

## 이미지 기반 축산물 불량 탐지에서의 희소 클래스 처리 전략

이범호<sup>1</sup> · 조예성<sup>1</sup> · 이문용<sup>2\*</sup>

### Sparse Class Processing Strategy in Image-based Livestock Defect Detection

Bumho Lee<sup>1</sup> · Yesung Cho<sup>1</sup> · Mun Yong Yi<sup>2\*</sup>

<sup>1</sup>Graduate Student, Graduate School of Data Science, Department of Industrial and System Engineering, KAIST, Daejeon, 34141 Korea

<sup>2\*</sup>Professor, Department of Industrial and Systems Engineering, KAIST, Daejeon, 34141 Korea

#### 요약

인공지능 기술의 발전으로 산업 4.0시대가 열렸고 축산업에서도 ICT 기술이 접목된 스마트 농장의 구현이 큰 관심을 받고 있다. 그중에서도 컴퓨터 비전 기반 인공지능 기술을 접목한 축산물 및 축산 가공품의 품질 관리 기술은 스마트 축산의 핵심 기술에 해당한다. 그러나 인공지능 모형 훈련을 위한 축산물 이미지 데이터 수의 부족과 특정 범주(class)에 대한 데이터 불균형은 관련 연구 및 기술 개발에 큰 장애물이 되고 있다. 이러한 문제들을 해결하기 위해, 본 연구에서는 오버샘플링과 적대적 사례 생성기법의 활용을 제안한다. 제안되는 방법은 성공적인 불량 탐지(Defect detection) 관점을 기반으로 하며, 이는 부족한 데이터 레이블을 효과적으로 활용하는데 필요한 방법이다. 최종적으로 실험을 통해 제안된 방법의 타당성을 확인하고 활용 전략을 검토한다.

#### ABSTRACT

The industrial 4.0 era has been opened with the development of artificial intelligence technology, and the realization of smart farms incorporating ICT technology is receiving great attention in the livestock industry. Among them, the quality management technology of livestock products and livestock operations incorporating computer vision-based artificial intelligence technology represent key technologies. However, the insufficient number of livestock image data for artificial intelligence model training and the severely unbalanced ratio of labels for recognizing a specific defective state are major obstacles to the related research and technology development. To overcome these problems, in this study, combining oversampling and adversarial case generation techniques is proposed as a method necessary to effectively utilizing small data labels for successful defect detection. In addition, experiments comparing performance and time cost of the applicable techniques were conducted. Through experiments, we confirm the validity of the proposed methods and draw utilization strategies from the study results.

**키워드**: 스마트팜, 축산물 관리, 인공지능, 불균형데이터 처리, 이상치 탐지

**Keywords**: Smart farm, livestock operations, Artificial intelligence, Imbalanced data, Anomaly detection

Received 18 October 2022, Revised 30 October 2022, Accepted 30 October 2022

\* Corresponding Author Mun Yong Yi(E-mail:munyi@kaist.ac.kr, Tel:+82-42-350-1613)

Professor, Department of Industrial and Systems Engineering, KAIST, Daejeon, 34141 Korea

Open Access <http://doi.org/10.6109/jkiice.2022.26.11.1720>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.  
Copyright © The Korea Institute of Information and Communication Engineering.

## I. 서 론

인공지능 기술의 발전으로 산업 4.0시대가 열렸고 다양한 산업에서 새로운 워크 플로(Work Flow) 변화를 맞이하고 있다. 컴퓨터 비전 분야는 컴퓨터와 인공지능을 통해 인간의 시각적 능력을 재현하고자 하는 연구 분야이다. 컴퓨터 비전 분야가 크게 발전하면서 특정한 이미지 내 객체의 위치와 종류를 파악하는 객체 인식(Object detection) 모형들의 성능이 크게 향상되었다. 그 결과, 다양한 산업에서 이미지 또는 동영상 기반 자동화 시스템이 구축되고 있고 특히 불량품 탐지(Defect detection) 시스템들이 주목받고 있다[1].

축산업에서도 4차 산업 혁명에 힘입어 ICT 기술이 접목된 스마트 농장의 구현이 큰 관심을 받고 있으며 컴퓨터 비전 기반 인공지능 기술을 접목한 자동 모니터링 및 개체 인식 시스템을 활용하여 축산물 및 축산 가공품의 품질을 관리하고자 하고 있다 [2]. 그러나 인공지능 모형 훈련을 위한 축산물 이미지 데이터의 수가 부족하고 특정한 불량상태를 인식하기 위한 레이블의 비율이 매우 불균등하게 분포되어 있어서 관련 연구 및 기술 개발에 큰 장애물이 되고 있다[2-4]. 게다가 축산물의 경우 시각 정보만으로는 이상 상태와 정상 상태를 구별하기 매우 어렵기 때문에 기존의 이상치 또는 결함 검출 모형만으로 해결하기에는 한계가 있다[5]. 그러나 현업에서 추가로 일일이 데이터를 수집하는 방법 이외에 축산물 데이터가 가지고 있는 데이터 수와 레이블 불균형 문제를 해결할 수는 없으므로, 해당 조건에서 가장 성능을 극대화하는 모형 구축 및 데이터 처리 전략이 중요해진다.

따라서 본 연구에서는 정상과 비정상 레이블이 극도로 불균등하게 분포된 축산물 데이터셋을 활용하여 더 정확한 검출 성능을 보이는 프레임워크 및 전략을 도출하고자 한다. 이를 위해 성공적인 불량 탐지 (Defect detection) 관점에서, 적은 데이터 레이블을 효과적으로 활용하기 위한 방법들을 조사하고 이를 축산물 문제에 적용하여 최적의 방법을 도출하고자 한다.

## II. 관련 연구

본 연구에서는 축산물 불량 탐지에서 문제가 되는 희소 라벨 문제를 해결하기 위해 이상 탐지 (Anomaly

detection)에서 활용되는 방법론을 채택하였다. 본 장에서는 이와 관련된 연구들에 대해 설명한다.

### 2.1. 인공지능 기반 이상 탐지 연구

인공신경망 기반 이상 탐지 기법은 모형의 구성 및 훈련 목표에 따라 크게 세 가지로 나뉜다[6]. 첫 번째는 특징 추출을 위한 딥러닝(Deep Learning for feature extraction)으로 이미지 특징을 추출하는 모형과 이상을 탐지하는 모형이 개별적으로 구성하여 조합되는 것이 특징이며, 특정 이미지들의 이상 탐지 모형 구축을 위한 저차원 특징 표현(Feature representation)을 추출하는 것이 목표이다. 두 번째 기법은 특징 표현의 정규성 학습(Learning feature representations of normality)을 위한 기법으로 이미지 내의 특징을 저차원 공간에서 표현하고 점수화하여 이상 특징을 재구성할 수 있도록 한다. 대표적으로 오토인코더(Autoencoder)를 활용한 이상치 특징추출 방식이 있다. 마지막은 이상치를 점수화하여 직접 학습하는 종단 간 이상치 점수 학습(End-to-end anomaly score learning)이다. 종단 간 학습을 통해 훈련 대상에 맞는 이상치 특징을 추출하고 정규화가 가능하다는 장점이 있지만, 복잡도 높은 문제를 풀기 위해서는 처리 비용(Cost)이 상대적으로 높고 데이터 활용이 효율적이지 못하다는 한계점이 있다. 본 연구에서는 축산물 희소 레이블로 인한 한계점을 해결하기 위해 특징 표현의 정규성 학습 관점에서 새롭게 접근하고자 한다.

### 2.2. 데이터 불균형 해소를 위한 특징 표현의 정규성 학습 모형

재구성 손실 (Reconstruction Loss)함수는 이상치 탐지 수행하는 데 사용되는 대표적인 손실함수다. 이 함수를 활용하여 오토인코더 기반 탐지 모형에서 재구성한 값과의 손실 값을 비교하고 정상적인 데이터의 특성을 학습한다. 이때 이상치를 포함한 데이터의 경우 완전하게 재구성되기 어렵기 때문에 재구성되지 않는 데이터를 이상치로 간주한다. 이러한 기법은 다양한 인코더 기반 탐지 모형에서 활용되었는데 다양한 구조를 가진 오토인코더들의 앙상블(Ensemble) 결과물을 활용하는 RandNet[7]이나 오토인코더와 주성분분석(Principal component analysis)의 특성들을 조합하여 이상치를 판단하는 Robust Deep Autoencoder[8]가 그 예이다.

이상치의 정규성을 학습하는 기법 중에서 가장 많이

활용되고 있는 방식은 단일 클래스 분류 기반 특성을 학습하는 방식(One-class classification-based measure dependent feature learning)이다[6,9]. 이 방식을 활용한 학습 모형은 서포트 벡터 머신(Support vector machine) 기법과 유사하게 사용자가 지정한 하나의 클래스 레이블의 특성을 확실하게 학습하고 새로운 인스턴스가 훈련데이터와 유사한지 판단하게 된다. 이를 위해 재구성 손실 외에도 각 클래스 군집 간의 거리를 활용하는 방법이 자주 이용되고 있었는데 대표적으로 DeepSVDD[10]와 DeepSAD[11]와 DevNet[9]이 있다.

DeepSVDD는 학습된 공간 (Feature space)에서 정상 데이터를 둘러싼 가장 작은 구를 찾고 그 경계와의 거리를 계산하여 이상치를 감지한다. DeepSAD는 DeepSVDD에 심층신경망 기반 비지도 학습을 적용한 것으로 훈련된 인코더 모델을 활용하여 대부분의 정상적인 데이터를 훈련하는데 재구성 손실을 토대로 최적화한다. 이때 군집의 중심에서 일정 수준 이상 벗어난 인스턴스는 이상치로 간주하게 된다. DevNet는 희소 레이블의 영향력을 극대화하기 위한 단일 클래스 학습 방식으로 적대적 학습 (Adversarial learning)을 통해 이상치를 합성·추정하고 별도로 정상 데이터를 학습한 구분자 (Discriminator)를 통해 추정된 이상치가 실제 이상치인지 판별한다. 이러한 학습 기법들은 매우 직관적이고 구현이 용이하며 성능이 우수하다는 장점이 있다. 하지만, 데이터 노이즈에 취약하고, 특성 공간(Feature space)에서 ‘구현된 이상치의 특성’이 데이터의 ‘실제 이상치의 특성’과 다를 수 있으므로, 이상치가 희소하게 포함된 사례에 적용하는 경우 성능의 저하가 우려된다 [5,6]. 최근 연구에서는 DeepSAD의 재구성 손실 기반 군집 학습과 적대적 학습 모형을 추가하여 극도로 희소한 이상치 레이블 수가 포함된 데이터에도 기존 모형들보다 나은 성능을 보이는 사례가 있었으나 희소 데이터의 적용과 모형의 강건성을 확보하는 차원에서는 추가적인 검증이 필요한 상황이다[5].

### 2.3. 희소 레이블 문제를 해소하기 위한 데이터 샘플링(Sampling)

모형적인 접근 이외에 불균형 데이터를 분석하는 데 가장 많이 사용되고 기본이 되는 기법은 데이터 샘플링이다[12]. 대표적인 데이터 샘플링의 기법에는 오버샘플링 (Oversampling)과 언더샘플링 (Undersampling)이 있다. 오버샘플링은 소수 클래스의 데이터를 반복적으로 활용하여 그 수를 증가시키는 기법으로 데이터 손실이

발생하지 않는다는 장점이 있다. 그러나 샘플링되는 데이터 수가 증가하면서 희소 데이터가 가지고 있는 특징이 사라지거나 반복되는 데이터 학습으로 과적합 문제가 발생할 수 있다.

언더샘플링의 경우 과소한 데이터 레이블의 수에 맞추어서 다수의 레이블 수를 줄여 전체 비율을 맞추는 방식이기 때문에 희소 클래스 데이터를 더 효율적으로 활용할 수 있다는 장점이 있다. 하지만 학습하는 전체 데이터 수가 적기 때문에 성능 저하 문제와 편향된 학습 문제가 발생할 수 있다. 특히 군집 기반 학습에서 그 명암이 갈리는 데 언더샘플링으로 비용 대비 효율은 높게 나오지만, 학습 데이터가 가지는 특성이 제대로 학습되지 않는 사례가 종종 나오고 있다[12]. 이외에도 오버샘플링과 언더샘플링을 모두 활용하는 하이브리드 방법이 있으나 기본적으로 각 샘플링이 가지는 한계에서 벗어나지 못한다.

상기 특징을 고려할 때 데이터 불균형이 심해서 희소 데이터 비율이 아주 적은 상태의 데이터셋에서 언더샘플링이나 하이브리드 방법을 적용하면 너무 많은 데이터의 특징을 잃을 수 있어서 해당 기법 적용이 부적절할 수 있다. 또한, 본 연구에서는 불균형 상태가 심한 데이터셋 환경에서의 데이터 처리를 연구 주제로 삼고 있으므로 결과적으로 우세한 클래스의 샘플을 덜어내어 불균형을 해소하는 언더샘플링 기법을 적용하는 것은 적합하지 못하다. 따라서 본 연구에서는 오버샘플링에 더 초점을 두고 매우 적은 비율의 희소 레이블이 포함된 데이터셋을 분석하는 데 있어 오버샘플링 필요성을 분석하고 검증하고자 한다.

### 2.4. 적대적 사례 (Adversarial example)를 활용한 불균형 데이터 레이블 처리

적대적 사례는 인스턴스에 노이즈를 추가하여 다른 클래스로 오인하도록 유도하는 인스턴스를 말한다[13]. 적대적 사례는 Szegedy et al.[14]에 의해 처음 소개되었으며 이후 분류기(Classifier)의 강건함을 확보하기 위해 적대적 사례를 인위적으로 생성하여 모형 학습에 적용하는 연구들이 지속적으로 나타나고 있다[15]. 가장 널리 알려진 적대적 사례의 생성 방법은 FGSM(Fast Gradient Sign Method) 방식[16]이 있는데 심층신경망의 손실함수를 증가시켜 분류기를 쉽게 속일 수 있는 적대적 사례를 만들어 낸다. FGSM은 단순하지만 효과가 좋은 방법으로 알려져 있으며 이외에도 가우스 분포를 따르는 노

이즈 (Gaussian noise)를 추가하거나[17]나 강화된 변이 샘플을 생성하는[18] 등 다양한 방법으로 노이즈에 강한 이상치 탐지 모형을 만드는 데 공헌하여 왔다.

Table. 1 Summary of prior research

Research Domain	Methodology type	Related Studies
Anomaly detection methodology	Learning feature representations of normality	RandNet[7], Robust Deep Autoencoder[8]
	One-class classification-based measure dependent feature learning	DeepSVDD[10], DeepSAD[11], DevNet[9], Adversarial Autoencoder using Loss Inversion[5]
Data strategy for sparse class treatment	Data sampling[12]	Oversampling, Undersampling, Hybrid Sampling
	Adversarial example generation	Fast Gradient Sign Method[16], Gaussian noise[17], Generating hardened variants samples[18]

본 연구에서는 불량 탐지 관점에서 정상 데이터에 대한 적대적 공격 사례를 생성하여 불량 사례로 레이블을 지정하고, 불량 탐지 모형 학습에 추가하여 그 성능을 검증하고자 한다. 이를 위해 인위적으로 만들어진 적대적 사례를 희소 레이블로 추가하여 데이터를 오버샘플링하고, 결과적으로 노이즈에 강건한 모형 학습을 확보하고자 한다. 또한, 과적합을 방지하고, 모형의 강건함을 확보하기 위한 접근법으로 희소 레이블에 포함되지 않는 불량 특징까지 탐지하기 위한 모형 구축 전략을 제안하고자 한다. 우리는 본 연구 목표에 맞는 샘플링 방법론을 조합하기 위해 대표적인 적대적 사례 생성 방법인 FGSM과 Gaussian Noise를 각각 적용하여 그 성능을 비교할 예정이다. 다음 장에서는 오버샘플링과 적대적 생성 전략을 비교하기 위한 축산물 불량 탐지 모형과 활용 데이터에 관해 설명하고 샘플링과 적대적 사례 생성 방법에 관해 설명한다.

### III. 축산물 데이터 내 희소 클래스 처리 방법 비교를 위한 불량 탐지 모형 프레임워크

#### 3.1. 모형 프레임워크 개요

본 연구에서는 오버샘플링과 적대적 사례 생성기법

을 통해서, 축산 데이터셋 내 희소한 불량 클래스를 보다 효과적으로 처리하고, 희소 클래스에 모형의 강건성을 확보하고자 한다. 또한, 각 기법의 효과와 최적의 조합을 분석하고자 한다. 이를 위해 기존 연구에서 축산물 불량 탐지 연구에 활용된 모형[5]과 데이터 셋[19]을 활용하였다(그림 1 참조).

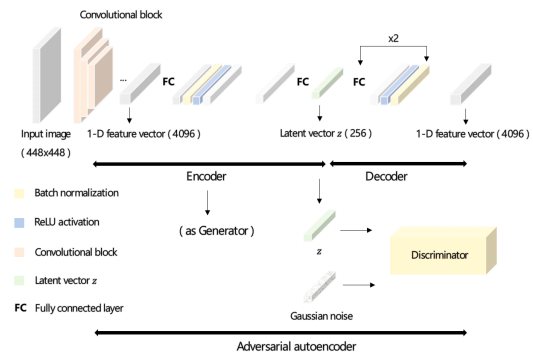


Fig. 1 Livestock defect detection model architecture[5]

본 연구에서 활용하는 불량 탐지 모형은 적대적 오토인코더 모형을 활용한 단일 클래스 이상치 분류 모형으로 입력된 이미지 데이터의 특징을 합성곱 신경망(Convolution Neural Network)를 통해 추출하고 이를 적대적 오토인코더에서 저차원 벡터로 변환-재구성하면서 재구성 손실을 측정하고 학습에 활용한다. 이때 재구성은 원본 이미지가 아닌 추출된 벡터 x에 대해 적용되며, 재구성 손실에 손실 역전(Loss inversion)을 추가하여 불량 사례가 입력되었을 때 나타나는 손실을 극대화하였다. 이때 적용된 재구성 함수는 다음과 같다.

$$\min_{\theta} \frac{1}{n} \sum_{i=1}^n \|x_i - \hat{x}_i\|_2^2 + \frac{2}{m} \sum_{i=n+1}^{n+m} (\|x_i - \hat{x}_i\|_2^2)^{-1} \quad (1)$$

여기서 n은 정상 이미지 사례이고 m은 불량 사례이다. 첫 번째 항은 벡터 x와 재구성된 x 간의 손실(거리)을 계산하며 두 번째 항은 불량 사례에 대한 손실에 역수를 취하도록 설계되었다. 따라서 불량 데이터의 경우 재구성 손실은 증가하게 되며 정상 사례와 비교하였을 때 확실하게 구분될 수 있도록 보조한다.

상기 손실 역전을 활용한 적대적 인코더 모형은 기존의 대표적인 이상 탐지 모형인 DeepSAD와 DevNet과 비교하였을 때 불량 레이블 비율이 3% 미만으로 포함된 축산물 데이터셋을 분류하는 과제 수행에서 더 높은 성

능을 보였다[5].

### 3.2. 활용 데이터셋

데이터는 CIFAR-10[20]과 닭 도체 품질 이미지 데이터셋[19]이 활용되었다. 우리는 공개된 CIFAR-10 데이터셋을 활용함으로써 먼저 구현된 모델의 유효성을 검증할 수 있었다. 또한, CIFAR-10 데이터셋의 경우 축산물 관련 데이터에 비해서 상대적으로 클래스 불균형 수준이 낮고, 이미지의 클래스 간 구분이 비교적 명확하다. 따라서, 좀 더 일반적이고 복잡도가 낮은 이미지 데이터를 활용하였을 때 제안된 모형 성능과 희소 클래스 처리 전략에 따른 차이를 비교할 수 있다. CIFAR-10 데이터셋을 단일 클래스 분류 기반의 이상 탐지 과제에 맞추어 활용하기 위해 2가지 등급(항공기와 자동차)을 포함하는 7,500개의 이미지를 추출하여 훈련 데이터셋을 구성하였고 이때 정상 대 비정상 클래스의 비율을 2:1(항공기:자동차)로 설정하였다. 또한 검증용 데이터셋은 별도로 1,500장의 이미지를 추가로 선별하여 동일한 비율로 배분하였다.

닭 도체 품질 이미지 데이터셋은 정보화진흥원에서 AI학습을 위해 제공하는 축산물 품질 데이터셋을 활용하였다[19]. 해당 데이터셋은 국내 닭 가공 공장에서 활용되는 닭도체 이미지로 구성되어 있으며 해당 도체 상태에 따라 정상 도체와 파계 도체로 구분되어 있다. 파계 클래스는 부러진 다리, 상처를 입은 피부, 구부러진 날개 등 제품 형태와 관련된 이상치를 모두 포함하고 있다(그림 2 참조). 표2는 본 연구에서 활용된 CIFAR-10 데이터셋과 닭 도체 품질 데이터셋의 구성이다.




Fig. 2 Chicken image examples. Left: normal ; Right: defect(wing torn apart with bruise).

축산물 중에서도 특히 가금류의 품질과 관련하여 불량(파계)이 나타나는 비율은 3% 미만으로 알려져 있다 [3]. 게다가 농장에서부터 최종 가공까지 생장 및 처리 관계에 따라 양질의 상품만 남겨지기 때문에 실제 불량 탐지 수집에 따른 비율은 더욱 불균등해진다. 수집된 닭 도체 품질 데이터에서도 총 30,493개의 이미지 중에서 파계로 분류된 이미지는 85개 (1:0.0028 비율)에 불과하다는 점을 보면 현업에서 수집할 수 있는 불량 축산물 데이터가 매우 희소하다는 것을 알 수 있다. 따라서 축산물 관련 불량 탐지 학습에서 희소 클래스를 처리하는 전략을 수립하는 것이 중요한 과제라고 할 수 있다.

Table. 2 Dataset composition

Dataset	Purpose	Normal	Defect
CIFAR-10	Train	5,000	2,500
	Test	1,000	500
Chicken	Train	30,223	55
	Test	270	30

## IV. 희소 데이터 처리 비교 실험 및 비교 결과

### 4.1. 불량 탐지 모형의 매개 변수 설정 및 성능 평가

본 연구에서는 활용하는 불량 탐지 모형의 매개 변수(hyper-parameter)를 표3과 같이 정의하였다. 매개 변수는 각 데이터셋에 동일하게 적용하였고 각 데이터셋 조건에 수행한 불량 탐지의 성능을 비교하였다. 성능 평가에는 AUROC(Area Under the Receiver Operating Characteristic curve)가 활용되었다. 비교 결과 닭 도체 데이터셋 조건에서의 탐지 성능은 0.760로 CIFAR-10 조건의 0.988보다 현저하게 떨어지는 것을 확인하였다(표4 참조). 이를 통해 기존 연구들에서 지적되었던 클래스 불균형 수준과 모형 학습 성능의 연관성을 확인할 수 있었고 희소 클래스 처리의 필요성을 재확인할 수 있었다.

Table. 3 Defect detection model hyper-parameter

Parameter	Value
Epoch	200 with early stopping
Input Size	448 x 448
Batch Size	16
Optimizer	SGD
Learning Rate	0.0001
Weight Decay	0.0005

#### 4.2. 희소 데이터 처리 설정

CIFAR-10의 경우 실험에 활용되는 탐지 모형의 검증과 불량 탐지 모형의 성능 비교 대상으로 활용하고자 하였다. 또한 CIFAR-10 데이터셋의 경우 클래스 불균형 수준이 비교적 낮았기 때문에 희소 데이터에 대한 추가적인 처리는 답도체 품질 데이터셋 조건을 중심으로 진행하였다.

##### 4.2.1. 오버샘플링

답도체 품질 데이터셋에서 모형 학습용 데이터 내 과제 레이블에 오버샘플링을 적용하였다. 55개의 과제 데이터를 반복적으로 추가하여 총 1,100개 사례로 오버샘플링하였고 최종적으로 정상 대 과제 비율을 1:0.03으로 조정하여 실제 현장에서 확인되는 3%의 과제 비율에 맞추었다[3]. SMOTE[21]와 같이 인위적으로 샘플 수를 늘리는 방법도 검토되었으나 활용하는 불량 탐지 모형에서 적대적 특성 학습을 활용하는 방식이 SMOTE의 거리 기반 샘플 증강 방법과 유사한 부분이 있고, 불량 클래스의 데이터 수가 현저하게 적은 상태에서 해당 데이터를 이용한 인위적인 데이터 증강 작업은 과적합의 위험을 더 늘릴 수 있으므로 해당 방법의 적용은 배제하였다.

오버샘플링 된 데이터셋을 활용하여 불량 탐지 학습을 수행한 결과 모형 성능이 0.929로 미처리 조건의 성능(0.760) 대비 성능이 크게 증가한 것을 알 수 있었다(표 4 참조). 이로써 희소 데이터의 학습 성능을 높이기 위해 일정 수준 이상의 오버샘플링이 꼭 필요하다는 것을 확인할 수 있었다.

##### 4.2.2. 적대적 사례 생성

본 연구에서는 FGSM과 Gaussian Noise를 적용하여 비교하였다. 클래스 불균형 수준에 따른 적대적 생성 사례의 효과를 심도 있게 비교하기 위해 답도체 품질 데이터셋과 CIFAR-10 모두 활용하여 실험을 진행하였다. FGSM을 활용한 적대적 공격 사례 생성은 입력되는 정상 이미지 데이터에 (2)의 공식을 대입하여 생성하였다.

$$x_{new} = x_n + \epsilon \text{sign}(\Delta_x J(\theta, x_{recon}, x)) \quad (2)$$

상기 식에서  $x_n$ 은 입력된 이미지를 나타내고 두 번째 항이 더해지면서 적대적 사례가 생성된다.  $x_{recon}$ 은 오토 인코더에 의해 재구성된  $x_n$ 을 의미한다. J함수는 재구성

손실을,  $\theta$ 는 모델의 가중치를 의미한다. 여기서 J의 기울기를 계산하여 sign함수를 적용하면 적대적 공격 값이 결정되는데 여기서 공격 값의 크기는 하이퍼 파라미터인  $\epsilon$ 에 의해 결정되는데 학습 목표에 맞게 최적화할 필요가 있다.

Gaussian Noise를 이용한 생성사례는 입력 이미지의 크기와 동일한 해상도의 이미지를 정규분포를 따르는 수치를 생성하여 더해주는 방식으로 입혀진다. 따라서 정규분포의 모양을 결정하는 평균( $\mu$ )과 표준편차( $\sigma$ )를 대입하고자 하는 작업과 사례에 맞게 역시 최적화할 필요가 있다. 본 연구에서는 상기 적대적 사례 생성에 필요한 최적화를 위해 베이저안 최적화(Bayesian optimization)를 수행하였다[22].

표4는 각 데이터별로 적대적 사례 기법이 적용된 후 수행된 불량 탐지 성능이다. 답도체 품질 데이터셋의 경우 오버샘플링 여부에 따른 차이가 있을 것으로 예상되어 오버샘플링이 적용된 조건과 적용되지 않는 조건의 성능을 모두 비교하였다. 결과적으로 적대적 생성사례가 추가되었을 때 성능이 크게 향상되는 것을 확인할 수 있었다. 특히 FGSM의 경우 불균형이 심한 오버샘플링이 되지 않은 실제 답도체 품질 데이터 조건에서 가장 큰 성능향상을 보였고 Gaussian Noise 적용 시에도 유사한 성능향상을 이루었다. 그러나 불균형 수준이 비교적 낮은 조건(CIFAR-10과 오버샘플링이 적용된 답도체 품질 데이터셋 조건)에서는 Gaussian Noise를 적용하였을 때 월등히 좋은 성능을 보였다. 본 비교 실험의 결과를 통해 적대적 생성사례를 활용한 희소 데이터 처리의 효용성을 확인할 수 있었으며 특히 불균형 수준에 따라 적대적 사례 생성기법이 다르게 적용되어야 함을 알 수 있었다.

**Table. 4** Defect detection performance according to types of the adversarial example generation and the dataset

Dataset	Type	AUROC
CIFAR-10	baseline	<b>0.988</b>
	FGSM	0.969
	G.N	0.983
Chicken (real world data)	baseline	0.760
	FGSM	<b>0.820</b>
	G.N	0.812
Chicken with over-sampled data	baseline	0.929
	FGSM	0.949
	G.N	<b>0.978</b>

4.2.3. 학습 및 하이퍼 파라미터 최적화 시간 비교

본 연구에서는 각 조건에서의 학습 및 하이퍼 파라미터 최적화에 소요된 시간을 측정하였고 사후검정 차원에서 비교하였다. 비교를 위해 분 단위로 소요 시간을 비교하였고 그 결과는 표 5와 같다.

표5에서 볼 수 있듯이 오버샘플링과 적대적 사례 생성으로 인하여 학습에 필요한 전체 시간이 늘어나고 있는 것을 확인할 수 있었다. 또한 적대적 사례 생성기법에 따른 모형 학습 시간에는 차이가 없었으나 파라미터 최적화에 따른 차이가 있음을 알 수 있다. 전반적으로 한 번의 최적화 수행 당 소모된 최적화 작업시간이 Gaussian Noise 조건에서 소폭 늘어나는 것을 확인할 수 있었다. 이는 최적화에 필요한 파라미터 수(FGSM: 2개, Gaussian Noise: 1개)의 차이에 기인한 것으로 추정된다. 결과적으로 Gaussian Noise를 오버샘플링 된 데이터 셋에 적용할 경우 가장 좋은 성능을 보이지만 최적화 수행이 반복될수록 소모 비용이 크게 늘어날 수 있다. 따라서 목표로 하는 데이터와 시간 등 비용 효율을 고려하여 FGSM을 선택적으로 활용하는 것도 필요하다.

**Table. 5** Comparison of time required for model training and hyper-parameter optimization

Dataset	Type	Average training time per epoch	Elapsed time for hyper parameter optimization per iteration
Chicken with over-sampled data	baseline	170 min.	-
	FGSM	191 min.	533 min.
	G.N	191 min.	559 min.

V. 결 론

인공지능 기반 축산물 관리 분야는 그 유망성에도 불구하고 데이터 수집 난이도가 높고 데이터 불균형이 극심하여 다른 1차 산업 분야에 비해 발전 속도가 매우 더딘 편이다[4]. 이러한 상황을 극복하기 위한 한 방법으로 적은 데이터를 최대한 활용하여 분석 수준을 높이는 접근방법이 필요하게 되었다.

이에 본 연구는 축산물 데이터에서 희소한 불량 데이터를 이상 탐지 (Anomaly detection) 관점으로 접근하여 새로운 데이터 처리 기법을 제안하고, 실험을 통해 기법들을 비교 분석하였다. 또한 본 연구에서는 제안된 방

법의 실제적 타당성과 활용 전략 수립을 위해서 현업에서 수집한 축산물 품질 데이터에 적용하였으며, 실제 축산물 데이터의 분석을 토대로 오버샘플링과 적대적 사례 생성기법의 활용을 통해 축산 데이터셋 내 희소한 불량 클래스를 보다 효과적으로 처리하고, 강건성을 확보할 수 있음을 확인하였다.

또한 CIFAR-10 및 실제 현업에서 수집한 축산데이터를 활용하여 다른 불균형 수준을 가진 데이터셋에 따라 두 가지 대표적인 적대적 생성이 가지는 차이를 비교하였다. 그 결과, 데이터 불균형 수준과 불량 탐지 난이도에 따라서 FGSM 및 Gaussian Noise 방식을 선택적으로 적용하는 전략이 필요함을 확인했다. 우리는 본연구의 결과가 향후 축산물 상품 검증 자동화뿐만 아니라 생산 관리에 필요한 이상치 탐지 모형 개발에 이바지할 수 있을 것으로 생각한다.

다만, 본 연구에서 수행한 실험은 특정 축종에 대한 데이터만을 가지고 수행하였다. 그 때문에 본문에 제시된 비교 결과가 해당 데이터셋에 특화된 수치로 볼 수도 있어서 일반화에 대한 한계점이 있다. 또한, 더 다양한 기법들을 비교에 적용하지 못한 부분도 본 연구의 한계점이라 볼 수 있다.

본 연구가 희소데이터 처리 전략의 필요성과 이와 관련된 기술의 효과성을 검증한 탐색적 연구이기는 하나, 연구관점에서 일반화 가능성의 범위를 더 이해하고 정확도 성능을 더욱 향상시키는 방법을 개발하는 것 역시 중요하다[2]. 따라서 추후 연구에서는 일반화와 성능향상 차원에서 더 다양한 모형, 데이터 처리 기법들을 적용하고 데이터의 포함되는 축종을 확장하여 더 높은 신뢰도와 효율성을 확보하는 전략을 구축할 수 있어야 할 것이다.

**ACKNOWLEDGEMENT**

This work was supported by Korea Institute of Planning and Evaluation for Technology in Food, Agriculture and Forestry (IPET) and Korea Smart Farm RD Foundation (KosFarm) through Smart Farm Innovation Technology Development Program, funded by Ministry of Agriculture, Food and Rural Affairs (MAFRA) and Ministry of Science and ICT (MSIT), Rural Development Administration (RDA) (421043-04)

## REFERENCES

- [ 1 ] A. A. Tulbure, A. A. Tulbure, and E. H. Dulf, "A review on modern defect detection models using DCNNs - Deep convolutional neural networks," *Journal of Advanced Research*, vol. 35, pp. 33-48, Jan. 2022.
- [ 2 ] H. Farhood, I. Bakhshayeshi, M. Pooshideh, N. Rezvani, and A. Beheshti, "Recent advances of image processing techniques in agriculture," in *Artificial Intelligence and Data Science in Environmental Sensing*, 1st ed. Cambridge, MA: Academic Press, ch. 7, pp. 129-153, 2007.
- [ 3 ] J. H. Choe, J. C. Lee, and C. U. Jo, "Relationship between the economical defects of broiler meat carcass and quality grade A with a meat grader," *Food Science of Animal Resources*, vol. 29, no. 4, pp. 494-499, Aug. 2022.
- [ 4 ] D. A. B. Oliveira, L. G. R. Pereira, T. Bresolin, R.E.P. Ferreira, and J. R. R. Dorea, "A review of deep learning algorithms for computer vision systems in livestock," *Livestock Science*, vol. 253, no. 104700, pp. 1-15, Sep. 2021.
- [ 5 ] H. S. Kim, N. Muallifah, Y. Cho, B. Lee, and M. Y. Yi, "Deep Learning-based Defect Detection on Livestock Operations," in *Proceedings of the International Conference on Research in Adaptive and Convergent Systems*, New York: NY, USA, pp. 21-27, 2022.
- [ 6 ] G. Pang, C. Shen, L. Cao, and A.V.D. Hengel, "Deep learning for anomaly detection: A review," *ACM Computing Surveys (CSUR)*, vol. 54, no. 2, pp. 1-38, Mar. 2021.
- [ 7 ] J. Chen, S. Sathe, C. Aggarwal, and D. Turaga, "Outlier detection with autoencoder ensembles," in *Proceedings of the 2017 SIAM international conference on data mining*, Houston: TX, USA, pp. 90-98, 2017.
- [ 8 ] C. Zhou and R.C. Paffenroth, "Anomaly Detection with Robust Deep Autoencoders," in *Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining*, Halifax: NS, Canada, pp. 665-674, 2017.
- [ 9 ] G. Pang, C. Shen, and A. van den Hengel, "Deep Anomaly Detection with Deviation Networks," in *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*, New York: NY, USA, pp. 353-362, 2019.
- [10] L. Ruff, R. Vandermeulen, N. Goernitz, L. Deecke, S. A. Siddiqui, A. Binder, E. Muller, and M. Kloft, "Deep One-Class Classification," in *Proceedings of International conference on machine learning(PMLR)*, Stockholmssmassan, Stockholm, Sweden, pp. 4393-4402, 2018.
- [11] L. Ruff, R. A. Vandermeulen, N. Goernitz, A. Binder, E. Muller, K. -R. Muller, and M. Kloft, "Deep Semi-Supervised Anomaly Detection," *arXiv preprint*, arXiv: 1906.02694, 2019.
- [12] V. Ganganwar, "An overview of classification algorithms for imbalanced datasets," *International Journal of Emerging Technology and Advanced Engineering*, vol. 2, no. 4, pp. 42-47, Apr. 2012.
- [13] W. Zhao, H. Li, L. Wu, L. Zhu, X. Zhang, and Y. Zhao, "Robustness of classifier to adversarial examples under imbalanced data," in *Proceedings of 7th International Conference on Computer and Communication Systems (ICCCS)*, Wuhan, China, pp. 156-161, 2022.
- [14] C. Szegedy, W. Zaremba, I. Sutskever, J. Bruna, D. Erhan, I. Goodfellow, and R. Fergus, "Intriguing properties of neural networks," *arXiv preprint*, arXiv:1312.6199, 2013.
- [15] F. Tramer, A. Kurakin, N. Papernot, I. Goodfellow, D. Boneh, and P. McDaniel, "Ensemble adversarial training: Attacks and defenses," *arXiv preprint*, arXiv:1705.07204, 2017.
- [16] I. J. Goodfellow, J. Shlens, and C. Szegedy, "Explaining and Harnessing Adversarial Examples," *arXiv preprint*, arXiv: 1412.6572, 2014.
- [17] K. Lee, K. Lee, H. Lee, and J. Shin, "A Simple Unified Framework for Detecting Out-of-Distribution Samples and Adversarial Attacks," *Advances in neural Information Processing Systems*, vol. 31, pp. 1-11, Dec. 2018.
- [18] F. Specht, J. Otto, O. Niggemann, and B. Hammer, "Generation of Adversarial Examples to Prevent Misclassification of Deep Neural Network based Condition Monitoring Systems for Cyber-Physical Production Systems," in *2018 IEEE 16th International Conference on Industrial Informatics (INDIN)*, Porto: Portugal, pp. 760-765, 2018.
- [19] National Information Society Agency, Livestock Quality (QC) Image Dataset [Internet]. Available: <https://aihub.or.kr/aidata/30733>.
- [20] A. Krizhevsky, "Learning Multiple Layers of Features from Tiny Images," University of Toronto, Technical Report, 2009.
- [21] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *Journal of artificial intelligence research*, vol. 16, pp. 321-357, Jun. 2002.
- [22] A. H. Victoria and G. Maragatham, "Automatic tuning of hyperparameters using Bayesian optimization," *Evolving Systems*, vol. 12, no. 1, pp. 217-223, Mar. 2021.





**이범호(Bumho Lee)**

2015.8: 연세대학교 인지과학협동과정 졸업 (인지공학 석사)  
2019.2 - 현재: 한국과학기술원 데이터사이언스 대학원 박사과정  
※ 관심분야: 빅데이터, 인공지능, 디지털 콘텐츠, 사용자 경험 분석



**조예성(Yesung Cho)**

2022.2: 한동대학교 ICT창업학부 졸업 (공학사)  
2022.3 - 현재: 한국과학기술원 데이터사이언스 대학원 석사과정  
※ 관심분야: 컴퓨터 비전, 머신러닝



**이문용(Mun Yong Yi)**

1993: University of Maryland 공학박사 (Information Systems)  
1998-2009: University of South Carolina 조교수, 부교수  
2009-현재: 한국과학기술원 산업및시스템공학과 부교수, 교수  
※ 관심분야: 컴퓨터 비전, 빅데이터, 인공지능, 사용자 경험 분석