

논문 2016-53-7-6

데이터 마이닝 결정나무를 이용한 포렌식 영상의 분류

(Forensic Image Classification using Data Mining Decision Tree)

이 강 현*

(Kang Hyeon RHEE[©])

요 약

디지털 포렌식 영상은 여러 가지 영상타입으로 위·변조되어 유통되는 심각한 문제가 대두되어 있다. 이러한 문제를 해결하기 위하여, 본 논문에서는 포렌식 영상의 분류 알고리즘을 제안한다. 제안된 알고리즘은 여러 가지 영상타입의 그레이 레벨 co-occurrence 행렬의 특성 중에서 콘트라스트와 에너지 그리고 영상의 엔트로피로 21-dim.의 특징벡터를 추출하고, 결정나무 플랜에서 분류학습을 위하여 PPCA를 이용하여 2-dim.으로 차원을 축소한다.

포렌식 영상의 분류 테스트는 영상 타입들의 전수조합에서 수행되었다. 실험을 통하여, TP (True Positive)와 FN (False Negative)을 검출하고, 제안된 알고리즘의 성능평가에서 민감도 (Sensitivity)와 1-특이도 (1-Specificity)의 AUROC (Area Under Receiver Operating Characteristic) 커브 면적은 0.9980으로 'Excellent(A)' 등급임을 확인하였다. 산출된 최소평균 판정 에러 0.0179에서 분류할 포렌식 영상타입이 모두 포함되어 분류 효율성이 높다.

Abstract

In digital forensic images, there is a serious problem that is distributed with various image types. For the problem solution, this paper proposes a classification algorithm of the forensic image types. The proposed algorithm extracts the 21-dim. feature vector with the contrast and energy from GLCM (Gray Level Co-occurrence Matrix), and the entropy of each image type.

The classification test of the forensic images is performed with an exhaustive combination of the image types. Through the experiments, TP (True Positive) and FN (False Negative) is detected respectively. While it is confirmed that performed class evaluation of the proposed algorithm is rated as 'Excellent(A)' because of the AUROC (Area Under Receiver Operating Characteristic Curve) is 0.9980 by the sensitivity and the 1-specificity. Also, the minimum average decision error is 0.1349. Also, at the minimum average decision error is 0.0179, the whole forensic image types which are involved then, our classification effectiveness is high.

Keywords : Forensic image, GLCM, PPCA, TP and NP, AUROC, Minimum average decision error

I. 서 론

디지털 영상 타입을 분류하는 기술이 멀티미디어 데이터의 공유, 불법 복제 및 배포에서 원 콘텐츠를 보호하기 위한 포렌식 툴 (Forensic Tool) 개발로 요구되고 있다^[1,2]. 영상타입을 분류하기 위해서는 각 영상 타입의 텍스처 특징을 추출해서 처리하는데, 이를 위한 기

술로서, Gray Level Co-occurrence Matrix (GLCM)^[3], 텍스처 스펙트럼^[4], 프랙탈 차원^[5], Markov 랜덤 필드^[6], Gibbs 랜덤 필드^[7] 등의 여러 가지 방법들이 개발되었다.

본 논문에서는 BMP, MF3, MF5, AVE3, JPEG90의 각 영상 타입에 따른 특징을 추출하기 위하여 영상에 포함되어 있는 콘트라스트 (Contrast), 에너지 (Energy) 그리고 엔트로피 (Entropy) 성분의 특징을 조합하여

* 평생회원, 조선대학교 전자정보공과대학 전자공학과 (Chosun University, College of Electronics and Information Eng., Dept. of Electronics Eng.)

[©] Corresponding Author (E-mail : khrhee@chosun.ac.kr)

※ 본 논문은 조선대학교 2016 교비지원으로 수행되었습니다.

Received ; May 3, 2016

Revised ; June 1, 2016

Accepted ; July 1, 2016

21-dim. 특징벡터를 생성한다. 생성된 특징벡터는 결정 나무 (Decision Tree) 플랜 (Plan)의 좌표를 갖기 위하여 PPCA (Probabilistic Principal Component Analysis)에서 2-dim.으로 차원 축소된다. 2차원 좌표는 결정 나무 플랜에서 각 영상타입이 분류되고 분류 경비 (Classification Cost)가 산출된다.

분류된 각 영상타입의 True Positive (TP)와 False Negative (FN)의 검출율이 계산되고, 본 논문의 제안 알고리즘 성능평가를 한다. 각 영상타입의 TP와 FN의 검출조합에 따른 영상 타입 분류의 민감도 (Sensitivity)와 1-특이도 (1-Specificity)의 AUROC (Area Under Receiver Operating Characteristic) 커브 면적과 최소평균 판정 에러를 산출한다.

본 논문의 구성은 II장에서 영상의 콘트라스트, 에너지 그리고 엔트로피 산출의 이론적 배경을 설명하고, III장에서는 영상타입의 분류를 위한 제안된 알고리즘을 기술한다. 그리고 IV장에서 실험을 통한 영상 타입의 분류 결과의 검토와 제안된 알고리즘의 성능평가를 하고 마지막으로 V장에서 결론을 맺는다.

II. 이론적 배경

2.1 GLCM

GLCM (Gray Level Co-occurrence Matrix)^[3, 12]은 오랫동안 영상처리 응용분야에서 텍스처 특징 (Texture Feature)을 추출하는 강력한 툴로 사용되었다^[10].

Co-occurrence Matrix는 영상의 공간 의존도 (Spatial Dependency)를 나타낸다^[3]. 분석하는 영상의 사이즈가 $2n \times 2n$ 이고, 각 픽셀의 그레이 레벨은 N_g 로 양자화 된다. 공간영역에 $L_x = \{0, 1, \dots, 2n-1\}$ 와 $L_y = \{0, 1, \dots, 2n-1\}$ 이 되고, 양자화된 그레이 레벨 N_g 의 set로 $S = \{0, 1, \dots, N_g-1\}$ 이 된다. 영상 I 는 S 의 $L_x \times L_y : I : L_x \times L_y \rightarrow S$ 에서 각 픽셀이나 좌표의 그레이 레벨을 할당하는 함수로 표현된다.

픽셀들 사이의 공간적 관련도를 추출하기 위하여, GLCM은 영상의 이웃하는 두 픽셀의 상대도수 (Relative Frequency) $P\theta(i, j)$ 를 기록하도록 표현된다. 서로 다른 그레이 레벨 i 와 j 의 θ 는 $0^\circ, 45^\circ, 90^\circ$ 그리고 135° 의 방향을 가지고 있다. 각 방향의 Matrix는 공간적 의존도를 측정하고, 다른 방향들의 Co-occurrence Matrix의 정의는 다음과 같다.

$((k, l), (m, n)) \in (L_x \times L_y) \times (L_x \times L_y)$ 이면,

$I(k, l) = i$ and $I(m, n) = j$ 이다. 즉 변위 d 와 각 θ 는

$$P^\theta(i, j, d, \theta) = \# \left\{ \begin{array}{l} ((k, l), (m, n)) \\ \tan \theta = (l - n) / (k - m), \\ \sqrt{(1 - n)^2 + (k - m)^2} = d \end{array} \right. \quad (1)$$

여기서 #는 set의 요소의 수를 나타낸다. 영상의 콘트라스트, 상관계수, 2차 각도 모멘트 등은 텍스처 특징과 같이 다른 d 와 θ 를 갖는 행렬로부터 계산된다.

2.2 결정나무

결정나무^[8] 학습법은 데이터마이닝의 지도학습에 의한 분류기법으로 입력 변수를 바탕으로 목표 변수의 값을 예측하는 모델을 생성하는 것을 목표로 한다. 종속 변수 Y 는 분류를 통해 학습되는 목표변수이고, x 는 입력변수로 n 개의 벡터로 구성된다.

$$(x, Y) = (x_1, x_2, \dots, x_n, Y) \quad (2)$$

그리고 학습의 최소비용에 의한 결정나무 그래프의 최적 레벨을 정의할 수 있다.

본 논문에서는 영상타입의 특징벡터를 입력변수 x 로 취급하며, 결정나무 학습의 관측 값에 의해 영상타입의 분류를 목표변수 Y 로 설정한다.

2.3 PPCA

확률적 PCA (PPCA)^[9]는 잠재공간 (Latent Space)에 주어진 데이터 X 를 확률적으로 차원축소를 한다. 이 방법은 축소된 데이터 공간 (Data Space) Y 에 선형으로 매핑 되는 W 를 구한다. Bayesian 모델로 데이터는 X 의 prior와 Y 의 likelihood가 조건적 분포 (Conditional Distribution)로 정의되어 있어야 한다.

$$Y = XW^T \quad (3)$$

조건적 분포는 그림 1의 $X \rightarrow Y$ 와 $W \rightarrow Y$ 이며,

$$p(X) = \prod_{n=1}^N N(x_{(n)} | 0, I) \quad (4)$$

$$p(Y|X, W) = \prod_{n=1}^N (y_{(n)} | Wx_{(n)}, \beta^{-1}I) \quad (5)$$

으로 N 은 데이터의 개수이며 $\beta^i T$ 는 likelihood의 분산이다.




그림 1. 조건적 분포의 표현
Fig. 1. Representation of conditional distribution.

III. 포렌식 영상 타입의 분류 알고리즘 제안

본 논문에서는, 포렌식 영상 타입의 분류를 위한 특징벡터 추출을 위하여, 미디언 필터링 (MF3: $w=3 \times 3$, w 는 필터링 윈도우 크기), 미디언 필터링 (MF5: $w=5 \times 5$), 비트맵 (BMP), 평균필터링 (AVE3: $w=3 \times 3$) 그리고 JPEG (JPG90: Quality Factor=90)의 5가지 영상에 대하여, 콘트라스트와 에너지, 엔트로피를 이용한다. 그레이 레벨은 10의 오프셋 (Offset)값을, 방향은 8의 오프셋 값으로 0° 에서 45° 간격으로 315° 까지 그림 2와 같이 GLCM을 생성하여, 콘트라스트와 에너지 정보를 각각 10-dim.으로 20-dim.과 엔트로피 1-dim.으로 전체 21-dim.의 특징벡터를 추출한다.




그림 5. 영상타입의 특징벡터 추출
Fig. 2. Extraction of an image types.

각 영상타입의 21-dim. 특징벡터는 결정나무 플랜 (Decision Tree Plan)에서 분류되기 위한 좌표 값을 구하기 위하여 PPCA에서 2-dim.으로 차원 축소를 한다. 2-dim.의 각 영상타입의 특징벡터는 결정나무 플랜 상에서 선형적으로 분류가 된다.

제안된 알고리즘의 흐름도는 그림 3과 같고, 각 단계별 수행은 다음과 같다.

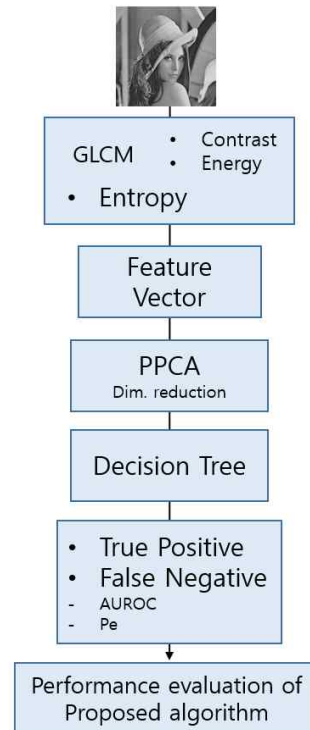


그림 6. 제안된 알고리즘의 흐름도
Fig. 3. Flow-chart of the proposed algorithm.

[Step 1] 여러 영상타입의 GLCM 처리를 위하여 각 픽셀의 이웃 픽셀과의 방향 오프셋 값 θ 와 그레이레벨의 변위 오프셋 값 d 를 정의하고 P_{θ} 를 계산한다.

[Step 2] P_{θ} 로부터 영상타입의 콘트라스트, 에너지 그리고 엔트로피를 구한다.

[Step 3] Step 2의 콘트라스트, 에너지 그리고 엔트로피는 21-dim.의 특징벡터로 추출된다.

[Step 4] 각 영상타입의 21-dim.의 특징벡터가 결정 나무 플랜에서 분류되기 위하여 PPCA에서 2-dim.으로 차원 축소된다.

[Step 5] 결정나무 플랜에서 분류된 각 영상타입의 표 1의 전수조합 (Exhaustive Combination)에 따라 TP와 FN을 산출하고, 제안된 알고리즘의 특이도와 민감

도를 계산한다.

[Step 6] Step 5의 결과에 대하여 AUROC와 최소 에러를 계산하여 최상의 영상타입의 분류에 대한 제안된 알고리즘의 성능평가를 한다.

IV. 실험 및 성능평가

제안된 포렌식 영상타입의 분류와 알고리즘의 성능평가를 위하여, UCID^[10]의 1,388개 영상에 적용하여 실험하였다. 제안된 알고리즘의 [Step 1]을 위하여, 우선원 영상 DB의 전체에 대하여, MF3, MF5, BMP, AVE3, JPG90으로 변환한 포렌식 영상을 만들어 각 영상타입의 특징벡터를 추출하였다.

21-dim.의 특징벡터에 포함되는 영상의 특징벡터는 콘트라스트 (10-dim.), 에너지(10-dim.) 그리고 엔트로피 (1-dim.)를 GLCM을 이용하여 추출하는데, 그림 2와 같이 픽셀과 이웃픽셀의 방향은 8개 그리고 그레이 레벨은 10단계를 준비하였다.

5가지 영상타입의 특징벡터 21-dim.은 결정나무 플랜에서 분류하기 위하여 플랜의 분포에서 사용할 좌표를 얻기 위하여 PPCA에서 2-dim.으로 차원이 축소되고, 특징벡터 분포도는 그림 4와 같다.




그림 4. 각 영상타입의 특징벡터 분포
Fig. 4. Feature vector distribution of each image type.

그림 4의 각 영상타입의 특징벡터분류를 위한 결정나무에서의 학습을 위하여 결정나무 플랜의 그리드 스케일은 0.01, K_Folder는 5의 cross-validation으로 셋업하여, 1,338영상×5개의 영상타입 6,690개의 전체영상 중에서 임의로 선택한 5,352개의 학습영상과 1,338개의 테스트영상을 사용하였다. 학습과 테스트는 실험의 분산오

차를 줄이기 위하여 5회 수행 후 평균을 구하였다. 그림 5는 각 영상타입의 2-dim.으로 차원 축소된 특징벡터의 결정나무 학습을 통하여 분류된 결과를 보여준다.

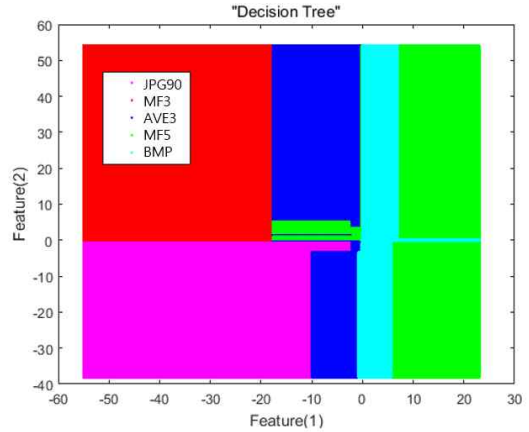


그림 5. 각 영상타입의 결정나무 분류
Fig. 5. Decision tree of each image type.

분류비용의 최소값은 0.0791로 산출되었으며, 그림 6과 같다. 그리고 이 값에서 결정트리는 그림 7과 같다.

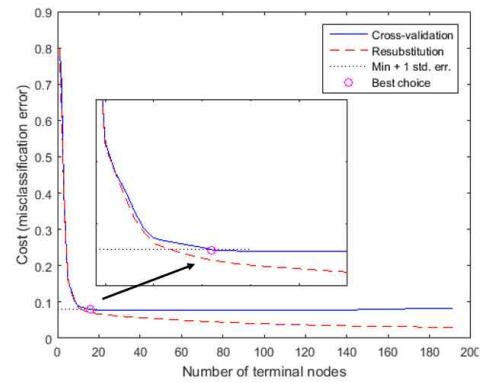


그림 6. 최소 분류비용의 산출: 0.0791
Fig. 6. Computing of min. classification cost: 0.0791.

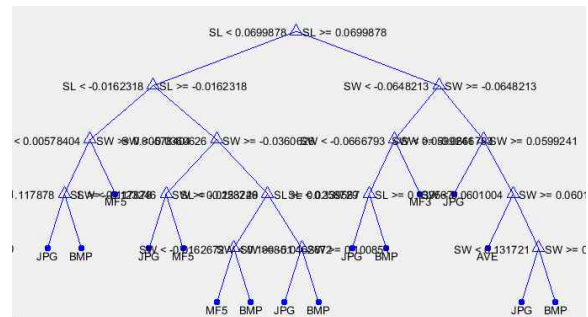


그림 7. 최소 분류비용에서의 각 영상타입의 결정트리
Fig. 7. Decision tree of each image type at min. classification cost.

표 1. 제안된 알고리즘의 성능평가

Table 1. Performance evaluation of the proposed algorithm.
EC No: Exhaustive Combination No.

EC No.	Image Types					TP	FN	TP rate (Sensitivity)	FP rate (1-Specificity)	P_e (6)
	MF3	MF5	BMP	JPEG90	AVE3					
0	-	-	-	-	-	0	0	1.0000	1.0000	0.5000
1	-	-	-	-	○	0	4	0.2765	1.0000	0.1383
2	-	-	-	○	-	0	35	0.2735	1.0000	0.1368
3	-	-	-	○	○	0	0	0.2474	1.0000	0.1237
4	-	-	○	-	-	0	96	0.2474	1.0000	0.1237
5	-	-	○	-	○	1	1	0.1756	1.0000	0.0878
6	-	-	○	○	-	1	9	0.1749	0.9993	0.0878
7	-	-	○	○	○	3	0	0.1682	0.9985	0.0848
8	-	○	-	-	-	0	127	0.1682	0.9963	0.0859
9	-	○	-	-	○	0	0	0.0732	0.9963	0.0385
10	-	○	-	○	-	0	13	0.0732	0.9963	0.0385
11	-	○	-	○	○	2	0	0.0635	0.9963	0.0336
12	-	○	○	-	-	0	36	0.0635	0.9948	0.0344
13	-	○	○	-	○	4	0	0.0366	0.9948	0.0209
14	-	○	○	○	-	1	13	0.0366	0.9918	0.0224
15	-	○	○	○	○	24	0	0.0269	0.9910	0.0179
16	○	-	-	-	-	0	24	0.0269	0.9731	0.0269
17	○	-	-	-	○	13	1	0.0090	0.9731	0.0179
18	○	-	-	○	-	0	4	0.0082	0.9634	0.0224
19	○	-	-	○	○	36	0	0.0052	0.9634	0.0209
20	○	-	○	-	-	0	2	0.0052	0.9365	0.0344
21	○	-	○	-	○	13	0	0.0037	0.9365	0.0336
22	○	-	○	○	-	0	0	0.0037	0.9268	0.0385
23	○	-	○	○	○	127	0	0.0037	0.9268	0.0385
24	○	○	-	-	-	0	3	0.0037	0.8318	0.0859
25	○	○	-	-	○	9	1	0.0015	0.8318	0.0848
26	○	○	-	○	-	1	1	0.0007	0.8251	0.0878
27	○	○	-	○	○	96	0	0.0000	0.8244	0.0878
28	○	○	○	-	-	0	0	0.0000	0.7526	0.1237
29	○	○	○	-	○	35	0	0.0000	0.7526	0.1237
30	○	○	○	○	30	4	0	0.0000	0.7265	0.1368
31	○	○	○	○	○	968	0	0.0000	0.7235	0.1383
Total						1,338	370	AUROC: 0.9980		P_e : 0.0179

표 1은 5가지의 영상타입의 전수조합에 따른 테스트 분류의 TP와 FN의 결과 값이다. 그리고 TP 검출율 (민감도)과 FP 검출율 (1-특이값)에 따른 ROC (Receiver Operating Characteristic) 커브 면적 (AUROC) 은 0.9980으로 제안된 알고리즘의 평가는 “Excellent (A: 0.9 이상)” 등급으로 판정이 되며, 최소평균 판정 에러 P_e 는 식 (6)로부터 0.0179이다. 표 1에서, 전수조합 No. 15와 17이 해당되어 모든 영상타입을 분류할 수 있

음이 확인되었다.

$$P_e = \min\left(\frac{P_{fp} + 1 - P_{tp}}{2}\right) \quad (6)$$

여기서 P_{fp} 는 FP rate, P_{tp} 는 TP rate 이다.

그림 8은 표 1의 각 영상타입의 전수조합에 따른 ROC 커브와 P_e 이다.

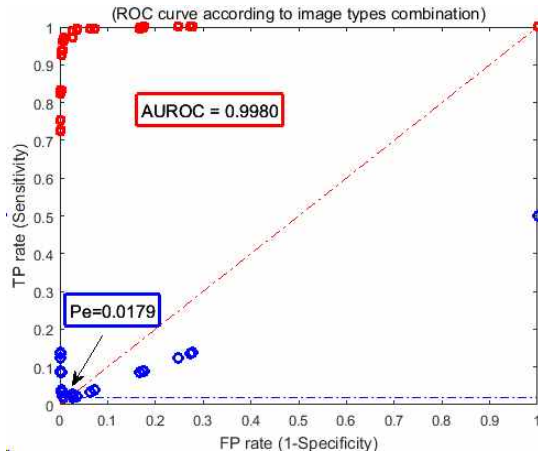


그림 13. 제안된 알고리즘의 ROC 커브와 Pe
Fig. 8. ROC curve and Pe of the proposed algorithm.

표 2는 본 논문에서 제안된 포렌식 영상의 포렌식 판정 알고리즘과 기존 방법들과의 AUROC 비교 값이다. 제안된 포렌식 영상타입의 분류가 기존의 미디언 필터링 (Post-sharpened와 Counter-filtering) 및 JPEG 압축방법보다 성능이 우수함을 확인하였다.

표 2. 제안된 알고리즘과 기존의 영상 포렌식 판정 방법의 AUROC 비교

Table 2. Comparison of Image forensic decision schemes and AUROCs between the proposed algorithm and the conventional schemes.

Schemes	영상의 특징 추출 방법		AUROC
[11]	Median filtering detection	Post-sharpened	0.923
		Counter-filtering	0.924
[1]	JPEG Compression: QF= 90,70,50,30.	Pixel detection of Large edge energy by SA and SPAM	0.9338
[2]	Median filtering detection	Difference distribution to feature set.	0.948
제안된 알고리즘	5 types image classification: - MF3 - MF5 - BMP - AVE3 - JPG90	Contrast and Energy by GLCM, and Entropy. Decision tree.	0.9980

V. 결 론

본 논문에서는 포렌식 영상에 가장 많이 사용되는 5가지 영상타입 MF3, MF5, BMP, AVE3 그리고 JPG90의 분류 알고리즘을 제안하였다. GLCM에 의한 영상의 콘트라스트와 에너지, 영상의 엔트로피를 기반으로 한 특징 벡터를 추출하고 PPCA로 차원축소를 하여 결정나무 플랜에서 분류학습을 통하여 포렌식 영상을 분류하였다. 기존의 포렌식 영상의 판정은 미디언 필터링 또는 JPEG 압축을 검출하는 방법으로 접근하였지만, 제안된 알고리즘은 포렌식 영상타입을 분류하였다.

제안된 알고리즘의 성능은 5가지의 영상타입의 전수조합에서 TP와 FN을 검출하고 따른 민감도와 1-특이도에서 AUROC는 0.9980으로 'Excellent(A)'로 평가되었고, 최소 판정예러 값에서 분류할 영상타입을 모두 포함하였다. 앞으로의 연구는 다양한 영상 공격과 위·변조 영상을 실시간으로 네트워크상에서 연동되어 효율적으로 추정할 수 있는 영상 포렌식 판정 알고리즘 개발 연구가 진행되어야겠다.

REFERENCES

- [1] Kang Hyeon RHEE, "Image Forensic Decision Algorithm using Edge Energy Information of Forgery Image," IEEK, Journal No. 51(3), pp. 27-34, 2014.7.
- [2] Kang Hyeon RHEE, "Median Filtering Detection using Latent Growth Modeling," IEEK, Journal No. 52(1), pp. 61-68, Jan. 2015.
- [3] Haralick, K. Shanmugam and Its'hak Dinstein, "Textural Features for Image Classification," IEEE Trans. on Systems, Man and Cybernetics, Vol. SMC-3, No. 6, pp. 610-621, November 1973.
- [4] Wang, Li and He Dong Chen, "Texture Classification Using Texture Spectrum," Pattern Recognition, Vol. 23, No. 8, pp. 905-910, 1990.
- [5] Pentland, A. P., "Fractal-based Description of Natural Science," IEEE Trans, on Pattern Analysis and Machine Intelligence, No. 6(6), pp. 661-674, 1984
- [6] Cross, G. R., and A. K. Jain, "Markov Random Field Texture Models," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-5, No. 1, pp. 25-39, 1983.
- [7] Derin, H. and H. Elliot, "Modeling and

Segmentation of Noisy Textured Images Using Gibbs Random Fields,” IEEE Trans. Pattern Analysis and Machine Intelligence, No. 9(I), No. 39-55, 1987.

- [8] <http://www.ke.tu-darmstadt.de/lehre/archiv/ws0809/mldm/dt.pdf>
- [9] Junshi Xia, Jocelyn Chanussot, Peijun Du and Xiyang He, “(Semi-) Supervised Probabilistic Principal Component Analysis for Hyperspectral Remote Sensing Image Classification,” IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol. 7, Issue: 6, pp. 2224-2236, 2014.
- [10] <http://vision.cs.aston.ac.uk/datasets/UCID/ucid.html>
- [11] G. Cao, Y. Zhao, R. Ni, L. Yu, and H. Tian, “Forensic detection of median filtering in digital images,” in *Proc. 2010 IEEE Int. Conf. Multimedia and EXPO*, pp. 89-94, Jul. 2010.
- [12] S. Wang, C. Lam, “Texture feature extraction using gray level gradient based co-occurrence matrices,” IEEE International Conference on systems, Man, and Cybernetics, 1996, Vol. 1, pp. 267-271, 1996.

저 자 소 개

이 강 현(평생회원)

대한전자공학회 논문지, 제53권2호 참조.