

論 文

循環벡터處理에 의한 디지털映像復원에 관한 研究

正會員 李 大 寧* 正會員 李 潤 鉉**

A Study on Improvement in Digital Image Restoration by a Recursive Vector Processing

Dai Young LEE* and Yun Hyun LEE**, Regular Members

要 約 本論文은 線形空間의 不變인 毀損(blur)과 白色가우스性雜音에 의해 損傷된 映像에 대한 循環復元(recursive restoration)技法을 論하였다. 映像은 確率統計學的으로 그 平均과 相關函數(correlation function)에 의해 特徵지워진다. 隣接모델(neighborhood model)에 指數的自己相關函數(exponential autocorrelation function)가 사용되며 解析이 간단하고 편리하므로 映像輝度相關函數를 나타내는데 벡터 모델이 사용된다. 이 벡터 모델을 基本으로 한 映像表現에 있어서 離散的, 統計學的인 12點隣接모델이 開發되고 次元의 增加를 抑制하며 毀損되고 雜音성인 映像을 復元하기 위한 窓(window) 移動處理技法이 採用되었다. 12點隣接모델이 8點隣接모델보다 優秀한 것으로 나타나며 隣接의 많은 面素를 요하는 精密 映像에 適合함을 보인다. 이 結果는 線形필터링을 요하는 映像處理에 널리 이용될 수 있음을 나타낸다.

ABSTRACT This paper describes technique of the recursive restoration for the images degraded by linear space invariant blur and additive white Gaussian noise. The image is characterized statistically by its mean and correlation function. An exponential autocorrelation function has been used to model neighborhood model. The vector model was used because of analytical simplicity and capability to implement brightness correlation function. Base on the vector model, a two-dimensional discrete stochastic a 12 point neighborhood model for representing images was developed and used the technique of moving window processing to restore blurred and noisy images without dimensionality increasing. It has been shown a 12 point neighborhood model was found to be more adequate than a 8 point pixel model to obtain optimum pixel estimates. If the image is highly correlated, it is necessary to use a large number of points in the neighborhood in order to have improvements in restoring image. It is believed that these result could be applied to a wide range of image processing problem. Because image processing techniques normally required a 2-D linear filtering.

1. 序 論

確率統計學的的信號處理은 人間活動의 넓은 分野에서 應用된다. 그같은 應用은 醫學의 診斷治療

로부터 産業用放射線寫眞, 光學地形調查 또는 地震信號處理, 宇宙의 目標物追跡, 交通制御등 매우 多樣하다⁽¹⁾⁻⁽³⁾.

映像은 光學시스템의 限界, film grain, 大氣의 turbulence 등의 blur와 回路나 sensor雜音, 傳送媒質등에 기인한 random noise를 피할 수 없게 된다 또 impulse應答이 object座標의 函數로 될 때 일어나는 resolution loss나 smearing 형태의 空間的 損傷을 받는다⁽³⁾. 따라서 映像復元은 degrade된 入力을 받아 원래의 無歪映像 x 의 양호한 estimate $\hat{x}(i, j)$ 를 얻기 위하여 情報들을 적절히 이

* 慶熙大學校工科大學電子工學科
Dept. of Electronic Engineering Kyunghee University Seoul, 132 Korea.

** 韓國航空大學通信工學科
Dept. of Communication Engineering, Hankuk Aviation College, Seoul, 122 Korea.

論文番號 : 83-16 (接受 1983. 8. 29)

용하는 것이다. 대부분 disturbance는 static으로 알려진 random process에 의해特徵지워질 수 있으며 더우기 어떤 應用에 있어서는 映像 그 자체의 先行知識은 統計的性質만을 갖는다. 따라서 映像復元은 正確한 推定과 判斷에 필요한 基準 및 先行情報등에 따라 차이가 생긴다⁽⁴⁾.

映像필터의 發展은 IC技術에 의한 digital 필터링의 實現容易함과 大規模計算能力의 디지털 컴퓨터出現, 그리고 確率統計學概念의 필터링에의 適用하는 理論的인 發展에 크게 자극되었다. 그 결과 光學的필터링의 많은 固有한 限界가 digital 處理에 의하여 극복되어 많은 새로운 接近이 可能하게 되었다.

映像復元은 1950年代初 Maréchal과 그의 同僚에 의해 寫眞의 復元可能性을 證明함으로써 비롯되었으며⁽³⁾ 信號處理接近의 filtering은 Wiener filter가 平均自乘誤差(mean square error: MSE)면에서 가장 양호한 것으로 알려졌으나 信號나 雜音의 non-stationarity가 固有問題로 되는 경우에는 不합하지 않음을 알게 되었다. 最近에 dimensionality와 on-line조건 하의 應用에 recursive filter가 더 重要하여 관심이 집중되었는데 Nahi와 Assefi가 그 先驅者이다^{(5),(6)}.

대부분의 映像은 brightness (gray) level을 나타내는 統計學的인 mean이나 correlation函數등을 定하는 random-process에 의해 잘 나타내어진다⁽⁴⁾. 本研究에서는 film grain雜音과 같이 Gaussian random variable로 近似시킬 수 있는 空間的不變인 blur와 增幅器등의 결합에 의한 random noise로 data가 質低下됨을 가상하여 이 random field에 대한 dynamic모델을 유도한다. 映像은 exponential autocorrelation函數를 갖는 離散 二次元random-process라 가정하며^{(7),(9)} 精密映像일 때 隣接點間의 correlation을 1 line interval이상이 요구되어야 할 것이므로 12 point隣接모델을 도입하였고 시스템 處理에서 dimensionality의 증가가 3×3 strip window보다 넘지 않도록 3×5 window를 normal로 처리하여 解像度를 改善하도록 한다. 이 결과를 computer simulation에 의해 이 approach의 正當성을 確認하고자 한다.

2. 映像信號모델

2.1 最隣接모델

空間的不變 (spatially invariant point spread function: SIPSF)인 映像시스템에서 映像모델의 discrete式은

$$r(i, j) = \sum_{m,n} h(m, n) x(i-m, j-n) + v(i, j) \tag{1}$$

이다. 여기서 h 는 PSF, $x(i, j)$ 는 $M \times N$ 크기의 원래의 信號映像, $v(i, j)$ 는 雜音이다. 실제 대부분의 映像은 stationary이며 이 형태에 의해 近似될 수 있다.

$M \times N$ 二次元映像에서 特定座標 (m, n) 에서의 intensity를 x_{mn} 으로 나타내며 이 映像의 autocorrelation函數가 다음 식으로 주어지는 映像이라고 한다^{(5),(6)}. 즉

$$E[x_{m,n}x_{m+i,n+j}] = R_{ij} = \sigma^2 \exp(-\gamma_1|i| - \gamma_2|j|) \tag{2}$$

여기서 E 는 mathematical expectation, i 는 垂直增分, j 는 水平增分, σ^2 은 random variable x_{ij} 의 variance, γ_1, γ_2 는 2-D에서 平均單位偏移相關係數이다.

映像모델은 random variable x_{ij} 가 그와 매우 가까운 隣接pixel을 통해서만 모든 다른 점들과 correlate된다는 사실에 기초를 둔다. 그림 1(a)는 8點隣接모델이며 x_{ij} 는 다음과 같이 표시될 수 있다⁽⁹⁾.

$$x_{ij} = a_1 x_{i,j+1} + a_2 x_{i+1,j} + a_3 x_{i,j-1} + a_4 x_{i-1,j-1} + a_5 x_{i+1,j-1} + a_6 x_{i-1,j+1} + a_7 x_{i-1,j} + a_8 x_{i+1,j+1} + k\xi_{ij} \tag{3}$$

여기서 ξ_{ij} 는 zero mean이며 uncorrelated random variable이고 a_i 는 그림과 같이 점 A가 이웃 pixel과 갖는 相關程度를 나타내는 regression係數이다. 이 식(3)은 2點境界값 문제를 구성하는 복잡한 알고리즘이 된다. 또 映像을 적당한 폭의 strip으로 처리하므로 적어도 垂直方向으로의 causality를 유지하는 semicausal等價로 하면 精確한 model에 기초를 둔 것과 비교하여 큰 損失없을 수 행이 가능하다⁽⁵⁾. 즉

$$x_{ij} = a'_1 x_{i,j-1} + a'_2 x_{i+1,j} + a'_3 x_{i-1,j-1} + a'_4 x_{i+1,j-1} + a'_7 x_{i-1,j} + k\xi'_{ij} \tag{4}$$




그림 1 8點隣接모델 (a)과 그의 semicausal 표현 (b)
(a) 8 point nearest neighbors model, (b) and its semicausal representation.

여기서 $\alpha'_1 = \alpha_1 + \alpha_3$, $\alpha'_4 = \alpha_4 + \alpha_6$, $\alpha'_5 = \alpha_5 + \alpha_8$ 이다. 이 식을 隣接點과 相關關係를 취하여 (6)과 같이 regression係數를 구하면 다음과 같다.

$$\begin{pmatrix} \alpha_1 \\ \alpha_2 \\ \alpha_4 \end{pmatrix} = \frac{1}{A} \begin{pmatrix} \gamma_{11} \\ \gamma_{01} \\ \gamma_{10} \end{pmatrix} \quad (5)$$

여기서

$$A = \begin{pmatrix} \gamma_{01} + \gamma_{21} & \gamma_{10} + \gamma_{12} & 1 + \gamma_{02} + \gamma_{20} + \gamma_{22} \\ 2\gamma_{11} & 1 + \gamma_{02} & 2(\gamma_{10} + \gamma_{12}) \\ 1 + \gamma_{20} & 2\gamma_{11} & 2(\gamma_{01} + \gamma_{21}) \end{pmatrix} \quad (6)$$

또 $\gamma_{ij} = R_{ij}/R_{0,0}$, $R_{0,0} = \sigma^2$

그러므로 semicausal모델의 regression係數는

$$\alpha'_1 = 2\alpha_1, \alpha_2 = \alpha_7, \alpha'_4 = \alpha'_5 = 2\alpha_4 \quad (7)$$

또 식(3)에서 양변을 제곱하여 expectation을 취하면 k 가 구해진다. 즉

$$k^2 = |1 - \alpha'_1 \gamma_{01} - 2\alpha_2 \gamma_{10} - 2\alpha'_4 \gamma_{11}| \quad (8)$$

2.2 映像信號모델

PSF(point spread function)가 random variable x_{ij} 를 중심으로 주위의 더 많은 pixel과 correlate 되어야 하는 精密画像일 때 映像모델을 2 line interval까지 擴張시켜야 하며 12點隣接모델은 이 목적으로 구했다. 그림 2의 12點隣接모델에서 x_{ij} 는 다음과 같이 표시된다.

$$\begin{aligned} x_{ij} = & \alpha_1 x_{i,j+1} + \alpha_2 x_{i+1,j} + \alpha_3 x_{i,j-1} + \alpha_4 x_{i-1,j-1} \\ & + \alpha_5 x_{i+1,j-1} + \alpha_6 x_{i-1,j+1} + \alpha_7 x_{i-1,j} \\ & + \alpha_8 x_{i+1,j+1} + \alpha_9 x_{i,j+2} + \alpha_{10} x_{i+2,j} \\ & + \alpha_{11} x_{i,j-2} + \alpha_{12} x_{i-2,j} + k\xi_{ij} \end{aligned} \quad (9)$$

따라서 semicausal표현은

$$\begin{aligned} x_{ij} = & \alpha'_1 x_{i,j-1} + \alpha_2 x_{i+1,j} + \alpha'_4 x_{i-1,j-1} \\ & + \alpha_5 x_{i+1,j-1} + \alpha_7 x_{i-1,j} + \alpha_9 x_{i,j+2} \end{aligned}$$




그림 2 12點映像모델
12point nearest neighbors model.

$$+ \alpha_{10} x_{i+2,j} + \alpha_{12} x_{i-2,j} + k\xi_{ij} \quad (10)$$

여기서 $\alpha'_1 = \alpha_1 + \alpha_3$, $\alpha'_4 = \alpha_4 + \alpha_6$, $\alpha'_5 = \alpha_5 + \alpha_8$, $\alpha'_{11} = \alpha_9 + \alpha_{11}$ 이다. 그러므로 위 식을 隣接點과 correlate를 취하여 regression係數를 구하면 다음과 같다.

$$\alpha'_1 = \frac{1}{B} \begin{pmatrix} \gamma_{01} & 2\gamma_{11} & 2\gamma_{10} & 2\gamma_{21} & \gamma_{01} \\ \gamma_{10} & 1 + \gamma_{20} & \gamma_{01} + \gamma_{21} & \gamma_{10} + \gamma_{30} & \gamma_{12} \\ \gamma_{11} & \gamma_{01} + \gamma_{21} & 1 + \gamma_{20} & \gamma_{11} + \gamma_{31} & \gamma_{11} \\ \gamma_{20} & \gamma_{10} + \gamma_{30} & \gamma_{11} + \gamma_{31} & 1 + \gamma_{40} & \gamma_{22} \\ \gamma_{02} & \gamma_{12} & 2\gamma_{11} & 2\gamma_{22} & 1 \end{pmatrix} \quad (11-a)$$

나머지 係數 $\alpha_2, \alpha'_4, \alpha_{10}, \alpha_{11}$ 도 Cramer's rule에 의해 같은 방식으로 구해진다. 여기서 B 는

$$B = \begin{pmatrix} 1 & 2\gamma_{11} & 2\gamma_{10} & 2\gamma_{21} & 2\gamma_{01} \\ \gamma_{11} & 1 + \gamma_{20} & \gamma_{01} + \gamma_{21} & \gamma_{10} + \gamma_{30} & \gamma_{12} \\ \gamma_{10} & \gamma_{01} + \gamma_{21} & 1 + \gamma_{20} & \gamma_{11} + \gamma_{31} & \gamma_{11} \\ \gamma_{21} & \gamma_{10} + \gamma_{30} & \gamma_{11} + \gamma_{31} & 1 + \gamma_{40} & \gamma_{22} \\ \gamma_{01} & 2\gamma_{12} & 2\gamma_{11} & 2\gamma_{22} & 1 \end{pmatrix} \quad (11-b)$$

또 k 는 식(9)로부터 구해진다. 즉

$$k^2 = |1 - \alpha'_1 \gamma_{01} + 2\alpha_2 \gamma_{10} - 2\alpha'_4 \gamma_{11} - 2\alpha_{10} \gamma_{20} - \alpha_{11} \gamma_{02}| \quad (12)$$

3. 循環映像處理알고리즘

다이나믹 시스템 信號모델의 state vector는 Kalman計算의 순서를 결정한다.

지금 strip window를 그림 3과 같이 raster모양으로 한 줄씩 영상을 scan할 때 $(k+1)$ 순간에 새로운 data set x'_3, x'_4, x'_9 가 새로 나타나는 반면 x_1 ,




그림 3 Kalman window 처리에 있어서 循環모우드
Mode of recursive in a Kalman window processor

x_6, x_7 은 탈락된다. 그리하여 한 줄씩 이동할 때 各點은 세 번 estimate되어 그 平均이 취해진다. 따라서 映像 scanning system은 다음과 같이 離散的이며 統計學的인 線形dynamic system이다. 즉

$$\mathbf{X}(k+1) = F\mathbf{X}(k) + G\mathbf{U}(k+1) \quad (13a)$$

$$r(k) = H\mathbf{X}(k) + v(k) \quad (13b)$$

여기서 $\mathbf{X}(k)$ 는 signal state vector, $r(k)$ 는 observation scalar 出力, F, G, H 는 각각 시스템의 transition, drive, observation matrix이다. 또 $\mathbf{U}(k), v(k)$ 는 zero mean이며 다음 covariance를 갖는 uncorrelated Gaussian noise이다. 즉

$$E[\mathbf{U}_k] = 0, \quad E[\mathbf{U}_k \mathbf{U}_k^T] = Q(k) \delta_{k,j} \quad (14)$$

$$E[v_k] = 0, \quad E[v_k v_k^T] = R(k) \delta_{k,j} \quad (15)$$

$$E[\mathbf{U}_k v_k^T] = 0 \quad \text{for all } k, j \quad (16)$$

여기서 $E[\cdot]$ 는 expectation, $\delta_{k,j}$ 는 Kronecker delta 函數, $Q(k)$ 및 $R(k)$ 는 각각 process noise 및 measurement noise covariance matrix이다.

이제 그림 4의 3×5 strip window를 채용하여 scan 方向으로 처리될 때 탈락되고 새로 영입되는 동작의 변환은 F, G 에 의하여 영상 pixel값 x_{ij} 가 white noise random variable인 理想的인 경우는 다음과 같이 된다.

$$F = \begin{pmatrix} 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & \dots & \dots & \dots & \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & \dots & \dots & \dots & \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & \dots & \dots & \dots & \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & \dots & \dots & \dots & \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & \dots & \dots & \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & \dots & \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & \dots & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & \dots & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & \dots & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{pmatrix}; G = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (17)$$

$$H = \begin{pmatrix} 0 & h_1 & h_2 & h_3 & 0 & 0 & 0 & h_4 & h_5 & h_6 & 0 & 0 & 0 & h_7 & h_8 & h_9 & 0 \end{pmatrix} \quad (18)$$

이제 식(13)에 의하여 기술된 discrete model의 기본에 대하여 recursive estimate가 논의될 수 있다. 이들 모델에 대한 vector Kalman filtering 모델은 (9), (10), (12)에 의한다. 이 映像處理에 Kalman 式이 적용되기 위해서는 條件式 (14)~(18)이 만족되어야 한다. 그러나 새로 더해지는 3개의 pixel이 uncorrelated random excitation noise vector가 아니므로 식(17)을 가진 모델식 (13)은 수정되어야




그림 4 3×5 벡터處理窓
 3×5 vector processor window.

사용할 수 있게 된다. 즉 $\mathbf{U}(k+1)$ 을 $(k+1)$ 순간의 data로 정의하여 空間的matrix位置函數로 다음과 같이 나타내어진다.

$$\mathbf{U}(k+1) = \begin{pmatrix} u(i-1, j+3) \\ u(i, j+3) \\ u(i+1, j+3) \end{pmatrix} = \begin{pmatrix} u_5(k+1) \\ u_6(k+1) \\ u_{15}(k+1) \end{pmatrix} \quad (19)$$

이 식에 x_{ij} 의 semicausal model을 적용하여 식(13)을 수정하면 이 때 변형된 $\mathbf{U}(k)$ 는 다음 auto-covariance 函數를 가진 white Gaussian process가 된다. 즉

$$Q(k) = E[\mathbf{U}_k \mathbf{U}_k^T] = \sigma^2 I \delta_{k,j} \quad (20)$$

따라서 이에 의해 구사된 시스템 모델은 적어도 optimum 近似의 수행을 기대한다.

3.1 第1 모델

식(4)와 (19)에서 다음을 얻는다.

$$u_5(k+1) = \alpha_1' x_5(k) + 2\alpha_1' x_6(k) + 2\alpha_2 u_6(k+1) + \beta \xi(k+1)$$

$$u_6(k+1) = \alpha_1' x_5(k) + \alpha_1' x_6(k) + \alpha_1' x_{15}(k) + \alpha_2 u_5(k+1) + \alpha_2 u_{15}(k+1) + \beta \eta(k+1)$$

$$u_{15}(k+1) = 2\alpha_1' x_6(k) + \alpha_1' x_{15}(k) + 2\alpha_2 u_6(k+1) + \beta \lambda(k+1) \quad (21)$$

위 식을 $u_5(k+1), u_6(k+1), u_{15}(k+1)$ 에 대해 풀어서 식(13)에 넣으면 다음 식을 얻는다.

$$\mathbf{X}(k+1) = F_1 \mathbf{X}(k) + G_1 \theta(k+1) \quad (22a)$$

$$r(k) = H\mathbf{X}(k) + v(k) \quad (22b)$$

여기서 벡터 $\theta(k+1)$ 는 white Gaussian process이며

$$\theta(k+1) = \begin{pmatrix} \xi \\ \eta \\ \lambda \end{pmatrix} (k+1) \quad (23)$$

또 matrix F_1 및 G_1 은 식(17)의 F 및 G 와 같으며 다음 위치에 zero가 아닌 값이 부가된다. 즉

		column number					column number		
row number		5	6	15	row number		1	2	3
$F_1 \rightarrow$	5	a	b	c	$G_1 \rightarrow$	5	a'	b'	c'
	6	d	e	d		6	d'	e'	d'
	15	c	h	a		15	c'	b'	a'

여기서 파라미터 a, b, c, d, e 및 a', b', c', d', e' 는

$$\begin{aligned} a &= C(\alpha_1' - 2\alpha_1'\alpha_2^2 + 2\alpha_2\alpha_4) & a' &= (1 - 2\alpha_2^2)\beta C \\ b &= 2C(\alpha_1'\alpha_2 + \alpha_4) & b' &= 2\alpha_2\beta C \\ c &= 2C\alpha_2(\alpha_1'\alpha_2 + \alpha_4) & c' &= 2\alpha_2^2\beta C \\ d &= C(\alpha_1'\alpha_2 + \alpha_4) & d' &= \alpha_2\beta C \\ e &= C(\alpha_1' + 4\alpha_2\alpha_4) & e' &= \beta C \\ C &= 1/(1 - 4\alpha_2^2) \end{aligned}$$

3.2 第2 모델

식(10)을 그림 4의 processor window에 적용하면

$$\begin{aligned} u_5(k+1) &= \alpha_{11}'x_4(k) + \alpha_1'x_5(k) + 2\alpha_1'x_6(k) \\ &\quad + 2\alpha_{10}x_{15}(k) + 2\alpha_6u_6(k+1) \\ &\quad + \beta\xi(k+1) \\ u_6(k+1) &= \alpha_1'x_5(k) + \alpha_1'x_6(k) + \alpha_{11}'x_7(k) \\ &\quad + \alpha_4'x_{15}(k) + \alpha_2u_5(k+1) \\ &\quad + \alpha_2u_{15}(k+1) + \beta\eta(k+1) \quad (24) \\ u_{16}(k+1) &= 2\alpha_1'x_6(k) + \alpha_{11}'x_{14}(k) + \alpha_1'x_{15}(k) \\ &\quad + 2\alpha_{10}u_5(k+1) + 2\alpha_2u_6(k+1) \\ &\quad + \beta\lambda(k+1) \end{aligned}$$

이 식을 식(13)에 넣으면 다음 식이 된다.

$$\mathbf{X}(k+1) = F_2\mathbf{X}(k) + G_2\theta(k+1) \quad (30a)$$

$$\mathbf{r}(k) = H\mathbf{X}(k) + \mathbf{v}(k) \quad (30b)$$

여기서 matrix F_2, G_2 는 식(17)의 F, G 에 다음 matrix 위치에 부가된다. 즉

		column number							column number			
row number		4	5	6	7	14	15	row number		1	2	3
$F_2 \rightarrow$	5	a	b	c	d	e	f	$G_2 \rightarrow$	5	a'	b'	c'
	6	d	g	h	i	j	g		6	d'	e'	d'
	15	e	f	c	d	a	b		15	c'	b'	a'

여기서

$$\begin{aligned} a &= D\alpha_{11}'(1 - 2\alpha_2^2) \\ b &= D[\alpha_{11}'(1 - 2\alpha_2^2) + 2\alpha_2\alpha_4'(1 + 2\alpha_{10})] \\ c &= 2D[\alpha_1'\alpha_2(1 + 2\alpha_{10}) + \alpha_4'(1 + 2\alpha_{10})] \\ d &= 2D\alpha_2\alpha_{11}'(1 + 2\alpha_{10}) \\ e &= 2D\alpha_{11}'(\alpha_2^2 + \alpha_{10}) \\ f &= 2D[\alpha_2\alpha_4'(1 + 2\alpha_{10}) + \alpha_1'(\alpha_2^2 + \alpha_{10})] \\ g &= D[\alpha_1'\alpha_2(1 + 2\alpha_{10}) + \alpha_4'(1 - 4\alpha_{10}^2)] \\ h &= D[2\alpha_2\alpha_4'(1 + 2\alpha_{10}) + \alpha_1'(1 - 4\alpha_{10}^2)] \end{aligned}$$

$$\begin{aligned} &+ 2\alpha_2\alpha_4'(1 + 2\alpha_{10}) \\ i &= D\alpha_{11}'(1 - 4\alpha_{10}^2) \\ j &= D\alpha_2\alpha_{11}'(1 + 2\alpha_{10}) \\ D &= \frac{1}{1 - 4\alpha_{10}^2 - 4\alpha_2^2(1 + 2\alpha_{10})} \\ a &= \beta D(1 - 2\alpha_2^2) \\ b &= 2\beta D\alpha_2(1 + 2\alpha_{10}) \\ c &= 2\beta D(\alpha_{10} + \alpha_2^2) \\ d &= \beta D\alpha_2(1 + 2\alpha_{10}) \\ e &= \beta D(1 - 4\alpha_{10}^2) \end{aligned}$$

4. 處理結果 및 檢討

새로 開發된 12點映像모델과 3×5 strip window 處理方式을 이용하여 映像復元處理하였다. 또 既存 8點모델을 3×5 strip에 적용시켰으며 3×3, 5×5 strip window 處理⁽⁹⁾와 비교하였다. 3×5 strip vector 處理를 행함으로써 3×3方式보다 dimension-





그림 5 原映像信號
Original image signal.



(a) 왜곡된 映像
corrupted image.




(b) 모델 I에 의해 복원된 映像
Restored image obtained using model I.

그림 6 映像復元 (SNR=0.818dB)
Image restoration.

ality와 기억용량이 증가되지 않음이 확인되었다.

映像復元改善을 위한 處理方式은 white additive noise만에 의하여 degraded된 映像의 필터링에 관심을 집중하였다. 시블레이션映像은 그림 5와 같이 3 level부처화를 사용하였으며 영상크기를 64×64로 하여 實際映像再現可能性을 알 수 있도록 하였고 여기에 white random noise를 발생시켜 入力映像信號와 같이 가해줌으로써 degrade된 映像을 얻었다. random noise는 回路나 傳送媒質등의 white Gaussian noise외에 映像録曲의 granularity sensing mechanism의 부정확, spurious object 등 blur는 線形성과 空間的不變性이 實際적으로 상




(c) 모델 II에 의해 복원된 映像
Restored image obtained using model II.

표 I 入力映像信號 파라미터

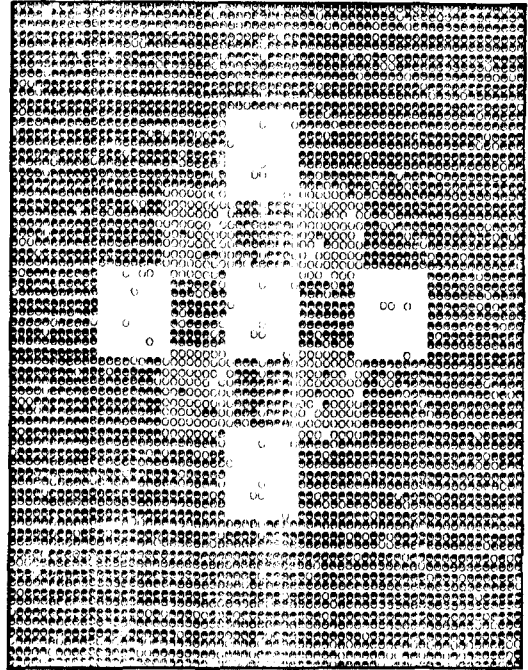
Input image signal parameters.

mean	49.16016	DET A	0.0025645
variance	622.8823	α_1	0.6777031
R_1	0.8905675	α_2	1.197935
R_2	0.7776105	α_4	-0.3377337
R_3	0.8007577	α_{10}	-0.8352208
R_4	0.8905694	α_{11}	0.0734763
R_5	0.7776086		


당히 정확하며 Gauss性 random variable로 된 다
3.4.2) 이 발생잡음의 variance변화에 의해 필요한



(a) 受損된 映像
Corrupted image.



(c) 모델 II에 의해 復元된 映像
Restored image obtained using model II.
그림 7 映像復元 (SNR = 4.578dB)
Image restoration.



(b) 모델 I에 의해 復元된 映像
Restored image obtained using model I.

SNR를 주어 data를 구했다. 여기서 정의된 SNR은 (4)에 따른다. 표 1은 실험에 사용된 映像信號 파라미터이다.

사용된 컴퓨터는 FACOM230 OS2/VS를 사용

하였고 SNR를 0.818dB, 4.578dB로 하였을 때의 시뮬레이션 결과를 그림 6, 7에 보였다.

표 2는 Dikshit에⁽⁹⁾의해 얻어진 8 point 모델에 3×3 및 5×5 window處理結果와 비교를 나타낸 것이다. 본 연구로부터 3×5 window處理에 대하여 8 point 모델보다 12 point 모델이 더 改善됨을 알 수 있다. 이것은 Kalman window를 水平으로 3×3에서 3×5로 늘리면 임의의 映像 pixel은 이웃 pixel과의 correlation에 의한 estimate가 3번에서 5번으로 증가되어 그 평균값이 그 지점의 gray level로 되므로 더 復元이 改善된다. 또 PSF를 3×3으로 제한하여 정함으로써 error가 무시될 수 없음을 뜻한다. 이것은 noise의 variance變化에 의해 SNR을 변함으로도 알 수 있다. Dikshit 방식의 모델 IV (8 point 5×5 strip)이 약간 더 우수함으로 미루어 dimensionality에 의한 計算時間과 memory容量을 각오하면 본 모델에 5×5 window處理로 약간 더 改善을 기대할 수 있다.

5. 結 論

空間的不變인 blur와 random process로 알려진

표 II 모델 I 과 II 에 의한 映像復元 結果比較

Comparison of the image restoration result by the model I and II.

Dikshit 方式			本 研 究				
SNR	모델 II	모델 IV	SNR	SNR 개선 (dB)		noise 의 mean	noise 의 variance
				모델 I	모델 II		
0	6.8	8.6	0.818	7.3666	7.8471	0.5165E-01	0.17876E+04
3.34	5	6.4	4.578	5.9107	6.2372	0.36573E-01	0.89579E+03

雜音에 의하여 損傷된 映像을 復元改善하기 위한 映像處理가 行해졌다. 이 處理에 循環Kalman filtering技法이 應用되었으며 strip window處理가 raster方向으로 이루어졌다. 이 과정은 zero mean이며 correlation函數에 의해 確率統計學的으로 특징지워진 이들 映像에 적용될 수 있다.

映像을 모델化하는데 隣接pixel이 指數的auto-correlation函數에 의해 특징지워지는 random field에 기초를 두고 semicausal모델로 簡素化하여 구했다. 시스템處理는 vector處理에 기초를 둔 3×5 strip window를 채용하여 process出力을 나타내는 dynamic model을 유도하였다. 이 window處理를 행함으로써 dimensionality를 3×3⁽⁹⁾ window로 했을 때와 같게 됨으로써 計算時間과 memory要求面의 증가가 억제된다. 또 recursive filtering採用에 의해 memory容量이 적은 microcomputer에서 處理가 가능하게 된다. 본 모델에 水半則을 더 많이 correlate시킨 system處理가 既存方式보다 優秀함을 確認할 수 있었다. 따라서 대부분의 映像이 2次元random field로 간주되어 隣接點과 相關되는 모델을 수립할 수 있으며 映像의 질에 관계됨을 알 수 있다.

參 考 文 獻


(1) H. C. Andrews, "Digital image restoration: A survey," Com-

put., vol. 7, pp. 36-45, May 1974.
 (2) B. R. Hunt, "Digital image processing," Proc. IEEE, vol. 63, pp. 693-708, Apr. 1975.
 (3) M. M. Sondhi, "Image restoration: The removal of spatially invariant degradations," Proc. IEEE, vol. 60, pp. 842-853, July 1972.
 (4) N. E. Nahi, "Role of recursive estimation in statistical image enhancement," Proc. IEEE, vol. 60, pp. 872-877, July 1972.
 (5) A. K. Jain, "A Semicausal model for recursive filtering of two-dimensional images," IEEE Trans. Comput., vol. C-26, pp. 343-350, Apr. 1977.
 (6) A. K. Jain and E. Angle, "Image restoration, modelling, and reduction of dimensionality," IEEE Trans. Comput., vol. C-23, pp. 470-476, May 1974.
 (7) L. E. Franks, "A model for the random video process," Bell System Tech. J., pp. 609-630, Apr. 1966.
 (8) N. E. Nahi and T. Assefi, "Baysian recursive image estimation," IEEE Trans. Comput., vol. C-12, pp. 734-738, July 1972.
 (9) S. S. Dikshit, "A recursive Kalman window approach to image restoration," IEEE Trans. Acoust. Speech Signal processing, vol. ASSP-30, pp. 125-140, Apr. 1982.
 (10) B. D. O. Anderson and J. B. Moore, Optimal Filtering. Prentice-Hall, 1979.
 (11) N. E. Nahi and C. A. Franco, "Recursive Image Enhancement-Vector Processing," IEEE Trans. Commun., pp. 305-310, Apr. 1973.
 (12) R. K. Mehra, "On the identification of variance and adaptive Kalman filtering," IEEE Trans. Automat. Contr., vol. AC-15, pp. 175-184, Apr. 1970.



李 大 寧 (Dai Young I.E.E.) 正會員
 1940年 3月 18日生
 1968年 9月~1970年 3月: 慶熙大學校 工學院 (工學碩士)
 1976年 9月~1979年 9月: 延世大學校 工學院 電子工學科 (工學博士)
 1971年 9月: 慶熙大學校 工學院 電子工學科 助教授

1977年 3月: 慶熙大學校 工學院 電子工學科 副教授
 1982年 3月: 慶熙大學校 工學院 電子工學科 教授
 1982年 9月: 慶熙大學校 工學院 學長, 韓國情報科學會理事



李 潤 鉉 (Yun Hyun LEE) 正會員
 1941年 8月 24日生
 1965年 2月: 韓國航空大學 電子工學科 卒業
 1979年 2月: 檀國大學校 大學生院 卒業
 1965年~1980年 2月: 韓國放送公社 (KBS), 東洋工業 專門大學
 1980年 3月~現在: 韓國航空大學 通信工學科 助教授