

계층적 트리 구조를 이용한 라만스펙트럼 판별 성능 개선

박준규¹, 백성준^{1*}, 서유경¹, 서성일²

¹전남대학교 전자컴퓨터공학부, ²호남대학교 전자공학과

Improvement in the classification performance of Raman spectra using a hierarchical tree structure

Jun-Kyu Park^{1*}, Sung-June Baek^{1*}, Yu-Gyeong Seo¹, Sung-Il Seo²

¹School of Electronics and Computer Engineering, Chonnam National University

²School of Electronics Engineering, Honam University

요약 본 논문에서는 라만스펙트럼의 효과적인 판별을 위해 계층 트리 구조로 클래스를 그룹화 하는 방식을 제안하였다. 실험데이터로는 28종 화학물질의 라만 스펙트럼을 준비하였고 잡음제거, 정규화 등의 전처리 수행하였다. 다음으로 사전 실험을 통해 서로 간에 분류오류를 발생시키는 물질들을 그룹화 하여 계층 구조의 클래스를 구성하였고, 각각의 상위, 하위 클래스에 PCA(principal component analysis) 특징추출과 MAP(maximum a posteriori probability) 방식의 분류실험을 수행하였다. 실험 결과에 의하면 계층 구조의 클래스를 적용한 경우 평균 2.7개의 특징을 사용하여 분류가 100% 이루어짐을 확인할 수 있었다. 계층 구조를 적용하지 않는 기존의 방식에서 6개의 특징을 사용할 때 동일한 분류결과를 보였음을 감안해 보면, 제안한 방식이 전체 계산 복잡도의 측면에서 훨씬 뛰어난 것을 알 수 있다. 따라서 제안한 방식이 실제 응용에 보다 적합하다고 할 수 있다.

Abstract This paper proposes a method in which classes are grouped as a hierarchical tree structure for the effective classification of the Raman spectra. As experimental data, the Raman spectra of 28 chemical compounds were obtained, and pre-treated with noise removal and normalization. The spectra that induced a classification error were grouped into the same class and the hierarchical structure class was composed. Each high and low class was classified using a PCA-MAP method. According to the experimental results, the classification of 100% was achieved with 2.7 features on average when the proposed method was applied. Considering that the same classification rates were achieved with 6 features using the conventional method, the proposed method was found to be much better than the conventional one in terms of the total computational complexity and practical application.

Key Words : Hierarchy tree structure classes, Pattern classification, Raman spectrum

1. 서론

현재 라만 분광법은 다양한 장점에 근거하여 여러 응용분야에서 적용되고 있다. 기존에는 대표적으로 인지증판별, 기저세포암 검출 등과 같은 의료분야에서 다양하게 적용되어왔는데[1,2], 이는 비파괴적으로 조직의 분자구조의 정보를 알 수 있다는 장점에서 기인한다. 또한 라

만분광법은 미량의 물질로도 정보를 알 수 있고, 샘플의 원거리 측정이 용이하며 유리나 플라스틱 병과 같은 밀폐된 용기 안에 있는 물질을 검출할 수 있기 때문에[3], 이를 이용하여 오염물질, 불법약물, 대기로 배출되는 신경가스에 대한 감지 또는 폭발물에 대응하기 위한 탐지 기술들이 요구되고 있는 실정이다[4,5]. 이와 관련하여 라만 분광법을 폭발성 화학물질의 판별에 적용한 연구 결

이 논문은 2011년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. 2011-0009213)

*Corresponding Author : Sung-June Baek(Chonnam National Univ.)

Tel: +82-62-530-1795 email: tozero@chonnam.ac.kr

Received April 22, 2014

Revised June 27, 2014

Accepted August 7, 2014

과가 최근 발표되었다[6]. 위 연구사례에서는 총 14종의 화약물질들을 고려하였고, 주성분분석(principal component analysis) 특징추출방식과 최대사후확률(maximum *a posteriori* probability)분류 방식을 이용하여 약 99.3%의 인식성능을 보여주었다. 이와 같은 선행 연구 결과를 토대로 본 연구에서는 28종의 화약물질 라만 스펙트럼에 대한 판별 연구를 수행하였다.

일반적으로 패턴인식에서는 고려하는 클래스의 수가 늘어날수록 전체 클래스를 모델링하는 비용이 늘어나며 전체 인식률은 떨어지기 마련이다. 본 연구에서 고려하였던 28종 화약물질의 판별 역시 이것으로부터 자유롭지 못했다. 더구나 기존의 특징추출 방식에서는 클래스 전체를 한 번에 모델링하고 있으므로 고려하는 클래스의 수가 늘어난다면 각 클래스를 대표하는 변별력 있는 특징벡터를 추출하는 것이 훨씬 어려워진다. 이 문제를 해결하고자 본 연구에서는 28종의 클래스를 계층 트리 구조로 그룹화 시키는 방법을 제안하였다. 이는 서로 간에 분류오류가 발생하는 클래스들을 모아 그룹화한 후 그룹화 된 새로운 상위 클래스들에 대해 1차 분류를 수행하고, 각 상위 클래스안의 하위 클래스들을 2차 분류하는 방식이다.

이를 위해 먼저 28종의 화약 물질 라만 스펙트럼에 평활화한 미분방식(smoothed derivative method)을 적용하여 배경잡음을 제거하였고, 정규화 과정을 거쳐 전치리를 수행하였다. 다음으로 대표적인 차원축소 및 특징추출방식인 주성분분석을 이용하여 전체 스펙트럼에 대한 특징벡터를 추출하고, 최대사후확률 방식을 이용하여 분류실험을 수행하였다. 이를 토대로 서로 간에 분류오류를 발생시키는 클래스들을 분석하였고, 이들을 그룹화하여 상위 클래스들을 구축한 후 주성분분석-최대사후확률방식을 적용하여 1차 분류를 행한 다음, 각 상위 클래스안의 하위 클래스들을 다시 2차 분류하는 방식을 취했다.

실험 결과 평균 약 2.7개의 특징벡터를 가지고 전체 화약 물질이 완전하게 모델링 되는 것을 확인할 수 있었다. 이를 통해 동일 조건의 계층적인 그룹화 없이 모델링하였던 이전 분류방식보다 특징벡터의 개수 대비 개선된 인식 성능을 얻을 수 있었으며, 인식을 대비 분류에 사용하는 특징벡터의 수를 줄임으로서 전체 계산량을 줄일 수 있음을 확인하였다.

2. 연구방법

2.1 화학 물질 라만 스펙트럼

실험에 사용된 화학 물질은 폭발성으로 총 28종을 순도의 분말로 준비하였다. 이들 화약물질의 IUPAC (International Union of Pure and Applied Chemistry) 이름과 축약된 이름을 Table 1에 나타내었다.

[Table 1] IUPAC and abbreviated name

Compound (IUPAC name)	Abbreviation
2-methyl-1,3,5-trinitrobenzene	TNT
Octahydro-1,3,5,7-tetranitro-1,3,5,7-tetrazocine	HMX
1,3,5-trinitroperhydro-1,3,5-triazine	RDX
[3-Nitrooxy-2,2-bis(nitrooxymethyl)propyl]nitrate	PETN
N-methyl-N,2,4,6-tetranitroaniline	Tetryl
Ammonium nitrate	AN
2,4,6,8,10,12-hexanitro-2,4,6,8,10,12-hexaazaisowurtzitane	HNIW
5-nitro-1,2-dihydro-1,2,4-triazole-3-one	NTO
1-nitroguanidine	NQ
Ammonium dinitramide	ADN
Ammonium perchlorate	AP
2,3-dimethyl-2,3-dinitrobutane	DMDNB
2-Amino-4,6-dinitrotoluene	2-ADNT
4-Amino-2,6-dinitrotoluene	4-ADNT
Diethylene glycol dinitrate	DEGDN
2,2,4,4,6,6-Hexanitrostill-bene	HNS
Trimethylolethane trinitrate	TMETN
composition c4	C4
Hexamethylene triperoxide diamine	HMTD
Picric acid	PA
2,6-Dinitrotoluene	2,6-DNT
3,4-Dinitrotoluene	3,4-DNT
3,5-Dinitrotoluene	3,5-DNT
2,4,6-Triaminotoluene trihydrochloride	2,4,6-TATC
Butane triol trinitrate	BTTN
1,2-Dinitrobenzene	1,2-DNB
1,3-Dinitrobenzene	1,3DNB
1,3,5-Trinitrobenzene	TNB

물질의 측정에는 Renishaw 2000 Raman microscope system (Renishaw plc, Wotton-under-Edge, UK)가 사용되었다. 28종의 화약물질 중 18종인 TNT, HMX, RDX, PETN, AN, HNIW, NTO, NQ, ADN, AP,

DMDNB, 1,2-DNB, 1,3-DNB, 2,6-DNT, 3,4-DNT, 3,5-DNT, HMTD, PA는 여기원(excitation source)으로 Spectra Physics사의 argon ion laser($\lambda = 514.5nm$)를 사용하여 측정하였으며, 나머지 10종인 Tetryl, TMETN, TNB, BTTN, C4, DEGDN, HNS, 2,4,6-TATC, 2-ADNT, 4-ADNT는 Spectra Physics사의 He-Ne laser($\lambda = 633nm$)를 여기원으로 측정하였다. 이때 레이저 전력은 1.0mW 보다 작게 유지하였다. 측정범위는 200–3500 cm^{-1} 이며 라만 산란은 4 cm^{-1} 스펙트럼 해상도의 CCD(charge-coupled device) 카메라를 통해 수집되었다. 28종 화약물질은 측정시료를 각각 서로 다른 위치(spot)에서 50회씩 측정하였다.

2.2 전처리

측정된 폭발물질 라만 스펙트럼은 데이터의 처리에 불필요한 배경 잡음 및 가산 잡음을 가지고 있기 때문에 이러한 잡음을 효과적으로 처리하여야 한다. 실험에서는 가산 잡음을 처리하기 위해 일반 지역 통과 필터보다 피크를 더 잘 보존하는 것으로 알려진 Savitzky-Golay 필터를 이용하여 평활화(smoothing) 하였다[7].

$$y[i] = \sum_{k=-N}^N a_k x[i-k] \quad (1)$$

여기서 $y[i]$ 는 $x[i]$ 에서 가산잡음을 제거한 신호이며, a_k 는 Savitzky-Golay 필터 계수이다. 본 연구에서는 필터 차수 N 에 30을 이용 하였다.

라만 스펙트럼은 가산 잡음 외에도 자가 형광과 낮은 신호 대 잡음비에 의한 배경 잡음이 발생한다[8]. 이러한 배경 잡음은 분류 성능에 직결 되는 문제이므로 효과 적인 제거 방식이 필요하다. 배경잡음 제거에는 본 논문에서 기존에 제안한 평활화한 미분방식을 적용하였다. 배경잡음 제거에 사용한 평활화한 미분방식은 피크검출과 평활화 및 보간법을 기반으로 한다. 이 방법은 전체 영역에서 완만한 변화를 보이는 배경잡음의 특성을 이용하여 측정된 스펙트럼의 미분값을 이용하여 중요한 피크를 찾아 그에 상응하는 피크영역을 잘라낸 후 선형 보간 방법과 적분을 통해 배경 잡음을 제거한다[9].

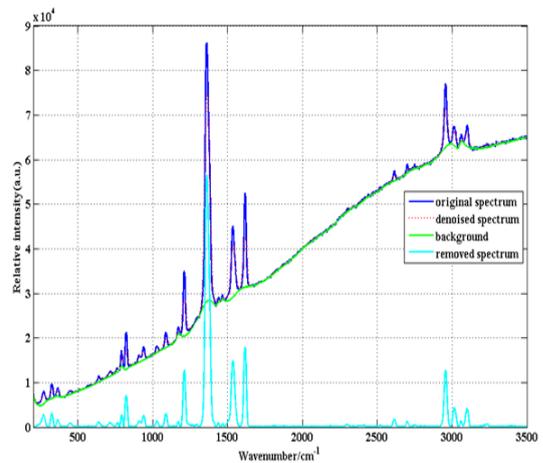
평활화한 미분방식을 통해 배경 잡음을 제거한 스펙트럼을 Fig. 1에 나타내었다.

배경잡음을 제거한 스펙트럼은 측정된 스펙트럼들 사

이의 편차를 최소화하기 위해 각 스펙트럼의 놈(norm)이 1이 되도록 정규화 하였다. X 를 측정된 스펙트럼이라고 하면 정규화된 스펙트럼 \hat{X} 는 다음과 같이 얻을 수 있다.

$$\hat{X} = \frac{X}{\|X\|} = \frac{X}{\sqrt{x_1^2 + \dots + x_N^2}} \quad (2)$$

이때 N 은 라만 스펙트럼을 측정된 Raman Shift의 개수이고, $X = [x_1, x_2, \dots, x_N]^T$ 는 그 점에서 측정된 스펙트럼의 크기이다.



[Fig. 1] Original and background eliminated spectrum.

3. 분류방법

3.1 주성분분석 특징 추출

주성분분석은 데이터의 차원을 감소시키기 위해 사용되는 통계적 차원축소 기법의 일종으로 사영들이 서로 상관관계가 없다는 사실을 근거하여 그 직교성을 식별한다. 주성분분석의 기저벡터는 식 (3)으로 주어진 scatter matrix의 고유벡터(eigenvector)들로 정의 된다 [10].

$$S_T = \sum_k (g_k - \mu)(g_k - \mu)^T \quad (3)$$

이 때 g_k 는 입력 패턴이고 μ 는 g_k 의 평균이다. 고유값의 내림차순 대각행렬을 D 라 하고 고유값에 대응하

[Table 2] Confusion matrix of a class containing 11 material

Tag Test	2,6-DNT	ADN	NTO	TNT	1,2-DNB	1,3-DNB	3,4-DNT	3,5-DNT	2-A-DNT	HNS	TNB
2,6-DNT	44	0	4	0	0	0	0	0	0	2	0
ADN	0	46	0	0	0	0	0	0	0	4	0
NTO	3	0	44	0	0	0	0	0	0	3	0
TNT	0	0	1	47	0	0	0	0	0	0	2
1,2-DNB	0	0	0	0	37	0	0	11	0	0	2
1,3-DNB	0	0	0	0	0	50	0	0	0	0	0
3,4-DNT	0	0	0	0	0	0	48	0	0	0	2
3,5-DNT	0	0	0	0	4	0	0	41	5	0	0
2A-DNT	0	0	0	0	0	0	0	6	44	0	0
HNS	1	3	0	0	0	0	0	0	0	44	2
TNB	0	0	0	0	0	0	3	0	0	4	43

는 고유벡터로 행이 구성된 직교행렬을 E 라고하면 주 요성분 Z_k 는 다음과 같이 얻을 수 있다.

$$S_T = EDE^T \quad (4)$$

$$Z_k = E^T x_k \quad (5)$$

3.2 최대사후확률 분류방식

최대사후확률은 확률분포가 모수로 표현되는 형태로 사전확률이 같다고 가정하여 클래스 조건부 확률 밀도를 최대로 하는 클래스를 선택하는 방식이다. 결국 최대사 후확률 방식에서는 데이터의 사후확률 $P(\omega_i|X)$ 을 최대 로 하는 클래스 ω_i 로 데이터를 분류한다. 본 실험에서는 클래스의 조건부 확률을 다변량 가우시안 확률밀도함수 (multivariate Gaussian probability function)로 모델링을 하였다. 이때 평균벡터 μ 와 공분산 행렬 Σ 는 최대우도 (maximum likelihood) 방법으로 추정하였다. n_i 를 클레 스 ω_i 의 데이터 수라고 하면, 최대사후확률방식의 결정 규칙은 다음과 같은 판별함수 $g_i(x)$ 로 표현할 수 있다 [11].

$$g_i(x) = -\frac{1}{2} X^T \sum_i X + \sum_i \mu_i X + r_i \quad (6)$$

$$r_i = -\frac{1}{2} \mu_i^T \sum_i \mu_i - \frac{1}{2} \ln \left| \sum_i \right| \quad (7)$$

3.3 계층 트리 구조의 그룹화

본 연구에서는 28종의 화약물질을 계층 트리 구조로 그룹화하기 위해 전체 클래스를 주성분 분석으로 모델링 한 후 최대사후확률 분류를 이용하여 서로 간에 분류오

류를 발생시키는 유사 클래스들을 선별 하였다. 기존 방 식의 주성분 특징 선택에서는 화약물질들 간의 분산을 가장 크게 만드는 주성분을 특징벡터로 고려한다.

하지만 계층 구조의 그룹화를 위한 PCA 특징벡터의 선택에서는 유사 클래스 간에 군집을 이루며, 동시에 다 른 군집과는 큰 변별력을 지닌 새로운 주성분을 필요로 한다. 이를 위해 사전 실험에서 최적의 주성분을 찾기 위 해 제한적인 완전탐색(exhaustive search)을 수행하였으 며 그 결과 2개의 주성분, 즉 2번과 14번을 선택하여 분 류실험을 수행하였다. 분류실험의 결과 전체 클래스들 중에 서로 간에 제한적으로 분류오류를 발생시키는 클레 스들을 그룹화 하여 선별 하였으며, 총 여섯 그룹의 confusion matrix를 Table 2-5에 나타내었다.

[Table 3] Confusion matrices of 4 class explosive compounds.

Tag Test	DMDNB	HMX	RDY	C-4
DMDNB	50	0	0	0
HMX	0	44	0	6
RDY	0	0	36	14
C-4	0	6	17	27

Tag Test	PETN	BTTN	DEGDN	TMETN
PETN	49	0	1	0
BTTN	0	49	1	0
DEGDN	2	0	48	0
TMETN	0	0	0	50

[Table 4] Confusion matrix of 3 class explosive compounds.

Tag Test	HNIW	NQ	HMTD
HNIW	49	1	0
NQ	8	41	1
HMTD	0	1	49

[Table 5] Confusion matrix of two classes containing 2 material

Test \ Tag		AN	AP
		49	2
Test \ Tag		4-A-DNT	Tetryl
		1	49

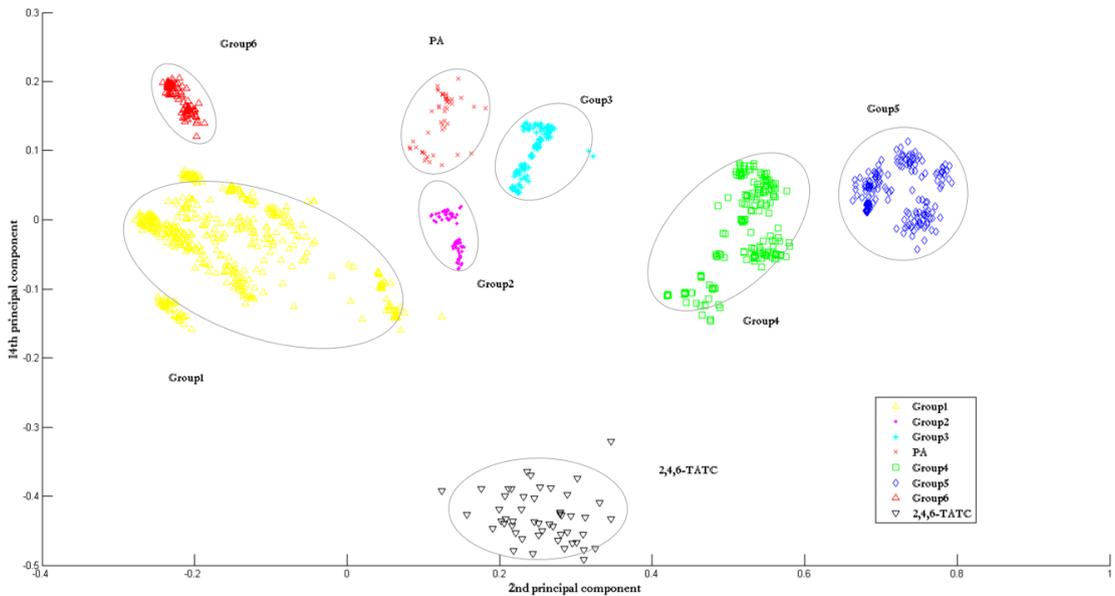
Table 2-5의 confusion matrix를 보면 각 그룹 내에 제한하여 서로 간에 분류오류가 발생되고 있음을 알 수 있다. 이를 바탕으로 각각 11, 4, 4, 3, 2, 2개의 화약물질을 하위클래스로 포함하는 총 6개의 상위클래스를 구성하였다. 이들 외에 나머지 2종의 화약물질인 2,4,6-TATC와 PA는 다른 화약물질들과의 분류오류가 없으므로 독자적으로 각각 1개의 클래스를 구성하도록 하였다. 다음으로 위의 6개의 상위 클래스 그룹과 2종의 화약물질에 대한 2차원의 주성분 분포를 Fig. 2에 나타내었다. Fig. 2의 분포를 보면 8개의 상위 클래스가 각각 군집을 이루며 다른 클래스들과는 서로 구분되는 뚜렷한 분포를 보이고 있으며, 이 경우 완전한 분류가 가능함을 직관적으로도 알 수 있다.

4. 실험결과

실험에서는 전체 데이터의 80%를 훈련 그룹으로 20%를 실험 그룹으로 나누었고, 실험방식으로 K-fold cross validation을 수행 하였다. 분류 실험이 1회 끝나면 실험 그룹의 샘플들은 훈련 그룹으로 이동시켰고, 동시에 훈련 그룹의 샘플을 무작위 추출하여 실험 그룹으로 이동시켰다. 이와 같은 방법으로 각각의 분류방식에서 총 5회의 실험을 수행하였으며 이를 평균한 값을 인식결과로 삼았다. 훈련그룹의 수는 1120개이며 실험그룹의 수는 280개이다.

실험은 제안한 방식과 기존 방식 두 가지로 나누어 진행하였다. 먼저 기존 방식에서는 28종의 클래스를 한 번에 모델링 하여 분류하였다. 이에 반해 제안한 방식에서는 먼저 28종의 클래스를 8개의 상위 클래스로 그룹화하고 이들을 1차 분류한 후 다시 각 그룹들에 속한 하위 클래스로 재분류하였다.

먼저 그룹화 없는 기존의 방식에 의한 주성분분석-최대사후확률을 적용한 분류결과와 그에 따르는 계산비용인 특징벡터의 수를 Table 6에 요약하였다.



[Fig. 2] 2nd and 14th principal component distribution of top level classes in hierarchical tree.

[Table 6] MAP classification results with the number of principal component combinations in the conventional method

The number of principal components	1	2	3	4	5	6
principal components combination	1	1, 9	2, 3, 17	3, 6, 14, 18	4, 6, 9, 14, 16	4, 6, 7, 9, 14, 16
classification result (%)	60.36	94.93	99.29	99.79	99.93	100
The number of features	28	56	84	112	140	168

Table 6을 살펴보면 전체 클래스를 모델링하는 주성분의 개수가 늘어날수록 그에 따른 인식률은 증가하고 있으나 그 증가율이 점차 미약해지고 있음을 알 수 있다. 단적인 예로 주성분 개수 5와 6의 인식률을 비교해 보면 0.07%의 향상을 위해 주성분의 수 하나가 더 필요한 상황이다. 주성분이 하나가 늘어남에 따라 분류에 사용되는 특징벡터 계산이 각 화학 물질의 개수만큼 28회 늘어나게 되는데, 이는 결국 전체 시스템의 응답 속도를 떨어뜨리게 된다. 따라서 실시간 응용을 위해서는 분류하려는 클래스가 많을 지라도 분류에 필요한 특징 벡터의 수를 줄이는 것이 중요한 문제가 된다.

다음으로 제안한 계층 구조의 클래스를 최대사후확률 방식으로 분류 결과와 분류에 필요한 특징벡터의 수, 각 그룹별 주성분의 상세를 Table 7에 요약하였다. Table 7의 실험결과에서는 6개의 상위 클래스 그룹과 그룹에 속하지 않은 두 가지 물질인 2,4,6-TATC와 PA를 1차 분류한 결과 2개의 주성분으로 100%의 인식률을 보임을 확인하였다. 다음으로 2차 분류에서는 그룹별로 구성된 화학 물질의 개수와 그룹 구성이 다르므로 각기 재분석을 통해 서로 다른 주성분을 얻었다. 2차 분류 역시 모든 그룹에서 100%의 인식률을 보였으며 1차, 2차 분류를 위해 필요한 특징 벡터의 평균 개수는 약 2.7 개였다. 이는 계층적 그룹화를 적용하지 않은 기존의 방식에서 100% 분류를 위해 평균 6개의 특징 벡터수를 필요로 한 것과 비교하면 현저히 적은 비용으로 시스템의 전체 계산량을 줄일 수 있다는 것을 의미한다. 또한 기존의 방식에서 3개의 특징벡터를 사용할 때의 인식률이 99.29%임을 감안하면 제안한 방식이 약 2.7개의 평균벡터를 사용하여 약 0.7%의 개선된 인식률을 보이고 있음을 알 수 있다.

[Table 7] The total number of features and MAP classification results of the proposed method

		The number of classes	principal components combination	The number of features
1st classification		8	2,14	16
2nd classification	Group 1	11	2,3,5	33
	Group 2	2	1	2
	Group 3	3	1	3
	Group 4	4	3,4	8
	Group 5	4	1,3	8
	Group 6	2	2	4
The total number of feature vector for classification of 100%				74
The average number of feature vector for classification of 100%				2.65

5. 결론

본 논문에서는 다양한 클래스의 라만 스펙트럼의 분류에 계층적 트리구조의 클래스를 도입하여 효과적으로 인식하는 방식을 제안하였다.

연구에서 사용한 라만 스펙트럼은 먼저 전처리를 수행한 후 서로 간에 분류오류를 발생시키는 클래스들을 그룹화 하여 상위 클래스 그룹과 하위 클래스로 구성된 계층적인 트리 구조의 클래스 그룹을 구축하였고, 계층적인 분류 실험을 수행하였다. 실험 결과에 따르면 제안한 방식이 그룹화 없는 기존의 방식의 경우 보다 특징벡터의 개수 대비 약 0.7%의 개선된 인식 성능을 얻을 수 있었다. 또한 동일 인식률 대비 분류에 사용된 특징벡터의 수를 비교해보면 제안한 방법이 클래스 당 사용된 특징 벡터 수가 약 2.7개로 기존의 방법에 비해 현저히 계산량을 줄일 수 있음을 확인하였다. 이러한 결과를 종합해보면 제안한 방식이 기존의 그룹화 없는 방식에 비해 계산 효율적이며, 더 나은 인식성능을 보이고 있음을 확인할 수 있다. 따라서 이러한 결과는 필드에서 가능한 빠른 시간에 보다 정확한 판별을 요구하는 화학물질 판별 시스템에 유용하게 적용될 수 있다고 할 수 있다.

References

[1] A. Park, S.-J.Baek, "A Diagnosis Method of Basal Cell Carcinoma by Raman Spectra of Skin Tissue using NMF Algorithm", Journal of The Institute of Electronics Engineers of Korea Vol.50, no.8, pp.2124-2130, Aug. 2013. DOI: <http://dx.doi.org/10.5573/ieek.2013.50.8.196>

[2] A. Park, S.-J.Baek, "Feature Ranking for Detection of Neuro-degeneration and Vascular Dementia in micro-Raman spectra of Platelet", Journal of The Institute of Electronics Engineers of Korea Vol.48-CI, no.4, pp.399-404, July. 2011.

[3] E.L. Izak, "Forensic and homeland security applications of modern potable Raman spectroscopy." Forensic Sci. Int. Vol.202, issue 1-3, pp.1-8, Oct, 2010. DOI: <http://dx.doi.org/10.1016/j.forsciint.2010.03.020>

[4] J.S. Caygill, F. Davis, S.P.J. Higson, "Current trends in explosive detection techniques," Talanta, Vol.88, pp.14-29, 2012. DOI: <http://dx.doi.org/10.1016/j.talanta.2011.11.043>

[5] R.S. Golightly, W.E. Doering, M.J. Natan, "Surface-Enhanced Raman Spectroscopy and Homeland Security: A Perfect Match?," ACS nano, Vol.3, No.10, pp.2859-2869, 2009. DOI: <http://dx.doi.org/10.1021/nn9013583>

[6] Joonki Hwang, Namhyun Choi, "Fast and sensitive recognition of various explosive compounds using Raman spectroscopy and principal component analysis," J MOL STRUCT, Vol.1038, pp.130-136, April 2013. DOI: <http://dx.doi.org/10.1016/j.molstruc.2013.01.079>

[7] A. Savitzky and M. J. E. Golay, "Smoothing and Differentiation of Data by Simplified Least Squares Procedures," Analytical Chemistry, Vol. 36, pp.1627-1639, 1964. DOI: <http://dx.doi.org/10.1021/ac60214a047>

[8] Z. Jianhua, L. Harvey, M. David and Z. Haishan, "Automated Autofluorescence Background Subtraction Algorithm for Biomedical Raman Spectroscopy," Society for Applied Spectroscopy, Vol.61, pp.248A-270A, Nov. 2007.

[9] S.-J.Baek, A. Park, A. Shen and J. Hu, "A simple background delination method for Raman spectra," Chemometrics and Intelligent Laboratory Systems, Vol.98, issue.1, pp.24-30, Aug. 2009. DOI: <http://dx.doi.org/10.1016/j.chemolab.2009.04.007>

[10] I. T. Jolloffe, Principal Component Analysis 2nd Edition, Springer, 2002.

[11] R. O. Duda, P. E. Hart, and D. G. Stork, Pattern

Classification Second Edition, Jone Wiley & Son, Inc.2001.

박 준 규(Jun-Kyu Park)

[정회원]



- 2009년 2월 : 전남대학교 전자컴퓨터공학부(공학사)
- 2009년 3월 ~ 현재 : 전남대학교 전자공학과(석박사통합과정)

<관심분야>
디지털 신호처리, 패턴인식

백 성 준(Sung-June Baek)

[정회원]



- 1989년 2월 : 서울대학교 전자공학과(공학사)
- 1992년 2월 : 서울대학교 전자공학과(공학석사)
- 1999년 2월 : 서울대학교 전자공학과(공학박사)
- 2002년 3월 ~ 현재 : 전남대학교 전자공학과 교수

<관심분야>
의료, 통신, 음성관련 디지털 신호처리

서 유 경(Yu-Gyeong Seo)

[학생회원]



- 2014년 2월 : 전남대학교 전자컴퓨터공학부(공학사)
- 2014년 3월 ~ 현재 : 전남대학교 전자공학과(석사과정)

<관심분야>
디지털 신호처리, 패턴인식

서 성 일(Sung-Il Seo)

[정회원]



- 1900년 2월 : 연세대학교 전자공학과(공학사)
- 1992년 2월 : 서울대학교 전자공학과(공학석사)
- 2014년 2월 : 광운대학교 전자융합공학과(공학박사)
- 1992년 2월 ~ 2007년 7월 : (주)삼성전자 책임연구원
- 2007년 7월 ~ 2009년 3월 : 한국 소프트웨어 진흥원 수석연구원
- 2010년 8월 ~ 2013년 8월 : (주)인트로메딕 이사
- 2013년 9월 ~ 현재 : 호남대학교 전기공학과 교수

<관심분야>

디지털 통신시스템, 디지털 신호처리