

적응형 복합 분류 알고리즘을 이용한 초소형 전자소자 탐지 향상 기법

김 광 열*, 임 정 환*, 김 송 강*, 조 준 경*, 신 요 안°

Improved Detecting Schemes for Micro-Electronic Devices Based on Adaptive Hybrid Classification Algorithms

Kwangyul Kim*, Jeonghwan Lim*, Songkang Kim*, Junkyung Cho*, Yoan Shin°

요 약

본 논문은 지적재산권 보호를 위한 방안으로 적응형 알고리즘 기반의 초소형 전자소자 탐지 기법을 제안한다. 전자소자를 탐지하는 기본 원리는 분류기의 송신기에서 특정 기본 주파수의 전파가 은닉된 물체로 전파되면, 물체로부터 반사되어 수신기로 들어오는 2차 및 3차 고조파의 크기를 분류기가 비교함으로써 판별하게 된다. 하지만, 측정 과정에서 발생하는 잡음 및 전자파의 간섭으로 인해 분류의 성능이 저하되므로, 이러한 환경에서도 은닉된 전자소자를 적응적으로 판별하기 위해 Fuzzy c-Means 클러스터링 알고리즘과 *k*-Nearest Neighbor 분류 알고리즘을 복합적으로 이용하는 방안을 제시한다. 모의실험 결과, 제안 기법이 잡음 및 전자파 간섭 환경에서도 적응적으로 전자소자 잘 탐지할 수 있었으며, 이에 따라 지적재산권을 효율적으로 보호할 수 있을 것으로 기대된다.

Key Words : Concealed Micro-Electronic Devices, Harmonics, Detection, Classification, Decision Boundary, Fuzzy c-Means Clustering, *k*-Nearest Neighbor

ABSTRACT

This paper proposes improved detection schemes for concealed micro-electronic devices using clustering and classification of radio frequency harmonics in order to protect intellectual property rights. In general, if a radio wave with a specific fundamental frequency is propagated from the transmitter of a classifier to a concealed object, the second and the third harmonics will be returned as the radio wave is reflected. Using this principle, we exploit the fuzzy c-means clustering and the *k*-nearest neighbor classification for detecting diverse concealed objects. Simulation results indicate that the proposed scheme can detect electronic devices and metal devices in various learning environments by efficient classification. Thus, the proposed schemes can be utilized as an effective detection method for concealed micro-electronic device to protect intellectual property rights.

1. 서 론

최근 인터넷과 무선 이동통신의 혁신적인 발전으로

지식 기반의 IT (Information Technology) 사회가 도
 래함에 따라, 지적재산권을 비롯하여 기업에서의 주요
 기술에 대한 중요성이 점차 부각되고 있다. 이에 따라

※ 본 논문은 중소기업청에서 지원하는 2012년도 산학연공동기술개발사업(No. C0040119호)의 연구수행으로 인한 결과물임을 밝힙니다.

♦ 주저자 : 송실대학교 정보통신전자공학부 통신 및 정보처리 연구실, kky1117@ssu.ac.kr, 학생회원

° 교신저자 : 송실대학교 정보통신전자공학부 통신 및 정보처리 연구실, yashin@ssu.ac.kr, 종신회원

* (주)엘트로닉스 연구소, jkcho@eltronix.co.kr, jhlim@eltronix.co.kr, skkim@eltronix.co.kr

논문번호: KICS2013-03-149, 접수일자 : 2013년 3월 31일, 최종논문접수일자 : 2013년 6월 24일

전세계 국가 및 기업 연구소는 기술 개발에 대한 지적 재산권의 선점을 위한 경쟁에 박차를 가하고 있는 추세이며, 우리나라도 1986년 이후로 현재까지 지적재산권의 출원 건수가 해마다 증가하고 있다. 이러한 결과로 인해, 해마다 세계 각국의 국가 경쟁력을 평가하는 IMD (Institute for Management Development)의 2009년도 “세계경쟁력 보고서”에서 우리나라의 과학기술력을 세계 3위, 기술 경쟁력을 세계 14위로 보고한 바 있다¹⁾.

그러나 동일한 2009년 IMD의 “세계경쟁력 보고서”에서는 한국의 사이버 보안을 세계 38위로 보고하였으며, 세계경제포럼 (World Economic Forum)에서는 지적재산권 보호 정도를 세계 41위로 보고하였다¹⁾. 이것은 지적재산권의 중요성의 증대와 함께 우리나라의 기술 개발 수준이 점차 향상되었고 이에 따른 지적재산권의 건수는 증가하였지만, 기술 개발 성과에 대한 관리와 보호는 제대로 이루어지지 않고 있는 것으로 분석할 수 있다. 특히 휴대용 멀티미디어의 발달로 인해 대용량의 데이터를 메모리 스틱과 같은 초소형 저장 매체에 저장시킬 수 있어, 전자문서 형태로 된 산업기밀 문서들을 보다 손쉽게 외부로 유출시킬 수 있는 위험성이 증대되고 있다. 그리고 이러한 산업기밀 유출로 인한 기업의 경제력 피해가 증가하고 있기 때문에 이에 대한 보호 기술이 필요한 실정이다.

국외에서는 이미 이러한 기술의 중요성과 필요성을 인지하여 지적재산권 및 산업기밀 정보의 보호를 위한 전자소자 탐지기가 개발되었다²⁾. 이 탐지기의 기본 원리는, 송신기가 특정 기본 주파수 (Fundamental Frequency)를 갖는 전파를 송신하면 수신기는 은닉된 물체로부터 반송되어 들어오는 2차 및 3차 고조파 (Harmonics) 신호의 특성에 따라 판별하는 것이다. 이때, 2차 고조파가 3차 고조파보다 큰 경우 전자소자로 판별하며, 2차 고조파가 3차 고조파보다 작은 경우에는 금속류로 판별하게 된다. 하지만, 은닉 물체를 탐지하는 과정에서 잡음 및 전자파 간섭으로 인한 탐지오류 (Detection Error) 및 오경보 (False Alarm)가 발생할 수 있기 때문에, 이에 대한 해법이 필요하다.

따라서, 본 논문에서는 적응형 복합 분류 알고리즘 기반의 초소형 전자소자 탐지 기법을 제안한다. 이는, 잡음 및 전자파가 유입된 환경에서도 단순히 2차 및 3차 고조파를 이용하여 판별하기 때문에 이 과정에서 오류가 발생할 수 있는 기존 기법을 보완하기 위하여 적응형 알고리즘을 통해 원본 신호와 잡음 및 전자파 신호에 대한 클러스터를 적응적으로 생성하여 분류 성능을 높이고자 하는 것이다. 본 논문에서 적용되는

적응형 알고리즘은 FCM (Fuzzy c-Means) 클러스터링 알고리즘^{3,4)}과 k -최근접 이웃 (k -Nearest Neighbor; k -NN) 분류 알고리즘⁵⁻⁸⁾이다. 본 논문의 구성은 다음과 같다. II장에서는 기본적인 전자소자 탐지 모델 및 환경을 설명하고, III장에서는 적응형 알고리즘을 정리한다. IV장에서는 본 논문에서 제안하는 전자소자 탐지 기법을 설명하고, V장에서 모의실험을 통하여 제안 기법의 성능을 평가한 후, 마지막으로 VI장에서 결론을 내린다.

II. 전자소자 탐지 모델 및 환경

그림 1은 은닉된 초소형 전자소자를 탐지하기 위한 분류기 모델을 도시한 것이다. 일반적으로 분류기의 송신기에서 특정 기본 주파수 f_0 의 전파를 송신하면, 은닉된 물체로부터 반송되는 신호에는 기본 주파수의 n 배 주파수인 nf_0 ($n=2, 3, \dots$) 성분을 갖는 고조파들 (Harmonics)이 포함되어 분류기의 수신기로 들어온다. 이 고조파는 은닉된 물체에 따라 다양한 속성값 (Features)을 갖는데, 전자소자의 경우에는 일반적으로 2차 고조파의 크기가 3차 고조파 크기보다 더 큰 값을 가지며, 이와 반대 상황인 금속류 물체에 대해서는 3차 고조파의 크기가 2차 고조파의 크기보다 더 큰 값을 갖는다²⁾. 따라서, 본 연구에서는 은닉된 물체로부터 반송되어 수신되는 2차 및 3차 고조파를 속성값으로 설정하고 전자소자와 금속류를 판별하는 방법을 기본 기법으로 고려한다.

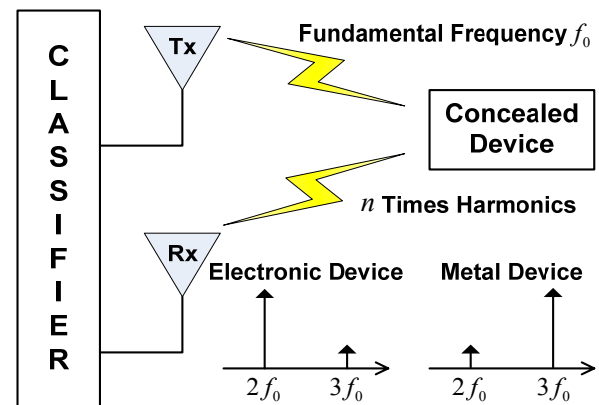


그림 1. 은닉된 전자소자를 탐지하기 위한 분류기 모델
Fig. 1. A model of concealed micro-electronic device classifier

그림 2는 전자소자 탐지기의 ADC (Analog-to-Digital Converter)에서 실측된 2차 및 3차 고조파의 크기를 도시한 것으로, 앞으로는 편의상 2차원 평면으로 변환하여 고려한다.




그림 2. 전자소자 탐지기의 ADC로부터 측정된 2차 및 3차 고조파 크기
 Fig. 2. Amplitude of the second and the third harmonics of concealed devices measured by the ADC in classifier

2.1. 대칭적인 학습 데이터 환경

그림 3은 분류기에서 측정된 2차 및 3차 고조파의 학습 데이터가 대칭적인 환경을 고려한 것이다. 여기서, 사각형 모양이 전자소자이고, 원모양이 금속류 클래스를 의미한다. 이 경우에는 학습 데이터가 대칭적인 환경이기 때문에 판별을 위한 기본 원리에 의해 판별 경계 (Decision Boundary; D/B)는 빨간색 점선과 같이 표현할 수 있다. 하지만, 대칭적인 D/B는 학습 데이터가 대칭적으로 위치해 있을 경우에만 정확한 판별이 가능하며, 학습 데이터가 비대칭적으로 위치해 있으면서 잡음 및 전자파 간섭이 높은 경우에는 효율적인 판별은 불가능해진다.




그림 3. 대칭적인 학습 데이터 환경에서의 D/B의 예
 Fig. 3. An example of symmetric learning data and the corresponding D/B

2.2. 비대칭적인 학습 데이터 환경

그림 4는 2차 고조파와 3차 고조파의 학습 데이터가 비대칭적인 환경을 고려한 것이다. 여기서, 빨간색 점선은 일반적인 판별 경계 (“Conventional D/B”)로, 비대칭적인 환경에서는 대다수의 은닉된 물체를 전자소자로 판별하게 되어 분류오율 (Classification Error Probability; CEP)이 커지게 된다는 것을 직관적으로도 알 수 있다. 따라서, 잡음 및 전자파 간섭으로 인해 악화되는 CEP 성능을 효율적으로 향상하기 위해서 전자소자와 금속류의 학습 데이터들의 평균값을 고려하여 파란색 실선의 향상된 판별 경계 (“Advanced D/B”)를 제안한다. “Advanced D/B”는 비대칭적인 학습 데이터 환경에서 발생할 수 있는 잡음 및 전자파 간섭에 의한 영향을 줄임으로써 CEP를 감소시킬 수 있을 것으로 예상된다.

하지만, 비대칭적인 학습 데이터 환경에서 D/B의 최적화를 위해서는 학습 데이터의 관점에서 대칭적인 D/B를 설정해야 한다. 따라서, 본 논문에서는 FCM을 이용한 D/B를 제안하였으며, 비대칭적인 학습 데이터들의 관점에서 대칭적인 D/B를 제공함으로써 대칭적인 학습 데이터 환경에서의 CEP 성능과 동일한 결과를 얻을 수 있을 것으로 예상된다. 그러나 FCM 내부에서 발생하는 반복으로 인해 데이터의 처리시간이 길어질 수 있어 반복횟수와 분류 성능의 절충관계를 이용할 필요가 있다. 또한, 보다 적응적인 시스템을 위하여, 학습된 데이터가 미리 수집되지 않은 환경에서도 기본 원리와 FCM을 이용하여 실시간으로 최적의 CEP 성능을 보장할 수 있는 기법을 제안하였다. 다음 장에서는 본 연구에서 적용한 FCM과 k-NN에 대해 간단히 정리한다.




그림 4. 비대칭적인 학습 데이터 환경에서의 D/B의 예
 Fig. 4. An example of asymmetric learning data and the corresponding D/B

III. 적응형 클러스터링 및 분류 알고리즘

3.1. FCM 클러스터링 알고리즘

FCM은 데이터 집합의 모든 데이터들에 특정한 소속 정도 (Degree of Membership)를 부여함으로써 n 개의 클러스터로 묶는 기능을 수행한다^[4]. 즉, 임의의 데이터가 클러스터의 중심에 가까이 놓여 있다고 할 때에 그 데이터는 그 클러스터에 높은 소속 정도를 갖는다고 할 수 있지만, 임의의 데이터가 클러스터의 중심과 멀리 떨어진 곳에 놓여 있다고 할 때에는 그 데이터는 그 클러스터에서 낮은 소속 정도를 갖는다고 할 수 있다. 식 (1)은 FCM의 목적 함수이며, 이 값을 최소화함으로써 클러스터를 생성할 수 있다^[4].

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \| \mathbf{x}_i - \mathbf{c}_j \|^2, \quad m = 1, 2, \dots \quad (1)$$

여기서, d 차원 벡터인 \mathbf{x}_i 는 i ($i = 1, \dots, N$) 번째 측정 데이터, \mathbf{c}_j 는 d 차원 클러스터의 중심, u_{ij} 는 j ($j = 1, \dots, C$) 클러스터 안에 있는 \mathbf{x}_i 의 소속 정도, 그리고 $\| \cdot \|$ 는 측정 데이터와 클러스터 중심의 거리를 통한 유사성을 의미한다. FCM은 반복적인 수행을 통해 식 (1)의 목적 함수를 최적화 하며, 식 (2)를 통해 소속 u_{ij} 과 클러스터 중심 \mathbf{c}_j 을 갱신한다.

$$u_{ij} = \left(\sum_{k=1}^C \left(\frac{\| \mathbf{x}_i - \mathbf{c}_j \|^2}{\| \mathbf{x}_i - \mathbf{c}_k \|^2} \right)^{\frac{2}{m-1}} \right)^{-1}, \quad \mathbf{c}_j = \frac{\sum_{i=1}^N u_{ij}^m \mathbf{x}_i}{\sum_{i=1}^N u_{ij}^m} \quad (2)$$

이 때, 반복은 $\max_{ij} \{ u_{ij}^{k+1} - u_{ij}^k \} < \epsilon$ 를 만족할 때까지 반복하게 되는데, ϵ 은 0과 1 사이에 있는 종료 조건이며 k 는 반복 단계를 의미한다. 이러한 과정을 통해 극소값 (Local Minimum) 혹은 J_m 의 새들포인트 (Saddle Point)로 수렴한다.

3.2. k -NN 분류 알고리즘

k -NN은 클래스가 이미 정의되어 있는 학습 데이터를 기반으로 새로운 데이터의 클래스를 추측하는 데이터 분류 알고리즘으로, 알고리즘의 유용성과 간결성이 입증되어 다양한 기계학습 분야에서 널리 사용되고 있다^[6,8]. k -NN은 새롭게 측정된 데이터와 각각의 학습 데이터들의 거리를 식 (3)의 유클리디언 거리 (Euclidean Distance)로 계산함으로써 측정 데이터와 가까이에 있는 학습 데이터들을 k 개만큼 찾게 된다.

그리고 학습 데이터들이 더 많이 포함된 클래스로 측정된 데이터의 클래스가 정의된다.

$$D = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_N - y_N)^2} \quad (3)$$

여기서, x_i 및 y_i ($i = 1, \dots, N$)는 각각 미리 정의된 학습 데이터의 속성값 및 클래스가 정의되어 있지 않은 데이터의 속성값이다.

IV. 제안된 적응형 복합 분류 알고리즘 기반의 향상된 전자소자 탐지 기법

4.1. 학습 데이터 기반의 적응형 복합 분류 기법

그림 5는 본 연구에서 제안하는 기법 중에서 학습 데이터 기반의 분류 기법의 과정을 도시한 것이다. 이 과정은 총 3단계로 구성되는데, 첫번째는 학습 데이터를 획득하고, 획득된 데이터 샘플로부터 속성값을 선택하는 단계이다. 그리고 두번째는 FCM을 이용하여 이미 학습된 데이터를 위한 클러스터를 생성하고, 판별을 위한 D/B를 설정하는 단계이다. 마지막으로 세 번째는 k -NN을 이용하여 새로 측정된 은닉 물체에 대한 분류를 수행하는 단계이다.

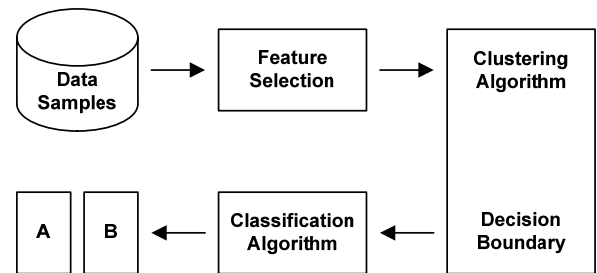


그림 5. 제안된 학습 데이터 기반의 탐지 과정
Fig. 5. The procedures of the proposed detection scheme

4.1.1. 첫번째 단계: 속성값 선택

속성 추출기는 몇몇의 변환을 통해 원본 데이터로부터 유용하고 참신한 속성을 생성하고, 속성값 선택은 이렇게 구성된 후보 집합으로부터 구별된 속성들을 선택함으로써 이루어진다. 이 과정은 효율적인 클러스터 생성에 매우 결정적인 요인이 된다. 속성값의 현명한 선택은 작업 부하를 현저하게 감소시킬 수 있으며, 설계 과정을 간략화 시킬 수도 있다. 일반적으로, 이상적인 속성값은 특징적인 패턴을 이용하여 잡음과 원하는 데이터를 쉽게 추출함으로써 서로 다른 클러스터로 해석할 수 있게 한다^[3]. 따라서, 본 논문에서는 2차 및 3차 고조파의 크기를 속성값으로 선택을 하였다.

4.1.2. 두번째 단계: FCM 알고리즘 기반의 D/B

두번째 단계의 목적은 비대칭적인 학습 데이터 환경에서의 정확한 분류를 위하여 가상의 대칭적인 D/B를 설정하는 것이다. 우선적으로 FCM을 이용하여 학습 데이터들을 각각의 클러스터로 구분하고 클래스로 정의하게 된다. 이 때, 가상의 학습 데이터를 사용하게 되는데, 가상의 학습 데이터는 서로 다른 클래스의 학습 데이터들의 평균 지점에 분포하게 되며, FCM은 학습 데이터와 가상의 학습 데이터들을 모두 고려하여 클러스터를 형성하고 클래스를 정의하게 된다. 그림 6은 지금까지 설명한 각 탐지 기법의 D/B를 도시한 것이다. 여기서, 빨간색 선이 “Conventional D/B”이며, 파란색 선이 “Advanced D/B”, 마지막으로 녹색 선이 “Proposed D/B”를 의미한다. 여기서 “Proposed D/B”가 비대칭적인 학습 데이터 환경에서 대칭적인 D/B를 설정함을 알 수 있다.




그림 6. 각 탐지 기법의 D/B 모습
Fig. 6. The D/B of each detection scheme

4.1.3. 세번째 단계: k-NN 알고리즘 기반의 분류

마지막 단계는 측정되는 새로운 데이터를 분류하고 전자소자를 탐지하는 단계이다. 분류를 위해서는 3장에서 소개된 k-NN을 이용하게 된다. 새롭게 측정된 데이터와 학습 데이터들을 식 (3)의 유클리디언 거리를 통해 계산하고, 측정 데이터와 근접해 있는 k개의 학습 데이터들을 찾는다. 그 후에 측정된 데이터는 더 많은 수의 학습 데이터를 포함하고 있는 클래스로 정의된다. 여기서, 첫번째 단계에서 이미 지정된 클래스와 세번째 단계에서 분류한 클래스가 동일할 경우에는 탐지가 제대로 된 것이며, 동일하지 않을 경우에는 오류가 발생된 것으로 한다.

4.2. 실시간 적응형 분류 기법

다음은 보다 적응적인 시스템을 위하여 미리 수집된 학습 데이터가 없는 환경에서도 측정된 데이터만을 이용하여 실시간으로 판별을 하는 기법이다. 이 기법은 측정된 데이터를 학습 데이터로 사용하기 때문에, 탐지기의 복잡도를 위해서 측정 시간에 따른 샘플링의 수를 고려해야 한다. 그림 7은 FCM을 이용한 측정 데이터 기반의 판별 모습을 도시한 것이다. 여기서, FCM의 클러스터 개수는 3으로 설정하였으며, 그 결과로 각각의 신호에 따라 3개의 클러스터를 생성한 것을 확인할 수 있다. 이 중 데이터 개수를 가장 많이 포함하고 있는 클러스터의 중심을 이용하여 판별을 하게 된다. 비교되는 방식은 샘플링 시간 동안 취득된 모든 고조파의 크기를 평균 (“Averaging”)하는 것으로, 가장 기본적인 방식이 될 수 있다. 하지만, 잡음 및 전자파 간섭으로 인한 오류의 개수가 많아질수록 CEP 성능이 높아질 수 있다는 단점이 있다.




그림 7. FCM을 이용한 실시간 측정 데이터 기반 분류 기법
Fig. 7. Real-time classification scheme based on FCM

V. 모의실험 결과

5.1. 모의실험 환경

본 논문에서 제안한 전자소자 탐지 기법의 성능을 측정하기 위하여 MATLAB을 이용한 모의실험을 수행하였다. 우선, 학습 데이터 기반 적응형 분류 기법의 성능을 측정하기 위하여 학습 데이터의 개수는 전자소자 50개, 금속류 50개로 총 100개를 사용하였으며, 전자소자와 금속류의 클래스 정의는 앞에서 설명한 3가지 D/B 방식을 이용하였다. 또한, 간섭을 강제로 주입시킨 학습 데이터를 사용하였으며, 학습 데이터에 주입된 간섭은 평균은 0, 표준편차는 50인 가우

시안 분포 특성을 갖게 된다. 그리고 측정 데이터의 표준편차는 30으로 설정하였으며, 간섭의 영향을 주기 위해서 표준편차가 2인 가우시안 랜덤 변수를 원본 측정 데이터에 주입하였다. 마지막으로 k -NN의 k 값은 3~51까지 4개씩 증가시키면서 측정을 하였으며, 측정 횟수는 총 100,000번을 수행하였다.

5.2. 학습 데이터 기반의 분류 기법 결과

5.2.1. 대칭적인 학습 데이터 환경




그림 8. 학습 데이터가 대칭적인 환경에서의 CEP 비교
Fig. 8. Comparison of CEP performance in symmetric learning data environments

그림 8은 학습 데이터가 대칭적인 환경에서의 k 에 따른 CEP 비교 결과이다. 그림을 통해, k -NN의 k 가 증가함에 따라 “Conventional D/B”의 경우에는 약 6%p, “Advanced D/B”의 경우에는 약 7%p, 그리고 “Proposed D/B”의 경우에는 약 4%p 정도 CEP가 감소되는 것을 확인할 수 있었다. 특히, $k=3$ 인 경우에 “Conventional D/B”와 다른 기법들을 비교하면, “Advanced D/B”는 약 1%p 정도 CEP가 감소되었지만, “Proposed D/B”는 반대로 약 3%p 정도 CEP가 상승하였다. 또한, $k=51$ 인 경우에 “Conventional D/B”와 다른 기법들을 비교하면, “Advanced D/B”는 약 2%p 정도 CEP가 감소되었지만, “Proposed D/B”는 반대로 약 6%p 정도 CEP가 상승하였다. 이러한 이유는 학습 데이터가 대칭적인 환경에서 이들의 평균을 이용한 “Advanced D/B”가 학습 데이터 간의 거리를 기반으로 분류하는 k -NN의 기준과 가장 비슷하였기 때문이라고 분석할 수 있다. 반대로, “Proposed D/B”의 경우에는 FCM에서 사용된 학습 데이터들의 잡음 및 전자파 간섭 영향에 따라 완벽한 대칭이 이루어지지 않았기에, 다른 기법들보다 CEP 성능이 상승

된 것으로 분석할 수 있다. 하지만, 결과적으로 제안된 k -NN을 통해 잡음 및 전자파 환경에서도 CEP의 성능이 감소되는 것을 확인하였다.

5.2.2. 비대칭적인 학습 데이터 환경

그림 9는 학습 데이터가 비대칭적인 환경에서의 k 에 따른 CEP 비교 결과이다. “Conventional D/B”의 경우에는 대칭적인 환경에서만 효율적인 분류가 가능하기 때문에 k 에 관계없이 약 50% 정도의 CEP를 얻는 것을 관측할 수 있다. 하지만, 이를 제외한 모든 기법에서는 k 가 증가함에 따라 CEP가 감소되었는데, “Advanced D/B”는 약 2%p 정도, “Proposed D/B”는 약 5%p 정도의 CEP가 감소되었다. 그리고 $k=3$ 인 경우를 비교해 보면, “Proposed D/B”가 “Advanced D/B”보다 약 6%p 정도, $k=51$ 인 경우에는 약 8%p 정도의 CEP가 감소되었다. 특히, “Proposed D/B”의 경우에는 대칭 환경에서와 동일한 성능을 얻을 수 있었기에, 제안된 기법이 다른 기법들보다 우수하다는 것을 입증할 수 있었다. 이러한 이유는 학습 데이터가 비대칭적인 환경을 가상의 대칭 환경으로 변경하여 줌으로써 대칭적인 환경에서의 k -NN의 분류 결과와 비슷한 결과로 만들었기 때문이다. 또한, 서로 다른 클래스 사이에 상대적인 여유 (Margin)를 줌으로써 잡음 및 전자파의 간섭 환경에서도 정확한 분류를 할 수 있었기 때문이라고 분석할 수 있다. 특히, 대부분의 환경에서 서로 다른 클래스는 비대칭일 경우가 많으며, 이에 따라 본 연구에서 제안한 기법이 은닉 물체를 탐지하기 위한 전자소자 탐지기의 분류 기법으로 적합하다고 할 수 있다.




그림 9. 학습 데이터가 비대칭적인 환경에서의 CEP 비교
Fig. 9. Comparison of CEP performance in asymmetric learning data environments

5.3. 실시간 적응형 분류 기법 결과

그림 10은 실시간 적응형 분류 기법의 CEP 측정 결과이다. 시스템의 복잡도를 고려하기 위하여 측정 데이터의 개수 N 을 10, 30, 50개로 변경하였으며, 고조파의 오류율은 0~100%까지 변경하였다. 그리고 원본 신호와 전자파 간섭 신호에 영향을 미치는 간섭 크기의 비율은 10:90으로 설정하였다. 모의실험 결과, 고조파의 오류율이 50~65%까지 일어나더라도 제안된 기법의 CEP는 약 10% 정도로 유지할 수 있었다. 특히, 데이터 개수 $N=50$ 이고, 고조파 오류율이 65%임에도 약 10%의 CEP를 보장할 수 있었다. 따라서, 제안된 기법이 실시간으로 측정되는 시스템의 복잡도를 효율적으로 낮추면서도, 전자소자를 정확하게 탐지할 수 있음을 확인하였다.




그림 10. 실시간 분류 기법의 CEP 비교
Fig. 10. Comparison of CEP performance of real-time classification scheme

VI. 결 론

본 논문은 지적재산권을 비롯한 산업기밀의 유출을 방지하기 위한 목적으로 적응형 분류 알고리즘 기반의 초소형 전자소자 탐지 기법을 제안하였다. 제안된 기법의 성능을 측정하기 위하여, 학습 데이터의 클래스를 미리 정의할 수 있는 FCM 기반의 D/B를 설정하였으며, k -NN을 이용하여 은닉 물체의 탐지를 실시하였다. 특히, 학습 데이터의 2차 및 3차 고조파가 대칭적인 경우와 비대칭적인 경우를 고려하였으며, 은닉된 물체를 탐지하는 과정에서 발생할 수 있는 잡음 및 전자파의 간섭 영향도 고려하였다. 모의실험 결과를 통해, 제안된 기법이 대칭 환경에서 약 10% 정도, 비대칭 환경에서 약 9% 정도의 CEP 성능을 얻음을 관찰하였다. 그리고 보다 적응적인 시스템을 위하여

학습 데이터를 이용하지 않고 실시간으로 측정되는 데이터를 이용하여 분류하는 기법을 제안하였다. 모의 실험 결과 잡음 및 전자파 간섭으로 인한 고조파 오류율이 65%일 때에도 약 10% 정도의 CEP 성능을 얻을 수 있었다. 따라서, 제안된 기법이 은닉된 초소형 전자소자를 효율적으로 탐지할 수 있을 뿐만 아니라, 잡음 및 전자파의 간섭 영향에서도 적응적인 분류 성능을 보임을 알 수 있었다.

References

- [1] Korea Industrial Technology Association, "A study on the current status of overseas industrial security management and case studies of American companies," *Korea Small and Medium Business Administration R&D Report*, Dec. 2009.
(한국산업기술진흥협회, "해외 산업보안 동향 및 사례분석 (미국편)," *중소기업청 연구용역 보고서*, 2009년 12월.)
- [2] B. R. Barsumian, T. H. Jones, and C. A. Liter, "Surveillance device detection utilizing nonlinear junction detection and reflectometry," US Patent 7212008, May 2007.
- [3] R. Xu and D. Wunsch, "Survey of clustering algorithms," *IEEE Trans. Neural Netw.*, vol. 16, no. 3, pp. 645-678, May 2005.
- [4] R. J. Hathaway and Y. Hu, "Density-weighted fuzzy c -means clustering," *IEEE Trans. Fuzzy Syst.*, vol. 17, no. 1, pp. 243-252, Feb. 2009.
- [5] S. Theodoridis and K. Koutroumbas, *An Introduction to Pattern Recognition: A MATLAB Approach*, Academic Press, 2010.
- [6] N. Roussopoulos, S. Kelley, and F. Vincent, "Nearest neighbor queries," in *Proc. ACM SIGMOD 1995*, pp. 71 - 79, San Jose, U.S.A., May 1995.
- [7] T. M. Cover and P. E. Hart, "Nearest neighbor pattern classification," *IEEE Trans. Inform. Theory*, vol. 13, no. 1, pp. 21-27, Jan. 1967.
- [8] J. C. Kim, S. H. Kim, and K. S. Kwak, "Classification of Korean traditional musical instruments using feature functions and k -nearest neighbor algorithm," *J. Korea Multimedia Soc.*, vol. 9, no. 3, pp. 279-286,

Mar. 2006.

(김재천, 김석호, 광경섭, “특성함수 및 k-최근접이웃 알고리즘을 이용한 국악기 분류,” 멀티미디어학회 논문지, 제9권, 제3호, 2006년 3월.)

신 요 안 (Yoan Shin)

한국통신학회논문지 Vol.34, No.1 참조

김 광 열 (Kwangyul Kim)

한국통신학회논문지 Vol.36, No.6 참조

임 정 환 (Jeonghwan Lim)



2001년 2월 서울산업대학교 제어계측공학과 학사

2010~2011년 (주)캠프넷 연구소 팀장

2011년 6월~현재 (주)엘트로닉스 연구소 팀장

<관심분야> 무선통신 시스템,

통신신호처리, 제어 시스템

김 송 강 (Songkang Kim)



2009년 2월 목포대학교 정보공학부 학사

2009년 1월~현재 (주)엘트로닉스 연구원

<관심분야> 무선통신 시스템, 통신신호처리, 제어 시스템

조 준 경 (Junkyung Cho)



1994년 2월 명지대학교 전자공학과 학사

1997년 8월 성균관대학교 전기 및 전자공학과 석사

2007년 8월 한국산업기술대학교 정보통신공학과 박사수료

1995년~2000년 성미전자(주) 연구소 G/W사업팀장

2000년~2003년 신영텔레(주) 연구소 기술이사

2004년~2008년 휴텍21(주) 연구소 기술이사

2009년~현재 (주)엘트로닉스 IRD연구소장/이사

<관심분야> 무선통신 시스템, 무선전력전송, 정보통신 시스템