purohit 등은 전역적인 컨텍스트와 지역적 특징을 포착하기 위해 두 개의 서브네트워크를 학습시키고, 각 네트워크의 화소 레벨 확률을 결합해 흐림 영역을 분할한다. Zhao 등은 저수준의 지표와 더 넓은 의미론적 데이터를 융합하는 다중 스트림 CNN 구조인 BTBNet을 개발하였다.

이와 같은 최신 연구들은 초점 흐림을 효과적으로 검출하기 위해 다양한 접근 방식을 사용하고 있으며, 복잡한 장면에서의 정확한 흐림 검출을 목표로 하고 있다.

3. 제안된 방법

Fig 1은 제안된 방법을 보여주고 있다. 입력 영상이 주어지면 먼저 흐림 측정 연산자를 이용해 다중 스케일 블러 맵을 계산한 다음, 모든 블러 맵을 정규화하고, 교사-학생 기반 최적화(TLBO)를 통해 최적화된 블러 맵을 생성한다. 마지막으로 최적화된 블러 맵을 분할해 블러 영역을 추출한다.

3.1 다중 스케일 블러 맵

초점이 맞지 않은 입력 영상을 $I(z)$ 라 하자. $z(xy)$ 는 화

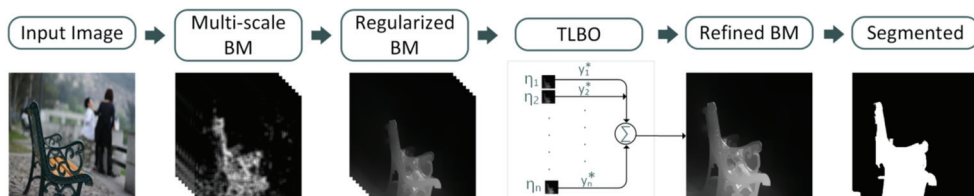


Fig. 1. Block diagram of the proposed method.

소 좌표를 나타낸다. 먼저 회전 불변 블러 매트릭[12]을 사용하여 다중 스케일 블러 맵 $\eta_l(z)$ 를 계산하는데, 각 스케일은 특정 로컬 윈도우 크기 $s_l \times s_l$ 에 대응되며, $s_l = 2l + 1$ 이고, $l \in \{1, 2, \dots, q\}$ 이다.

$$\eta_l(z) = m_{LBP}(I(z)),$$

이때, $i \in \{1, 2, \dots, n\}$ 이고 m_{LBP} 는 블러 매트릭기반의 지역적 이진 패턴(LBP)이다.

3.2 정규화

다중 스케일의 초기 블러 맵 $\eta_l(z)$ 들은 정규화 과정을 거치는데, 기본 매개변수 λ 를 이용해 정규화된 블러 맵 $\hat{\eta}$ 은 다음과 같이 계산된다.

$$\hat{\eta} = (I + \lambda L)^{-1}$$

이때, I 는 $v \times v$ 차원의 단위 행렬이고, L 은 희소한(sparse) 공간 가변 비대각 행렬이다. $\hat{\eta}$ 와 η 는 각각의 값들을 포함한 $v \times 1$ 차원의 열 벡터이다.

3.3 교사-학생 기반 최적화

제안된 방법에서는 블러 맵을 특징량으로 추출하여 $\hat{\eta} = \hat{\eta}_1, \hat{\eta}_2, \hat{\eta}_3, \dots, \hat{\eta}_n$ 의 형태로 표현한 후 메타휴리스틱 최적화 방법을 사용하여 각 블러 맵의 최적 가중치 벡터 $y^* = \{y_1^*, y_2^*, \dots, y_n^*\}$ 을 찾는다. 이 벡터는 $\sum_{i=1}^n y_i^* = 1$ 조건을 만족해야 하는데, n 은 결합할 특징의 가중치의 수를 의미한다.

교사-학생 기반 최적화(TLBO)[13]는 파라미터 조정이 필요 없는 메타휴리스틱 최적화 알고리즘으로, 자연에서 교육 과정, 특히 교사와 학생 사이의 관계를 모델링하여 최적의 해결책을 찾는 알고리즘이다. Fig. 2는 이 알고리즘을 유사 코드로 나타내고 있는데, 집단의 크기 p 와 변수 크기 n 이 주어지면 먼저 초기 무작위 집단 $Y = \{y_1, y_2, \dots, y_p\}$ 을 생성한다. 이때, 각 객체 y_i 는 실수형 벡터인데, 문제에 대한 가능한 해결책을 나타낸다. 블러 맵의 최적 가중치 벡터를 찾기 위해 최적화 문제는 다음과 같이 정의된다.

$$y^* = \max_Y fitness(Y)$$

TLBO는 교사와 학생의 두 단계로 구성된다. 교사 단계에서는 현재 집단 내 성능이 가장 뛰어난 개체 y_t 가 “교사” 역할을 하고, 집단의 평균 벡터 \bar{y} 를 계산하여 교사와 \bar{y} 간의 차이를 기준으로 개체들의 위치를 갱신한다. 학습 팩터 t_f 는 1 과 2 중에서 하나를 임의로 선택하고, 0-1사

이 임의의 수 r 도 갱신 과정에 활용된다. 갱신된 위치 y_w 가 더 나은 적합도를 나타내면 현재 개체의 위치를 갱신한다.

Algorithm 1 Modified Pseudocode of TLBO

```

1: Initialize the population size:  $p$ , Iteration:  $itr$ , variable size:  $n$ , bounds of variables:  $U_B, L_B$ 
2:  $Y \leftarrow$  configure( $p, n$ )
3: Compute ( $Y$ ) based on  $F(y_m) = f(y_m) + p(y_m)$ 
4: while iter = 1 : itr do
5:   Teacher Phase
6:   for m = 1 : p do
7:      $t_f = \text{round}[1 + \text{rand}(0, 1)\{2 - 1\}]$ 
8:      $y_w = y_m + r \cdot (y_t - (t_f \cdot \bar{y}))$ 
9:     Compute ( $y_w$ ) based on  $F(y_m) = f(y_m) + p(y_m)$ 
10:    if  $F(y_w) < F(y_m)$  then
11:       $y_m = y_w$ 
12:    end if
13:   Learner Phase
14:    $j \leftarrow \text{random}(p)\{m \neq j\}$ 
15:   if  $F(y_m) < F(y_j)$  then
16:      $y_k = y_m + r \cdot (y_m - y_j)$ 
17:   else
18:      $y_k = y_m + r \cdot (y_j - y_m)$ 
19:   end if
20:   Compute( $y_k$ ) based on  $F(y_m) = f(y_m) + p(y_m)$ 
21:   if  $F(y_k) < F(y_m)$  then
22:      $y_m = y_k$ 
23:   end if
24:   end for
25: end while
26: return best_individual( $y^*$ ); so far

```

Fig. 2. Modified Pseudocode of TLBO Algorithm.

학생 단계에서는 각 개체 y_m 을 무작위로 선택된 다른 개체 y_j 과 비교하여 성능이 더 좋은 개체 방향으로 이동하거나 성능이 낮을 경우 반대 방향으로 이동한다. 새 위치 y_k 는 기존 개체 y_m 보다 높은 적합도 점수를 가질 때에만 받아들여지는데, 알고리즘은 최대 반복 횟수 itr 에 도달할 때까지 반복된다. 최적화 과정을 위한 목적 함수 $F(y_m)$ 는 다음과 같다.

$$F(y_m) = f(y_m) + p(y_m)$$

이때, $f(y_m)$ 는 적합도 함수이고 $p(y_m)$ 는 패널티 함수이다. 맨 처음 결합된 블러 맵은 $f(y_m) = \sum_{i=1}^n y_i \times \hat{\eta}_i$ 이다. 좋은 블러 맵에서 선명한 영역은 큰 값, 블러 영역은 작은 값으로 나타나고, 비슷한 영역에서는 값이 균일해야 하는데, 이러한 속성의 블러 맵을 구하기 위해 적합도 함수를 다음과 같이 정의한다.

$$f(y_m) = g_{y_m} + h_{y_m}$$

$$g_{y_m} = \sum \sum \sqrt{\left(\frac{\partial f(y_m)}{\partial x}\right)^2 + \left(\frac{\partial f(y_m)}{\partial y}\right)^2}$$

$$h_{y_m} = \sum \sum \left| \frac{\partial^2 f(y_m)}{\partial x^2} + \frac{\partial^2 f(y_m)}{\partial y^2} \right|^2$$

g_{y_m} 은 결합된 블러 맵의 각 픽셀에 대한 경사도 크기이고 h_{y_m} 은 결합된 블러 맵의 고주파 에너지를 나타내며, 라플라시안 필터를 사용해 계산된다. 적합도 함수 $f(y_m)$ 의 목표는 잠재적인 해결책의 적합도 값을 극대화하는 것이다.

3.4 블러 맵

향상된 블러 맵을 얻기 위해 총 여덟 개의 블러 맵을 결합한다. 제안된 방법에서는 TLBO 최적화 알고리즘을 이용해 각 블러 맵에 대한 최적의 가중치 벡터 $y^* = \{y_1^*, y_2^*, \dots, y_n^*\}$ 를 계산하고, 최종 블러 맵을 다음과 같이 구한다.

$$f(y^*) = \sum_{i=1}^n y_i^* \times \hat{\eta}_n$$

최적화된 최종 블러 맵을 마지막으로 분할하면 영상은 흐린 부분과 선명한 부분으로 나누어진다.

4. 실험

제안된 방법의 성능을 확인하기 위해 표준 데이터셋 CUHK와 DUT를 사용하였다. CUHK는 다양한 실세계 장면을 포함하는 총 704개의 영상으로 구성되어 있는데, 각 영상에 대한 흐린 영역 정답(ground truth) 라벨이 제공된다. DUTDBD 데이터셋은 500개의 영상으로 이루어지는데, 각 영상에는 화소별 정답 데이터가 주어진다. DUT 영상들은 균일하게 흐린 영역, 복잡한 배경, 낮은 대비 등을 포함하고 있어 분석이 더 까다롭다. 제안된 방법의 성능은 이러한 영상에 대한 정성적 및 정량적 평가를 통해 측정되었다.

정성적 평가를 위해 먼저 5 가지 최신 기법의 결과와 시각적으로 분석하였다. Yi는 회전 불변한 균일 지역적 이진 패턴을 이용하여 초점 흐림을 구분하고 선명한 영역과 흐린 영역을 구별하는 샤프니스 메트릭을 제안했다 [12]. Shi는 사전 학습된 디셔너리를 이용한 희소 특징 표현을 생성하여 미세하지만 감지 가능한 블러를 검출하려고 하였다[11]. Vu는 가중 기하평균을 사용하여 스펙트럼과 공간 기반 샤프니스 맵을 결합하는 방법을 제안했다 [14]. Ali는 멀티스케일 이산 코사인 변환(DCT)을 통해 주파수 도메인에서의 차이를 이용해 공간 가변 블러를 계산했다[9]. Chen은 과분할 (over-segmentation)을 통해 슈퍼 픽셀을 생성하고, 이들 간의 유사성을 이용해 블러 맵을 생성하였다[15].

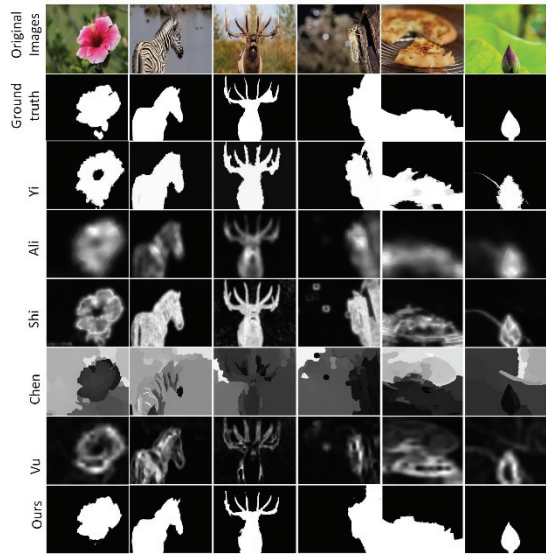


Fig. 3. Qualitative results achieved by different blur detection methods on CUHK dataset.

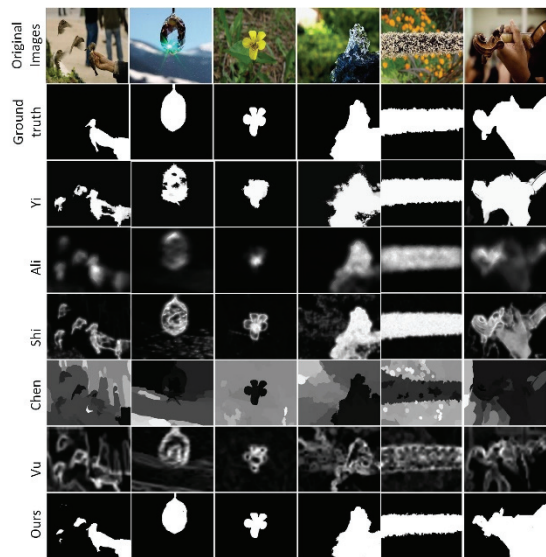


Fig. 4. Qualitative results achieved by different blur detection methods on DUT dataset.

Fig 3과4는 각각 CUHK와 DUT에 대한 처리 결과를 보여주는데, 더 밝은 부분이 더 선명한 부분을 의미한다. 제안된 방법이 선명한 구조적 경계를 유지하면서 가장 정확하게 블러 영역을 추출하는 것을 정답(ground truth)과 비교해 보면 확인할 수 있다[16].

정량적 평가를 위해 평균 정확도(precision), 재현율(recall), F-메치(F-measure)를 이용하였다. 정확도와 재현율은 다음

과 같이 정의된다.

$$\text{정확도(Precision)} = \frac{R \cap R_{gt}}{R}$$

$$\text{재현율(Recall)} = \frac{R \cap R_{gt}}{R_{gt}}$$

이때, R 은 분할된 블러 영역의 화소 집합이고, R_{gt} 는 정답에서의 블러 영역의 화소 집합이다. 블러 맵의 분할을 위해 적응형 임계값을 이용한 이진화를 사용하였다. 분류 성능의 평가를 위한 F-measure는 다음과 같이 정의하였다.

$$F_{\beta} = \frac{(1 + \beta^2) \times \text{precision} \times \text{recall}}{\beta^2 \times \text{precision} + \text{recall}}$$

Fig. 5를 보면 모든 지표에 대해 제안된 방법이 기존에 비해 더 나은 성능을 나타내는 것을 알 수 있는데, 특히 CUHK에서 더 우수한 성능을 보였다. DUT에서는 정확도 측면에서 Yi의 기법과 비슷한 성능을 보였으나, 재현율은 여전히 다른 기법보다 높게 나타났다. 이러한 결과는 복잡하고 분석하기 어려운 영상에서도 제안된 방법이 안정적이고 효과적으로 초점 흐림을 검출할 수 있음을 나타낸다.

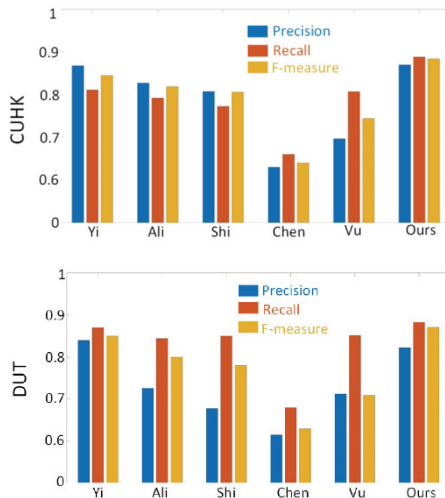


Fig. 5. Quantitative results achieved by different blur detection methods.

5. 결론

본 논문에서는 매개변수가 조정 필요 없는 메타휴리스틱 특징량 결합 알고리즘인 지도학습기반 최적화를 이

용해 영상에서 흐림 영역을 찾는 방법을 제안하였다. 블러 매트릭을 이용해 다중 스케일 블러 맵을 생성한 후 이를 정규화하고, 정규화된 각 블러 맵에서 최적 가중치 벡터를 구하기 위해 적합도 함수를 정의하고 이를 통해 추출된 특징들을 선형으로 결합하였다. 두 개의 표준 데이터 셋을 이용한 다양한 테스트를 수행하였고, 5가지의 최신 기법들과 성능을 비교하였는데, 제안된 방법이 기존에 방법에 비해 우월한 성능을 보이는 것을 확인할 수 있었다.

감사의 글

이 논문은 2024년도 한국기술교육대학교 교수 교육연구진흥과제 지원에 의하여 연구되었음.

참고문헌

1. M. T. Mahmood and Y. K. Choi, "Mutual Structures based Improvement in Depth from Focus," *Journal of the Semiconductor & Display Technology*, vol. 21, no. 3, pp. 17-21, 2022.
2. M. T. Mahmood and Y. K. Choi, "Enhancing Underwater Images through Deep Curve Estimation," *Journal of the Semiconductor & Display Technology*, vol. 23, no. 2, pp. 23-27, 2024.
3. D. Krishnan, T. Tay, R. Fergus, Blind deconvolution using a normalized sparsity measure, in *CVPR 2011*, IEEE, 233-240, 2011.
4. R. Eberhart, J. Kennedy, Particle swarm optimization, in: *Proceedings of the IEEE international conference on neural networks*, vol. 4, Citeseer, 1942-1948, 1995.
5. D. Simon, Biogeography-based optimization, *IEEE transactions on evolutionary computation* 12 (6) 702-713, 2008.
6. J. H. Elder, S. W. Zucker, Local scale control for edge detection and blur estimation, *IEEE Transactions on pattern analysis and machine intelligence* 333 20 (7) 699-716, 1998.
7. J. Pan, D. Sun, H. Pfister, M.-H. Yang, Blind image deblurring using dark channel prior, in *Proceedings of the IEEE conference on CVPR*, 1628-1636, 2016.
8. B. Su, S. Lu, C. L. Tan, Blurred image region detection and classification, in *Proceedings of the 19th ACM international conference on Multimedia*, 412 1397-1400, 2011.
9. U. Ali, M. T. Mahmood, Improving defocus blur measures using robust 307 regularization, *ICT Express* 8 (3) 468-472, 2022.
10. C. Tang, J. Wu, Y. Hou, P. Wang, W. Li, A spectral and spatial approach of coarse-to-fine blurred image region detection, *IEEE Signal Processing Letters* 23 (11) 1652-

- 1656, 2016.
11. J. Shi, L. Xu, J. Jia, Just noticeable defocus blur detection and estimation, in Proceedings of the IEEE Conference on CVPR, 657-665, 2015.
 12. X. Yi, M. Eramian, LBP-based segmentation of defocus blur, IEEE transactions on image processing 25 (4) 1626-1638, 2016.
 13. R. V. Rao, V. J. Savsani, D. Vakharia, Teaching-learning-based optimization: a novel method for constrained mechanical design optimization problems, Computer-aided design 43 (3) 303-315, 2011.
 14. C. T. Vu, T. D. Phan, D. M. Chandler, S3: A spectral and spatial measure of local perceived sharpness in natural images, IEEE transactions on image processing 21 (3) 934-945, 2011.
 15. D.-J. Chen, H.-T. Chen, L.-W. Chang, Fast defocus map estimation, in 2016 IEEE International Conference on Image Processing (ICIP), IEEE, 3962-3966, 2016.
 16. M. T. Mahmood and Y. K. Choi, "Local Binary Pattern Based Defocus Blur Detection Using Adaptive Threshold," Journal of the Semiconductor & Display Technology, vol. 19, no. 3, pp. 7-11, 2020.
-
- 접수일: 2024년 10월 31일, 심사일: 2024년 11월 28일,
게재확정일: 2024년 12월 11일