

## 특집

딥러닝, 소음진동분야에도 유용한가?

# 소음진동 품질검사를 위한 딥러닝

김영기\*, 박성효, 이재선

(에스엠인스트루먼트)

## 1. 머리말

자체적으로 소음과 진동을 발생하는 자동차, 가전 제품 등은 생산 과정의 마지막 단계에서 이에 대한 품질 검사를 실시한다. 제품을 실제로 동작 시킨 후, 사람이 소음을 듣거나 기계로 측정하여 합격 혹은 불합격 판정을 내린다. 배경소음 등으로 소음을 듣기가 어려울 경우 진동을 측정해 간접적으로 소음을 측정하기도 한다. 고객에게 소음 불량인 제품이 배송되는 것을 방지하기 위한 매우 중요한 단계이다. 검사 과정에서 판정의 기준은 평균적으로 생산되는 제품의 소음의 특성이다. 검사 대상의 제품이 평균 이상의 소음을 발생하면 불량으로 처리한다. 소음의 크기가 판정에 도움을 주기도 하지만 대부분 소음의 음질, 음색 등 복합적인 기준으로 판정한다. 생산이 안정된 일반적 생산라인에서는 1% 이내의 적은 양을 불량으로 판정한다. 검사를 객관적이고 안정적으로 수행하기 위해서 많은 현장에서 검사 과정을 자동화하고 있는 추세이다.

신호처리 방법 및 계측기가 발달함에 따라 소음진동 품질검사 과정이 급속도로 자동화되어져 왔다. 자동화된 검사라인에서는 마이크로폰이나 가속도계를 이용하여 데이터를 측정하고 이를 분석

한다. 현재까지는 대부분 전통적인 신호처리를 통해 데이터로부터 고장의 특성을 추출한다. 신호처리 결과를 통해 고장 제품의 특징을 분석할 수 있는 검사 인덱스(feature index)를 계산하고 이 인덱스의 통계적인 특성을 통해 검사를 실시한다. 일반 소음의 경우, 주파수 분석을 통한 밴드 파워(band power)를 계산하기도 한다. 베어링(bearing)의 복잡한 고장이 포함되는 경우, 인벨럽(envelope) 및 캡스트럼(cepstrum) 등의 고급신호처리가 포함되기도 한다. 이러한 자동화 방법이 성공적으로 적용되는 경우, 객관적이고 안정적인 검사를 수행할 수 있다. 하지만, 소음진동 품질검사를 자동화하는 과정에서 검사 인덱스를 찾아 내는 것은 쉽지 않은 일로 많은 시간과 노력을 필요로 한다. 고급신호처리과정을 쉽게 적용하고 다양한 인덱스를 취할 수 있는 도구를 관련 업계에서 제공하고 있지만, 여전히 고급인력이 투입되고 오랜 시간이 걸리는 과정으로 남아 있다.

이 글에서 딥러닝 방법을 소음진동 품질검사에 적용하는 것은 검사 인덱스를 찾아가는 과정과 노력을 줄이기 위한 것이다. 실제 기존의 신호처리를 이용한 검사 자동화 과정에서 검사 인덱스의 개발과 안정화는 수개월에서 수년의 시간이 소요된다. 다양한 딥러닝 예제에서 볼 수 있듯이 충분

\* E-mail : youngkey@smins.co.kr

한 데이터와 딥러닝 방법을 이용한다면 상대적으로 매우 짧은 시간 내에 검사 방법을 확정할 수 있을 것으로 기대할 수 있다<sup>(1,2)</sup>. 하지만, 딥러닝을 사용한다는 것은 많은 데이터를 사전에 확보하여야 한다는 것을 전제한다. 실제 현장에서는 다양한 데이터를 사전에 확보한다는 것이 매우 어렵기 때문에, 이러한 어려움을 해결하는 방법도 이 글에서 동시에 제시한다.

## 2. 소음진동 데이터의 이미지 변환을 통한 CNN적용

소음진동 품질검사 데이터의 딥러닝 적용 가능성 확인을 위해 수행해야 할 첫 번째 단계는 검사 가능성의 확인이다. 생산라인에서 비전(vision)을 이용한 품질검사에는 이미 딥러닝이 사용되고 있지만, 소음진동 품질검사의 예제는 쉽게 찾아볼 수 없다. 이 연구에서는 먼저 소음진동 데이터를 스펙트로그램(spectrogram)을 통하여 이미지 데이터로 변경하고(그림 1), 잘 알려진 CNN(convolutional neural network)을 적용하여 검사 가능성을 확인하였다<sup>(3,4)</sup>. 그림 1에서 보는 것처럼 스펙트로그램을 통해 시간에 따른 주파수의 변화,

크기의 변화를 한눈에 확인할 수 있다. CNN을 통해 이러한 특성이 학습된다면, 좋은 검사 결과가 나올 것을 기대할 수 있다.

CNN의 시험적 적용을 위해서 기존의 신호처리 방법을 이용한 검사라인의 검사 결과를 사용하였다. 데이터의 총 측정 길이는 7.3초이며, 샘플은 16 kHz이다. 단순히 스펙트로그램을 이용한 이미지로 변환할 경우, 이미지의 크기가 매우 크기 때문에 이미지 필터링을 거친 후 크기를 조절하는 작업을 거쳤다. 3개의 합성곱 레이어를 갖는 CNN을 사용하였으며, 드롭아웃(dropout)과 배치 정규화(batch normalization) 등의 교과서에 나오는 매우 기본적인 기술을 적용하였다. 양품과 불량품 각각 500개의 데이터를 이용하여 교육하고, 불량품 500개를 통해 검증하였다.

교육 및 시험 결과는 그림 2와 같다. 총 정확도가 99.2%로 매우 잘 수렴하였다. 원본 라벨의 정확도가 100%가 아니고, 매우 기초적인 알고리즘을 적용한 것을 감안하자면 매우 높은 수치이다.

## 3. 생산현장 적용을 위해 해결해야 할 문제

소음진동 품질검사를 현장에 활용하기 위해서




그림 1 스펙트로그램을 통한 진동 신호의 이미지 변환 예(7.3초의 진동 데이터)




그림 2 CNN을 이용한 양품 및 불량품 판정 수렴 결과를 표시하는 총 정확도

해결하여 할 가장 중요한 문제는 여타의 다른 딥러닝 문제와 마찬가지로 데이터의 확보이다. 일반적으로 생산 현장에서는 양품만이 생산되고 매우 드물게 불량품이 생산된다. 표 1에서 살펴볼 수 있는 것과 같이, 불량률이 0.1 %인 생산라인에서 60개의 불량 샘플을 확보하기 위해서는 60일이 소요된다. 반면 동기간 내에 총 생산대수는 106,000대에 달한다. 따라서, 일반적으로 딥러닝을 적용할 때 요구되는 균형 있는 숫자의 데이터 확보가 불가능하다. 또한 확보된 불량 샘플에 대해 라벨을 부여하는 작업도 쉽게 수행하기 힘들다. 예를 들어 냉장고와 같은 가전제품의 경우, 가격 및 크기의 문제로 불량 샘플을 공장에 보관할 수 없다. 다양한 데이터를 측정하여 보관할 수는 있으나, 불량률의 종류도 매우 다양하기 때문에 이를 조직적으로 수행하는 것은 매우 큰 노력을 필요로 한다. 어느 정도 단계 이상의 자동차 및 가전제품 부품도 마찬가지이다. 데이터 수집 단계에서는 불량률의 종류 및 수량도 파악할 수 없으므로, 불

량 샘플을 모두 보관하지 않는 이상 데이터의 확보가 쉽지 않다. 따라서, 소음진동 품질검사에 딥러닝을 적용하기 위해서는 대부분 양품으로 구성된 라벨이 없는 데이터 집단을 이용한 딥러닝 방법의 적용이 필수적임을 알 수 있다.

#### 4. 이상 검사

양품이 대부분인 데이터를 이용해 불량품을 선별하는 딥러닝 방법의 개발을 수행하기 위해 이 연구에서 주목한 방법은 이상 검사(anomaly detection) 방법이다<sup>(5,6)</sup>. 이상 검사 방법은 분류(classification) 방법과는 달리, 정상 데이터의 특성을 학습하고 이를 통해 불량을 감지해 내는 방법이다. 그림 3에 개념적으로 표시한 것처럼, GAN(generative adversarial networks)이나 VAE(variational auto encoder) 등의 방법을 사용하여 데이터의 피쳐(feature)를 충분히 학습하고 이상 데이터를 찾아낸다. 마치 과녁에서 멀어지는 화살을 찾아내는 것과 같은 방법이다. 이전에 맞은 수백 발을 화살의 위치로부터 중심과 반경을 찾아내고, 그로부터 멀리 떨어진 타격점을 이상 타격으로 파악하는 방법이다. 이 연구에서는 DCGAN(deep convolutional generative adversarial networks)을 사용하여 이상 검사 방법을 구현하고, 편의상 그 명칭을 도베르만(Dobermann) 이상 검사 방법이라 칭하였다.

이 연구에서 개발한 도베르만 이상 검사를 생산라인 소음진동 품질검사에 사용하여 얻을 수 있는

표 1 불량률에 따른 불량대수 및 총 생산대수

생산 일수	불량률(%) 및 불량 대수				총 생산대수
	0.50	0.10	0.05	0.01	
1	5	1	1	0	1,000
5	25	5	3	1	6,000
10	50	10	5	1	16,000
30	150	30	15	3	46,000
60	300	60	30	6	106,000

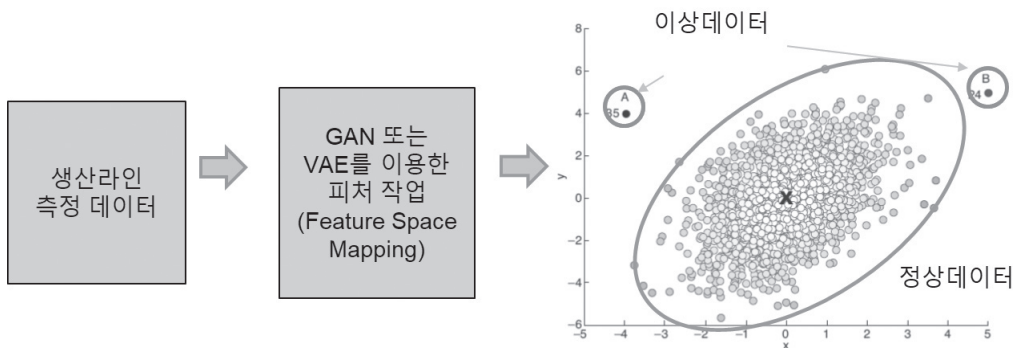


그림 3 GAN 또는 VAE을 이용한 이상 검사 방법의 개념적 설명

장점은 매우 크다. 첫째, 불량품에 대한 정보나 데이터가 없어도 교육이 가능하다. 양품만을 이용해 교육을 실시하므로 불량품을 얻기 힘든 생산라인 소음 품질 검사에 유용하다. 따라서 불량에 대한 구체적인 정보가 없어도 곧바로 검사의 시작이 가능하다. 둘째, 모든 측정 데이터에 검사결과에 따른 인덱스 값이 부여된다. 양품의 중앙값에서 떨어진 정도를 비정상 점수(anomaly score)로 표시해준다. 따라서, 생산되는 제품의 품질 수준을 실시간으로 파악할 수 있다. 셋째, 결과적으로 소음진동 품질검사를 안정시키는 시간을 획기적으로 줄여준다. 불량품이 없어도 검사를 시작할 수 있으며, 객관적이고 일관적인 데이터를 빠른 시간 내에 생성할 수 있다.

### 5. MNIST 데이터를 이용한 검사 성능 확인

이 연구에서 개발한 도베르만 이상검사를 통한 품질검사의 성능은 MNIST(modified national institute of standard and technology) 데이터 베이스의 이미지 데이터를 통해 확인할 수 있다. MNIST 데이터는 '0' 부터 '9' 까지의 숫자를 수기로 기입한 데이터로 모든 데이터에 라벨이 붙어 있다. 분류(classification) 방법의 성능 검사를 위해 주로 사용되는 데이터이다. 이상 검사의 성능을 확인하기 위해서, 총 10가지의 데이터 중 1개를 정상으로 보고 나머지를 비정상상으로 바라보는 접근법을 사용할 수 있다. 즉, '0' 을 정상의 데이

터라고 가정할 경우, '0' 만을 사용해서 딥러닝 네트워크를 교육하고 '0' 이 아닌 데이터가 들어왔을 때, 이를 '비정상(anomaly)' 라고 잘 판단하는지를 살펴보는 방법을 사용할 수 있다.

이 연구에서는 2000개의 '0' 을 이용해 딥러닝 네트워크를 교육시키고, 1000개의 '0' 과 1000개의 '0' 이 아닌 숫자를 입력하여 그 결과를 확인하였다. 그림 4는 그 결과를 히스토그램을 통하여 보여주고 있다. '0' 을 입력하였을 경우에는 비정상 점수가 대부분 매우 낮게 나오고, '0' 이 아닌 숫자를 입력하였을 경우 높은 비정상 점수를 출력하는 것을 알 수 있다. 또한, '9' 나 '6' 을 '0' 과 헛갈리게 썼을 경우에는 중간 정도의 비정상 점수를 출력하는 것을 알 수 있다. 예상 가능한 결과이며, '0' 만을 사용하여 교육한 도베르만 이상 검사 방법이 훌륭하게 작동하는 것을 보여준다.

### 6. 세 단계로 구분된 소프트웨어의 구성

이 연구에서 개발된 도베르만 이상 검사 방법의 적용은 세 단계로 구분되어 이루어질 수 있으며, 상용 소프트웨어로 구성되어 있다. 첫째 단계는 소음 혹은 진동 데이터를 이미지로 바꾸는 단계이다. 소음진동 데이터의 크기 및 해상도에 따라 전처리가 필요하므로 이를 하나의 단계로 구성할 수 있다. 편의상 도베르만 익스플로러(explorer)라 칭하였다. 둘째 단계는 이미지로 변환된 데이터를 통해 도베르만 네트워크를 교육시키는 과정이다. 교

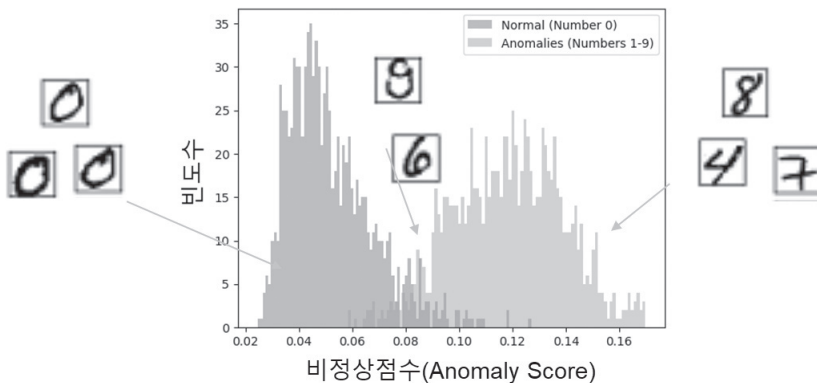


그림 4 MNIST 데이터 베이스를 이용한 도베르만 이상 검사 방법의 검증

육의 정확성을 확인하기 위하여 통계적인 특성을 살펴보는 기능이 필요하다. 기능의 목적에 따라 도베르만 트레이너(trainer)라 칭하였다. 셋째 단계는 교육된 네트워크를 이용해 실제 검사를 수행하는 소프트웨어이다. 교육된 네트워크를 빠르게 적용하는데 주안점을 두어 최대한 간단하게 구성되었다. 도베르만 디텍티브(detective)라 칭하였다. 상기의 세 단계를 이용하여 이 연구에서 개발된 이상 검사 방법을 조직적이고 빠르게 적용할 수 있다. 그림 5에서 세 단계로 구분된 소프트웨어 구성을 볼 수 있다.

## 7. 생산현장 적용 예제

이 연구에서 개발된 도베르만 이상 검사 방법은 자동차 부품, 가전 부품 등의 실제 생산 제품의 소음진동 검사에 다양하게 적용되고 있다. 이 글에서는 가전제품에 들어가는 모터의 검사 사례를 소개하고자 한다.

기존의 신호처리 방법을 이용해 모터류의 소음 검사를 위해서는 일반적으로 주파수 분석 및 인벨

럽 분석, 캡스트럼 분석이 필요하다. 모터의 축에 포함된 베어링의 고장을 판단하기 위해서 인벨럽을 통한 고장 주파수의 진단을 수행한다. 베어링에 포함된 볼의 개수, 내륜과 외륜의 지름 등을 이용해서 고장 주파수를 계산하고, 이 주파수에 따라 임펄스가 발생하는지를 인벨럽 분석 및 캡스트럼 분석을 통해 찾아낸다. 고장의 원인을 정확하게 찾아내는 장점이 있는 반면, 인벨럽을 구하는 과정에서 밴드패스 필터(bandpass filter) 등을 튜닝해주고, 배경소음과의 레벨 차이를 확인하는 등의 비교적 복잡한 안정화 과정을 거쳐야 한다.

도베르만 이상 검사 방법을 사용하는 경우, 복잡한 신호 처리과정을 곧바로 생략할 수 있다. 충분한 양품 데이터를 확보한다면 도베르만 익스플로러와 트레이너를 통해 네트워크를 손쉽게 교육할 수 있다. 그림 6은 가전제품에 들어가는 모터의 소음진동 품질 검사 결과를 나타낸 것이다. 세로축은 생산 시간을 나타내며, 가로축은 비정상 점수를 나타낸다. 각각의 원은 측정된 각각의 모터를 나타낸다. 데이터는 2018년 10월 5일과 6일의 양일간의 데이터이다. 그림 6에서 2018년 10월 5일

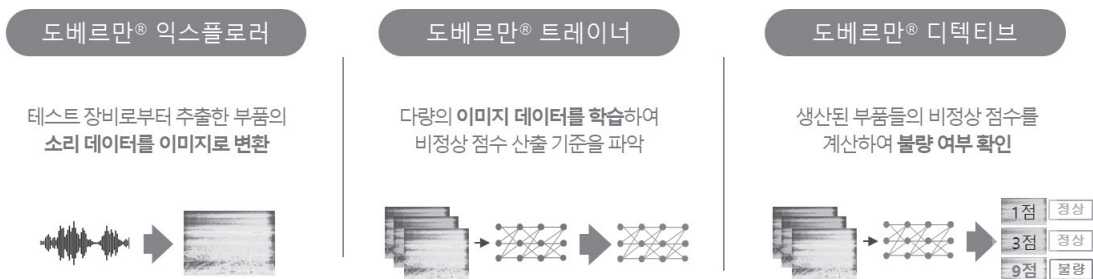


그림 5 세 단계를 통해서 구성된 도베르만 이상 검사 방법




그림 6 가전제품 모터의 도베르만 이상 검사 적용 예(세로축은 생산시간, 가로축은 비정상 점수를 나타냄)






그림 7 딥러닝 방법의 생산라인 품질 검사 적용 시 기대되는 효과

오후에 집중적으로 비정상 데이터가 발생했음을 확인할 수 있다. 정상 분포를 고려해 비정상 점수 0.1 근처에 경계선을 그을 경우, 총 9개의 비정상 샘플을 손쉽게 확인할 수 있다.

## 8. 맺음말

이 연구에서는 생산라인의 소음 품질 검사를 위한 딥러닝 방법을 소개하였다. 기존의 신호처리를 이용한 방법의 안정화 시간문제를 지적하고 이를 해결하기 위하여 딥러닝 방법을 제안하였다. 현장에서의 문제점을 해결하기 위해서는 비대칭적인 데이터의 문제를 해결하여야 함을 지적하고 비정상 검사(anomaly detection)을 해결 방법으로 제시하였다. DCGAN(deep convolutional generative adversarial network)을 이용해 자체 방법을 구성하고 이를 도베르만이라 칭하였다. MNIST의 데이터를 적용하여 도베르만의 적용 가능성 및 정확도를 확인하였다. 가전제품 모터의 적용 사례를 통해 실제 현장에서 사용 가능함을 확인하였다.

이 글의 초기에 언급되었던 것처럼 딥러닝 방법은 검사 인덱스를 계산하는 시간을 획기적으로 단축시켜 준다. 그뿐만 아니라, 개발된 검사 인덱스

의 신뢰도가 개발자에 따라 다르지 않고, 항상 일정한 신뢰도를 갖는다. 따라서, 생산라인에 적용하는 경우, 검사 공정의 개발에 따른 시간을 절약하고 결과적으로 획기적인 비용 절감을 가져올 수 있다(그림 7). **KSNVE**

## 참고문헌

- (1) 국경완, 2019, 인공지능 기술 및 산업 분야별 적용 사례, 정보통신기획평가원 주간기술동향 1888호, pp. 15~27.
- (2) Hadad, Y., 2017, 30 Amazing Applications of Deep Learning, <http://www.yaronhadad.com>.
- (3) Wikipedia, 2019, Convolutional Neural Network, [https://en.wikipedia.org/wiki/Convolutional\\_neural\\_network](https://en.wikipedia.org/wiki/Convolutional_neural_network)
- (4) Bric, 2018, CNN 기본개념, <http://www.birc.co.kr>
- (5) Wikipedia, 2020, Anomaly Detection, [https://en.wikipedia.org/wiki/Anomaly\\_detection](https://en.wikipedia.org/wiki/Anomaly_detection)
- (6) 인투더데이터, 이상 감지 - Anomaly Detection, <http://intothedata.com>