

시각 장치를 이용한 직물 결함 결합 인식에 관한 연구

김계현, 고명삼, 이상욱, 이범희
서울대학교 공과대학 제어계측공학과

A Study on The Visual Inspection of Fabric Defects

Kye Hyun Kyung, Myoung Sam Ko, Sang uk lee, Bum Hee Lee
Dept. of Control & Instrumentation Eng. College of Engineering,
Seoul National University

ABSTRACT

This paper describes the automatic visual inspection system of fabric defects based on pattern recognition techniques. To extract features for detection of fabric defects, four different techniques such as SGLDM, GCM, decorrelation method, and Laws' texture measure were investigated. From results of computer simulation, it has been found that GCM and decorrelation techniques provide good features. By employing a simple statistical pattern recognition technique, the accuracy of classification of defect and nondefect was more than 90%. Some experimental results are also presented.

1. 서론

많은 연구 노력들이 자동화 공정의 발전을 향해서 이루어져 왔다. 특히 최근의 하드웨어와 소프트웨어의 발전은 인식(inspection)을 포함하는 많은 생산라인이 컴퓨터에 의해 제어되는 것을 가능하게 하였다. 이들 중 카메라로부터의 영상데이터를 처리하는 능력의 발전은 많은 제조 공정이 인간의 시각(human vision)에 의존하므로 자동화 공정에 중요한 의미를 갖는다.

지금까지 직물 생산 공정에서 대부분의 결함 검출은 숙련공에 의해 행해져 왔다. 그런데 이와같은 숙련공에 의한 방법은 특히 반복적이고 복잡한 직물 결함 인식과 같은 작업에서는 일관성(consistency)과 신뢰성(reliability)에서 떨어지며 경제적으로도 많은 비용이 든다. 따라서 이와같은 문제점을 해결하기 위한 직물 결함 인식의 자동화가 요구되어 왔다. 본 논문에서는 컴퓨터 비전 기술의 한 적용으로 직물 결함 인식에 관해 연구하였다.

그림1은 직물 결함 인식을 위해 개발된 시스템을 나타낸다.

카메라로부터의 아날로그 영상신호를 디지털 영상데이터로 바꾸어주는 디지털타이저는 512*512*8 bits




그림1. 직물 결함 인식을 위한 시스템 블록선도
Fig.1. Block diagram of a fabric defect inspection system

의 해상력을 가지도록 제작되었으며 1/30 초마다 카메라가 한 화면을 구성하도록 동기신호를 발생시키며, 이 화면을 받아들여 1/30 초 이내에 변환시켜서 256 Kbytes의 기억장치에 저장하고 이를 실시간으로 모니터에 display한다. 컴퓨터는 기억장치에 저장된 영상데이터를 이용하여 직물 결함의 검출과 직물 결함의 형태의 분류를 행한다.

직물 결함의 검출은 직물이 고해상율 요구하는 texture[1]이므로 texture analysis 방법에서 찾을 수 있다. 그동안 texture 분류를 위한 여러 방법들이 연구되어 왔는데 본 논문은 이들 중에서 Gray level co-occurrence matrix를 사용한 방법[2,3]과, Laws' texture measure에 의한 방법[4], 그리고 모서리 검출자에 의한 local maxima에 기초한 Generalized co-occurrence matrix를 사용한 방법[5]과 Decorrelation method에 의한 방법[6] 등을 적용하여 직물 결함 검출에 적당한 feature를 training에 의해 선택하고, 선택된 feature에 의한 결함 검출 결과를 조사하였다.

검출된 직물의 결함은 표1에서와 같이 네가지의 형태로 분류할 수 있다. 그림2는 형태에 따른 결함 샘플의 사진이다. 이와같은 형태의 분류는 한 프레임의 영상에서 검출된 결함의 영역(region)을 projection 시킴에 의해 얻을 수 있다.

표1. 형태에 따른 직물 결함의 분류
Table1. classification of type of fabric defects

I. Vertical line
II. Horizontal line
III. Region
IV. Dispersed

2절에서는 직물 결함 검출을 위해 사용한 texture analysis의 각 방법에 대해 설명하였고 3절에서는 결함 형태의 분류의 방법을 설명하였다. 4절에서는 실험 및 그 결과를 설명하였으며 5절에서는 결론을 제시하였다.

2. 직물 결함 검출을 위해 사용한 texture analysis 방법

이 장에서는 직물 결함 검출을 위해 사용한 feature들에 대해 설명하였다. 이 feature들은 직물 결함이 포함된 경우와 그렇지 않은 경우의 각각의 영역의 texture의 묘사(description)를 나타내게 된다.

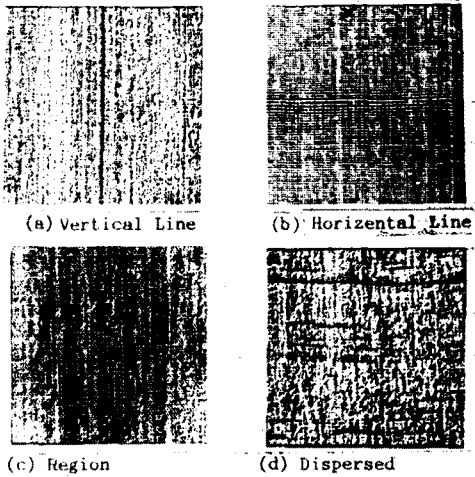


그림2. 직물 결함의 샘플
Fig.2. Samples of fabric defects

2.1 Spatial gray level dependence method(SGLDM)

영상 평면 $f(x,y)$ 에서 $\delta=(dx,dy)$ 라고 정의하면, 영상 평면에서 δ 만큼 떨어진 화소들의 쌍들에서 발생하는 gray level의 second order joint probability density가 계산될 수 있다. Gray level의 총 수가 m 이면 위의 joint density는 $m*m$ 의 배열이 되며 $S(\delta,T)$ 로 표시된다. 이 때 T 는 주어진 영역(region)을 나타낸다. 이 배열을 co-occurrence matrix라고 하며 이 배열의 각 요소는 식(1)과 같이 정의된다.

$$S(i,j,\delta,T) = \Theta(x|x, x+\delta \in T, g(x)=i, g(x+\delta)=j) / N \quad (1)$$

식(1)에서 i 와 j 는 gray level의 값을 나타내며 N 은 식(2)와 같다. 그리고 Θ 는 주어진 조건을 만족하는 쌍(pair)의 수를 의미한다.

$$N = \Theta(x|x, x+\delta \in T) \quad (2)$$

이 때 δ 는 방향과 거리에 의해 $\delta=(d,\theta)$ 로 나타낼 수 있다.

$$d = \max(dx, dy) \quad (3-a)$$

$$\theta = \arctan(dy/dx) \quad (3-b)$$

위와 같이 구한 co-occurrence matrix를 이용하여 다음의 여섯가지의 feature를 구할 수 있다.

- Contrast
 $f1 = \sum \sum (i-j)^2 s(i,j,\delta,T) \quad (4)$

- Cluster Shade
 $f2 = \sum \sum (i+j - \mu_x - \mu_y)^2 s(i,j,\delta,T) \quad (5)$

- Cluster Prominence
 $f3 = \sum \sum (i+j - \mu_x - \mu_y)^4 s(i,j,\delta,T) \quad (6)$

- Local Homogeneity
 $f4 = \sum \sum s(i,j,\delta,T) / (1+(i-j)^2) \quad (7)$

- Angular Second Moment
 $f5 = \sum \sum [s(i,j,\delta,T)]^2 \quad (8)$

- Entropy
 $f6 = \sum \sum s(i,j,\delta,T) \log[s(i,j,\delta,T)] \quad (9)$

식(5)와(6)에서 μ_x, μ_y 는 다음과 같이 주어진다.

$$\mu_x = \sum i \sum s(i,j,\delta,T) / K \quad (10)$$

$$\mu_y = \sum j \sum s(i,j,\delta,T) / K \quad (11)$$

위의 식들에서 K 는 gray level의 총 수를 의미하는데 계산 속도를 향상시키기 위하여 그 level을 256

에서 8로 줄였다. 이때 각 level들은 동일한 equal probability를 갖도록 결정하였다. 따라서 co-occurrence matrix는 $8*8$ 의 배열이 된다.

2.2 Laws' texture energy measure

Laws는 local property-복리 화소 이웃(neighborhoods)과 convolve된 몇개의 표준 mask에 의한 성질의 평균값에 기초한 texture의 성질을 조사하여, texture region이 local property에 의해 묘사될 수 있다고 제안하였다.

Laws' property는 $3*1$ 의 세가지 기본 벡터와 이들 벡터를 서로 convolve시켜 얻은 다섯가지의 벡터로부터 유도되며 그 벡터들은 다음과 같다.

$$L3 = (1, 2, 1); \text{one dimensional operations of center-weighted local averaging}$$

$$E3 = (-1, 0, 1); \text{symmetric first differencing(edge-detection)}$$

$$S3 = (-1, 2, -1); \text{second differencing(spot detection)}$$

$$L5 = (1, 4, 6, 4, 1) = L3 * L3$$

$$S5 = (-1, 0, 2, 0, -1) = E3 * E3 = L3 * S3$$

$$R5 = (1, -4, 6, -4, 1) = S3 * S3$$

$$B5 = (-1, -2, 0, 2, 1) = L3 * E3$$

$$W5 = (-1, 2, 0, -2, 1) = E3 * S3$$

위의 식들에서 *는 1차원 convolution을 의미한다. 이들 길이 3(5)의 행 벡터를 같은 길이의 열 벡터와 곱합에 의해 local property를 얻기 위한 $3*3(5*5)$ 의 Laws의 표준 mask를 얻게되며, 이들을 이용한 texture region의 묘사(description)는 이들 mask를 영상데이터에 convolve시킨 다음 그 결과의 통계치로 한다. Laws는 가장 유용한 통계치는 이들 mask와 영상데이터를 convolve시킨 결과들의 절댓값이나 제곱한 값의 합이라고 주장하였다.

2.3 Texture analysis using generalized co-occurrence matrix(GCM)

GCM은 texture 영상을 모서리(edge)와 같은 local property의 위치를 나타내는 새로운 영상으로 대체한 다음에, local maxima의 공간적 분포 특성을 이용하여 얻는다. GCM의 정의는 다음과 같다.

(x_i, y_i) 는 i 번째 local maxima p_i 의 위치이고 d_i 는 p_i 의 묘사일 경우 p_i 의 집합 P 는 식(12)과 같이 정의되며 spatial constraint predicate F 를 식(13)과 같이 정의할 수 있다.

$$P = \{p_i = (x_i, y_i, d_i)\} \quad (12)$$

$$F = \{p_i, p_j, k = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} < k\} \quad (13)$$

즉 predicate F 는 p_i 와 p_j 사이의 거리가 k 보다 작을 때만 참값(true)을 갖는다. 이와 같은 정의하에서 GCM의 $(d1, d2)$ 번째항 GF는 F 가 참값을 가지며 p_i 의 묘사는 $d1, p_j$ 의 묘사는 $d2$ 로 나타나는 (p_i, p_j) 쌍의 총 수가 된다.

GCM을 이용하여 얻을 수 있는 texture의 feature는 SGLDM의 경우와 같다.

2.4 Decorrelation method

그림3은 stochastic texture 발생의 일반적인 모델의 블록선도이다.




그림3. stochastic texture 발생 모델
Fig.3. stochastic texture generation model

그림3에서 iid process $W(j,k)$ 의 추정치 $\hat{W}(j,k)$ 는 식(14)와 같이 whitening operator decorrelate 시김에 의해 얻을 수 있다. 식(14)에서 $Hw(j,k)$ 는 whitening operator이고 $**$ 는 2-D convolution을 나타낸다. 한 window에서 구해진 $\hat{W}(j,k)$ 의 히스토그램은 $W(j,k)$ 의 확률 분포 $p(w)$ 를 추정하는 데 사용된다. 그림4은 이와 같은 방법으로 texture feature를 추출하는 방법의 블록선도이다.

$$\hat{W}(j,k) = F(j,k) ** Hw(j,k) \quad (14)$$




그림4. stochastic에 기초한 texture feature 추출 방법
fig.4. stochastic-based texture feature extraction method

그림4에서 spatial autocorrelation function measurement는 식(15)와 같이 주어진다. 식(15)에서 μ_m 과 μ_n 은 식(16)으로 주어진다.

$$S(u,v) = \sum \sum (m - \mu_m)^u (n - \mu_n)^v A(m,n) \quad (15)$$

$$\mu_m = \sum \sum mA(m,n) / \sum \sum A(m,n) \quad (16-a)$$

$$\mu_n = \sum \sum nA(m,n) / \sum \sum A(m,n) \quad (16-b)$$

그리고 autocorrelation function $A(m,n)$ 은 식(17)과 같다.

$$A(m,n) = \sum \sum f(u,v) f(u+m, v+n) \quad (17)$$

L level을 갖는 히스토그램 $P(b)$ 로부터는 아래의 네가지 moment를 feature로 추출할 수 있다.

$$\text{Average} : B_a = \sum bP(b) \quad (18-a)$$

$$\text{Variance} : B_v = \sum (b - B_a)^2 P(b) \quad (18-b)$$

$$\text{Skewness} : B_s = \sum (b - B_a)^3 P(b) / B_v^{3/2} \quad (18-c)$$

$$\text{Kurtosis} : B_k = \sum (b - B_a)^4 P(b) / B_v^2 \quad (18-d)$$

그런데 decorrelation operator는 계산을 간단히 하기 위해 sobel이나 laplacian operator와 같은 근사화된 operator로 whitening operator를 대체할 수 있다. 본 논문에서는 sobel operator를 decorrelation operator로 사용하였다.

3. 식물 결함의 형태 분류

식물 결함의 형태는 표1에서와 같이 네가지로 분류할 수 있는데 이것은 앞으로의 진행과제인 tree 구조에 의한 식물 결함 인식을 위한 것이다. 식물 결함의 형태 분류는 결함의 검출이 모두 이루어진 한 영상에서 결함이 포함되었다고 판단된 window 영역에는 '1'을 할당하고, 결함이 포함되지 않았다고 판단된 window 영역에는 '0'을 할당하여 이루어진 binary 평면에서 X, Y축으로 projection 시김에 의해 얻을 수 있다. 그림5는 네가지 부류에 대한 projection의 예를 나타낸다.

4. 실험 및 결과

실험을 위한 데이터베이스는 "식물의 흠 한도 건본집" [7]의 샘플레이 식물과 "스프 식물 결함 표준본건본" [8]의 스프 식물의 사진을 이용하여 작성하였다. 건본자의 데이터베이스는 training에 의해 2절에서 설명

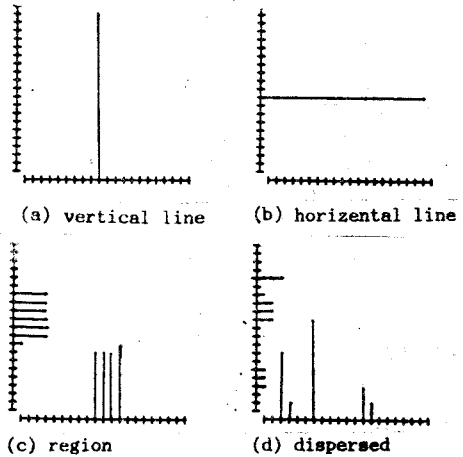


그림5. 식물 결함의 형태에 따른 projection의 예
Fig.5. example of projections for type of defect

한 여러 feature들 중에서 어떤 것이 식물 결함 검출을 위해 유용한가를 판단하는데 이용하였고, 후자의 데이터베이스는 이를 바탕으로 식물의 결함의 검출과 그 형태를 분류하는데 이용하였다.

Training을 위한 각 샘플은 식물에 결함이 포함되었거나 그렇지 않은 16*16화소를 갖는 정사각형의 window영역으로 하였다. Window의 크기는 식물 결함이 많은 경우 몇개의 위사 또는 경사의 잘못된 방향 한 가는 선에 의해 나타나는데 반하여, texture analysis의 여러 방법들은 서로 다른 두 성질의 영역을 구분하는데 사용되므로 이와같은 작은 결함의 검출이 가능하도록 작게 하였다. Training은 식물의 결함이 포함된 영역과 그렇지 않은 영역의 각각에 대해 feature 값을 도시함에 의해 행하였다.

그림6은 2절에서 설명한 네가지 방법들의 여러 feature들에 대한 training 결과의 예이다. 그림6-a는 $d=2, \theta=0$ 인 경우의 co-occurrence matrix로부터 계산한 contrast, cluster shade, cluster second moment, local homogeneity, angular second moment, entropy의 training 결과인데 그림에서 볼 수 있듯이 결함이 포함된 경우와 그렇지 않은 경우에 대해 각 feature들의 값의 구분이 어렵기 때문에 이 fea-

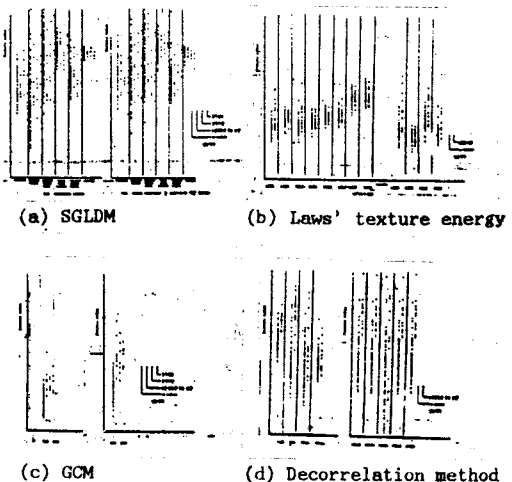


그림6. Training 결과의 예
Fig.6. Example of training result

ture들은 직물 결함 검출을 위한 유용한 feature라고 할 수 없다.

그림6-b는 2.2절에서 설명한 Laws' mask를 각 데이터에 convolve시킨 다음 생성된 데이터의 각 화소값의 절대값을 더한 결과인데 1585의 mask로부터 얻은 결과와 같이 결함이 포함된 경우 그 값이 결함이 없는 경우에 비해 뚜렷히 큰 경우도 있지만, Laws의 각 mask는 수평 성질 또는 수직 성질과 같은 하나의 특성을 갖도록 이루어져 있으므로 여러 형태를 갖는 직물 결함을 검출할 수 있는 feature로 판단되지 않으며 다른 training의 결과들은 이것을 증명해주었다.

그림6-c는 GCM으로부터 계산한 contrast의 training 결과이다. GCM을 구하기 위한 local maxima는 sobel operator를 convolve시킨 뒤 그 magnitude가 threshold보다 큰 화소로 하였고, 각 화소의 묘사는 수평(horizontal), 수직(vertical), 우대각(right diagonal), 좌대각(left diagonal)을 나타내는 네 개의 3*3 mask를 convolve시켜 가장 큰 magnitude를 갖는 방향으로 정하였다. 즉 GCM은 4*4의 배열이 된다. 그림5-c는 predicate $F(p_i, p_j, k)$ 에서 k의 값이 2와 3인 경우에 대한 결과로 GCM에 의한 feature가 직물 결함 검출을 위해 유용함을 나타냈다.

그림6-d는 decorrelation method로부터 계산된 feature들의 training 결과이다. Training은 이들 중에서 일자의 히스토그램에서 얻은 variance와 autocorrelation function spread measure 중의 $S(0,2)$, $S(2,0)$ 가 직물 결함 검출을 위해 아주 유용한 feature임을 나타냈다.

이상의 training과정에서 SGLDM과 Laws' texture energy measure의 방법은 직물의 결함 검출에 적당하지 못한 것으로 판명되었으며, GCM에 의한 방법과 decorrelation에 의한 방법은 결함 검출에 유용함을 알 수 있었다. 이와 같은 유용한 feature들을 이용하여 주어진 영역이 결함을 포함하고 있는지에 대한 판별은 다음과 같은 방법으로 하였다. 이때 각 feature의 분포는 $f(x) = N(\mu, \sigma^2)$ 의 정규 분포를 갖는다고 가정하였는데 이것은 standard chi-squared test에 의해 시험될 수 있다.

주어진 한 영역은 측정 feature x가 식(19)를 만족하면 결함이 포함되지 않은 영역으로 분류된다.

$$|(x - \mu) / \sigma| \leq T \quad (19)$$

식(19)에서 μ 는 결함이 포함되지 않은 영역의 추정된 평균 feature 값이고, σ 는 같은 경우의 추정된 feature의 분산이다. 그리고 threshold T는 유의수준 1%로 결정하였다. 이때 각 parameter는 maximum likelihood estimation에 의해 추정하였다.

표2는 식(19)에 의해 결정된 직물 결함 검출의 결과이다. 결함 검출은 43개의 영상을 결함이 포함된 3162개의 window영역과 결함이 포함되지 않은 17140개의 window영역으로 나눈다음 결함이 포함되지 않은 window영역들에서 MLR로 평균값과 분산을 추정하여 모든 window영역에 대해 식(19)의 결정함수를 이용하여 행하였다.

결함 검출의 실험은 다섯가지의 feature에 대해 하였는데, 그 feature들은 GCM으로부터 계산된 contrast, local homogeneity, entropy와 decorrelation method에서 계산된 variance와 $S(0,2)$ 이다.

표2에서 P(error)는 식(20)으로 표시되며 주어진 영역을 잘못 판단할 확률이다. 이때 P(defect)와 P(no defect)는 실험에서 사용한 전체 window영역의 수에 대한 결함 영역과 비결함 영역의 비례치로 추정하였다.

$$P(\text{error}) = P(A)P(\text{defect}) + P(B)P(\text{no defect}) \quad (20)$$

이 때 각 결함의 크기는 최소한 둘 이상의 window에 걸쳐 있다고 가정하고 한 window영역이 결함을 포함한다고 판단되었을 때 주어진 결함의 인접한 8개의 window영역을 검색하여 모두 결함이 포함하지 않은 것으로 판단되면 그 결함의 영역은 잡음에 의한 것으로 간주하면 표3의 검출 결과와 얻을 수 있다.

표2. 결함 검출의 결과

Table2. results of defect detection

P(A): 결함이 포함된 영역을 잘못 판단한 확률
P(B): 결함이 포함되지 않은 영역을 잘못 판단한 확률
P(error): 주어진 영역을 잘못 판단할 확률

feature	P(A)	P(B)	P(error)
contrast	35.7%	2.3%	7.51%
local homogeneity	10.2%	2.1%	3.36%
entropy	6.8%	3.4%	3.93%
variance	9.7%	1.4%	2.69%
S(0,2)	7.4%	1.3%	2.25%

표3. 결함 검출의 결과

Table3. results of defect detection

가정: 결함의 크기는 둘 이상의 window에 걸쳐 있다.

P(A): 결함이 포함된 영역을 잘못 판단한 확률
P(B): 결함이 포함되지 않은 영역을 잘못 판단한 확률
P(error): 주어진 영역을 잘못 판단할 확률

feature	P(A)	P(B)	P(error)
contrast	38.3%	0.54%	6.43%
local homogeneity	10.7%	0.53%	2.12%
entropy	6.9%	0.91%	1.84%
variance	9.9%	0.21%	1.72%
S(0,2)	7.6%	0.14%	1.30%

Projection에 의한 형태 분류는 결함 검출에 가장 좋은 결과를 보인 $S(0,2)$ 를 이용하여 결함 검출을 행한 영상에서 실시하였다. 표4는 그 결과를 나타낸다. 표4로부터 projection에 의한 결함의 형태 분류가 약 95.3%의 정확도로 이루어짐을 알 수 있다.

표4. projection을 이용한 직물의 형태 분류

Table4. classification of type of defect using projection

	I	II	III	IV
I	9	0	0	0
II	0	6	0	1
III	0	0	18	1
IV	0	0	0	8

5. 결론

직물 결함 인식의 자동화는 다음의 세가지 이유에서 필요하다. 첫째 직기에서 생산되는 모든 직물을 인식하여 결함 데이터를 기록하고 생산 직물의 질을 평가한다. 둘째 현재 10-20%의 직물만이 인식 과정을 통과하여 발생하는 이 직물을 이용한 다음 생산 과정에서의 결함 직물의 사용을 막는다. 셋째 직물 결함의 원인을 결정하고 예방 조치를 취함의에 결함 발생을 최소화 할 수 있다.

본 논문에서는 이와같은 필요에 따라 직물 결함 추출과 추출된 결함의 형태 분류에 관해 연구하였다. 직물 결함 추출을 위해서는 texture 분류를 위한 여러 방법들을 적용하여 training에 의해 GCM을 이용한 방법과 decorrelation method가 결함 추출을 위한 좋은 feature를 제공함을 알았고 이들 feature들을 이용한 직물 결함 검출은 90%이상의 정확성을 나타냈다. 그리고 추출된 결함의 평면에서 수직 방향과 수평 방향으로 행한 projection으로 결함의 형태 분류의 좋은 결과를 얻었다. 이것은 앞으로의 연구과제인 tree 구조에 의한 직물 결함 인식을 위한 연구이다.

REFERENCE

- 1) H. Ballard and M. Brown, Computer Vision, Prentice Hall, 1982.
- 2) R.M. Haralick and K. Shanmugam, and I.H. Dinstein, "Textural features for image classification," IEEE Trans. Syst., Man, Cybern., vol.SMC-3, pp. 610-621, Nov. 1973.

- 3) W. Conners, W. Mcmillin, Kingyao Lin, and B. Vasquez-espinosa, "Identifying and Locating Surface Defects in Woods: Part of an Automated Lumber Processing System," IEEE PAMI-5, NO.6, Nov. 1983
- 4) A. Rosenfeld, S. Davis, "Experiments with Texture Classification Using Averages of Local Pattern Matches," IEEE Trans. Syst., Man, Cybern., vol.SMC-13, May/June 1983.
- 5) S. Davis, A. Johns, and K. Aggarwal, "Texture Analysis Using Generalized Co-occurrence Matrices," IEEE PAMI-1, NO.3, Jul. 1979.
- 6) D. Faugeras, K. Pratt, "Decorrelation Methods of Texture Feature Extraction," IEEE PAMI-2, July 1980.
- 7) 직물의 흠 한도 기본집, 한국원사직물시험검사소
- 8) 스프직물결점표준기본, 일본화학섬유검사협회