

---

# Half Hanning 윈도우 전처리를 통한 기저 세포암 자동 검출 성능 개선

## Performance Improvement of Automatic Basal Cell Carcinoma Detection Using Half Hanning Window

---

박아론, 백성준, 민소희, 유홍연, 김진영, 홍성준  
전남대학교 전자컴퓨터공학부

Aaron Park(dode@daum.net), Seong-Joon Baek(tozero@chonnam.ac.kr),  
So Hee Min(minsh@chonnam.ac.kr), Hong-Yoen You(keister@vip.chonnam.ac.kr),  
Jin Young Kim(beyondi@chonnam.ac.kr), Sung-Hoon Hong(hsh@chonnam.ac.kr)

---

### 요약

본 연구에서는 일반적으로 잘 알려진 기저 세포암 검출을 위한 간단한 전처리 방법을 제안하였다. 전처리 과정은 half Hanning 윈도우와 함께 데이터를 클리핑하고 PCA (principal components analysis)를 이용하여 차원을 감소하였다. Half Hanning 윈도우는  $1650\text{ cm}^{-1}$  피크 부근의 크기를 낮춤으로써 음성 오류율을 줄여 분류 성능을 향상시켰다. 이 실험에서 사용한 MAP (maximum a posteriori), KNN (k-nearest neighbor), PNN (probabilistic neural network), MLP (multilayer perceptron), SVM (support vector machine)와 MBE (minimum squared error)의 분류결과는 제안한 방법이 효과적임을 입증하고 있다. KNN 분류방법은 216개 리만 스펙트럼에 대한 분류실험에서 민감도가 약 97.3%로 제안한 윈도우를 적용한 이 실험에서 기저 세포암 검출 성능이 가장 많이 개선되었다.

■ 중심어 : 기저 세포암, 리만 스펙트럼, 패턴 인식

### Abstract

In this study, we propose a simple preprocessing method for classification of basal cell carcinoma (BCC), which is one of the most common skin cancer. The preprocessing step consists of data clipping with a half Hanning window and dimension reduction with principal components analysis (PCA). The application of the half Hanning window deemphasizes the peak near  $1650\text{ cm}^{-1}$  and improves classification performance by lowering the false negative ratio. Classification results with various classifiers are presented to show the effectiveness of the proposed method. The classifiers include maximum a posteriori probability (MAP), k-nearest neighbor (KNN), probabilistic neural network (PNN), multilayer perceptron (MLP), support vector machine (SVM) and minimum squared error (MBE) classification. Classification results with KNN involving 216 spectra preprocessed with the proposed method gave 97.3% sensitivity, which is very promising results for automatic BCC detection.

■ keyword : BCC, Raman Spectrum, Pattern Recognition

---

## 1. 서론

근래 들어 피부암 발생은 오존층의 고갈과 환경오염

등으로 인해 피부가 자외선에 과도하게 노출되면서 급속도로 증가하고 있다. 피부암은 발생 초기에 발견된다면

\* 본 연구는 산업자원부 지방기술혁신사업(RT04-03-03) 지원으로 수행되었습니다.

접수번호 : #081117-002

접수일자 : 2008년 11월 17일

심사완료일 : 2008년 12월 21일

교신저자 : 박아론, e-mail : dode@daum.net

거의 100% 치료될 수 있지만 불행하게도 암 발견을 위해서 피부과 생체조직검사에 의존하고 있기 때문에 조기 발견이 어려운 실정이다.

일반적으로 피부암은 기저 세포암 (Basal Cell Carcinoma: BCC)과 편평상피 세포암 (Squamous Cell Carcinoma: SCC)으로 분류한다. BCC는 SCC보다 자주 나타나는 피부 종양이지만 주위의 암이 아닌 정상조직 (normal tissue: NOR)과 구별하기가 매우 어렵기 때문에 정확한 진단이 쉽지 않다[1]. 일반적으로 BCC의 검출은 피부에서 의심되는 조직을 채취하여 H&E (hematoxylin and eosin) 염색한 후 조직학적인 기형을 판단함으로써 이루어진다. 하지만 이 방법은 병리학자들의 경험에 따른 주관적인 판단에 의존하며 때로는 정확한 생체검사를 위해 다량의 조직을 필요로 한다. 따라서 암종의 조기 검출을 위한 빠르고 정확한 피부암 진단 기술이 필요하다[2].

본 연구에서는 공초점 라만 분광기를 통해 얻어진 스펙트럼을 이용하여 MAP (maximum a posteriori), KNN (k-nearest neighbor), PNN (probabilistic neural network), MLP (multilayer perceptron), SVM (support vector machine)와 MSE (minimum squared error) 분류 방법으로 자동 분류기를 구현하였다. 이 분류기를 이용하여 윈도우를 사용하지 않은 경우, 클리핑 윈도우만을 사용한 경우와 클리핑 윈도우와 half Hanning 윈도우를 함께 사용한 경우에서 각각 BCC를 검출하고 그 결과를 비교한다.

## II. 공초점 라만 스펙트럼

### 1. 공초점 라만 스펙트럼

최근 라만 스펙트럼을 이용하여 각종 암을 진단하는 시도가 꾸준히 이루어지고 있다. 요즈음 FT (Fourier transform) 라만 스펙트럼을 광범위하게 사용하였다[3]. 이 경우 피부조직의 자기형광 (autofluorescence)을 줄이기 위해 장파장 여기 레이저 (1064nm Nd:Yag 레이저 또는 850nm 티타늄 레이저)를 사용한다. 그러나 장파장 여기 레이저는 낮은 신호 대 잡음비 (signal-to-noise)로 인해 배경 잡음 (background noise) 문제가 발생한다[2].

따라서 FT 라만 스펙트럼은 배경 잡음을 제거하기 위해 복잡한 통계적 처리가 필요하였다[4].

배경잡음 문제를 해결하기 위해 자기형광을 효과적으로 제거해야한다. 공초점 라만 분광기는 자기형광을 효과적으로 제거하는데 가장 뛰어난 것으로 알려져 있다. 최근에는 파장이 514nm인 단파장 아르곤 이온 레이저를 이용한 공초점 (confocal) 라만 기법으로 BCC 스펙트럼을 직접 관찰하는 방법이 제안되었다[2]. 이 연구 결과에 따르면 공초점 라만 스펙트럼은 특별한 처리 없이도 전암 (precancerous)과 암이 아닌 부분의 분류에서 좋은 결과를 보였다.

## III. 공초점 라만 측정과 전처리

### 1. 실험샘플 준비와 공초점 라만 측정

조직 샘플은 몇 가지 처리에 의해 준비하였다. 10명의 환자로 부터 일반적인 생검법을 사용하여 BCC 조직샘플을 획득하였다. 샘플은 -20℃에서 마이크로톰 (microtome)을 사용하여 20μm 두께의 횡단면으로 두 개를 절단하고 액화 질소에 저장하였다. 이런 방법으로 얻어진 두 개의 얇은 단면이 실험에 사용된다. 한 단면은 분류 실험에 사용되고 다른 단면은 조직검사를 실시하여 전문 피부학자의 진단을 통해 BCC와 NOR 사이의 경계를 결정한 후 분류실험의 기준값으로 쓰인다.

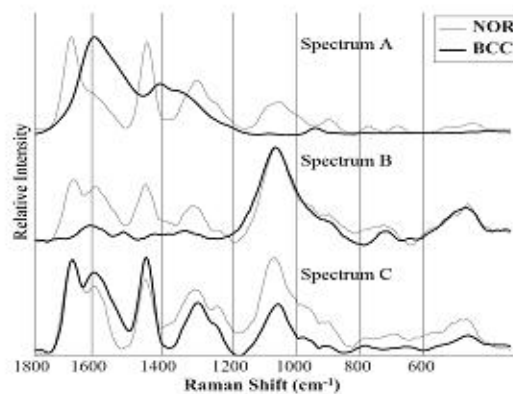


그림 1. 세 명의 환자의 각각 다른 지점에서 측정된 공초점 라만 스펙트럼

2. 데이터 전처리와 차원 축소

2.1 데이터 전처리

라만 스펙트럼은 레이저의 강도, 라만 스펙트럼을 측정하여 적분하는 시간, 그리고 피부의 물리화학적 구성에 따라 크기가 달라지기 때문에 모든 스펙트럼의 정규화가 필요하다. 알려진 정규화 방법이 많지만 예비 실험에서 minmax 방법을 이용한 경우 가장 좋은 결과를 보였다. 따라서 본 논문에서는 minmax 방법을 이용하여 [-1, +1] 범위로 정규화하였다.

이전 연구에 의하면 [그림 1]의 Spectrum A와 같이 1640 ~1680cm<sup>-1</sup>의 영역에서 BCC와 NOR을 구별할 수 있는 가장 두드러진 특징이 나타난다. 그러나 [그림 1]의 Spectrum B와 같이 1220 ~1300cm<sup>-1</sup>의 영역에서는 BCC와 NOR이 비슷한 특징을 나타낸다. 따라서 본 실험에서는 정규화 과정이 거친 스펙트럼에 클리핑 윈도우를 사용하여 분류기의 성능을 저하시키는 1500cm<sup>-1</sup>이하 불필요한 영역의 데이터를 제거하였다. BCC와 NOR의 근접 부위에서는 [그림 1]의 Spectrum C와 같이 두 개의 피크치가 종종 나타나게 되는데 1800 ~1600cm<sup>-1</sup> 영역의 데이터에 half Hanning 윈도우를 사용함으로써 분류율을 향상시켜 양성 오류율 (false positive ratio)과 음성 오류율 (false negative ratio)을 보다 더 낮출 수 있다[5]. 이 Hanning 윈도우의 영역의 너비라 할 때 본 실험에 사용한 half Hanning 윈도우의 영역은 이고 다음의 식과 같다.

클리핑 윈도우와 half Hanning 윈도우를 결합한 전체 윈도우는 [그림 2]와 같다. 그림에서 1800 ~1600cm<sup>-1</sup> 영역은 half Hanning 윈도우이고 1500cm<sup>-1</sup>이하 영역은 불필요한 데이터를 제거하기 위한 클리핑 윈도우이다.

2.2 차원 축소

윈도우 과정을 거친 후 차원 줄이기 위해 PCA (principal components analysis)를 적용한다. PCA는 데이터를 감소하기 위한 가장 우선되는 방법으로 사영 (projection)들이 서로 상관관계가 없다는 사실을 근거하여 그 직교성을 식별한다. 주성분은 다음의 분산 행렬의 고유값 (eigenvalue) 분해에 의해 얻는다.

$$S = \frac{1}{n} \sum_{i=1}^n x_i x_i^T \quad (2)$$

가 입력 패턴일 때  $\mu$ 는  $\mu$ 의 평균 (mean)이다. 고유값의 내림차순 대각행렬을  $\Lambda$ 라고 하고 고유값에 대응하는 고유벡터로 행이 구성된 직교행렬을  $V$ 라고하면 주요 성분  $\mu$ 는 다음과 같다.

$$\mu = V \Lambda \mu \quad (3)$$

$$x = V \Lambda x \quad (4)$$

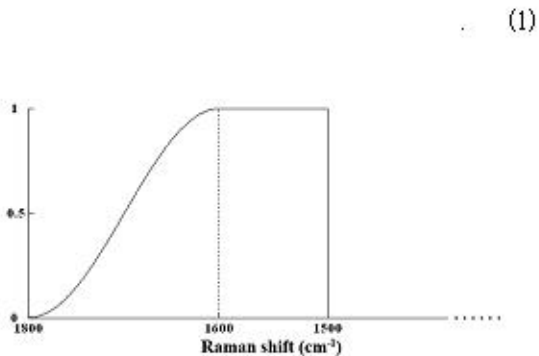


그림 2. 클리핑 윈도우와 half Hanning 윈도우를 결합한 윈도우

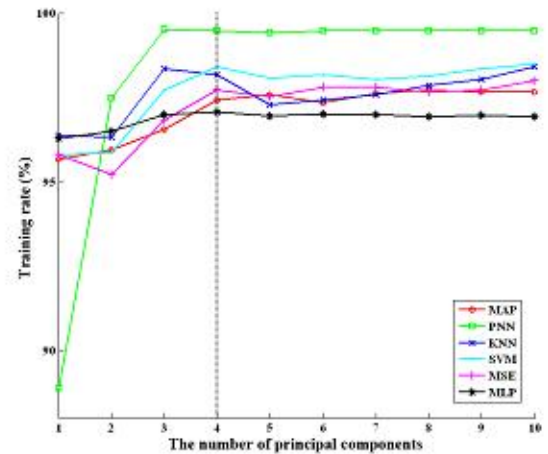


그림 3. 주성분 수의 변화에 따른 여러 분류기의 훈련율

데이터의 감소는 의 중요하지 않은 성분을 버리는 것으로 완료된다. [그림 3]에 주성분 수를 선택하기 위한 예비 실험 결과를 나타내었다. 주성분 수의 변화에 따른 각 분류기의 훈련 데이터 분류율 (training rate)을 분석하고 가장 적합한 주성분의 수를 결정하였다. 이 결과를 근거하여 본 실험에서는 PCA를 적용하여 얻어진 주성분 중 처음 4개를 사용한다.

IV. 분류방법과 실험결과

1. 분류방법

BCC와 NOR 클래스의 특징벡터가 잘 분리되는지를 알아보기 위해 변환된 특징벡터의 첫 번째부터 세 번째 까지 대응되는 성분들을 3차원에 나타내었다. [그림 4]에서 보듯이 입력된 특징벡터들이 잘 구분된다. 그러므로 본 실험에 사용된 분류기에서 좋은 결과를 기대할 수 있다.

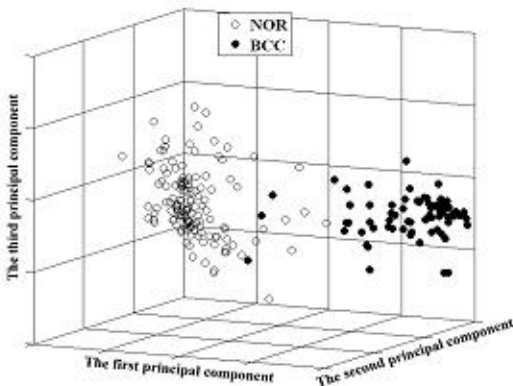


그림 4. PCA 변환된 스펙트럼 중 처음 3개 주성분의 분포

본 실험에서는 MAP, PNN, KNN, MLP와 SVM의 5가지 분류기를 사용한다. MAP는 패턴의 사후확률 을 최대로 하는 클래스 로 패턴을 분류한다. 사전확률을 같다고 가정하면 클래스 조건부 확률 밀도를 최대로 하는 클래스를 선택하는 것과 같다. BCC 클래스와 NOR 클래스를 각각 , 라고 할 때 MAP 결정 규칙은 다음과 같다.

$$\geq \quad (5)$$

본 실험에서는 클래스 조건부 확률을 다변수 가우시안 확률밀도함수 (multivariate Gaussian probability function)로 모델링을 하였다. 그리하여 평균벡터 와 공분산 행렬 을 Maximum likelihood 방법으로 추정하였다. 를 클래스 의 데이터 개수라고 하면 이때 결정 규칙은 다음과 같이 판별함수 로 표현된다.

$$\text{Decide} \quad \geq \quad (6)$$

$$\quad (7)$$

$$\quad (8)$$

$$\quad (9)$$

KNN는 Mahalanobis 거리를 이용하여 클래스를 분류한다. 는 훈련 그룹의 모든 데이터로부터 계산된 샘플 공분산 행렬이다.

$$\quad (10)$$

KNN에서 판별식 는 에서 번째로 가장 가깝게 이웃하는 클래스의 훈련 데이터의 수이다. 본 실험에서 인접하는 이웃 를 5로 결정하였다. KNN 알고리즘은 훈련 데이터의 수에 비례하여 큰 계산량을 필요로 한다. 본 실험에서는 fast 알고리즘을 이용하였다[6].

PNN은 훈련 그룹의 각 특징벡터가 단위 길이가 되도록 조정하고 입력벡터는 분류하기 전에 정규화한다[7]. 훈련 그룹의 모든 데이터에 대한 를 측정하고 훈련 그룹의 정규화한 특징벡터를 라 하였을 때 PNN에 대한 판별식은 다음과 같다. 이 때 는 예비 실험에 의해 0.0001로 결정하였다.

$$\begin{aligned}
 (11) \quad & \mathbf{W} = \mathbf{W}^T \mathbf{W} \\
 (12) \quad & \mathbf{W} = \mathbf{W}^T \mathbf{W}
 \end{aligned}$$

MLP는 임의의 복잡한 사후 확률함수를 모델링할 수 있는 강력하고 유연성이 있는 분류 방법이다[8]. MLP의 각 층은 노드 또는 뉴런이라고 불리는 몇 개의 처리 유닛으로 구성되어 있다. 이 유닛들은 입력 유닛을 제외하고 일반적으로 비선형 유닛이다. 은닉층의 활성화 함수를 라고 할 때 MLP의 은닉층에 대한 입력 와 은닉층의 출력 는 다음과 같이 표현된다.

$$(13) \quad \mathbf{z} = \mathbf{W} \mathbf{x} + \mathbf{b}$$

$$(14) \quad \mathbf{y} = \mathbf{f}(\mathbf{z})$$

MLP는 한 개의 출력 유닛을 사용하여 두 개의 클래스를 구분할 수 있다. 이 실험에서는 9개의 유닛으로 은닉층을 구성하고 하나의 유닛으로 출력을 구성하였다. NOR 클래스에 대해 -1, BCC 클래스에 대해 +1이 출력 되도록 오류 역전파(Error Back Propagation) 알고리즘을 이용하여 훈련하였다. MLP의 초기값에 따라 그 성능이 달라지므로 본 연구에서는 실험을 20회 수행하고 그 결과를 평균하여 제시하였다.

SVM는 비선형 분류 문제를 해결하는 강력한 방법이다. 주어진 클래스가 원래 입력 평면에서 선형으로 구분되지 않을 경우 SVM은 주어진 특징을 높은 차원 특징 평면으로 비선형 변환한다. 이 변환은 polynomial, sigmoid와 radial basis function (RBF)와 같은 비선형 사상으로 얻을 수 있다. 비선형 변환 후 최적으로 구분되는 선형 초평면을 쉽게 찾을 수 있다. 결과적으로 초평면은 훈련 데이터에 대하여 가장 효과적인 마진을 가진 분류기가 될 수 있다[9]. 본 실험에서는 다음과 같은 가우시안 RBF 커널을 사용하였다.

$$(15) \quad K(\mathbf{x}, \mathbf{y}) = \exp\left(-\gamma \|\mathbf{x} - \mathbf{y}\|^2\right)$$

여기에서 사용된 파라미터는 예비 실험의 결과에 의해서 20, 최소 제곱 SVM을 최적화하는 정규화 파라미터를 1.0으로 설정하였다[10].

MSE는 훈련 단계에서 여러 제곱의 합을 최소화해야 하는데 이 문제에 대한 해는 잘 알려져 있다. 가 훈련 벡터일 때 를 가 되는 확장 훈련 벡터 (argumented training vector)로 정의하면 가 열벡터인 행렬 의 의사역행렬 (psedoinverse) 를 구함으로써 이 문제를 해결할 수 있다. 결정 초평면 (hyperplane)에 수직인 벡터 를 얻었다면 입력 패턴 는 확장 벡터 와 의 내적 부호에 따라 분류될 수 있다. 를 마진이라고 하면 MSE의 해벡터는 다음의 식으로 구해진다.

$$(16) \quad \mathbf{w} = \mathbf{W}^T \mathbf{W}^{-1} \mathbf{W} \mathbf{y}$$

본 실험에서는 예비 실험의 결과에 의해서 마진 를 0.08로 설정하였다.

## 2. 실험결과

본 실험에서는 먼저 총 216개의 데이터를 훈련 그룹과 테스트 그룹의 두 그룹으로 나누었다. 9명의 환자의 데이터는 훈련 그룹으로 나머지 1명의 환자의 데이터는 테스트 그룹으로 나누었다. 분류가 끝나면 한 환자의 데이터는 훈련 그룹에서 새로운 테스트 그룹으로 이동되며 기존의 테스트 데이터는 훈련 그룹으로 이동된다. 이와 같은 방법으로 모든 환자의 데이터는 테스트 그룹으로 한번 씩 사용된다. 실험에서 사용된 BCC와 NOR의 평균 개수는 테스트 그룹이 각각 8개와 14개이며 훈련 그룹은 68개와 126개이다.

[표 1]에 데이터 윈도우를 적용시키지 않은 경우 분류 결과를 요약하였다. 앞서 언급한 바와 같이 모든 분류기의 주성분은 4개이다. 표에서 보듯이 모든 분류기의 평균 민감도 (sensitivity)는 93.2%이고 평균 특이도 (specificity)는 96.0%이다.

표 1. 데이터 윈도우를 사용하지 않은 경우의 분류 결과 (\*는 전문 병리학자의 결정임)

분류기	BCC*		NCR*	
	민감도 (sensitivity) (%)	음성 오류율 (false negative rate) (%)	양성 오류율 (false positive rate) (%)	특이도 (specificity) (%)
MAP	93.4	6.6	5.0	95.0
PNN	93.4	6.6	3.6	96.4
KNN	90.8	9.2	3.6	96.4
MLP	93.4	6.6	4.5	95.5
SVM	93.4	6.6	3.6	96.4
MSE	94.7	5.3	3.6	96.4

분류 성능의 향상을 위해 클리핑 윈도우와 half Hanning 윈도우를 결합하여 데이터에 적용하였다. [표 2]에 제안한 윈도우를 사용한 결과를 요약하였다. 표에서 모든 분류기의 특이도가 비슷한 수준을 유지한 가운데 민감도가 향상되었다. 평균 민감도가 약 96.6%로 제안한 윈도우를 적용하지 않은 경우보다 3.4% 향상되었다.

표 2. 클리핑 윈도우와 half Hanning 윈도우를 결합하여 데이터에 적용한 경우의 분류 결과 (\*는 전문 병리학자의 결정임)

분류기	BCC*		NCR*	
	민감도 (sensitivity) (%)	음성 오류율 (false negative rate) (%)	양성 오류율 (false positive rate) (%)	특이도 (specificity) (%)
MAP	94.7	5.3	4.3	95.7
PNN	96.1	3.9	5.6	94.3
KNN	97.4	2.6	2.9	97.1
MLP	96.7	3.3	4.6	95.4
SVM	97.3	2.7	3.6	96.4
MSE	97.4	2.6	4.3	95.7

이 결과는 half Hanning 윈도우가 양성 오류율보다 암 판정에 있어 치명적인 음성 오류율을 더 감소시킨다는 것을 나타낸다. 본 실험에 사용한 모든 분류기의 평균 음성 오류율이 6.6%에서 3.4%로 감소하였고 전체 분류율이 약 96.2%이다. [표 3]에 윈도우를 적용하지 않은 경우, 클리핑 윈도우만을 적용한 경우와 제안한 윈도우를 적용

한 경우의 평균 분류 오류율을 요약하였다. 표에서 보듯이 클리핑 윈도우만을 적용한 경우에는 모든 분류기의 평균 분류 오류율이 제안한 윈도우를 적용하지 않은 경우와 같거나 감소하였다. 그러나 제안한 윈도우를 적용한 경우에는 적용하지 않은 경우보다 감소하여 모든 분류기의 성능이 향상된 것을 확인할 수 있다. 이 성능 향상이 어떠한 비용 없이 달성된 것을 고려하면 제안한 윈도우의 유용성이 명백하게 확인되었다.

표 3. 윈도우를 적용하지 않은 경우, 클리핑 윈도우만 적용한 경우, 제안한 윈도우를 적용한 경우의 평균 분류 오류율 비교

	평균 분류 오류율 (%)					
	MAP	PNN	KNN	MLP	SVM	MSE
제안한 윈도우를 적용하지 않은 경우	5.6	5.1	6.4	5.6	5.1	4.5
클리핑 윈도우만을 적용한 경우	4.9	5.1	4.1	4.1	3.8	4.5
제안한 윈도우를 적용한 경우	4.6	4.8	2.6	4.0	3.2	3.5

비록 분류 오류율이 이미 낮더라도 분류 오류율을 더욱 향상시킬 수 있는 가능성은 존재한다. 거의 모든 양성 오류가 [그림 1]의 Spectrum C와 같은 경우로 BCC 영역의 중간부근에서 발생한다. 매우 작은 초점반경을 사용하는 공초점 라만 분광기는 측정할 때 뜻밖에 BCC 조직 대신 정상 조직에 초점이 맞춰진 경우가 있다. 이 경우에 오류가 발생하는 것이다. 이러한 문제를 해결하기 위한 연구를 진행 중에 있으며 이 점을 고려하면 완벽한 BCC의 자동검출이 가능할 것이다.

## V. 결론

본 논문에서는 공초점 라만 분광기를 이용한 BCC 검출을 위해 간단한 전처리 방법을 제안하고 다양한 분류 방법의 성능 향상에 대해 살펴보았다. 전처리 단계에서 클리핑 윈도우와 half Hanning 윈도우를 이용하여 불필요한 영역을 감소 또는 제거하고 데이터 차원을 줄이기 위해 PCA를 이용하였으며 실험 결과에 따르면 데이터

윈도우를 사용함으로써 음성 오류율이 감소한다는 사실을 확인하였다. 모든 분류 방법에서 제안한 윈도우를 적용하여 성능이 향상되었으며 특히 KNN의 경우에는 민감도가 90.8%에서 97.4%로 6.6% 상승하였다. 이 연구 결과를 토대로 기존의 분류방법보다 성능이 개선된 자동 BCC 검출 도구를 현재 개발 중이다.

참고 문헌

[1] A. Jijssen, T. C. B. Schut, F. Heule, P. J. Caspers, D. P. Hayes, M. H. Neumann, and G. J. Puppels, "Discriminating Basal Cell Carcinoma from its Surrounding Tissue by Raman Spectroscopy," *Journal of Investigative Dermatology*, Vol.119, pp.64-69, July 2002.

[2] J. Choi, J. Choo, H. Chung, D. G. Gweon, J. Park, H. J. Kim, S. Park, and C. H. Oh, "Direct Observation of Spectral Differences Between normal and Basal Cell Carcinoma (BCC) Tissues Using Confocal Raman Microscopy," *Biopolymers*, Vol.77, pp.264-272, April 2005.

[3] L. O. Nunes, A. A. Martin, L. Silveira Jr, M. Zampieri, and E. Minin, "Biochemical Changes between Normal and BCC Tissue: a FT-Raman study," *Proceedings of the SPIE*, Vol.4955, pp.546-553, July 2003.

[4] S. Sigurdsson, P. A. Philipsen, L. K. Hansen, J. Larsen, M. Gniadecka, and H. C. Wulf, "Detection of Skin Cancer by Classification of Raman Spectra," *IEEE Trans. on Biomedical Engineering*, Vol.51, pp.1784-1793, Oct. 2004.

[5] S. J. Baek and A. Park, "Basal Cell Carcinoma Detection by Classification of Confocal Raman Spectra," *LNCIS* 345, pp.735-740, 2006.

[6] S. J. Baek and K. M. Sung, "Fast KNN Search Algorithm for Nonparametric Classification," *IEE Electronics Letters*, Vol.35, No.24, pp.2104-2105,

Nov. 2000.

[7] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*, John Wiley & Son Inc., 2001.

[8] M. Gniadecka, H. Wulf, N. Mbrtensen, O. Nielsen, and D. Christensen, "Diagnosis of Basal Cell Carcinoma by Raman Spectra," *Journal of Raman Spectroscopy*, Vol.28, pp.125-129, 1997.

[9] V. Kecman, *Learning and Soft Computing* The MIT Press, 2001.

[10] J. A. K. Suykens, T. Van Gestel, J. De Brabanter, B. De Moor, and J. Vandewalle, *Least Squares Support Vector Machines*, World Scientific, Singapore, 2002.

저자 소개

박 아론(Aaron Park)

정회원



• 2006년 2월 : 전남대학교 전자컴퓨터정보통신공학부 (공학사)  
 • 2006년 3월 ~ 현재 : 전남대학교 전자컴퓨터공학부 (공학석사)  
 <관심분야> : 디지털 신호처리, 패턴인식

백 성준(Seong-Joon Baek)

정회원



• 1989년 2월 : 서울대학교 전자공학과 (공학사)  
 • 1992년 2월 : 서울대학교 전자공학과 (공학석사)  
 • 1999년 2월 : 서울대학교 전자공학과 (공학박사)  
 • 2002년 3월 ~ 현재 : 전남대학교 전자컴퓨터공학부 교수  
 <관심분야> : 디지털 신호처리, 의료통신 음성관련 신호처리

민 소 희(So Hee Min)

정회원



- 1993년 2월 : 전남대학교 전자공학과 (공학사)
- 2003년 3월 ~ 현재 : 전남대학교 전자공학과 (석박사통합과정)

<관심분야> : 디지털 신호처리, 바이오인포메틱스

김 진 영(Jin Young Kim)

정회원



- 1986년 2월 : 서울대학교 전자공학과 (공학사)
- 1988년 2월 : 서울대학교 전자공학과 (공학석사)
- 1994년 8월 : 서울대학교 전자공학과 (박사수료)

•1995년 1월 ~ 현재 : 전남대학교 전자컴퓨터공학부 교수

<관심분야> : 음성신호처리, 음성인식, 음성합성

유 흥 연(Hong-Yoen You)

정회원



- 2001년 2월 : 동신대학교 전자공학과 (공학사)
- 2004년 2월 : 전남대학교 전자공학과 (공학석사)
- 2006년 2월 : 전남대학교 전자공학과 (박사수료)

<관심분야> : 멀티미디어 시스템, 의료영상처리

홍 성 훈(Sung-Hoon Hong)

정회원



- 1988년 2월 : 영남대학교 전자공학과 (공학사)
- 1991년 2월 : 한국과학기술원 전기 및 전자공학과 (공학석사)
- 1999년 8월 : 한국과학기술원 전기 및 전자공학과 (공학박사)

•2000년 7월 ~ 현재 : 전남대학교 전자컴퓨터공학부 교수

<관심분야> : 영상부호화, 의료영상처리, 멀티미디어 시스템, 영상처리용 SoC, 객체분할