

음향신호 특징요소 추출을 통한 신경회로망기반 침입탐지 시스템의 개발

The development of invasion detection system based on artificial neural network through the feature extraction on the acoustic signal

윤이연(Yi-Yeon Yoon)*, 김우주(Woo-Ju Kim)*, 홍준석(June-Seok Hong)**
김경민(Kyung-Min Kim)*, 이노복(Noh-Bok Lee)***, 김상훈(Sang-Hoon Kim)****
김대식(Dea-Sik Kim)***

pryieon@yonsei.ac.kr, wkim@yonsei.ac.kr, junehong@kyonggi.ac.kr,
milren78@yonsei.ac.kr, nblee1004@gmail.com, goldkim@lignex1.com

초 록

유비쿼터스 환경에서 다양한 센서 신호를 이용하여 침입을 탐지하고 식별하려는 연구들이 많이 진행되어 왔다. 그 중에서 가장 쉽게 적용하여 사용할 수 있는 음향센서를 이용한 탐지의 경우에 시간 도메인의 음향신호를 대상으로 침입자 탐지를 위한 식별 특성을 추출하는 작업은 탐지 시스템의 성능에 매우 중요한 영향을 미친다. 본 연구에서는 기존의 관련 연구들의 분석을 통하여 음향 신호 특성을 추출하고, 이러한 특성 값을 이용하여 침입자 탐지를 위한 신경회로망 기반의 분류기 시스템을 구축하였다. 그리고 다양한 실험을 통하여 개발된 시스템의 성과를 검증하였다.

1. 서론

UGS(Unattended ground Sensors), USN(Ubiquitous Sensor Network)와 같은 센서 네트워크(Sensor Network)기술의 발달에 따라 침입탐지 시스템의 활용 가능성

및 중요성이 증대되고 있다. 예를 들어, 이전의 침입탐지 시스템은 단순히 침입자의 탐지 역할만을 수행 가능하였다면, 유비쿼터스 도시 내에서의 침입탐지 시스템은 다양한 센서 네트워크와의 정보공유를 통해 더욱 정확한 표적탐지가 가능하게 되고, 또한 표적탐지 이후 침입탐지 관련 프로토콜

본 연구는 민국 검용 기술과제의 지원으로 이루어졌음.

* 연세대학교 정보산업공학과

** 경기대학교 경영정보학과

*** LIG

**** 국방

(Protocol)을 수행 할 수 있게 되었다.

침입탐지를 위해서는 다양한 센서들이 사용 가능한데, 현재 침입자탐지에서 많이 사용되는 센서는 음향센서, 영상센서(CCTV), 적외선센서, 진동센서 등이 있다[9]. 그 중 음향센서는 1차원적인 센서로써, 침입탐지 시스템에서 많이 사용되는 2차원 영상 정보 보다는 정보량이 적고 외부 노이즈에 더 많은 영향을 받는다는 단점이 있다. 하지만 연산량에서 많은 이득을 볼 수 있을 뿐 만 아니라 완벽한 잠복성을 지녀 발견되거나 혼선되기가 어려우며, 작은 파워 소비로 다수의 센서를 이용함으로써 센서 네트워크의 효율을 극대화 시킬 수 있다.

음향센서를 사용한 침입자탐지는 특이성을 갖는 소리를 탐지하여 시간의 흐름에 따라 움직이는 물체의 패턴을 모델링 하게 되고, 주파수의 특성으로 대상 종류를 추정하는 방법을 사용할 수 있다. 이때 시간적으로 움직이는 물체의 패턴을 모델링 하기 위해서는 그 물체가 시간도메인에서 갖는 소리의 특징을 추출(Feature Extraction)하여 물체의 패턴 모델링에 반영해야 한다. 즉, 소리의 특징 추출이 어떻게 되었느냐에 따라 패턴 모델링의 성능이 결정 되기 때문에 시간도메인 상에서의 특징 추출은 물체의 패턴 탐지에 중요한 역할을 한다. 이에 본 논문은 침입탐지 시스템에 적용 가능한 발자국소리 신호의 시간도메인에서의 특성을 이해하고, 발자국소리를 분류하는데 있어 최적화된 특징을 추출한다.

2. 관련연구

음향신호를 이용한 대상분류 연구는 크게 시간도메인, 주파수도메인, 그리고 시간-주파수도메인 분석의 세 가지 접근방법으로

나눌 수 있다. 일반적으로 분류대상이 갖는 음향신호의 특성에 따라 접근방법이 선택 되는데, <표 1>에서는 이러한 세 가지 접근방법을 통한 각 대상을 분류한 연구를 나타낸다. 이는 Sampan(1997)의 시간도메인을 이용한 자동차분류연구, 안경룡 외(2002)의 시간-주파수도메인을 이용한 회전기계결함 분류연구, Sreejith 외(2008)과 Hariharan 와 Srinivasan (2009)의 시간도메인을 이용한 구름요소베어링의 결함진단분류연구, Azra' ai외(2008)의 주파수도메인을 이용한 심장 이상진단연구가 있다.

발자국신호 분류에 관한 연구는 진동센서를 이용한 방법과 음향센서를 이용한 방법 등이 있다. 발자국신호 분류에 관한 선행연구로는 <표 1>에서 제시한 것과 같이 Suutala와 Röning (2004) 의 진동센서를 통해 획득한 진동신호를 이용한 연구와, Cai 외 (2010)의 음향센서를 통해 획득한 음향신호를 주파수도메인으로 변환하여 이용한 연구가 있다.

이상 관련연구를 분석한 결과, 음향신호를 통한 대상분류 연구에서는 각 접근방법과는 상관없이 대상신호의 특성을 나타내기 위해 여러 가지 특징을 사용하는 것을 알 수 있었다. 또한 발자국 신호를 이용한 대상분류 연구에서는 대부분의 경우 주파수도메인 분석이나 진동센서를 이용한 연구가 진행되었으며 본 논문에서 하고자 하는 시간도메인 분석에 대한 연구는 아직 미흡한 것으로 보인다.

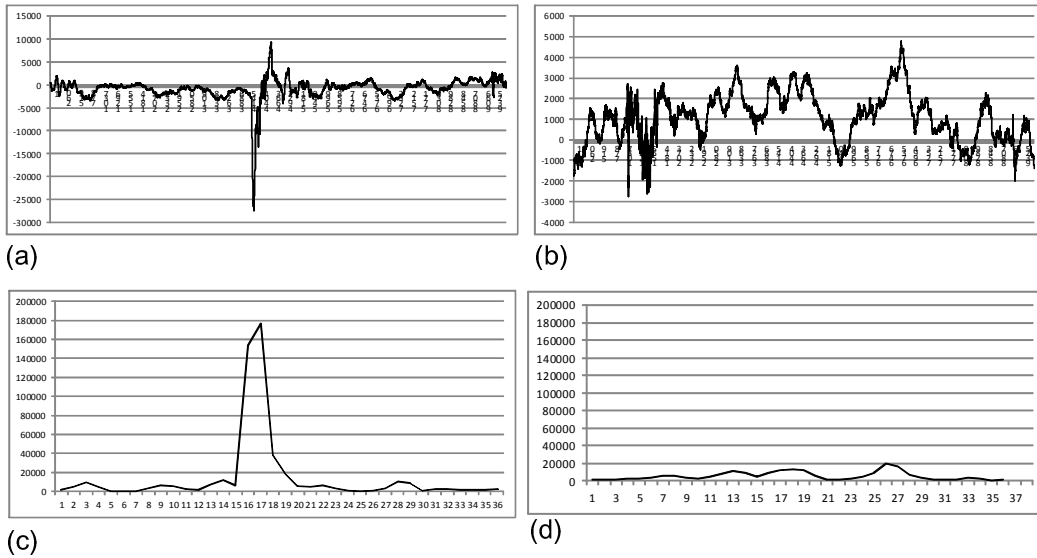
본 논문에서는 이를 바탕으로 음향신호 기반의 발자국소리 신호의 특성을 적절하게 표현할 수 있는 특징을 추출 및 선택하고자 한다. 이를 위해 3장에서는 발자국소리 신호를 사용한 침입탐지 시스템의 절차에 대해 설명한다.

<표 1> 관련연구

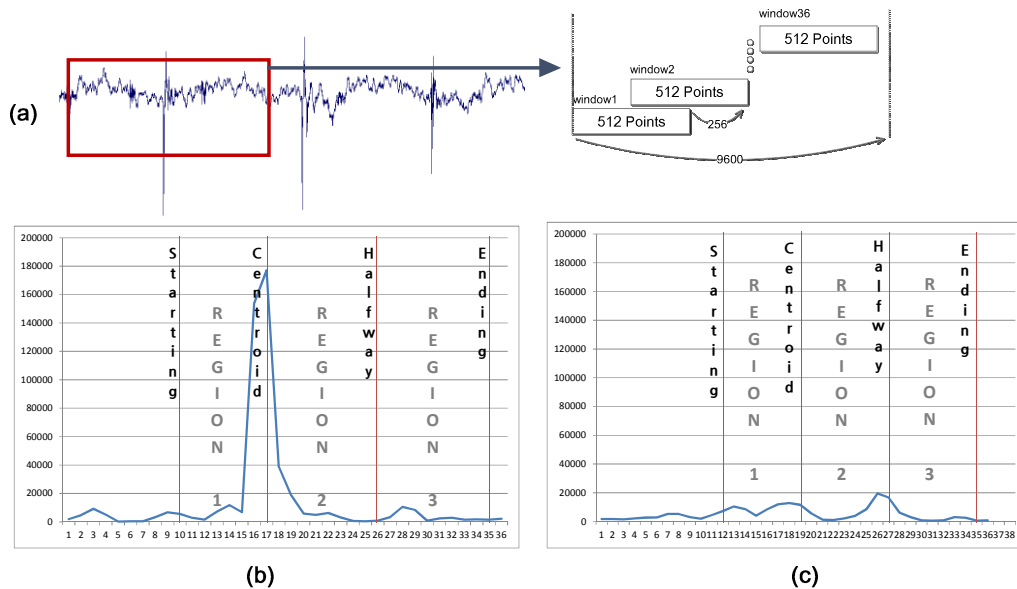
| 종류 | 관련연구 | | | | |
|----------------------|--|------|--|----|-------|
| 자동차 분류 | Somkiat Sampan (1997) | 목적 | 자동차 종류를 Federal Highway Administration (FHWA)에서 권장하는 13개의 종류로 분류 | | |
| | | 특징집합 | 논문에서 정의한 30개의 특징 | | |
| | | 분류기 | 신경회로망, 퍼지로지시스템 | 성능 | 97% |
| 회전기계 결함분류 | 안경룡 외 (2002) | 목적 | 회전기계를 정상상태, 불평형, 편심 및 편각 정렬 불량, 베어링의 외륜결함, 내륜결함, 볼 결함, 베어링에 여러 결함이 포함된 종합결함상태로 분류 | | |
| | | 특징집합 | 시계열 신호의 Shape Factor, 파고율 및 표준편차, Wavelet 변환 레벨 1의 평균 및 엔트로피, Wavelet 변환 레벨 2의 Shape Factor 및 표준오차, Wavelet 변환 레벨 3의 엔트로피 | | |
| | | 분류기 | ART-Kohonen network | 성능 | 94% |
| 구름요소 베어링의 결함진단 | B.Sreejith, A.K. Verma, A.Srividya (2008) | 목적 | 구름요소베어링을 정상상태, 구름요소결함, 외륜결함, 내륜결함의 결함진단 | | |
| | | 특징집합 | Peak Value, Rms Value, 표준편차, Kurtosis, Crest Factor, Clearance Factor, Impulse Factor, Shape Factor, Normal Negative Log-Likelihood Value, Weibull Negative Log-Likelihood Value | | |
| | | 분류기 | 신경회로망 | 성능 | 100% |
| | V. Hariharan &PSS.Sriniva san (2009) | 목적 | 구름요소베어링을 정상, 외륜결함, 내륜결함, 케이지결함의 결함진단 | | |
| | | 특징집합 | Clearance, Crest Factor, Kurtosis, 최고값, RMS Value, 분산, 평균 | | |
| | | 분류기 | 신경회로망 | 성능 | 100% |
| 심장이상 진단 | Rohaida Ahmad Azra'ai외 (2008) | 목적 | 정상, 대동맥 협착증, 심장중격 결손, 심장잡음, 승모판탈출증, 대동맥 기능부전, 승모판협착증, 동맥관개존증, 폐협착증, 가중궤립의 심장이상 진단 | | |
| | | 특징집합 | 주파수 분석결과 | | |
| | | 분류기 | 신경회로망 | 성능 | 98% |
| 발자국신 호 분류 | Suutala J , Röning J (2004) | 목적 | 진동센서를 이용한 발자국신호로 사람 분류 | | |
| | | 특징집합 | 논문에서 정의한 31개의 특징 | | |
| | | 분류기 | DSLQ, LVQ1, LVQ3 | 성능 | 70.2% |
| | F. Cai, D. Philipson, S. Syed (2010) | 목적 | 발자국소리 신호를 주파수도메인으로 변환 후 지나가는 사람의 수 판단 | | |
| | | 특징집합 | Mel-Frequency Cepstrum Coefficients | | |
| | | 분류기 | SVM | 성능 | 87.8% |



<그림 1> 침입탐지 시스템 절차



<그림 2> (a) 이벤트 구간의 음향신호, (b) 노이즈 구간의 음향신호, (c) 이벤트 구간의 에너지 변환 그래프, (d) 노이즈 구간의 에너지 변환 그래프



<그림 3> (a) 데이터 구간 추출 방법, (b)이벤트 구간 Sampan(1997)연구 적용 모형, (c)노이즈 구간 Sampan(1997)연구 적용 모형

3. 특징 추출

본 논문에서는 <그림 1>과 같은 절차로 연구를 진행한다. 먼저 발자국소리 신호가 들어오면 선처리 작업(pre-processing)을 통해 입력된 신호에 대한 특징을 추출하기 위한 데이터로 변환한다. 그리고 발자국소리 신호의 특성을 잘 설명할 수 있는 특징을 추출 후, 정해진 특징에 대해 신경회로망 분류기를 이용해 발자국 소리인지의 여부를 판단하게 된다.

3.1 선처리 작업

본 논문에서 음향신호 기반의 발자국 소리 신호를 구별하기 위해 실험에 사용된 음향 신호는 음향센서를 통해 추출한 데이터로, 샘플링 주파수 48000Hz, 샘플링 시간 10초의 길이로 수집하였다.

발자국소리를 구분하기 위해 수집한 데이터를 <그림 2>의 (a)와 같은 이벤트(발자국이라고 판단한) 구간과, <그림 2>의 (b)와 같은 노이즈(발자국이 아닌) 구간을 추출하고, 이 데이터를 본 논문의 실험환경과 비슷한 Sampan(1997)의 논문에 제시한 형

태로 변환하기 위해 <그림 3>의 (a)에서 보는 것과 같이 512윈도우로 나누어 50%씩 겹쳐가며 Sampan(1997)의 논문에서 제시한 에너지 계산방법을 적용시켰다.

$$E = \frac{\sum_{k=1}^N s^2(k)}{N} \quad (1)$$

여기서 N은 한 윈도우에 해당하는 샘플의 개수이고, s(k)는 해당 윈도우의 k번째 신호샘플이다[6].

이러한 방법을 적용하여 <그림 2>의 (c)와 (d)와 같은 이벤트 구간과 노이즈 구간의 에너지 변환 그래프를 얻었다. 이와 같은 그래프를 특징 추출작업에 적용시키기 위해 <표 2>에서 제시한 기준에 따라 각각의 구간을 정의하고, 이 구간에 따라 지역 1, 2, 3으로 나누었다. 이는 <그림 3>의 (b), (c)와 같다.

3.2 특징추출

본 논문에 사용하는 발자국 신호는 <그림 2>의 (c), (d)에서 보는 것과 같이 이벤트 구간과 노이즈 구간의 그래프 패턴이 구분되는 것을 볼 수 있다. 이와 같이 서로

<표 2> 구간 기준 및 지역 정의[6]

| 용어 | 설명 |
|---------------------|--|
| 중심점 (centroid) | $L = \frac{\sum_{k=1}^N k \cdot E(k)}{\sum_{k=1}^N E(k)} \quad (2)$ <p>N: 한 구간에 해당하는 포인트 개수 E(k): k번째 윈도우의 에너지 값</p> |
| 끝점(ending point) | 한 구간의 에너지값 중 마지막 변곡점 |
| 중간지점 (halfway) | 중심점와 끝점의 중간이 되는 지점 |
| 시작점(starting point) | 중심점에서 7.2포인트를 뺀 지점 |
| 지역1(region 1) | 시작점부터 중심점까지의 구간 |
| 지역2(region 2) | 중심점부터 중간지점까지의 구간 |
| 지역3(region 3) | 중간지점부터 끝점까지의 구간 |

<표 3> 실험에 사용한 특징

| No. | 특징 설명 |
|-------|--|
| 1 | 에너지평균의 최대값 |
| 2 | 시작점으로부터 중심점의 위치 |
| 3 | 시작점으로부터 에너지평균의 최대값 위치 |
| 4 | 중심점과 한 구간의 최대값의 위치의 차이 |
| 5 | 에너지의 최대값 |
| 6 | 시작점으로부터 끝점까지의 윈도우 개수 |
| 7~9 | 지역 1의 에너지/에너지평균의 최대값의 위치, 에너지 중심위치, 에너지평균 |
| 10~12 | 지역 2의 에너지/에너지평균의 최대값의 위치, 에너지 중심위치, 에너지평균 |
| 13~15 | 지역 3의 에너지/에너지평균의 최대값의 위치, 에너지 중심위치, 에너지평균 |
| 16 | 에너지/에너지평균의 값이 1보다 큰 윈도우의 개수 |
| 17 | 최대 에너지평균*0.5 보다 큰 에너지평균을 갖는 윈도우의 개수 |
| 18 | 최대 에너지평균*0.25 보다 큰 에너지평균을 갖는 윈도우의 개수 |
| 19 | 지역 3의 에너지평균의 최대값 |
| 20~22 | 지역 1, 2, 3에서의 zero crossing rate의 합 |
| 23 | 피크에너지 이후의 윈도우 개수 |
| 24 | 처음부터 중심위치까지 구간의 에너지 값에 대한 Kurtosis |
| 25 | 처음부터 중심위치까지 구간의 에너지 값에 대한 Crest Factor |
| 26 | 처음부터 중심위치까지 구간의 에너지 값에 대한 Clearance Factor |
| 27 | 처음부터 중심위치까지 구간의 에너지 값에 대한 Impulse Factor |
| 28 | 처음부터 중심위치까지 구간의 에너지 값에 대한 Shape Factor |

다른 패턴을 갖는 신호를 분류하기 위해 다음과 같은 방법으로 특징을 추출한다. 이를 위해 본 논문은 음향신호 기반의 발자국소리 신호를 Sampan(1997)논문에서 제안된 30개의 특징 중 발자국소리 신호를 잘 표현할 것으로 기대되는 특징 23개를 선택하였다. 하지만 특징 23개 중 대다수의 특징이 특정구간의 평균이나 최대값, 중심위치 등 기본적인 수치 값으로 구성되어있기 때문에, 발자국소리 신호의 패턴에 나타나는 특성을 적용하고자 안경룡 외(2002), Sreejith 외(2008), Hariharan과 Srinivasan(2009)연구에서 특징으로 사용한 값들 중 발자국소리 신호의 패턴을 더욱 상

세한 수치 값으로 비교할 수 있는 5개의 특징을 추가하였다[1][3][8]. 각 특징에 대한 설명은 <표 3>과 같다. 여기서 에너지평균은 이전 5개의 에너지 값의 이동평균을 나타내고, Zero crossing rate는 정해진 구간 내에 신호의 부호가 바뀌는 정도를 나타낸다. 추가한 5개의 특징은 아래 수식 (3)~(7)에 의해 정의된다.

Kurtosis
$$Kv = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{(RMS)^4} \quad (3)$$

Crest factor
$$Crf = \frac{Peak\ Value}{RMS} \quad (4)$$

Clearance factor
$$Clf = \frac{Peak\ Value}{\left(\frac{1}{N} \sum_{i=1}^N |x_i|\right)^2} \quad (5)$$

Impulse factor
$$Imf = \frac{PeakValue}{mAV} \quad (6)$$

Shape factor
$$Shf = \frac{RMS}{mAV} \quad (7)$$

여기서 RMS(Root Mean Square)는 실효값을 나타내고, PeakValue는 한 구간의 최대값과 최소값의 차이를 1/2 한 것이다. 그리고 mAV(mean Absolute Value)는 절대값 평균을 나타낸다. 이러한 값을 이용하여 추가한 5가지 특징값을 계산하였다. 이는 데이터의 분포가 얼마나 뾰족한지를 나타내는 Kurtosis와, 절대값을 고려하여 피크값을 나타낸 Crest Factor와 절대값을 고려하지 않은 방법으로 피크값을 나타낸 Clearance Factor. 그리고 피크값을 절대값 평균으로 나눈 Impulse Factor와, 그래프변동의 정도에 따라 값이 달라지는 Shape Factor를 포함한다.

4. 실험

4.1 실험 방법

본 논문은 침입자탐지를 위한 발자국소리 신호 구분을 위해 두 가지 특징집합으로 실험을 수행하였다. 첫 번째 특징집합은


Sampan(1997)이 제시한 <표 3>의 1~23번의 23개의 특징으로 구성하였고, 두 번째 특징집합은 Sampan(1997)의 특징에 신호의 모양을 고려하여 추가한 5개의 특징으로, <표 3>의 특징 28개로 구성하였다.

음향신호의 분류를 위해 사용되는 분류기는 ANN, HMM, GMM, SVM등 매우 다양한 종류가 있지만, 본 논문에서는 음향신호의 분류를 위해 제안된 연구에서 가장 많이 사용하고 있는 신경회로망 분류기를 사용하였다[3][5][6][8].

분류기의 모형은 <그림 4>와 같다. 여기서 입력층(Input Layer)의 데이터는 <표 3>에서 제시한 특징값을 계산한 것으로, 각 특징마다 매트릭스형태로 존재한다. 입력층의 개수는 특징집합 1의 경우 23개, 특징집합 2의 경우 28개를 사용하였다. 은닉층(Hidden Layer)은 64개이고, 하나의 출력층(Output Layer)으로 발자국인지의 여부를 판단하게 된다.

4.2 실험 결과

실험은 두 가지 방법으로 진행하였다. 실험1은 훈련(training)집단과 검증(validation)



<그림 4> 신경회로망의 모형

집단, 평가(test)집단을 6:2:2의 비율로 랜덤하게 나누어 각 특징집합마다 10번씩 수행하여 식별성공률평균을 비교하는 실험이고, 실험2는 훈련집단과 검증집단, 평가집단을 3가지 형태로 고정된 상태에서 각 특징집합을 비교하는 실험이다. 각 실험에 대한 두 가지 특징집단의 성능을 비교하기 위해 식별성공률을 사용하였고, 실험1에 대한 결과는 <표 4>와 같다. <표 4>에서 보는 것과 같이, 특징집합1보다 특징집합2로 실험을 했을 경우 식별성공률이 12% 증가한 것을 볼 수 있다. <표 5>는 실험2에 대한 결과를 보여준다. 특징집합 1에서는 50%밖에 식별하지 못한 고정셋을 특징집합2에서는 100%식별하는것을 볼 수 있다. 또한 특징집합1에서 90%의 높은 식별율을 보인 고정셋에서도 100%의 식별율을 보여, 실험1의 결과와 마찬가지로 새롭게 추가한 특징 5개가 발자국소리 신호의 특성을 잘 반영한다는 것을 의미한다.

<표 4> 실험 1에 대한 특징집합에 따른 식별성공률

| | 특징집합1 | 특징집합2 |
|-----------|-------|-------|
| 식별성공률 (%) | 82 | 94 |

<표 5> 실험 2에 대한 특징집합에 따른 식별성공률

| 테스트데이터 일련번호 | 식별성공률 (%) | |
|----------------|-----------|-------|
| | 특징집합1 | 특징집합2 |
| 1 | 90 | 100 |
| 2 | 80 | 100 |
| 3 | 50 | 100 |

본 논문은 침입자탐지를 위한 음향센서를 통해 획득한 발자국소리 신호의 특성을 이해하고 발자국소리 신호를 분류하는데 있어 최적화된 특징을 추출하기 위한 연구이다.

연구의 절차는 발자국소리 신호가 입력되면 선처리 작업을 통해 특징추출을 하기 위한 데이터로 변환을 한 후, 발자국소리 신호의 특성을 잘 설명할 수 있는 특징을 추출한다. 그리고 정해진 특징에 대해 신경회로망 분류기를 이용하여 발자국 소리인지의 여부를 판단하게 된다.

실험을 위해 발자국소리 신호의 특성을 잘 반영할 것으로 기대되는 23개의 특징(특징집합1)과 발자국소리 신호의 패턴을 더욱 상세하게 설명할 수 있는 5개를 더해 총 28개의(특징집합2) 특징을 추출하였다. 실험은 신경회로망 분류기를 사용하여 진행하였으며, 훈련, 검증, 평가집단을 랜덤으로 변경하여 실험하는 실험1과 훈련, 검증, 평가집단을 고정하여 실험하는 실험2의 두 가지 실험을 통해 각 특징집합의 식별성능을 비교하였다. 실험1에서는 특징집합1보다 특징집합2가 12% 높게 나타나 94%의 식별성공률을 보였고, 실험2에서는 각기 다른 테스트데이터에서의 실험에 특징집합1보다 특징집합2의 성능이 전체적으로 높게 나타났다.

우리는 이러한 실험을 통해 발자국소리 신호의 특성을 잘 반영하는 28개의 특징을 추출하였다.

5. 결론

참고문헌

- [1] 안경룡, 한천, 양보석, 전재진, 김원철, "ART-Kohonen 신경망을 이용한 회전기계의 결함진단 알고리즘", 한국소음진동공학회논문집, 제 12권, 제 10호, pp.799~807,2002
- [2] 임재덕, 한승완, 최병철, 정병호, "콘텐츠 분류를 위한 오디오 신호 특징 추출 기술", 전자통신동향분석 제 24권 제 6호, 2009
- [3] B.Sreejith, A.K. Verma, A.Srividy, "Fault Diagnosis Of Rolling Element Bearing Using Time-Domain Features And Neural Networks", IEEE Region 10 Colloquium and the third ICIS, 2008
- [4] Francisco Cai, David Philipson, Salik Syed, "A step-by-step approach to footstep detection", 2010
- [5] Rohaida Ahmad Azra'ai, Mohd Nasir bin Taib and Nooritawati Md Tahir, "Artificial Neural Network for Identification Of Heart Problem", Signal Processing and Communication Systems, 2008. ICSPCS 2008. 2nd International Conference on, Dec. 2008
- [6] Somkiat Sampan, "Neural Fuzzy Techniques In Vehicle Acoustic Signal Classification", 1997
- [7] Suutala J and Röning J, "Towards the adaptive identification of walkers: automated feature selection of footsteps using distinction sensitive LVQ", 2004
- [8] V. Hariharan, PSS. Srinivasan, "New Approach Of Classification Of Rolling Element Bearing Fault Using Artificial Neural Network", Journal of Mechanical Engineering, Vol. ME 40, No. 2, December 2009 119-130
- [9] William E. Audette, David B. Kynor, Jed C. Wilbur, John R. Gagne, "Improved Intruder Detection Using Seismic Sensors and Adaptive Noise Cancellation", Human, Light Vehicle, and Tunnel Detection Workshop, 2009
- [10] Z. Liu, Y. Wang, and T. Chen, "Audio Feature Extraction and Analysis for Scene Segmentation and Classification," Journal of VLSI Signal Process Systems, Vol.20, No.1/2, pp.61-79., 1998
- [11] Zhang, G. P. "Business Forecasting With Artificial Neural Networks: An Overview." Georgia state University, USA. 2004.