

Deinterlacing Algorithm Based on Statistical Tests¹⁾

Yeong-Hwa Kim²⁾ · Ji-Ho Nam³⁾

Abstract

The main reason for deinterlacing is frame-rate conversion. The other reason for deinterlacing is of course improve clarity and reduce flicker. Using a deinterlacer can help clarity and stability of the image. Many deinterlacing algorithms are available in image processing literatures such as ELA and E-ELA. This paper propose a new statistical deinterlacing algorithm based on statistical tests such as the Bartlett test, the Levene test and the Kruskal-Wallis test. The results obtained from the proposed algorithms are found to be comparable to those from many well-known deinterlacers. However, the results in the proposed deinterlacers are found to be more efficient than other deinterlacers.

Keywords: Bartlett Test; Deinterlacing; E-ELA; ELA; Kruskal-Wallis Ttest; Levene Ttest; NTSC.

1. 서 론

현재 우리나라와 미국, 일본에서는 지상파TV 표준규격으로 NTSC (National Television Standard Committee)방식을 사용하고 있다. 이 방식은 525개의 수직 라인을 홀수와 짝수 필드로 나누어 화면에 표시하는데 각각의 필드는 원래 화면의 홀수 번째 라인과 짝수 번째 라인을 가지고 있기 때문에 두 필드를 겹쳐 하나의 화면을 구현하게 된다. 이와 같은 방식을 비월주사(interlaced scanning)방식이라 하며, 간단한 정의는 다음과 같다. 텔레비전의 화면을 주사(走査)할 때 1회만 위로부터 아래로 순차 주사하는 것이 아니라 처음에는 위로부터 아래로 거칠게 주사하고 다음에는 다시 위로 되돌아가서 먼저 지나간 주사선(走査線) 사이를 위로부터 아래로 주사하고 이것을 몇 번 되풀이 한다. 보통 두 번 주사하고 세 번째에는 최초의 주사로 되돌아가는 방

1) This research was supported by the Chung-Ang University research grants in 2007.

2) Associate Professor, Department of Statistics, Chung-Ang University, Seoul, Korea.
E-mail : gogators@cau.ac.kr

3) Graduate Student, Department of Statistics, Chung-Ang University, Seoul, Korea.
E-mail : jiho0803@nate.com

식이다. 이때 하나 건너 주사로 생기는 거친 화면을 필드(field)라 하고 다음에 주사선 사이를 메워 나가는 2회의 주사로 만들어지는 완전한 화면을 프레임(frame)이라고 한다.

일반적인 TV주사방식으로 채택돼온 비월주사 방식에서는 홀수, 짝수 필드의 주사선이 한 화면의 절반에 불과하지만 초당 60장씩 보내기 때문에 동영상을 구현하는 데 시각적으로 큰 문제는 없었다. 그러나 점차 TV의 고화질 추세가 이어지고 각종 기기와의 호환성 문제가 대두되면서 현재의 방식을 고해상도로 개선할 필요성이 높아지고 있다. 다시 말해 현행 비월주사 방식은 홀수, 짝수 필드를 번갈아 보내기 때문에 자세히 관찰하면 화면이 깜박거리는 떨림현상(flicker)이 나타난다. 이것은 움직임이 많은 영상보다는 움직임이 적은 영상에서 많이 관찰된다. 특히 물체의 경계선이나 화면자막 등에서 떨림현상이 나타나게 된다. 화면이 커질수록 비월주사방식의 떨림현상은 더욱 눈에 띈다. 따라서 현행 비월주사방식으로는 TV가 대형 화면을 구현할수록 화질에서 한계가 발생한다. 이와 같은 떨림현상을 없애기 위해서는 필드 1개당 사용되는 라인수를 많게 해야 한다. 필드 1개당 사용되는 라인수를 많게 하면 홀수, 짝수 필드가 번갈아 가면서 데이터를 보여주더라도 워낙 촘촘하게 라인이 구성되어 있기 때문에 화면상으로는 떨림현상을 발견하기 어렵게 되는 것이다. 따라서 1080개의 주사선으로 구성된 비월주사방식의 HD급 디지털TV는 떨림현상이 눈에 거의 띄지 않는다. 하지만 주사선수가 현재의 NTSC 기준인 525개보다 월등히 많아야 하므로 하드웨어 제조원가가 상승해 일반 TV에 적용하기에는 어려움이 따른다. 또 다른 해결 방법은 모든 필드가 동일한 위치에서 데이터를 표현하도록 하는 방식으로 바꾸는 것이다. 이와 같은 방식을 순차주사(progressive scanning)방식이라 하는데 이것은 영상을 주사하여 전기 신호로 출력하거나 화면에 나타낼 때, 화면의 위에서 아래로 주사선을 건너뛰지 않고 차례로 주사하는 방식이다.

비월주사와 순차주사를 비교해보면 정지 영상의 경우 비월주사방식은 홀수, 짝수 필드가 서로 다른 위치에서 데이터를 표시하므로 특히 문자 등 표시라인이 적은 화면에서는 떨림현상이 나타날 수 있다. 반면 순차주사방식은 홀수, 짝수 필드 모두 같은 위치에서 순차적으로 데이터를 표시하므로 떨림현상이 없어져 눈의 피로를 덜어줄 뿐만 아니라 수직 해상도를 높이는 효과를 낼 수 있다. 특히 주사선이 두 배가 되면서 프로젝션TV 등 대형 화면에서는 기존 비월주사방식에 비해 월등한 화질이 구현된다. 하지만 비월주사 방식의 이런 문제점은 TV가 개발된 당시의 기술력의 한계에 기인한 것으로서 현재의 기술력으로는 이러한 문제를 해결할 수 있지만 이미 만들어진 영상 소스들이 모두 이와 같은 비월 주사 방식으로 제작되었고, 전송 대역폭 등의 문제 때문에 아직도 비월 주사 방식을 고수하고 있다. 이런 이유로 현행의 방대한 영상 소스를 차세대 영상에 이용하기 위해서는 순차주사 방식으로 변환시켜야 하는데 이 과정을 Deinterlacing 이라 한다. 순차주사로 변환하기 위해서는 기존의 주사선들 사이에 새로운 선을 만들어야 한다. 이를 위해 보간(interpolation)기법을 사용하여 원래 있던 주위 화소값들을 사용하여 새로운 값을 만들어내야 한다. 여기서 어떤 방법으로 보간해 주느냐에 따라 화질에 차이가 나타나게 된다. 새로 보간되어 삽입하는 라인은 단순히 현재의 값을 두 배로 끌어올린다고 해서 해상도가 좋아지진 않는다. 보다 좋은 화질을 얻으려면 새로 삽입되는 라인의 각 화소마다 주위의 화소값을 고려해 최적값을 찾아야 한다. 이런 Deinterlacing 알고리즘 중에 널리 사용되는 ELA(Edge based Line Average) 알고리즘은 계산이 간단하며 하드웨어를 구성할 경우 쉽게 구현 가능

한 장점을 가지고 있다. 그러나 ELA 알고리즘은 수평방향으로 윤곽이 통과하는 이미 지일 경우 효율이 좋지 못하고, 수직 윤곽선 방향 검출 특성이 좋지 않다. Park and Kang(2004)는 에지(Edge)의 패턴에 근거하여 ELA의 단점을 보완한 알고리즘을 제시 하였다.

본 연구의 출발점 및 목적은 이러한 변환을 하는데 있어서 새로 삽입되는 라인의 각 화소값을 주위의 화소값을 고려해 최적화 시키는 것이 과제이기 때문에 영상처리 의 문제를 통계적인 문제로 변환하여 새로운 개선방안을 제공하고자 하는 데 있다. 본 연구결과에서 볼 수 있는 것처럼 통계적 가설검정을 이용하여 방향성을 찾아낼 수 있는 통계적 알고리즘의 개발은 Deinterlacing 변환 과정에서 발생하는 여러 가지 기 능적 한계를 극복할 수 있을 것으로 판단된다. 본 연구에서는 짝수 번째 라인만 가지 는 영상을 만든 후, 그 영상에 통계적 알고리즘을 적용하여 방향성을 찾아내는 Deinterlacing 변환을 거친 영상과 PSNR을 제시함으로써 ELA 방법과 비교하여 개선 된 정도를 확인하였다.


2. 연구의 필요성

Hann and Bellers(1998)는 여러 가지 Deinterlacing 알고리즘을 소개하고 있으며, Kim(1996)은 뚜렷하지 않은 상관관계가 존재하는 경우에 대한 알고리즘을 제시하였 다. 이러한 Deinterlacing 알고리즘 가운데 Kuo., Liao and Lin(1996)에 의하여 개선되 어 널리 사용되는 ELA 알고리즘은 방향성을 찾기 위해 각 방향의 화소값 차이를 비 교하여 가장 작은 차이를 보이는 방향의 화소값의 평균을 이용하여 보간한다. 그러나 실생활에서 사용하는 영상구현 장치들은 가능한 원래의 영상에 가까운 영상을 구현하 는 것을 기본적인 목적으로 하지만 이러한 장치를 통하여 구현되는 최종 영상은 다양 한 원인에 의한 Noise(잡음)가 더해져 원래의 영상이 손상되는 것이 일반적이다. 따라 서 Feature와 Noise를 정확히 구별한 후 Feature의 방향성을 찾아서 보간을 하는 것 이 합리적이다. Noise문제를 개선한 E-ELA 알고리즘에서는 각 방향에 해당하는 두 화소값 차이를 누적한 값을 이용해서 차이가 적은 방향성을 찾아 보간하고 있다. 하 지만 각 방향의 누적값들의 단순 크기 비교를 통해서 는 노이즈에 의한 차이인지, Feature에 의한 차이인지를 정확히 구별하기에는 어려움이 따른다. 영상처리 분야에 서 Feature와 Noise를 구별하는 방법으로서 자주 사용하는 것이 통계학에서 일반적으 로 정의되는 표본분산(sample variance)이다. 그러나 Kim and Lee(2005) 와 Kim and Nam(2007)은 단순히 표본분산을 사용하는 데 따르는 한계점을 지적하였다. 본 연구에 서도 이차원 데이터를 일차원 시열 데이터로 재배열하는 Kim and Lee(2005)의 아이 디어에 기초하여 위 문제의 본질을 데이터의 분산의 동일성에 대한 가설검정의 문제 로 변환하였다. 이를 검정하기 위하여 모수, 비모수적 검정 방법을 응용하였으며 그 결과로 Feature의 존재여부를 판단하여, Feature가 있을 때에는 화소값 차이가 가장 작은 방향 주위의 화소값의 평균을 이용하여 보간하였다. 또한 PSNR을 통해서 기존 방법들에 비해 본 연구결과의 우수성을 보여주하고자 한다. 또한 본 연구에서는 이차원 데이터를 일차원 시열 데이터로 재배열하는 Kim and Lee(2005)의 방법에 기초하여 Deinterlacing 문제에 적용하였다.

3. 에지(Edge)에 근거한 Deinterlacing 알고리즘

3.1 ELA 알고리즘

ELA 알고리즘은 보간하고자 하는 화소의 주변 6개의 화소를 사용하여 보간을 하는 방식이며, 그림과 같이 수직과 대각선 두 방향으로 화소의 방향성 상관 관계를 계산하여 에지 방향을 검출하고, 검출된 방향으로 두 화소값을 평균하여 보간하게 된다. 이 방법은 각 화소의 상관관계를 기초로 하여 방향에 의존하는 독립 보간 알고리즘으로 잘 알려져 있다. 즉, 보간하고자 하는 화소를 대칭으로 공간방향의 각 화소의 상관도를 알아내어 계산하는 방법으로 공간방향의 상관만을 이용하는 방법이다. 따라서 시간축을 이용한 움직임 보상이나 움직임 예측 방법보다 연산량이 적으며 실시간 구현에도 적합하다. 수평 방향 윤곽선의 경우 공간상에서 처리하는 알고리즘의 경우엔 수평 방향의 윤곽선을 검출한다는 것은 거의 불가능하다. 따라서 다른 방향에서 고려한 방법이 제안되었다. 즉, 시간축을 고려한 경우와 움직임 예측 및 보상을 이용한 경우이며, 이러한 방식은 많은 연산량을 필요로 하게 된다. 그러나 ELA 알고리즘은 상당히 적은 연산량을 사용하여 실시간 구현에 있어 더 유리하며 아래 <그림 1>에서와 같이 각 방향의 화소 상호간의 상관관계를 구하여 방향을 결정한다.



<그림 1> ELA 알고리즘

<그림 1>에서와 같이 각각의 방향을 a, b, c 라 하면 다음 식과 같이 계산하여 가장 높은 상관관계를 갖는 방향을 찾는다.

$$\begin{aligned} a &= |x(k-1, m) - x(k+1, m)| \\ b &= |x(k-1, m+1) - x(k+1, m-1)| \\ c &= |x(k-1, m-1) - x(k+1, m+1)| \end{aligned}$$

각 방향에 대한 값을 계산한 후 가장 작은 값을 갖는 방향 즉, 두 라인에서 상관관계가 가장 큰 화소를 찾은 다음 이들 중에 가장 작은 차의 값을 갖는 방향의 두 화소 값을 평균한다. 예를 들어, 만약 a 가 가장 작은 차의 값을 갖는다면 보간될 값 (k, m)

은 다음과 같이 계산한다.

$$(k,m) = |x(k-1,m) + x(k+1,m)|/2$$

즉, 각각에 대한 방향에 ELA 알고리즘을 적용하여 정리하면 다음과 같다.

- (1) 우선 식에 따라 각 방향에 대해서 상관관계가 가장 높은 a, b, c 를 찾는다.
- (2) 방향 a, b, c 에 따라 보간되는 값은 다음과 같다.

$$a = |x(k-1,m) + x(k+1,m)|/2$$

$$b = |x(k-1,m+1) + x(k+1,m-1)|/2$$

$$c = |x(k-1,m-1) + x(k+1,m+1)|/2$$

이러한 ELA 알고리즘은 대부분의 상황에서 좋은 성능을 발휘하지만 에지의 방향을 잘못 예측하였을 경우에는 고주파 영역에서 보간 에리가 발생하게 되고 이러한 원하지 않은 에리는 영상의 화질에 심각한 열화로 나타난다.

3.2 E-ELA 알고리즘

E-ELA 알고리즘은 기존의 ELA 알고리즘이 Noise에 민감하기 때문에 나타나는 문제를 해결하기 위한 방법으로 에지 방향 판단의 조건을 더 정확하게 하여 오류를 최소화한다. 또한 구현의 용이성과 알고리즘의 복잡도를 낮추기 위해 에지(Edge)의 방향성 검사를 위한 윈도우 크기는 ELA와 동일하게 3x2 크기로 유지하며, 기존의 ELA 알고리즘에 에지 검출을 보다 정확하게 하는 식을 추가한다.

$$P = |x(k-1,m-1) - x(k+1,m)| + |x(k-1,m) - x(k+1,m+1)|$$

$$Q = |x(k-1,m+1) - x(k+1,m)| + |x(k-1,m) - x(k+1,m-1)|$$

여기서 P 는 왼쪽에서 오른쪽으로 향하는 대각선 방향의 화소들의 차이를 나타내며, Q 는 오른쪽에서 왼쪽으로 향하는 대각선 방향의 화소들의 차이를 나타낸다. 이 두 함수를 이용하여 다음과 같은 3가지 방향성을 유추한다.

$x(k-1,m-1)$	$x(k-1,m)$	$x(k-1,m+1)$	$x(k-1,m-1)$	$x(k-1,m)$	$x(k-1,m+1)$
$x(k,m-1)$	$x(k,m)$	$x(k,m+1)$	$x(k,m-1)$	$x(k,m)$	$x(k,m+1)$
$x(k+1,m-1)$	$x(k+1,m)$	$x(k+1,m+1)$	$x(k+1,m-1)$	$x(k+1,m)$	$x(k+1,m+1)$

(a)

(b)

$x(k-1, m-1)$	$x(k-1, m)$	$x(k-1, m+1)$
$x(k, m-1)$	$x(k, m)$	$x(k, m+1)$
$x(k+1, m-1)$	$x(k+1, m)$	$x(k+1, m+1)$

(c)

<그림 2> E-ELA 알고리즘


첫 번째는 $P > Q$ 인 경우이다. 이 경우는 에지가 Q 의 에지 방향처럼 흐른다고 할 수 있다. 따라서 <그림 2>의 (b),(c)처럼 두 가지 요소만 고려하여 상관도가 높은 요소의 두 화소 평균으로 새로운 화소 값을 취한다. 두 번째로 $P = Q$ 인 경우는 에지가 어느 방향으로 흐른다는 것을 알 수 없기 때문에 <그림 2>의 (a),(b),(c)처럼 세 가지 요소를 모두 고려하여, 그 중 상관도가 높은 요소의 두 화소 평균으로 새로운 화소 값을 취한다. 마지막으로 세 번째는 $P < Q$ 인 경우로서 이 경우는 에지가 P 의 에지 방향처럼 흐른다고 할 수 있다. 그래서 <그림 2>의 (a),(b)처럼 두 가지 요소를 고려하여 상관도가 높은 요소의 두 화소 평균으로 새로운 화소 값을 취한다.

4. 새로운 Deinterlacing 알고리즘

4.1 Feature Vector 정의

본 연구에서 랜덤성을 검정하기 위하여 기본적으로 사용하는 방법은 다음과 같이 Kim and Lee(2005)가 제안한 것과 같다.

M_{ij}^N 를 중심에 x_{ij} 가 있는 $N \times N$ 픽셀(pixel) 윈도우라고 하면 픽셀 윈도우의 전체 픽셀의 수는 N^2 개 이다. 이 픽셀의 값들을 방향성 θ ($\theta = 1, 2, \dots, n$)에 따라 재배열한 것을 $U^\theta = [U_1^\theta, U_2^\theta, \dots, U_{N^2}^\theta]$ 라 하자. 픽셀의 재배열에 대한 이해를 돕기 위해 <그림 3>에 $N=4$, $n=4$ 의 경우를 예시하였다. 여기서 고려하는 4가지 방향은 $\theta = [0^\circ, 90^\circ, 45^\circ, 135^\circ]$ 이다.



<그림 3> 4 방향성에 따른 픽셀의 재배열 방법

이렇게 재배열된 픽셀 값들을 기초로 특정 방향성 θ 에 대한 Feature 벡터를 다음과 같이 정의한다.

$$Z^\theta = [Z_2^\theta, Z_3^\theta, \dots, Z_{N^2}^\theta] \quad , \quad \text{단} \quad Z_k^\theta = U_k^\theta - U_{k-1}^\theta, \quad \theta = 1, 2, \dots, n \quad ,$$

$$k = 2, 3, \dots, N^2$$

M_{ij}^N 에 특정한 방향 θ 에 대해서 Feature가 존재할 때, 작은 값을 갖는 Z_k^θ 가 많아질 것이며, 특정한 방향성이 없는 랜덤한 경우 또는 랜덤 Noise 부분에서는 그렇지 않게 될 것이다. 만약 M_{ij}^N 에 특정한 방향 θ 쪽으로 특정한 Feature가 존재한다면, Z^θ 값의 변동성은 θ 와는 다른 $\theta^* (\neq \theta)$ 에 대한 Z^{θ^*} 의 변동의 크기보다 작게 될 것이다. 따라서 임의의 픽셀 윈도우 M_{ij}^N 에 Feature가 존재하는가, 즉 방향성이 존재하는가에 대한 문제는 $Z^\theta, \theta = 1, 2, \dots, n$ 의 분산의 동일성 검정의 문제로 변환시킬 수 있게 된다.

4.2 분산의 동일성 검정방법

Kim and Lee(2005)가 제안한 것과 같이 임의의 픽셀 윈도우 M_{ij}^N 에 특정한 Feature가 존재하는가, 즉 방향성이 존재하는가를 검정하는 경우의 영가설과 대립가설은 다음과 같다.

$$H_0 : M_{ij}^N \text{에는 Feature가 존재하지 않는다.} \quad H_1 : M_{ij}^N \text{에는 Feature가 존재한다.}$$

이러한 가설은 전술한 바와 같이 여러 집단의 분산의 동일성 검정에 대한 문제의 영가설과 대립가설로 변환할 수 있다.

$$H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_n^2 \quad H_1 : \text{적어도 하나의 } i \neq j \text{에 대하여 } \sigma_i^2 \neq \sigma_j^2$$

위의 가설에서 σ_θ^2 은 $Z^\theta, \theta = 1, 2, \dots, n$ 의 모분산이다. 본 연구에서는 다음에 설명하는 모수적, 준모수적, 비모수적인 세 가지 검정 방법을 이용하여 위의 가설을 검정한다.

4.2.1 The Bartlett Test

모수적(parametric) 방법인 Bartlett Test는 적어도 두 개의 표본들에 대해 분산이 같지 않다는 대립가설에 대하여 표본들 사이의 분산의 동일성을 검정하는 데 사용된다. 이 방법에서는 Z^θ 의 정규성을 가정하며, 정규성 가정에 대해 매우 민감한 것으로 알려져 있다. Bartlett Test의 검정통계량(test statistic) G 는 다음과 같이 정의된다.

$$G = \left[1 + \frac{1}{3(n-1)} \left(\frac{n}{N^2-2} - \frac{1}{L-n} \right) \right]^{-1} \left\{ (L-n) \ln s_p^2 - (N^2-2) \sum_{\theta=1}^n \ln s_\theta^2 \right\}$$

여기서 s_θ^2 는 $Z^\theta = [Z_2^\theta, Z_3^\theta, \dots, Z_{N^2}^\theta]$ 의 표본분산, $L = n(N^2 - 1)$, s_p^2 은 합동 표본분산으로서 표본분산을 가중평균한 값, 즉 $s_p^2 = \frac{N^2 - 2}{L - n} \sum_{\theta=1}^n s_\theta^2$ 으로 정의된다.

Bartlett Test는 $G > \chi^2(\alpha; n-1)$ 일 때 영가설을 기각하며, 여기서 $\chi^2(\alpha; n-1)$ 는 자유도가 $n-1$ 인 카이제곱 분포의 상위 α -분위수를 의미한다.

4.2.2 The Levene Test

준모수적(semi-parametric) 검정절차인 Levene Test는 Z^θ 의 정규성을 가정한다. 이 방법은 정규성 가정이 위배되었을 때 다른 모수적인 방법들보다 일반적으로 더 좋은 결과를 제공하는 것으로 알려져 있다. Levene Test는 다음과 같이 표본 평균과의 절대 편차에 근거한다.

$$y_k^\theta = |z_k^\theta - \bar{z}^\theta|, \quad \theta = 1, 2, \dots, n; \quad k = 2, 3, \dots, N^2$$

여기서 \bar{z}^θ 는 z^θ 의 표본 평균이다. z_k^θ 대신에 y_k^θ 를 사용하는 것은 등분산 검정을 등평균 검정으로 변환한 것이다. Levene Test의 검정 통계량 W 는 다음과 같다.

$$W = \left\{ (n-1) \sum_{\theta=1}^n \sum_{i=2}^{N^2} (y_i^\theta - \bar{y}^\theta)^2 \right\}^{-1} \left\{ (L-n) \sum_{\theta=1}^n (N^2-1) (\bar{y}^\theta - \bar{\bar{y}})^2 \right\}$$

여기서 \bar{y}^θ 는 $Y^\theta = [y_2^\theta, \dots, y_{N^2}^\theta]$ 의 표본 평균이며, $\bar{\bar{y}}$ 는 $\theta = 1, 2, \dots, n$; $k = 2, 3, \dots, N^2$ 에 대한 y_k^θ 의 전체 평균이다.

Levene Test에서는 $W > F(\alpha; n-1, L-n)$ 일 때 영가설을 기각하며, $F(\alpha; n-1, L-n)$ 는 분자, 분모의 자유도가 각각 $n-1$ 과 $L-n$ 인 F 분포의 상위 α -분위수를 의미한다.

4.2.3 The Kruskal-Wallis Test

비모수적(nonparametric) 방법인 Kruskal-Wallis Test에서는 Z^θ 의 정규성 가정을 필요로 하지 않는다. 이 방법에서는 검정통계량의 계산에서 각 관찰치들은 순위(rank)로 대체되며 검정통계량 H 는 다음과 같이 정의된다.

$$H = \frac{12}{L(L+1)} \sum_{\theta=1}^n \frac{(R^\theta)^2}{N^2-1} - 3(L+1)$$

여기서 $R^\theta = \sum_{k=2}^{N^2} r_k^\theta$, $\theta = 1, 2, \dots, n$ 이고 r_k^θ 는 y_k^θ 의 순위이다. 또한, 만약 영가설이

사실이라면, 통계량 H 는 점근적으로 자유도가 $n-1$ 인 카이제곱 분포를 따르게 된다. 따라서 Kruskal-Wallis Test 는 $H > \chi^2(\alpha; n-1)$ 라면 영가설을 기각하게 된다. 그리고 만약 y_k^g 의 값들 중에서 동점(tie)이 발생할 경우, H 통계량 값을 아래의 H' 으로 대체하게 된다.


$$H' = \frac{H}{1 - \left\{ \sum_{l=1}^g (t_l^3 - t_l) / (L^3 - L) \right\}}$$

여기서 H 는 평균순위를 사용하여 계산되며 g 는 동점(tie)그룹의 개수이며, t_l 은 동점그룹 L 의 크기이다.

4.3 방향성 검출 및 Deinterlacing 방법

모수적, 준모수적, 비모수적인 세 가지 검정 방법을 이용하여 위의 가설을 검정한 후, 검정결과에 따라서 방향성은 다음과 같이 결정한다.

1. 만약 H_0 을 기각하지 못하면 방향성이 없다고 판단하고, 주위의 화소값의 평균값을 보간값으로 사용한다.
2. 만약 H_0 을 기각하면 방향성이 있다고 판단하고 표본분산의 값이 가장 작은 방향성을 Feature의 방향으로 정한다. 방향성이 결정되면 <그림 4>에서 보는 바와 같이 각 방향성에 따라서 검은색의 화소값의 평균값을 사용하여 보간값으로 사용한다.



<그림 4> 방향성에 따른 Deinterlacing 방법

5. 모의실험 및 결론

본 논문에서는 Noise가 없는 원래의 이미지에 정규분포 $N(0, \sigma^2)$ 을 따르는 가우시안 Noise를 추가하여 Noise에 오염된 이미지를 만들고, ELA 방법과 본 연구에서 제안하는 방법에 따라 Deinterlacing 을 적용하는 모의실험을 실시하였다. 또한 모의실

험의 결과를 이미지 개선의 척도로서 가장 널리 사용되는 PSNR(Peak Signal-to-Noise Ratio) 값으로 비교하였고 실제 처리 이미지의 일부를 제공한다. 또한 PSNR의 값은 클수록 이미지의 질이 좋은 것을 의미한다.

5.1 Noise의 분포 및 PSNR

모의실험에서는 $\sigma^2 = 30, 100, 300$ 인 경우의 가우시안 Noise를 영상처리분야에서 자주 사용되는 'Tiffany' 이미지에 추가하여 사용하였다. 또한 PSNR은 MSE(Mean Squared Error)의 함수로서 PSNR과 MSE의 정의는 각각 다음과 같다.

$$PSNR = 20 \cdot \log_{10} \left(\frac{255}{\sqrt{MSE}} \right), \quad MSE = \frac{1}{J} \sum_i \sum_j (d_{ij} - o_{ij})^2$$

여기서 J 는 이미지의 전체 픽셀의 수, d_{ij} 는 Deinterlacing을 거쳐 생성된 픽셀의 값, o_{ij} 는 Noise가 없는 원래 이미지의 픽셀의 값이다.

5.2 모의실험 결과 및 결론

<표 1>의 모의실험 결과는 Noise의 분산 σ^2 값과 Deinterlacing 방법에 따른 PSNR 값을 비교한 것이다. 표에서 'ELA'는 ELA를 사용한 결과에 대한 PSNR 값, 'Bartlett'은 Bartlett Test를 사용하여 방향성을 찾아 Deinterlacing한 결과에 대한 PSNR 값, 'Levene'은 Levene Test를 사용하여 방향성을 찾아 Deinterlacing한 결과에 대한 PSNR 값, 'KW'는 Kruskal-Wallis Test를 사용하여 방향성을 찾아 Deinterlacing한 결과에 대한 PSNR 값을 의미한다.


<표 1> PSNR 결과 비교

σ^2	ELA	Bartlett	Levene	KW
30	31.94	32.88	31.73	31.38
100	28.90	29.49	28.84	28.68
300	23.14	25.14	25.13	25.65

<표 1>의 PSNR 값을 보면, $\sigma^2 = 30$ 과 $\sigma^2 = 100$ 인 경우, ELA 방법과 비교하여 모수적 방법인 Bartlett Test의 PSNR 값이 가장 좋은 것을 알 수 있다. 또한, $\sigma^2 = 300$ 인 경우, ELA 방법과 비교하여 비모수적 방법인 Kruskal-Wallis Test의 PSNR 값이 가장 좋은 것을 알 수 있다. 따라서 통계적 검정방법을 적용한 Deinterlacing 방법의 유용성을 확인할 수 있으며, 특히 Noise 분산이 큰 경우에 비모수적인 방법이 가장 효과적인 방법임을 알 수 있다.

5.3 처리영상 예

전술한 바와 같이 본 모의실험에서 사용한 샘플 이미지는 영상처리 분야에서 널리 사용되는 ‘Tiffany’ 이미지이다. <그림 5>는 <표 1>에서 $N(0,300)$ 을 따르는 가우시안 Noise에 오염된 이미지를 ELA 방법과 Kruskal-Wallis Test를 사용하여 Deinterlacing한 결과를 보여주고 있다. <그림 5>의 (a)는 Noise에 오염된 interlaced 이미지, (b)는 ELA 방법에 따라 Deinterlacing한 결과 이미지, (c)는 Kruskal-Wallis Test에 근거하여 Deinterlacing한 결과 이미지이다. 또한 <그림 5>의 (d)와 (e)는 Deinterlacing 결과를 시각적으로 확인하기 위하여 <그림 5>의 (b)와 (c)의 동일한 부분을 확대하여 보여주고 있는데, (d)는 (b)의 일부분 확대 이미지, (e)는 (c)의 일부분 확대 이미지이다. (d)와 (e)를 비교하여 보면, Noise 분산이 큰 경우에 비모수적인 방법이 더 효과적인 것을 시각적으로 확인할 수 있다.



<그림 5> Deinterlacing 결과 비교

참고문헌

1. Hann, G. D. and Bellers, E. B. (1998). Deinterlacing - An Overview, *Proceedings of the IEEE*, 86(9), pp. 1839-1857,

2. Kim, Y.(1996). Deinterlacing algorithm based on sparse wide, vector correlations, *SPIE Optical Engineering*, 2727, 89-99.
3. Kim, Y and Lee, J.(2005). Image Feature and Noise Detection Based on Statistical Hypothesis Tests and Their Applications in Image Processing, *IEEE Transactions on Consumer Electronics*, 51(4), 1367-1378.
4. Kim,Y. and Nam,J.(2007). Image Feature Detection and Contrast Enhancement Algorithms based on Statistical Test. *Journal of Korean Data & Information Science Society*, 18, 385-399.
5. Kuo, C. J., Liao, C. and Lin, C. C.(1996). Adaptive Interpolation Technique for Scanning Rate Conversion, *IEEE Transactions on Circuits and Systems Video Technology*, 6(3), pp.317-21.
6. Park, M. and Kang, M.(2004). A New Edge Dependent Deinterlacing Algorithm Based on Edge Patterns, *IEEE ISPACS 2004*, Seoul, Korea, 96-99.

[접수일(2008년 7월 22일), 게재확정일(2008년 8월 23일)]