

논문 2007-44CI-1-9

모호한 패턴 클래스 도입을 통한 기저 세포암 분류기의 신뢰도 향상

(Reliability Improvement of Automatic Basal Cell Carcinoma Classifier
with an Ambiguous Pattern Class)

박 아 론*, 백 성 준**, 정 인 육*, 송 민 규*, 나 승 유**

(Aaron Park, Seong-Joon Baek, In-Wook Jung, Min Gyu Song, and Seung Yu Na)

요 약

라만 분광법은 피부암 진단에 사용되는 매우 유력한 비침습성 진단 방법이다. 라만 스펙트럼을 이용한 이전의 연구에 따르면 MAP (maximum *a posteriori* probability)와 MLP (multilayer perceptron networks)와 같은 기존의 분류 방법으로도 좋은 분류결과를 얻을 수 있다. 하지만 암 진단은 작은 오류에도 종종 치명적인 결과가 따르기 때문에 본 연구에서는 판정이 모호한 데이터를 따로 집단화하여 분류 오류를 감소하는 방법을 제안한다. 이때 모호한 패턴은 조작검사를 통하여 다시 암여부를 판정하게 된다. 본 논문에서는 모호한 패턴 클래스를 MSE (minimum squared error), MAP와 MLP에 도입하기 위해 기존 알고리듬을 수정하였고 모호한 패턴 클래스가 본래 도입되어 있는 RCE (reduced coulomb energy networks)와 실험결과를 비교하였다. 216개의 광초점 라만 스펙트럼에 대한 실험결과에 의하면 모호한 패턴으로 판정된 데이터를 늘림에 따라 나머지 패턴은 완벽하게 분류할 수 있음을 보였다. 그 중 MSE는 테스트 패턴 중 약 8.8%의 모호한 패턴으로 나머지 패턴에 대하여 완벽한 분류결과를 보였다.

Abstract

Raman spectroscopy is known to have strong potential for providing noninvasive dermatological diagnosis of skin cancer. According to the previous work, various well known methods including maximum *a posteriori* probability (MAP) and multilayer perceptron networks (MLP) showed competitive results. Since even the small errors often leads to a fatal result, we investigated the method that reduces classification error perfectly by screening out some ambiguous patterns. Those ambiguous patterns can be examined by routine biopsy. We incorporated an ambiguous pattern class in MAP, linear classifier using minimum squared error (MSE), MLP and reduced coulomb energy networks (RCE). The experiments involving 216 confocal Raman spectra showed that every methods could perfectly classify BCC by screening out some ambiguous patterns. The best results were obtained with MSE. According to the experimental results, MSE gives perfect classification by screening out 8.8% of test patterns.

Keywords: 기저 세포암, 라만 스펙트럼, 패턴 인식, BCC, Raman spectroscopy

I. 서 론

피부암은 세계에서 가장 일반적인 암 중 하나이다.

최근 피부암 발생은 오존층의 고갈과 환경오염 등으로 인해 피부가 자외선에 과도하게 노출되면서 급속도로 증가하고 있다. 피부암은 초기에 검출된다면 100% 치료될 수 있지만 불행하게도 병리학자에 의한 생체조직 검사에 의존하고 있기 때문에 피부암의 조기 발견이 어려운 실정이다^[1]. 일반적으로 피부암은 기저 세포암 (Basal Cell Carcinoma: BCC)과 편평상피 세포암 (Squamous Cell Carcinoma: SCC)으로 분류한다. BCC는 SCC보다 자주 나타나는 피부 종양이지만 주위의 암

* 학생회원, ** 평생회원, 전남대학교 전자컴퓨터공학부
(The School of Electronic and Computer
Engineering, Chonnam National University)

※ 이 논문은 2006년도 정부재원(교육인적자원부 학술
연구조성사업비)으로 한국학술진흥재단의 지원을
받아 연구되었음. (KRF-2006-003-D00413)

접수일자: 2006년11월17일, 수정완료일: 2007년1월10일

이 아닌 정상 조직 (normal tissue: NOR)과의 구별이 쉽지 않기 때문에 정확한 진단이 쉽지 않다. 일반적으로 BCC는 조직 샘플을 피부암으로 의심되는 조직을 채취하여 H&E (hematoxylin and eosin) 염색한 후 병리학적으로 검사하여 검출한다. 하지만 이 방법은 처리가 복잡하고 각 병리학자의 경험에 의한 주관적인 판단에 따르며 때로는 정확한 생체검사를 위해 피부 조직을 과도하게 필요로 한다. 따라서 암종의 조기 검출을 위한 빠르고 정확한 진단 기술이 필요하다^[2].

라만 스펙트럼으로 이러한 문제를 해결할 수 있다. 라만 스펙트럼은 BCC와 NOR을 정확하게 구별하는 의학적 진단을 할 수 있다. 최근 몇몇 연구에서 라만 스펙트럼을 이용한 BCC 검출을 수행하고 있다. 요즈음 광범위하게 사용되는 방법은 FT (Fourier transform) 라만 스펙트럼이다^[3,4]. 이 경우 피부조직의 자가형광 (autofluorescence)을 줄이기 위해 장파장 여기 레이저를 사용한다. 하지만 낮은 신호 대 잡음비 (signal-to-noise)로 인해 배경 잡음(background noise) 문제가 발생한다. 따라서 FT 라만 스펙트럼은 배경 잡음을 제거하기 위해 복잡한 통계 처리가 필요하였다^[3].

최근에는 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.

이전 연구에서 BCC 검출을 위해 MAP (maximum *a posteriori* probability), PNN (probabilistic neural networks), KNN (*k*-nearest neighbor), MLP (multilayer perceptron networks)과 SVM (support vector machine) 분류 방법을 사용하였고 그 결과 분류 오류율이 약 4~5%정도였다^[5]. 때로는 이 오류가 치명적일 수 있기 때문에 본 연구에서는 모호한 패턴 클래스를 도입하여 분류 오류율을 낮추는 방법을 제안하였다. 분류기에 의해 모호한 클래스로 분류된 패턴들은 다시 조직검사를 통하여 좀 더 세밀하게 조사될 수 있을 것이다.

II. 실험샘플 준비와 전처리

1. 실험샘플 준비

조직 샘플은 몇 가지 처리에 의해 준비하였다. 10명의 환자로부터 일반적인 생검법을 이용하여 BCC 조직

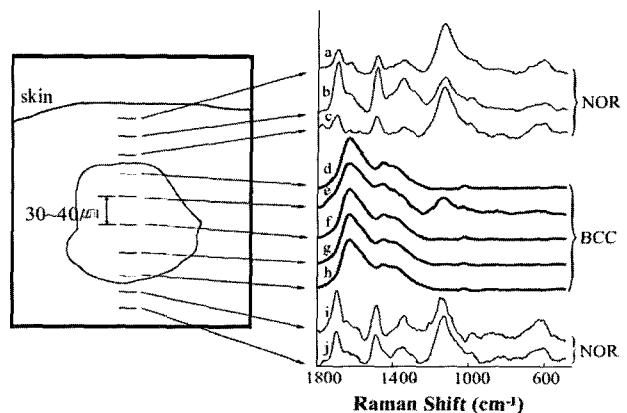


그림 1. 30~40μm 간격으로 측정된 공초점 라만 스펙트럼의 프로파일

Fig. 1. Confocal Raman profiles of skin tissue with an interval of 30~40 μm.

샘플을 획득하였다^[2]. 샘플은 -20°C에서 마이크로토름 (microtome)을 사용하여 20μm 두께의 획단면으로 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.

Renishaw 2000 공초점 라만 분광 시스템(confocal Raman microscope system)은 초점에서의 빛영역은 통과되고 인접영역의 빛은 거부한다. 따라서 주변 영역으로부터의 스펙트럼의 간섭 또는 오염을 최소화할 수 있다. 아르곤 이온 레이저는 여기원 (excitation source)의 출력은 약 20mW이며 $\lambda = 514.5\text{nm}$ 에서 작동하였다. 공초점 라만 분광기를 이용한 조직 샘플의 스펙트럼은 피부 표면으로부터 수직인 방향 30~40μm 간격으로 서로 다른 약 22개의 지점에서 측정하였다. 이와 같은 방식으로 본 연구에서는 10명의 환자로부터 216개의 라만 스펙트럼을 얻었다. 그림 1은 공초점 라만 분광기를 이용하여 측정한 조직 샘플 스펙트럼의 프로파일이다.

2. 전처리

측정된 스펙트럼은 minmax 방법을 이용하여 [-1, 1] 범위로 정규화를 한 후 clipping 윈도우와 half Hanning 윈도우를 결합한 윈도우를 사용하여 불필요한 스펙트럼 영역을 제거하였다^[6]. 그 다음 패턴의 차원을 줄이기 위해 잘 사용되는 PCA (principal components analysis)를 적용하였다. PCA는 데이터를 감소하기 위한 가장 우선되는 방법으로 사영 (projection)들이 서로 상관관계가 없다는 사실을 근거하여 그 직교성을 식별한다.

주성분은 다음의 분산 행렬 S 의 고유값 (eigenvalue) 분해에 의해 얻는다.

$$S = \sum_k (x_k - \mu)(x_k - \mu)^T. \quad (1)$$

x_k 가 입력 패턴일 때 μ 는 x_k 의 평균 (mean)이다. 고유값의 내림차순 대각행렬을 D 라 하고 고유값에 대응하는 고유벡터로 행이 구성된 직교행렬을 E 라고 하면 주요 성분 y_k 는 다음과 같다.

$$S = E D E^T, \quad (2)$$

$$y_k = E^T x_k. \quad (3)$$

데이터 감소는 y_k 의 중요하지 않은 성분을 버림으로써 완료된다. 그림 2는 BCC와 NOR 클래스의 특징 벡터 분포를 나타낸다. x 축과 y 축은 첫 번째와 두 번째 주성분에 대응된다. 그림에서 보듯이 대부분의 중요한 특징들은 쉽게 구별 될 수 있지만 약간의 혼란스러운 특징들이 경계(타원)에 분포되어 있다.

하지만 경계 영역에 있는 특징들을 모호한 패턴 클래스로 분류하여 따로 처리할 수 있다면 기존의 분류기도 보다 신뢰성 있는 분류 결과를 얻을 수 있을 것이다. 따라서 본 연구에서는 모호한 패턴 클래스를 도입하고 첫 번째와 두 번째 주성분만을 이용하여 분류기의 성능을 분석하였다.

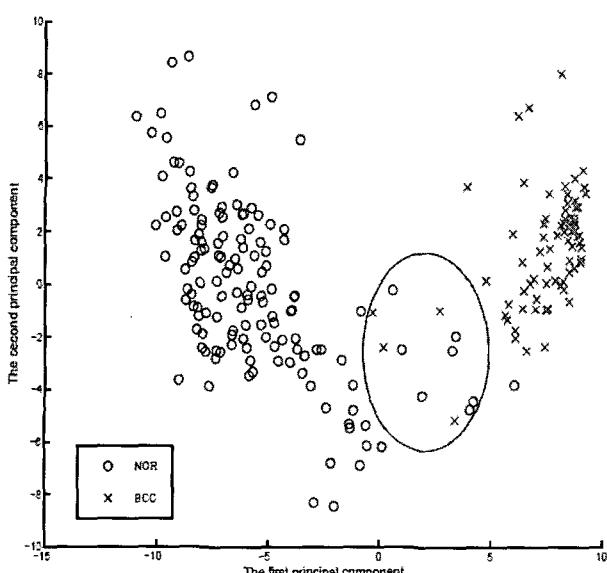


그림 2. BCC와 NOR의 첫 번째와 두 번째 주성분
Fig. 2. The first and the second principal components of BCC and NOR.

III. 분류방법과 실험결과

1. 분류 방법

본 실험에서는 모호한 패턴 클래스를 새롭게 도입한 MAP, MSE, MLP와 모호한 패턴 클래스를 고유하게 포함하고 있는 RCE를 포함하여 네 가지 유형의 분류 방법으로 BCC를 자동 검출하였다. 이 분류 방법 중 MSE는 선형 결정 영역을 가진 유일한 분류 방법이다. 모호한 패턴 클래스를 도입하기 위해 MAP, MSE와 MLP의 결정 규칙을 수정하였다.

RCE는 본래 모호한 패턴 클래스가 고유하게 도입되어 있는 분류기이다. 훈련 단계에서는 훈련 집단의 각 패턴은 다른 패턴 클래스로부터 둘러싸인 어떤 점도 없는 가능한 가장 큰 반지름을 갖게 한다^[7]. 새로운 패턴이 존재하면 각 반지름은 다른 패턴 클래스의 구면에 둘러싸이지 않도록 축소된다. 이와 같은 방법으로 각 구면은 오직 같은 패턴 클래스를 가진 패턴으로만 둘러싸이게 된다. 서로 다른 클래스들로 겹치는 영역의 테스트 패턴은 모호한 패턴 클래스로 분류된다.

훈련 패턴 y_i 의 반지름을 λ_i , 테스트 패턴 x 가 놓인 초평면에서의 훈련 패턴 라벨의 집합을 L 이라고 할 때 y_i 의 클래스 라벨이 l_i 라고 하고 다음과 같은 Euclidian 거리를 사용하였다.

$$D(x, y_i) = \sqrt{(x - y_i)^T (x - y_i)}. \quad (4)$$

본 실험에서 사용한 RCE 분류 알고리듬은 다음과 같이 요약된다.

initialization: $L = \{\}$,

for all y_i : if $D(x, y_i) < \lambda_i$ then $L = L \cup l_i$, (5)

decision: corresponding label, if all labels in L

are the same ambiguous label, otherwise.

RCE와 같은 비모수 (nonparametric) 방법은 모든 패턴이 저장되어 있어야 한다는 단점이 있다. 따라서 좋은 결과를 얻기 위해서는 많은 수의 샘플이 필요하며 상당한 메모리와 계산 시간이 필요하다. 따라서 본 실험과 같이 충분한 데이터를 얻기 힘든 경우에는 MAP, MLP와 같은 모수 (parametric) 방법이 오히려 더 낫다.

MAP는 패턴의 사후확률 $P(\omega_i|x)$ 을 최대로 하는 클래스 ω_i 로 패턴을 분류한다. 사전확률을 같다고 가정하

면 클래스 조건부 확률 밀도를 최대로 하는 클래스를 선택하는 것과 같다. BCC 클래스와 NOR 클래스를 각각 ω_1 , ω_2 라고 할 때 MAP 결정 규칙은 다음과 같다.

$$\begin{cases} \omega_1, & \text{if } P(\mathbf{x}|\omega_1) \geq P(\mathbf{x}|\omega_2), \\ \omega_2, & \text{otherwise.} \end{cases} \quad (6)$$

본 실험에서는 클래스의 조건부 확률을 다변수 가우시안 확률밀도함수 (multivariate Gaussian probability function)로 모델링을 하였다. 그리하여 평균벡터 μ 와 공분산 행렬 Σ 을 Maximum likelihood 방법으로 추정하였다. n_i 를 클래스 ω_i 의 데이터 개수라고 하면 이 때 결정규칙은 다음과 같이 판별함수 $g_i(\mathbf{x})$ 로 표현된다.

Decide ω_1 if $g_1(\mathbf{x}) \geq g_2(\mathbf{x})$, where

$$g_i(\mathbf{x}) = -\frac{1}{2} \mathbf{x}^T \Sigma_i^{-1} \mathbf{x} + \Sigma_i^{-1} \mu_i^T \mathbf{x} + r_i, \quad (7)$$

$$r_i = -\frac{1}{2} \mu_i^T \Sigma_i^{-1} \mu_i - \frac{1}{2} \ln |\Sigma_i^{-1}|, \quad (8)$$

$$\mu_i = \frac{1}{n_i} \sum_{k=1}^{n_i} \mathbf{x}_k, \quad (9)$$

$$\Sigma_i = \frac{1}{n_i} \sum_{k=1}^{n_i} (\mathbf{x}_k - \mu)(\mathbf{x}_k - \mu)^T. \quad (10)$$

모호한 패턴 클래스를 도입하기 위해 ω_3 를 모호한 클래스, θ_M 을 경계값이라고 하면 본 연구에서는 모호한 클래스를 도입하기 위해 MAP 결정 규칙을 다음과 같이 수정하였다.

$$\begin{cases} \omega_1, & \text{if } g_1(\mathbf{x}) - g_2(\mathbf{x}) \geq \theta_M, \\ \omega_2, & \text{if } g_2(\mathbf{x}) - g_1(\mathbf{x}) \geq \theta_M, \\ \omega_3, & \text{otherwise.} \end{cases} \quad (11)$$

MSE는 훈련 단계에서 여러 계곱의 합을 최소화해야 하는데 이 문제는 잘 알려져 있다. \mathbf{y} 가 훈련 벡터일 때 \mathbf{y}_a 를 $[1, \mathbf{y}^T]^T$ 가 되는 확장 훈련 벡터 (augmented training vector)로 정의하면 \mathbf{y}_a 가 열벡터인 행렬 \mathbf{Y} 의 의사역행렬 (psedoinverse) \mathbf{Y}^+ 을 구함으로써 이 문제를 해결할 수 있다. 결정 초평면 (hyperplane)에 수직인 벡터 \mathbf{w}_a 를 얻었다면 입력 패턴 \mathbf{x} 는 확장 벡터 \mathbf{y}_a 와 \mathbf{w}_a 의 내적 부호에 따라 분류될 수 있다.

본 연구에서는 모호한 패턴 클래스를 도입하기 위하여 내적 대신에 테스트 패턴에서 결정 초평면까지의 최

소 거리를 계산한다. \mathbf{x} 에서 결정 초평면까지의 최소 거리를 d_x , σ 를 임의의 작은 양수 그리고 θ_L 을 경계값이라고 하자. NOR 클래스의 확장 훈련 벡터 부호를 미리 정규화하였다고 가정하고 본 연구에서는 MSE 알고리듬은 다음과 같이 수정하였다.

$$\mathbf{w}_a = \sigma(\mathbf{Y}^T \mathbf{Y})^{-1} \mathbf{Y}^T \mathbf{I} = \sigma \mathbf{Y}^+ \mathbf{I}, \quad (12)$$

$$d_x = \frac{\mathbf{w}_a^T \mathbf{x}_a}{\|\mathbf{w}\|}, \quad (13)$$

$$\begin{cases} \omega_1, & \text{if } d_x > +\theta_L, \\ \omega_2, & \text{if } d_x < -\theta_L, \\ \omega_3, & \text{otherwise.} \end{cases} \quad (14)$$

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 활성 함수를 $f()$ 라고 할 때 MLP의 은닉층에 대한 입력 net_k 와 은닉층의 출력 $o_k = f(net_k)$ 는 다음과 같이 표현된다^[9].

$$net_k = \sum_i \omega_{ik} o_i + bias_k, \quad (15)$$

$$f(net_k) = \frac{2}{1 + \exp(-2net_k)} - 1. \quad (16)$$

MLP는 한 개의 출력 유닛을 사용하여 두 개의 클래스로 구분할 수 있다. 이 실험에서는 5개의 유닛으로 은닉층을 구성하고 하나의 유닛으로 출력을 구성하였다. NOR 클래스에 대해 -1, BCC 클래스에 대해 +1이 출력되도록 오류 역전파(Error Back Propagation) 알고리듬을 이용하여 훈련하였다. MLP의 출력값이 z , θ_N 을 경계값이라고 하면 본 연구에서는 MLP에 모호한 패턴 클래스를 도입하기 위하여 결정 규칙을 다음과 같이 수정하였다.

$$\begin{cases} \omega_1, & \text{if } z > +\theta_N, \\ \omega_2, & \text{if } z < -\theta_N, \\ \omega_3, & \text{otherwise.} \end{cases} \quad (17)$$

MLP는 초기값에 따라 그 성능이 달라지므로 본 연구에서는 실험을 20회 수행하고 그 결과를 평균하여 제시하였다.

그림 3은 BCC, NOR과 모호한 클래스의 특징 벡터 분포를 나타낸다. x 축과 y 축은 첫 번째와 두 번째 주

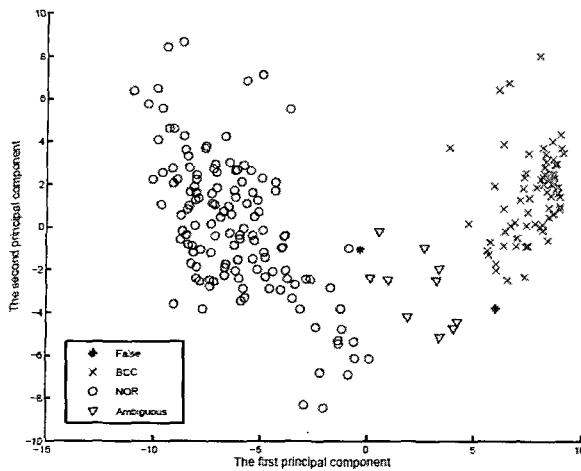


그림 3. MAP 분류기에 의한 BCC, NOR과 모호한 패턴의 분포

Fig. 3. The distribution of BCC, NOR and ambiguous patterns with MAP classifier.

성분에 대응된다. 그림은 모호한 데이터들이 결정 경계의 근처에 있는 것을 분명하게 보여준다. 이 모호한 패턴 클래스의 도움으로 BCC와 NOR의 입력 특징 벡터들이 잘 구분되었다. 그러므로 모호한 패턴 클래스를 도입한 분류기들이 향상된 성능을 기대할 수 있다.

2. 실험 결과

표 1에는 모호한 패턴 클래스를 적용하지 않았을 경우에 대한 분류 결과를 요약하였다. 표에서 평균 민감도 (sensitivity)가 약 95.8%이고 평균 특이도 (specificity)가 약 96.5%이다. 두 개의 주성분만으로도 아주 좋은 분류 결과를 보여준다. 따라서 공초점 라만 스펙트럼이 BCC와 NOR을 구별할 수 있는 특징을 가지고 있다는 사실을 확인할 수 있다.

표 2에 모호한 패턴 클래스를 적용한 경우에 대한 실험 결과를 요약하였다. 이 때 사용한 경계값 θ 는 각각 0.75,

표 1. 모호한 패턴 클래스를 적용하지 않았을 경우에 대한 분류 결과 (*는 전문 병리학자의 결정임)
Table 1. Classification results without ambiguous pattern class. Stars indicate the decision of an expert pathologist.

분류기	BCC*		NOR*	
	BCC	NOR	BCC	NOR
MAP	96.1	3.9	3.6	96.4
MSE	96.1	3.9	3.6	96.4
MLP	95.3	4.7	3.3	96.7

표 2. 모호한 클래스를 적용한 경우에 대한 분류 결과 (*는 전문 병리학자의 결정임)

Table 2. Classification results with ambiguous pattern class. Stars indicate the decision of an expert pathologist.

분류기	BCC*		NOR*	
	BCC	NOR	BCC	NOR
RCE	100	0	3.3	96.7
MAP	96.8	3.2	0.9	99.1
MSE	100	0	0	100
MLP	100	0	1.6	98.4

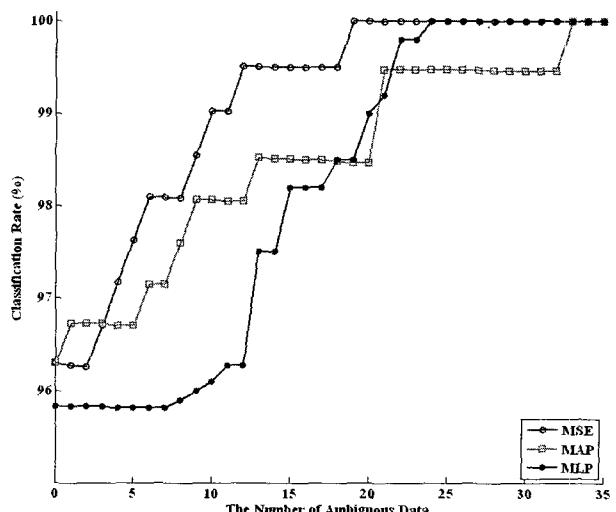


그림 4. 모호한 데이터가 증가함에 따른 MSE, MAP와 MLP의 분류 결과

Fig. 4. Classification results of MSE, MAP and MLP with the number of ambiguous data increasing.

8.7, 3.4, 0.89이다. 모호한 클래스로 분류되는 패턴의 수는 테스트 패턴의 10%를 넘지 않도록 조절하였다. 결과에 따르면 평균 민감도 약 99.2%이고 평균 특이도가 약 98.6%이다. 여기에서 MSE가 BCC와 NOR을 완벽하게 분류하는 가장 좋은 결과를 보였다. 이 때 모호한 데이터의 비율은 테스트 패턴의 약 8.8%였다.

그림 3에서 이 실험에서의 모호한 데이터의 비율을 추정할 수 있다. 그림에서 패턴을 약간의 마진 (margin)으로 선형 분리할 수 있고 이 결정 경계의 부근에서 몇 개의 패턴이 검출되었다. 다른 분류 방법들 또한 약간의 모호한 데이터를 더 허용한다면 완벽한 분류율을 보일 수 있다.

그림 4는 모호한 데이터가 증가함에 따른 MSE, MAP와 MLP의 분류율을 나타낸다. 이 결과에 의하면 MAP는 테스트 패턴은 모호하게 분류된 데이터가 테스트

특징의 15.3%일 때 MLP는 11.1%일 때 완벽하게 분류된다. MSE와 비교하면 MAP와 MLP는 비선형 결정 경계로 분류되기 때문에 완벽한 분류에 더 많은 모호한 데이터를 필요로 한다.

IV. 결 론

본 논문에서는 모호한 패턴 클래스를 도입하여 이전의 연구보다 분류기의 성능을 향상시키는 방법을 조사하였다. 세 가지 유형의 분류기 MAP, MSE와 MLP에 모호한 패턴 클래스를 적용하기 위해 각각의 알고리듬을 수정하고 RCE와 비교하였다. 이 실험에서 모호한 데이터의 수를 증가시킴으로써 분류 오류율을 감소시킬 수 있다는 것을 확인하였다. 실험 결과에 따르면 모호한 데이터의 수를 적절하게 허용하면 완벽한 분류가 가능하다. MSE의 경우는 약 8.8%의 데이터를 모호한 클래스로 판정함으로써 나머지 데이터를 완벽하게 분류할 수 있었다.

참 고 문 헌

- [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, 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] 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.
- [4] L. O. Nunes, A. A. Martin, L. Silveira Jr, M. Zampieri, E. Munin, "Biochemical Changes between Normal and BCC Tissue: a FT-Raman study," *Proceedings of the SPIE*, vol. 4955, pp. 546-553, July 2003.
- [5] S.-J. Baek, A. Park, J.-Y. Kim, S.Y. Na, Y. Won, and J. Choo, "Detection of Basal Cell Carcinoma by Automatic Classification of Confocal Raman Spectra," *LNBI* 4115, Aug. 2006.
- [6] S.-J. Baek, and A. Park, "Basal Cell Carcinoma Detection by Classification of Confocal Raman Spectra," *LNCIS* 345, pp. 735-740, Aug. 2006.
- [7] R. O. Duda, P. E. Hart and D. G. Stork, *Pattern Classification*, Jone Wiley & Son, Inc. 2001.
- [8] M. Gniadecka, H. Wulf, N. Mortensen, 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.

저자소개



박 아 론(학생회원)
 2006년 전남대학교 전자컴퓨터
 정보통신공학부 학사
 2006년~현재 전남대학교 전자
 공학과 석사과정
 <주관심분야 : 디지털 신호처리,
 패턴인식>



송 민 규(학생회원)
 2004년 전남대학교 정보통신
 공학부 학사
 2006년 전남대학교 전자공학과
 석사
 2006년~현재 전남대학교
 전자공학과 박사과정
 <주관심분야 : 디지털 신호처리, 영상 및 음성 신
 호처리>



백 성 준(평생회원)
 1989년 서울대학교 전자공학과
 학사
 1992년 서울대학교 전자공학과
 석사
 1999년 서울대학교 전자공학과
 박사
 2002년~현재 전남대학교 전자컴퓨터공학부 교수
 <주관심분야 : 디지털 신호처리, 의료 통신 음성
 관련 신호처리>



나 승 유(평생회원)
 1977년 서울대학교 전자공학과
 학사
 1984년 University of Iowa
 전자및컴퓨터공학 석사
 1986년 University of Iowa
 전자및컴퓨터공학 박사
 1987년~현재 전남대학교 전자컴퓨터공학부 교수
 <주관심분야 : 지능제어 및 계측, 신호처리>



정 인 육(학생회원)
 2002년~현재 전남대학교 전자
 컴퓨터공학부 학부과정
 <주관심분야 : 디지털 신호처리,
 음성처리>