

A Genetic Programming Approach to Blind Deconvolution of Noisy Blurred Images

Muhammad Tariq Mahmood[†] · Yeon Ho Chu^{**} · Young Kyu Choi^{***}

ABSTRACT

Usually, image deconvolution is applied as a preprocessing step in surveillance systems to reduce the effect of motion or out-of-focus blur problem. In this paper, we propose a blind-image deconvolution filtering approach based on genetic programming (GP). A numerical expression is developed using GP process for image restoration which optimally combines and exploits dependencies among features of the blurred image. In order to develop such function, first, a set of feature vectors is formed by considering a small neighborhood around each pixel. At second stage, the estimator is trained and developed through GP process that automatically selects and combines the useful feature information under a fitness criterion. The developed function is then applied to estimate the image pixel intensity of the degraded image. The performance of developed function is estimated using various degraded image sequences. Our comparative analysis highlights the effectiveness of the proposed filter.

Keywords : Image Restoration, Blind Deconvolution, Deblurring, Genetic Programming, Surveillance Systems

잡음이 있고 흐릿한 영상의 블라인드 디컨벌루션을 위한 유전 프로그래밍 기법

Muhammad Tariq Mahmood[†] · 추연호^{**} · 최영규^{***}

요 약

영상의 디컨벌루션은 보통 감시 시스템에서 모션 블러 (motion blur)나 초점이 맞지 않아 발생하는 블러 (out-of-focus blur) 문제를 줄이기 위해 전처리 과정에서 사용된다. 본 논문에서는 유전 프로그래밍 (Genetic Programming, GP)에 기반한 새로운 블라인드 영상 디컨벌루션 필터링 방법을 제안한다. GP 진화 과정을 통해 영상 복원을 위한 수학적 표현이 만들어지는데, 이것은 블러 영상의 특징들 사이의 관계를 최적으로 조합하여 원래 화소 값을 복원할 수 있는 추정자 함수가 된다. 이를 위해, 먼저 각 화소의 작은 이웃으로부터 특징 벡터를 만들고 추정자 함수를 학습시키는데, 이러한 GP 진화 과정을 통해 지정한 적합성 기준에 따라 유용한 정보들이 자동으로 조합된다. 개발된 함수는 훼손된 영상의 각 화소에 적용하여 원래의 화소 값을 복원하게 된다. 개발된 함수는 다양한 방법으로 훼손된 영상에 적용하여 실험하였는데, 실험 결과 제안된 방법이 기존 알고리즘에 비해 좋은 결과를 나타내는 것을 알 수 있었다.

키워드 : 영상 복원, 블라인드 디컨벌루션, 흐림 제거, 유전 프로그래밍, 감시 시스템

1. 서 론

영상기반 감시 시스템에서는 흐릿하고 잡음이 있는 영상을 개선하여 시각 정보를 복원하는 것이 매우 중요한 작업이다[1]. 영상이 흐려지는 상황은 다양하게 발생할 수 있는데, 초점거리가 긴 렌즈를 사용하는 경우 영상 내의 어떤

부분은 초점이 잘 맞는데 비해 다른 부분은 초점이 맞지 않아 흐려지는 카메라 심도(depth of field) 문제 등이 대표적인 블러(blur) 현상의 원인이다[2]. 또한 촬영시 물체나 카메라의 상대적인 작은 움직임에 의해서도 모션 블러(motion blur) 현상이 발생한다.

이러한 블러 현상은 점 확산 함수 (point spread function, PSF)로 표현할 수 있는데, 어떤 화소의 밝기가 PSF에 의해 주변 화소의 밝기를 왜곡시키는 현상이다. $f(i,j)$ 을 원 영상이라 하면 훼손된 영상 $g(i,j)$ 은 다음과 같이 $f(i,j)$ 와 PSF의 컨벌루션(convolution)으로 나타낼 수 있다.

※ 본 연구는 정부(미래창조과학부)의 재원으로 2013년 특구기술사업화사업(A2013DD005)의 지원을 받아 수행되었습니다.
† 비 회 원 : 한국기술교육대학교 컴퓨터공학부 교수
** 비 회 원 : 한국기술교육대학교 컴퓨터공학과 석사과정
*** 종신회원 : 한국기술교육대학교 컴퓨터공학부 교수
논문접수 : 2013년 7월 17일
수 정 일 : 2013년 10월 11일
심사완료 : 2013년 12월 6일
* Corresponding Author : Young Kyu Choi(ykchoi@koreatech.ac.kr)

$$g(i,j) = f(i,j)*h(i,j) + n(i,j)$$

이때, *는 2차원 컨볼루션을 의미하며, $h(i,j)$ 는 PSF를 $n(i,j)$ 는 잡음 함수를 나타낸다. PSF를 알고 있을 때 $g(i,j)$ 로부터 원 영상 $f(i,j)$ 를 복원하는 것을 디컨볼루션(deconvolution)이라 하는데, 일반적으로 훼손된 영상의 PSF를 미리 아는 것은 어려운 일이다. 따라서 PSF에 대한 사전 정보가 없는 상태에서 원 영상과 PSF를 동시에 추정하는 것을 블라인드 디컨볼루션(blind deconvolution)이라 한다[3]. 본 논문에서는 유전 프로그래밍 기법을 이용한 새로운 블라인드 디컨볼루션 방법을 제안한다.

제안된 방법은 효과가 좋은 것으로 알려져 최근 많은 관심을 끌고 있는 Lucy-Richardson (LR) 디컨볼루션 알고리즘 및 Wiener 필터링 기법과 비교한다 [4,5]. LR 알고리즘은 최대 공산 추정 (maximum likelihood estimate, MLE)을 사용하는데, 추가되는 잡음에 대한 정보는 부족하더라도 확산 함수에 대한 정보가 충분한 경우 매우 효과적이다. 그러나 훼손된 영상을 반복적으로 복원하기 위해 원 영상의 사전 분포를 알아야 하고, 비선형 반복 기법에 기반하여 매우 계산량이 많아 수렴을 위해 오랜 시간이 필요하다는 단점이 있다[4]. Wiener 필터는 블러나 잡음을 제거하고 영상을 복원하는 목적으로 많이 사용되는데, 최소 자승법 (least square)을 사용하여 원래 영상과 잡음이 제거된 영상의 차이를 줄인다. 또한 이 방법은 완전히 결정적(deterministic)이며, 따라서 사용자는 상황에 따라 파라미터를 조정해야 하고, 필터의 성능은 공간 불변의 블러와 비유동적 가우시안 잡음에 큰 영향을 받게 된다[5].

다른 방법으로는 기계학습 (machine learning) 기반의 접근법이 효율적인 영상의 블라인드 디컨볼루션을 위한 대안이 될 수 있다 [3]. 보통 원 영상과 훼손된 영상의 전체적인 특징은 서로 차이가 크지만, 다양한 방법에 의해 훼손된 영상들 간에 공통적인 특징도 존재하는데, 예를 들어, 모든 종류의 블러는 이웃 화소의 값들로 평활되는 것이 대표적이다. 문제는 어떻게 이런 유용한 지역적 정보를 선택하고 조합하여 일반화된 매핑 함수를 만들어 다양한 유형의 잡음 환경에 잘 적용하도록 하는가 하는 것이다. 이를 위해 적응형 신경-퍼지 (adaptive neuro-fuzzy, Anfis) [6], 서포트 벡터 머신 (support vector machine, SVM) [7] 그리고 인공 신경 회로망(artificial neural network, ANN) [8] 등의 기법들이 활용될 수 있다. [6]에서는 충격 (impulsive) 잡음에 의해 왜곡된 영상을 복원하기 위해 Anfis 기반 필터가 제안되었고, 최근에 다중 스케일 사전 학습 방법들이 제시되고 있다. SVR과 ANN 모두 모델 파라미터를 최적화하지만 ANN은 일반화 능력이 떨어지고, SVR은 입력 샘플의 특성에 의해 성능이 영향을 받는다. 따라서 이들 방법들은 모두 학습 샘플에 독립적인 매핑 함수를 얻기가 어려우며 일반화된 기술을 만들기 위해 여전히 많은 어려움이 있다. 이 외에도 블라인드 디컨볼루션을 위해 다양한 방법들이 제안되고 있다[9].

본 논문에서는 유전 프로그래밍 (genetic programming, GP)에 기반한 블라인드 디컨볼루션 방법을 제안하는데, 유용한 정보들을 조합하고 적합성 조건을 바탕으로 최적의 함수를 도출하도록 하였다. GP기반 최적화 기법들은 패턴 인식과 컴퓨터 비전의 다양한 응용 분야에 널리 사용되고 있

다[10,11]. 제안된 방법에서는 훼손된 화소의 지역적인 이웃 화소 정보가 입력 특징량으로 사용되고, 이에 대응되는 원본 영상의 화소 값이 목표 값이 된다. GP 진화 과정에서 다양한 형태의 블러 현상과 잡음을 처리할 수 있는 효율적인 프레임워크가 만들어 지는데, 다양한 실험을 통해 제안된 방법이 기존의 방법들에 비해 우월한 결과를 나타내는 것을 알 수 있다.

본 논문의 구성은 다음과 같다. 먼저 2장에서 유전 프로그래밍에 기반한 새로운 영상 복원 방법을 제안한다. 3장에서는 제안된 방법의 성능을 기존의 방법들과 비교하여 제시하며, 4장에서 결론을 맺는다.

2. 제안된 방법

GP 기법은 주어진 문제에 대한 모든 가능한 해(solution) 공간에서 자연적인 선택과 재결합의 진화 과정을 통해 최적의 해를 구하고자 하는 방법이다. 그림 1은 제안된 방법을 블록도로 나타내고 있는데, 전체 과정은 먼저 GP 과정을 위한 학습 데이터를 준비하는 전처리 모듈과, 학습 데이터를 이용하여 최적의 함수를 도출하는 GP 모듈, 그리고 개발된 함수를 이용하여 훼손된 영상의 화소 값들을 복원하는 추정 모듈 (estimation module)로 이루어진다.

2.1 전처리 모듈 (Preprocessing Module)

이 모듈에서는 특징량 벡터를 정의하고, GP 모듈의 입력이 되는 학습 데이터를 만든다. 특징량 벡터로는 훼손된 화소값 주변의 이웃 화소 값을 이용하는데, 훼손된 영상 $g(i,j)$ 의 임의의 화소에 대해 작은 윈도우 W 을 설정하고 W 내의 화소 값을 이용하였다. W 의 크기로는 너무 큰 것 보다는 3×3 의 작은 윈도우가 적당하였는데, 이것은 화소간의 거리가 멀면 그만큼 화소간의 연관성이 떨어지며, 윈도우가 커지면 이에 따라 특징량 벡터가 커져 학습과 테스트에 많은 시간이 걸리게 되기 때문이다. 따라서 제안된 방법에서는 9차원의 특징량 벡터 $\mathbf{x} = \{x_1, \dots, x_9\}$ 를 사용하는데, 이때 x_9 가 중앙 화소가 되도록 설정하였다.

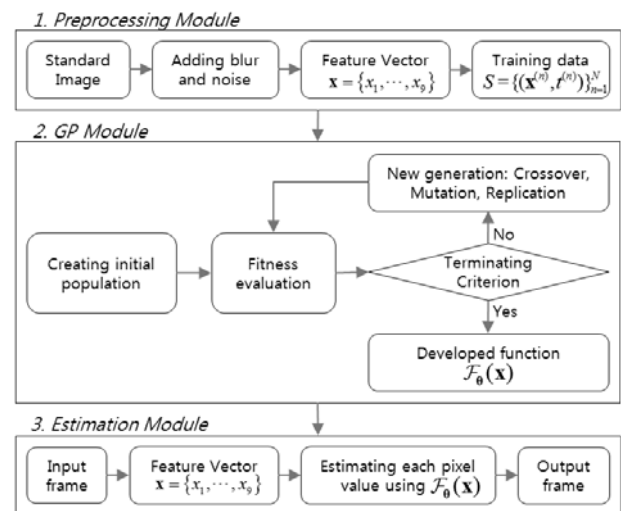


Fig. 1. Block diagram of GP based proposed scheme

GP 모듈을 위한 학습 데이터를 만들기 위해 표준 Lena와 Cameraman 영상을 사용하였는데, 이들 영상에 흐려짐 처리를 하고 잡음을 추가하여 훼손된 영상 $g(i,j)$ 를 만든다. $g(i,j)$ 의 각 화소에 3×3 윈도우를 적용하여 특징량 벡터 $\mathbf{x} = \{x_1, \dots, x_9\}$ 를 추출하는데, 최종적으로 N 개의 입력-목표치 쌍으로 이루어진 학습 데이터 세트 $S = \{(\mathbf{x}^{(n)}, t^{(n)})\}_{n=1}^N$ 가 만들어진다. 이때 $\mathbf{x}^{(n)}$ 은 n 번째 목표치 (원본 영상의 화소값) $t^{(n)}$ 에 대응되는 n 번째 특징량 벡터를 의미하고, N 은 학습을 위해 무작위로 선택된 데이터 포인트의 개수를 나타낸다.

2.2 GP 모듈

이 모듈에서는 학습 데이터를 이용하여 추정(estimation) 함수 $y = F_\theta(\mathbf{x})$ 를 만들게 되는데, 이때 $\mathbf{x} \in R^9$ 이고, $y \in R$ 이며 θ 는 GP 트리를 위한 적절한 파라미터 집합을 나타낸다. 목표 함수가 적절한 구조를 갖도록 하기 위해 다양한 함수와 변수 및 상수들을 제공하였는데, 이를 통해 GP 시뮬레이션 과정에서 최적의 후보 해 (candidate solution)를 찾을 수 있는 더 많은 기회를 갖도록 하였다.

후보 해 $h_\theta(\mathbf{x})$ 는 말단 노드와 비말단 노드들로 이루어진 트리 형태의 데이터 구조로 표현하게 되며, 표 1은 전체 GP 파라미터 설정 상태를 보여주고 있다. 말단 노드들은 특징량 벡터와 정규 분포로 무작위로 생성한 상수 값들로 이루어지며, GP 진화 과정을 통해 가장 정보가 많은 연산이나 삼각 함수, 변수 및 랜덤 상수가 선택된다. GP 트리의 표현 방법을 정한 후 크기가 100인 초기 개체군 (initial population)을 만들는데, 이를 위해 half-and-half 방법을 사용하였다 [12]. 다음 단계에서는 개체군 내의 각 개체에 대해 적합성을 평가하는데, 이러한 적합성 함수(fitness function)는 방대한 탐색 공간 내에서 유용한 해를 전개해 나가는데 있어 매우 중요한 역할을 한다. 제안된 방법에서는 다음과 같이 평균 제곱에러 (meas square error, MSE)를 사용한다.

$$h_s = \frac{1}{N} \sum_{n=1}^N [h_\theta(\mathbf{x}^{(n)}) - t^{(n)}]^2, n = 1, 2, \dots, N,$$

Table 1. GP parameters setting.

Parameters	Set Values
Terminals / non-terminal set	- Variable set of feature vectors: $\mathbf{x} = \{x_1, \dots, x_9\}$ - Parameters set: $\theta = \{\text{functions set, constant set}\}$ where, Functions set: {plus, minus, times, divide, log, sin, cos, exp, power } Constants set: random constants [0-1]
Fitness criterion	Minimization of MSE
Pop. size	500
Generations	200
Pop. Initialization	Ramped half and half
Sampling	Tournament
Expected offspring	rank85
Operators probabilities	Variable crossover/mutation ratio
Survival criterion	Keep the best individual

이때 $h_\theta(\mathbf{x}^{(n)})$ 는 특징량 벡터 $\mathbf{x}^{(n)}$ 에 대한 원본 화소 값의 예측 값이며, 최소 적합성 h_s 는 GP 개체가 얼마나 효율적으로 최적의 해로 움직이는지를 나타내게 된다. 다음은 현재의 개체군에서 최선의 개체를 선택하는 단계로, 크기가 P 인 개체군 내의 각각의 후보에 대한 적합성 확률은 다음과 같이 계산된다.

$$\Pr(h_s^p) = \frac{h_s^p}{\sum_{p=1}^P h_s^p}$$

이때, $\sum_{p=1}^P h_s^p$ 는 개체군의 전체 적합성 합이다. 이러한 적합성 확률이 높은 개체는 자식을 만드는데 참여할 가능성이 높아진다.

GP 최적화 과정에서 생존 개체를 선택하기 위해 세 가지 전략이 주로 사용되고 있다. 먼저 적합성 기반 (fitness proportional) 선택 전략은 전적으로 적합성만을 이용해 선택하며 적합성이 낮은 개체는 생존하기 어렵다. 그러나 자연스러운 진화 과정에서는 이전 세대에서 적합성이 상대적으로 부족했던 개체가 다음 사이클을 개선할 가능성도 있다는 문제가 있다. 이를 개선하기 위해 룰렛 (Roulette Wheel) 선택 기법도 활용되고 있는데, 보다 덜 적합한 개체에도 기회를 주지만 계산량이 많다는 단점이 있다. 제안된 방법에서는 토너먼트 기반 (tournament based) 선택 전략을 사용하였는데 [13], 룰렛 기법과 달리 전체 개체군이 아니라 작은 부분집합 안에서 경쟁을 하며, 이에 따라 적합성이 낮은 개체도 생존할 가능성이 있으면서도 계산량이 많지 않다는 장점이 있다.

다음 단계에서는 선택된 개체에 교배(crossover), 돌연변이(mutation), 및 복제(replication)와 같은 유전 연산자를 적용하여 새로운 세대를 생성하게 된다. 교배는 두 부모 개체로부터 유전 요인들을 교환하여 자식을 만들며, 돌연변이는 다양한 자식이 나올 수 있도록 하는데, 교배와 돌연변이의 비율이 탐색 공간에서 후보 해가 최적의 해로 근접하는데 중요한 영향을 미친다. 즉, 교배는 최적 해로 수렴하는데 도움을 주며, 돌연변이는 지역적인 최적 상태 (local minima)에 빠져 초기에 수렴을 끝내는 것을 방지하는 역할을 한다. 본 논문에서는 이 비율을 가변적으로 사용하는데, 전역적인 최적 상태 (global minima)에 수렴할 수 있도록 자동으로 비율을 조정한다. 이러한 시뮬레이션은 세대의 수가 설정된 최대치(200)에 이르거나 적합성 h_s 가 설정된 최소값(0.01)에 도달하면 멈추게 된다. 최종적으로 개체군에서 최고의 개체가 추정 함수 $h_\theta(\mathbf{x}) \rightarrow F_\theta(\mathbf{x})$ 가 된다.

2.3 추정 모듈

GP 모듈을 통해 추정 함수 $F_\theta(\mathbf{x})$ 가 만들어지면 이를 이용해 훼손된 영상을 복원할 수 있다. 훼손된 영상의 복원을 위해서는 영상 내의 모든 화소에 대해 학습 과정에서와 같은 방법으로 특징량 벡터 $\mathbf{x} = \{x_1, \dots, x_9\}$ 를 추출하고, 이를 추정 함수에 적용한다. 실제로 CCD 카메라로 촬영한 영상 (훼손된 영상) 시퀀스를 $g^{(k)}(i,j)$ 라 하면, 최종적으로 시퀀스

의 각 프레임에 대한 복원 영상 $\hat{f}(i,j)$ 추정해야 하는데, 이는 각 화소 (i,j) 에 대해 특징량 벡터 $\mathbf{x}=\{x_1,\dots,x_9\}$ 를 추출하고, 개발된 추정 함수 $F_\theta(\mathbf{x})$ 를 적용하여 다음과 같이 계산된다.

$$\hat{f}(i,j) = F_\theta(x_1,\dots,x_9)$$

이 영상은 블러나 잡음 등의 왜곡이 없이 이상적으로 촬영된 영상 $f(i,j)$ 에 대한 좋은 복원 영상이 된다.

3. 실험 결과

3.1 실험 준비

제안된 방법의 성능을 평가하기 위해 그림 2와 같이 Lena와 Cameramen 데이터를 사용하였다. 학습 과정을 위해서 이들 표준 영상을 3×3 크기의 평활필터를 이용하여 흐릿하게 만들었고, 여기에 평균이 0이고 분산이 0.01인 가우시안 잡음을 추가하여 훼손된 영상을 만들었다. 특징량 벡터를 위해 각 화소에 3×3 윈도우를 적용하여 $\mathbf{x}=\{x_1,\dots,x_9\}$ 를 만들었는데, x_5 가 중앙 화소가 되도록 하였다. 이와 같은 방법으로 $2\times 512\times 512=524,288$ 개의 특징 벡터를 만들었다. 추정함수 $F_\theta(\mathbf{x})$ 가 보다 일반적인 데이터에도 잘 적용되게 하기 위해 이들 데이터 중에서 70,000개만을 무작위로 선택하여 학습과정에 사용하였는데, 나머지 데이터들은 학습과정에는 사용하지 않았고 학습/테스트 비율을 낮게 유지하였다.

그림 3은 세대가 지나감에 따라 적합성이 수렴하고 복잡도가 증가하는 것을 보여주고 있다. (a)에서 알 수 있듯이 적합성의 변화는 초기에 크게 개선되면 50대 이후는 개선의 정도가 낮았다. (b)에서는 복잡도를 나타내기 위해 트리의 깊이와 노드의 개수를 사용하였다. GP 진화 과정에서 유용한 블록들이 없어지는 것을 최소화하기 위해 건설적(constructive) 블록들을 만들었는데 [12], 이에 따라, (b)의 몇 군데에서 성능의 큰 향상이 없는데도 GP 개체가 급속히 늘어나는 구간들이 나타났다. GP 진화 과정을 통해 복잡도가 증가하고 최적 개체의 성능 커브가 최적 해로 근접하게 된다. 각 GP 시뮬레이션을 위해서 상당한 계산량이 필요한데 이들은 입력 데이터의 크기, 개체군의 크기, 그리고 개체군의 크기에 크게 영향을 받는다. GP 진화 사이클의 종료와 함께 다음과 같은 추정 함수가 만들어졌다.

$$\begin{aligned} F_\theta(x_1,\dots,x_9) = & x_5 + \sin(x_1 + x_2) \times (x_5 + \sin(x_5 + ((x_7 \\ & \times (x_1 + x_2) \times x_9) \times 0.493) \times x_2) \\ & + (((x_7 + x_9) \times \cos(x_9) \times x_9) \times 0.493) \\ & + \sin(x_1 + x_2) \times 2(x_7 + x_3) \times x_4 \\ & + (0.98 \times ((x_4 + x_6) + 0.493)) \\ & \times (x_8 + (x_5 + (x_8 \times (0.493 \times x_4))) \\ & \times (x_1 - (x_9 - \cos(\exp(x_4)) \div x_2) + 0.493) \\ & + (\log(x_5) - (((x_4 - (x_5 + x_3)) + 0.493) \times x_6)) \end{aligned}$$

개발된 함수의 성능을 평가하기 위해 RMSE (root mean square error), PSNR (peak signal-to-noise error) 그리고 ISNR (improvement in signal to noise ratio)을 사용하였다. RSME는 다음과 같이 원 영상 $f(i,j)$ 과 복원된 영상 $\hat{f}(i,j)$ 간의 차이를 나타낸다.



Fig. 2. Test images: Lena(left) and Cameraman(right)




Fig. 3. Accuracy vs complexity. (a) Improvement in accuracy/fitness score in each generation. (b) Increase in complexity in terms of tree depth and number of nodes.

$$RMSE = \sqrt{\frac{1}{I \times J} \sum_{i=1}^I \sum_{j=1}^J (f(i,j) - \hat{f}(i,j))^2}$$

PSNR은 가능한 최대 신호 세기와 잡음 세기의 비율을 나타내는데, 영상의 최대 밝기를 MAX_1 라고 하면 다음과 같은 함수로 표현된다.

$$PSNR = 10 \log_{10} \frac{(MAX_1)^2}{MSE}$$

RMSE는 작을수록 PSNR은 클수록 좋은 영상 복원을 의미한다. ISNR은 다음과 같이 Li [3] 등이 제안한 식을 사용하였다.

$$ISNR = 10 \log_{10} \frac{\sum_{i=1}^I \sum_{j=1}^J (f(i,j) - g(i,j))^2}{\sum_{i=1}^I \sum_{j=1}^J (f(i,j) - \hat{f}(i,j))^2}$$

3.2 정량적 분석

제안된 필터 F_θ 의 성능을 기존 알고리즘과 비교하기 위해 LR 알고리즘 F_{LRA} 와 Wiener 필터 F_{WF} 를 사용하였다. 성능의 정량적 분석을 위해 Lena와 Cameraman 영상을 3×3 크기의 가우시안 마스크로 평활화하고 가우시안 잡음 (평균=0, 분산=0.02)을 추가하여 왜곡된 영상 $g(i,j)$ 를 먼저 만들고, 이것을 F_{WF} , F_{LRA} 및 F_θ 을 이용하여 복원하였다. 표 2는 복원 결과를 보여주고 있는데, 제안된 방법이 RMSE, PSNR 및 ISNR의 세 가지 지표 모두에서 F_{WF} 와 F_{LRA} 에 비해 훨씬 우월한 성능을 보이는 것을 알 수 있다. 이와 같은 정량적 실험 결과는 제안된 방법이 기존 방법에 비해 훼손된 영상의 복원에 매우 효과적임을 나타낸다.

Table 2. Performance comparison

	Lena			Cameraman		
	RMSE	PNSR (db)	ISNR (db)	RMSE	PNSR (db)	ISNR (db)
F_{WF}	0.452	3.452	-11.792	0.442	3.529	-12.801
F_{LRA}	0.132	8.791	-1.113	0.118	9.257	-1.344
F_{θ}	0.058	12.164	5.984	0.064	11.777	3.959

3.3 정성적 분석

제안된 방법의 정성적인 성능 평가를 위해 다양한 표준 영상과 실제 비디오를 사용하였다. 흐릿해지고 훼손된 표준 영상들을 기존 방법과 제안된 방법을 이용하여 복원하였는데, 그림 4은 이러한 실험 결과를 보여주고 있는데, 제안된 방법에 의한 복원 결과가 F_{LRA} 나 F_{WF} 에 의한 결과보다 우수하다는 것을 알 수 있다.

제안된 방법은 그림 5와 같이 실제 도로 환경에서 취득된 동영상에 대해서도 적용해 보았다. 지능형 교통 시스템의 핵심 분야의 하나인 영상 검지기에서는 도로 영상에서 배경을 모델링하고 전경 객체를 분리하는 것이 향후 이들을 추적하고 인식하기 위해 매우 중요한 과정이다. 그림 6은 이와 같은 영상에서 광학 흐름(optical flow)를 이용하여 전경 영역을 추출하고 객체를 분리하는 과정을 보여주고 있는데, 이를 위해 Matlab의 비전 툴킷 (version7.12, release 2011a)을 사용하였다 [14].




Fig. 4. Restored images by using F_{LRA} , F_{WF} and F_{θ}



Fig. 5. Some frames of a traffic video data

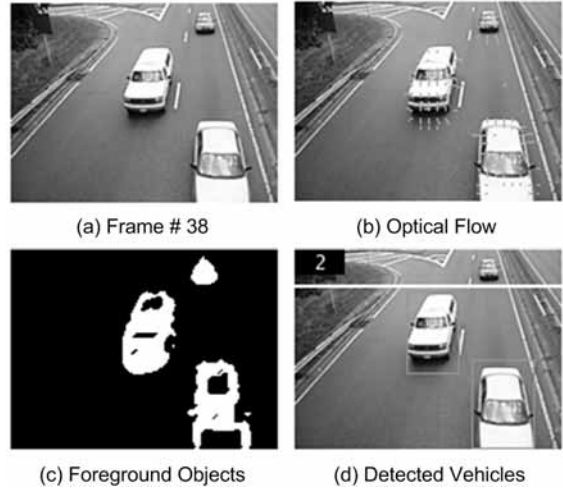


Fig. 6. Intermediate stages for vehicle detection based on optical flow

이러한 실제 데이터에 대해서도 제안된 방법이 잘 동작하는 것을 보이기 다양한 형태의 평활화 커널을 적용하여 원 영상을 훼손하고 평균이 0이고 분산이 0.05인 가우시안 잡음을 추가하였다. 그림 7은 필터를 적용하지 않은 경우와 적용한 후 같은 차량 검출 알고리즘을 처리한 결과를 보여주고 있는데, 처리하지 않은 경우에서 뒤쪽 차량이 검출되지 못하였지만 F_{θ} 로 복원한 영상에서는 성공적으로 모든 차량을 검출할 수 있었다. 그림 8에서는 영상에 salt-and-pepper 잡음을 추가하여 훼손한 데이터에 대한 처리 결과를 보여주고 있는데, 미디언 필터로 처리한 경우에는 영상이 평활화 되었지만 모든 차량의 검출은 실패하였다. 제안된 필터를 처리한 경우




Fig.7. Vehicle detection results using proposed filter from corrupted video with white Gaussian noise

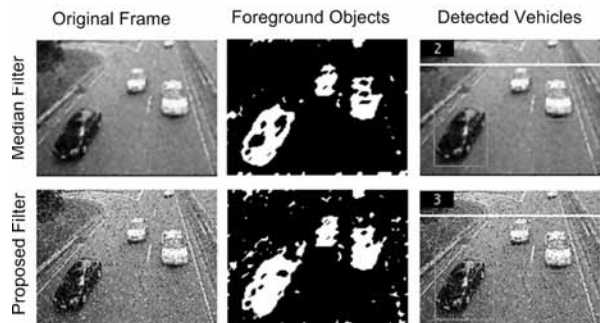


Fig. 8. Vehicle detection results using median filter and proposed filter (corrupted image with salt and pepper noise)

에는 모든 차광을 성공적으로 검출할 수 있었는데, 이를 통해 제안된 GP 기반 추정자 함수가 다양한 실제 데이터의 디컨볼루션과 블러 제거에도 효과적임을 확인할 수 있었다.

4. 결 론

본 논문에서는 훼손된 영상을 복원하기 위한 GP 기반의 추정 함수를 개발하였다. 중앙 화소 값의 복원을 위해 이웃 화소 값을 특징 벡터로 사용하였으며, GP 진화 과정을 통해 파라미터와 연산 함수 및 무작위 상수들이 적합성 기준에 따라 자동으로 선택되고 효율적으로 조합되었다. 개발된 함수의 성능을 평가하기 위해 다양한 형태로 훼손된 영상들을 사용하였는데, 실험을 통해 제안된 방법이 LR 알고리즘이나 Wiener 필터에 비해 정확하고 강건하게 동작한다는 것을 알 수 있었다. 향후 제안된 방법은 PSF와 기존의 방법들에서 얻은 정보(특징량이나 함수 등)를 추가시키는 방법으로 더욱 성능을 개선할 수 있을 것으로 기대되는데, 이것은 GP가 주어진 문제 해결을 위한 최적 모델을 찾는 방법이므로 다양한 방법들의 장점을 잘 조합하고 약점들을 약화시킬 수 있는 프레임워크를 제공하기 때문이다.

참 고 문 헌

[1] D. Vallejo, "A multi-agent architecture for supporting distributed normality-based intelligent surveillance," *Engineering Applications of Artificial Intelligence*, vol. 23, no. 2, pp. 325-340, 2011.

[2] M.T. Mahmood and T.S. Choi, "Optimal depth estimation by combining focus measures using genetic programming," *Information Sciences*, vol. 181, pp. 1249-1263, 2011.

[3] D. Li, R.M. Mersereau and S. Simske, "Blind Image Deconvolution Through Support Vector Regression," *IEEE Transactions on Neural Networks*, vol. 18, no. 3, pp. 931-935, 2007.

[4] W.H. Richardson, "Bayesian-Based Iterative Method of Image Restoration," *J. Opt. Soc. Am.*, vol. 62, no. 1, pp. 55-59, 1972.

[5] M. Grundle, "Weiner and Kalman filters for systems with random parameters," *IEEE Transactions on Automatic Control*, vol. 29, no. 6, pp. 552-554, 1984.

[6] E. Besdok, "A new method for impulsive noise suppression from highly distorted images by using Anfis," *Engineering Applications of Artificial Intelligence*, vol. 17, no. 5, pp. 519-527, 2004.

[7] S.C. Tan, C.P. Lim and M.V. Rao, "A hybrid neural network model for rule generation and its application to process fault detection and diagnosis," *Engineering Applications of Artificial Intelligence*, vol. 20, no. 2, pp. 203-213, 2007.

[8] S.M. Jakubek and T.I. Strasser, "Artificial neural networks for fault detection in large-scale data acquisition systems," *Engineering Applications of Artificial Intelligence*, vol. 17, no. 3, pp. 233-248, 2004.

[9] M. Fahmy, G. Raheem1, U. Mohamed, and O. Fahmy, "A New Fast Iterative Blind Deconvolution Algorithm," *Journal of Signal and Information Processing*, vol. 3, pp. 98-108, 2012

[10] N.I. Petrovic and V. Crnojevic, "Universal Impulse Noise

Filter Based on Genetic Programming," *IEEE Transactions on Image Processing*, vol. 17, no. 7, pp. 1109-1120, 2008.

[11] A. Majid, M.T. Mahmood and T.S. Choi, "Optimal Composite Depth Function for 3D Shape Recovery of Microscopic Objects," *Microscopy Research and Technique*, vol. 73, pp. 657-661, 2010.

[12] A. Majid, A. Khan and A.M. Mirza, "Combination of support vector machines using genetic programming," *International Journal of Hybrid Intelligent Systems*, vol. 3, no. 2, pp. 109-125, 2006.

[13] J.R. Koza, M.J. Streeter and M.A. Keane, "Routine high-return human-competitive automated problem-solving by means of genetic programming," *Information Sciences*, vol. 178, no. 23, pp. 4434-4452, 2008.

[14] S. Silva and J. Almeida, "GPLAB-a genetic programming toolbox for MATLAB," 2003.



Muhammad Tariq Mahmood

e-mail : tariq@koreatech.ac.kr

He received the MCS degree in computer science from AJK University of Muzaffarabad, Pakistan in 2004 and, the MS degree in intelligent software systems from Blekinge Institute of Technology, Sweden in 2006, and the PhD degree in information and mechatronics

from Gwangju Institute of Science and Technology, Korea in 2011. He is currently an Assistant Professor at School of Computer Science and Engineering, Korea University of Technology and Education, Korea. His research interests include image processing, 3D shape recovery from image focus, computer vision, pattern recognition, and machine learning.



추 연 호

e-mail : blue77@koreatech.ac.kr

2005년 한국기술교육대학교 정보기술공학부 (학사)

2005년~2007년 넷코텍 연구원

2007년~현 재 테슬라시스템 책임연구원

2012년~현 재 한국기술교육대학교 컴퓨터공학과 석사과정

관심분야 : 영상처리, 컴퓨터비전, 모바일

프로그래밍 등



최 영 규

e-mail : ykchoi@koreatech.ac.kr

1989년 경북대학교 전자공학과(학사)

1991년 KAIST 전기및전자공학과 (공학석사)

1995년 KAIST 전기및전자공학과 (공학박사)

1995년~1999년 LG산전연구소 선임연구원

1999년~현 재 한국기술교육대학교 컴퓨터공학부 교수

관심분야 : 영상처리, 머신비전, 컴퓨터그래픽스 등