

CNN-Based Thread Defect Detection System for Manufacturing Process Automation

Yeong-Seo Lee*, Seongbae Eun**, Dong-beom Shin***, Jae-Heum Lee****

*Researcher, Dept. of Information and Communication Engineering, Hannam University, Daejeon, Korea

**Professor, Dept. of Information and Communication Engineering, Hannam University, Daejeon, Korea

***Principal Researcher, Electronics and Telecommunications Research Institute (ETRI), Daejeon, Korea

****Director, Research Institute, Netvision Telecom, Daejeon, Korea

[Abstract]

In this paper, we propose a deep learning-based thread error detection system for improving the quality reliability of fastening parts in automated manufacturing environments. Thread images are acquired using a camera and acceptance or rejection is automatically determined based on a convolutional neural network (CNN). To overcome recognition limitations caused by repetitive and fine thread structures, the image acquisition environment and learning strategy were designed to ensure stable performance with limited training data. Experimental results showed 85% accuracy with 84% Precision and 82% Recall, confirming suppression of false and missed detections. The results confirm that the system can be applied to automatic defect determination in manufacturing processes.

▶ **Key words:** Deep learning, Vision-based inspection, Thread defect detection, Convolutional neural network, Manufacturing automation

[요 약]

본 논문에서는 제조 공정 자동화를 위한 딥러닝 기반 나사산 오류 검출 시스템을 제안한다. 카메라로 획득한 나사산 영상을 합성곱 신경망(CNN)을 이용해 합격 및 불합격으로 자동 판정한다. 반복적이고 미세한 나사산 구조로 인한 인식 한계를 극복하기 위해 영상 획득 환경과 학습 전략을 구성하여 제한된 학습 데이터에서도 안정적인 성능을 확보하였다. 실험 결과 85% 정확도, Precision 84%, Recall 82%의 성능을 보여 오검출과 미검출을 억제할 수 있음을 확인하였다. 이를 통해 제조 공정 자동 불량 판정 시스템으로 적용 가능성을 확인하였다.

▶ **주제어:** 딥러닝, 영상 기반 검사, 나사산 오류 검출, 합성곱 신경망, 제조 공정 자동화

-
- First Author: Yeong-Seo Lee, Corresponding Author: Seongbae Eun
 - *Yeong-Seo Lee (ysone11@naver.com), Dept. of Information and Communication Engineering, Hannam University
 - **Seongbae Eun (sbeun@hnu.kr), Dept. of Information and Communication Engineering, Hannam University
 - ***Dong-beom Shin (sdb@etri.re.kr), Electronics and Telecommunications Research Institute (ETRI)
 - ****Jae-Heum Lee (leejhmi@gmail.com), Research Institute, Netvision Telecom
 - Received: 2026. 01. 23, Revised: 2026. 02. 12, Accepted: 2026. 02. 23.
 - This paper is an extension of the paper presented at the 73rd Winter Conference of the Korean Computer Information Society in 2026 ("Deep Learning Technology-Based Thread Error Detection System").

I. Introduction

제조 공정의 자동화가 고도화됨에 따라, 딥러닝 기반 영상 인식 기술을 활용한 지능형 품질 검사 및 설비 상태 진단 기술의 중요성이 지속적으로 증가하고 있다. 특히 체결 부품과 같은 소형 구성 요소의 결함은 제품 신뢰성과 안전성에 직접적인 영향을 미치기 때문에, 이를 정밀하게 검출하기 위한 자동 검사 기술에 대한 연구가 활발히 이루어지고 있다[1,2].

최근에는 ResNet, Wide Residual Network, YOLO 등 다양한 딥러닝 모델을 기반으로 볼트 및 체결부 결함을 검출하거나, 자동 검사 및 치수 측정을 수행하는 방법들이 제안되었다[1,3,4]. 또한 제한된 학습 데이터 환경에서도 성능을 확보하기 위한 전이학습 기반 접근 방법도 보고되고 있다[5]. 이러한 연구들은 체결 부품 검사 자동화 가능성을 보여주었다는 점에서 의미가 있다.

그러나 기존 연구들은 대부분 볼트 또는 너트의 외관 결함, 존재 여부 판별, 표면 상태 분석에 초점을 두고 있으며, 체결 성능에 직접적인 영향을 미치는 나사산(thread) 구조 자체의 오류를 정밀하게 검출하는 연구는 상대적으로 부족한 실정이다. 나사산은 반복적이면서도 시작점이 불규칙한 미세 구조를 가지며, 촬영 조건과 조명 환경 변화에 민감하여 안정적인 영상 기반 검출이 어렵다.

이에 본 논문에서는 렌즈, 조명, 딥러닝 기법을 통합적으로 적용한 나사산 오류 검출 시스템을 제안한다. 제안된 방법은 영상 획득 단계에서의 광학적 설계를 고려하여 나사산 형상 정보를 안정적으로 확보하고, 딥러닝 기반 분석을 통해 자동 판정을 수행함으로써 제조 공정에서의 검사 정확도와 신뢰성 향상을 목표로 한다.

본 논문의 구성은 다음과 같다. II장에서는 데이터 및 센서 기반 제조 공정과 딥러닝 기반 외관 결함 검출에 관한 관련 연구를 정리한다. III장에서는 나사산 오류 검출을 위한 시스템 구조와 영상 획득 환경을 설명하고, 영상 기반 검출을 위한 기술적 고려사항을 제시한다. IV장에서는 제한된 학습 데이터 환경을 고려한 딥러닝 기반 나사산 검출 전략과 적용된 CNN 모델 구조, 학습 환경 및 실험 결과를 분석한다. 마지막으로 V장에서는 본 연구의 결론과 향후 연구 방향을 제시한다.

II. Preliminaries

2.1. Data and sensor-based manufacturing processes

제조 산업에서는 생산 효율과 품질 일관성 확보를 위해 제조공정 자동화 기술이 지속적으로 발전하고 있다. 자동화 공정 환경에서는 공정 조건 변화가 품질에 직접적인 영향을 미치므로, 공정 파라미터와 품질 간의 관계를 체계적으로 관리하기 위한 데이터 기반 공정 분석 및 공정 윈도우 개념이 활용되고 있다[6,7].

자동화 설비의 정밀도와 신뢰성은 볼스크류 및 체결 부품과 같은 핵심 기계 요소의 상태에 크게 의존한다. 반복 하중과 장시간 운전에 따른 열화는 공정 오차의 원인이 되며, 이를 해결하기 위해 관성 센서 기반 비침습적 상태 감시 기법이 자동화 생산 라인에 적용 가능한 유지보수 기술로 제안되고 있다[8,9].

또한, IoT 및 센서 융합 기술의 발전은 제조공정 자동화 시스템의 지능화를 촉진하고 있다. 센서와 영상 데이터를 활용한 자동 모니터링 기술은 설비 이상을 조기에 감지하고 공정 신뢰성을 향상시키는 기반 기술로 활용되고 있다[10].

2.2. AI based research in manufacturing

제조 공정에서의 외관 결함 검출은 제품의 품질과 신뢰성 확보를 위한 핵심 검사 공정으로, 최근에는 딥러닝 기반 영상 인식 기술을 활용한 자동화 검사 시스템이 활발히 연구되고 있다. 기존의 규칙 기반 영상 처리 방식은 조명 변화나 형상 다양성에 취약한 반면, 합성곱 신경망(CNN)을 이용한 접근 방법은 복잡한 결함을 보다 안정적으로 검출할 수 있는 대안으로 제시되고 있다[6]. 기존 CNN 기반 비전 검사 관련 연구는 외관 결함 검출을 중심으로 한 연구, 체결 부품을 대상으로 한 결함 분석 연구, 그리고 공정 및 설비 상태 분석과 연계된 시스템 연구의 세 가지 범주로 구분할 수 있다.

먼저 CNN 기반 외관 결함 검출 연구에서는 볼트 및 너트와 같은 체결 부품의 외형적 결함을 분류하거나 표면 상태를 분석하는 방법들이 제안되었다. 특히 CNN을 활용한 볼트 외관 결함 분류 기법이 보고되었으며[6], 제조 공정 환경에서 요구되는 정확도와 추론 성능을 동시에 만족시키기 위한 딥러닝 기반 비전 검사 시스템의 성능 개선 연구도 수행되었다[7]. 이러한 연구들은 딥러닝 기반 외관 결함 검출 기법이 산업 현장에 적용 가능함을 보여준다.

한편 외관 결함 검출 연구는 단순한 영상 판별을 넘어 공정 조건 및 설비 상태 분석과 연계되는 방향으로 확장되고 있다. 공정 윈도우 분석을 위한 머신러닝 기법[8], 센서 기반 설비 상태 감시 기술[9], IoT 기반 설비 모니터링 시스템[10] 등은 제조 공정 전반의 안정성과 신뢰성을 향상

시키기 위한 접근 방법으로 제안되고 있다. 그러나 이러한 기존 연구들은 주로 외관 결함이나 설비 상태 분석에 초점을 두고 있으며, 체결 성능에 직접적인 영향을 미치는 나사산(thread) 구조 자체의 오류를 영상 기반으로 정밀하게 검출하는 연구는 상대적으로 제한적이다. 본 논문에서는 이러한 한계를 보완하고자 나사산 구조에 특화된 CNN 기반 자동 오류 판정 시스템을 제안한다.

III. System Structure for Thread Error Detection

3.1. System structure

기판 상부에는 촬영을 위한 조명과 카메라가 배치되어 있으며, 나사는 기판 위에 고정된 상태로 위치한다. 기판 하단에는 상하 및 좌우 방향의 미세 위치 조절을 가능하게 하는 마이크로미터 핸들이 장착되어 있다.




Fig. 1. Physical structure of the system

3.2. Technical considerations for thread image-based inspection

기술적 고려 사항을 크게 3가지로 설명한다.

1) 나사산 오류 검출은 반복적이고 미세한 나선형 구조를 안정적으로 인식해야 한다는 점에서 일반적인 외관 결함 검출과는 다른 기술적 어려움을 가진다. 나사산의 시작점과 끝점은 촬영 위치에 따라 상이하게 나타나며, 이러한 구조적 특성은 특정 기준점에 의존하는 규칙 기반 방식이나 단일 기준점 정의를 적용하는 데 한계를 가진다.

본 연구의 목표는 단순히 나사산을 정상 또는 불량으로 분류하는 것이 아니라, 촬영된 영상에서 나사산의 산(crest)과 골(root) 위치를 직접 인식하고 해당 지점에 포인트를 추출하는 것이다. 이를 위해 본 연구에서는 영상

전반에 걸쳐 반복적으로 나타나는 나사산 형상 패턴을 CNN이 학습하도록 구성하여, 나사산 시작점의 불규칙성이나 촬영 위치 변화에도 불구하고 crest 및 root 위치를 안정적으로 검출할 수 있도록 설계하였다.




Fig. 2. Acquisition and analysis of screw images using a telecentric lens

2) 영상 획득 과정에서 발생하는 원근 왜곡과 금속 표면 반사는 나사산 형상 인식 정확도를 저하시키는 주요 요인이며, 이는 crest 및 root 위치를 정밀하게 검출하는 데 직접적인 영향을 미친다. 일반 렌즈 사용 시 촬영 조건 변화에 따라 나사산의 크기와 간격이 달라 보일 수 있으며, 과도한 반사 영역은 CNN 기반 특징 추출 과정에서 위치 오인식의 원인이 된다.

본 연구에서는 이러한 문제를 완화하기 위해 텔레센트릭 렌즈를 적용하여 영상 내 픽셀 좌표와 실제 길이(mm) 간의 정량적 대응이 가능한 영상 획득 환경을 구성함으로써 촬영 위치 변화에 따른 원근 왜곡을 최소화하였다. 또한 조명 각도 및 광량을 조절하여 금속 표면에서 발생하는 과도한 반사를 억제하고, 나사산 형상의 대비를 안정적으로 확보하였다.

이와 같은 광학적 설계와 조명 조건을 통해 영상의 기하학적 일관성을 확보함으로써, CNN 기반 분석 과정에서 crest 및 root 위치가 보다 안정적으로 검출되고, 이후 mm 단위의 정밀한 위치 측정이 가능하도록 하였다.



Fig. 3. A picture of a thread

조명 조건의 영향으로 좌측 영역에서는 영상 획득 품질이 저하된 반면, 우측 영역에서는 나사산 형상이 비교적

명확하게 관측된다. 이를 통해 촬영 환경이 나사산 영상 품질에 큰 영향을 미침을 확인할 수 있다.

3) 또한 제조 현장에서는 나사산 결함 데이터 확보에 제약이 존재하므로, 소규모 학습 데이터 환경에서도 안정적인 검출 성능을 확보할 수 있는 접근이 요구된다. 이에 본 연구에서는 렌즈 및 조명 조건을 고려한 영상 획득 환경을 기반으로 입력 영상의 기하학적 일관성을 확보하고, CNN의 계층적 특징 학습 특성을 활용하여 나사산 형상의 반복 패턴과 국소적 구조를 동시에 학습하는 딥러닝 기반 위치 검출 구조를 적용하였다.

이러한 통합적 접근을 통해 제한된 학습 데이터 환경에서도 학습 불안정성을 완화할 수 있었으며, 촬영 조건 및 환경 변화에 대해서도 crest 및 root 위치 검출 성능이 비교적 안정적으로 유지됨을 확인하였다. 위와 같은 기술적 고려 사항을 바탕으로, 본 연구에서는 나사산 오류 검출을 위해 영상 획득 환경과 딥러닝 기반 분석 과정을 통합한 탐색 구조를 설계하였다. 획득된 나사산 영상은 전처리 과정을 통해 기하학적 일관성과 대비가 확보되며, 이후 CNN 기반 모델을 통해 나사산의 crest 및 root 위치가 자동으로 추출되고, 해당 좌표 정보를 기반으로 정상 및 오류 여부가 판별된다.

Table 1. Thread detection problems and response strategies in limited learning data environments

Category	Conventional Approach	Proposed Method (This Study)
Training data scale	Requires large-scale data	Uses small-scale data
Image acquisition	General shooting environment	Image acquisition considering lens & lighting
Learning stability	Performance decreases due to lack of data	Stable learning
Detection reliability	Sensitive to environmental changes	Robust to environmental changes
Applicability	Limited field applicability	Applicable in the field

3.3. Detection scenario and design of the threaded error detection algorithm

이를 바탕으로, 본 알고리즘은 나사산 영상 획득, 전처리, CNN 기반 특징 추출, 그리고 오류 판정 단계로 구성된 탐색 시나리오를 따른다.

CNN은 영상 내 나사산의 반복적 패턴과 미세 형상 변화를 학습하여 오류 여부를 판별하는 핵심 모듈로 사용되며, 세부 네트워크 구조와 학습 과정은 4장에서 상세히 설명한다.

나사산 오류를 자동으로 판별하기 위해, 본 연구에서는 영상 획득과 딥러닝 기반 분석을 결합한 검사 알고리즘을 설계하였다.

Fig. 4에 도시된 바와 같이, 본 알고리즘은 나사산 영상

획득 단계와 딥러닝 기반 영상 분석 및 판정 단계로 구성된다. 획득된 영상은 전처리 과정을 거쳐 특징이 강조되며, 이후 CNN 기반 모델을 통해 나사산 오류 여부가 판별된다.




Fig. 4. Algorithm flow of the screw automatic detection system

제안된 알고리즘은 영상 획득부터 분석 및 판정까지의 전 과정을 자동으로 수행함으로써, 나사산 불량에 대한 자동 판정이 가능한 검사 시스템을 구현한다.

IV. Deep Learning Network

4.1. Thread detection strategy considering limited learning data

제조 현장에서 수집되는 나사산 결함 데이터는 발생 빈도가 낮고 결함 유형이 다양하여 대규모 학습 데이터를 확보하는 데 한계가 있다. 이러한 제한된 데이터 환경은 딥러닝 모델의 학습 안정성과 일반화 성능을 저하시킬 수 있으므로, 이에 적합한 학습 전략과 모델 구조에 대한 검토가 요구된다. 기존 연구에서는 합성곱 신경망(CNN)의 계층적 특징 추출 능력을 활용할 경우 비교적 적은 데이터 환경에서도 유의미한 성능을 확보할 수 있음을 보고하고 있다[11].

특히 사전 학습된 CNN 모델을 활용한 전이학습(transfer learning)은 제한된 학습 데이터 환경에서 효과적인 접근 방법으로 제안되고 있다[12]. 전이학습은 대규모 데이터셋을 통해 학습된 저수준 및 중간 수준의 특징을 재활용함으로써, 소량의 도메인 특화 데이터만으로도 안정적인 학습이 가능하다는 장점을 가진다. 이러한 특성은 반복적이면서도 미세한 구조적 특징을 가지는 나사산 영상 분석에 적합하다.

Fig. 5는 대규모 데이터셋으로 사전 학습된 CNN의 특징을 소규모 나사산 영상 데이터에 전이하여 학습하는 전이학습의 개념을 도시한다. 전이학습은 특정 객체 자체를 이전하는 방식이 아니라, 영상 전반에 공통적으로 나타나는 특징 표현을 활용하는 방법이다.




Fig. 5. A picture of transfer learning

한편, 본 연구에서는 제한된 나사산 결함 데이터 환경에서 최적의 검출 성능을 확보하기 위해 단일 CNN 구조에 국한되지 않고, 여러 CNN 기반 알고리즘을 대상으로 한 상대적 성능 비교를 통해 나사산 오류 검출에 적합한 모델을 탐색하였다. 이를 통해 데이터 수량의 한계를 보완하면서도 안정적인 검출 성능을 확보할 수 있는 나사산 검출 전략을 수립하고자 하였다.

본 연구에서 사용된 CNN은 합성곱 계층을 통해 영상의 국소적 특징을 단계적으로 학습하고, 최종적으로 완전연결 계층을 통해 나사산의 합격 및 불합격을 분류한다. 이러한 구조는 반복적이고 미세한 패턴을 가지는 나사산 형상을 효과적으로 인식하는 데 적합하다.

Fig. 6은 본 연구에서 적용한 ResNet-34 기반 CNN의 전체 구조를 나타낸다.




Fig. 6. ResNet-34 structure

4.2. Deep learning model

본 연구에서는 제한된 학습 데이터 환경에서 나사산 오류 검출에 적합한 딥러닝 모델을 선정하기 위해, 기본적인 CNN 구조와 전이학습 기반 CNN 모델, 그리고 잔차 연결(residual connection)을 포함한 ResNet 기반 모델을 대상으로 상대적 성능 비교를 수행하였다. 그 결과, 일부 CNN 구조는 제한된 데이터 환경에서 과적합 또는 학습 불안정성을 보인 반면, ResNet 기반 모델은 안정적인 학습 특성과 우수한 일반화 성능을 나타내어 최종 모델로 선정되었다.

적용된 CNN 모델은 잔차 연결을 포함한 ResNet 기반 구조로 설계되었으며, 다단계(feature-level) 특징 학습을 통해 나사산의 형상 정보를 효과적으로 표현한다. 입력 특징 x 에 대해 합성곱 연산 결과 $F(x)$ 를 직접 더하는 잔차 학습 방식을 사용함으로써, 하위 계층에서는 나사산의 윤곽선 및 미세 형상과 같은 저수준 특징을, 상위 계층에서는 결함 여부와 관련된 고수준 특징을 안정적으로 학습할 수 있다.




Fig. 7. Residual block structure

Fig. 7은 잔차 연결 방식이 적용된 기본 블록의 구조를 도시한다. 이러한 잔차 학습 구조는 기울기 소실 문제를 완화하여 깊은 신경망에서도 안정적인 학습을 가능하게 한다.

ResNet은 2015년 ILSVRC에서 Top-5 error 3.57%로 1위를 기록한 모델로, 깊은 신경망 구조에서도 우수한 성능을 보이는 것이 특징이다. 본 연구에서는 이러한 ResNet의 구조적 장점을 활용하여, 제한된 나사산 결함 데이터 환경에서도 안정적인 오류 검출이 가능한 ResNet-34 기반 CNN 모델을 적용하였다.

4.3. Training environment and data

훈련 환경은 다음과 같다.

- CPU: Intel Xeon E5-2620 v4 2.1GHz
- RAM: 32GB
- GPU: RTX 2080 Ti (11GB Memory)

훈련 데이터는 딥러닝 모델 학습에 적합하도록 전처리 과정을 거쳤으며, 제한된 결함 데이터 환경을 보완하기 위해 데이터 증강 기법을 적용하였다. 이를 통해 훈련 데이터의 다양성을 확보하고 모델의 과적합을 방지하고자 하였다. 또한, 전이학습 기반 학습 전략을 적용하여 사전 학습된 CNN 모델의 특징을 나사산 영상 데이터에 효과적으로 전이함으로써, 소량의 학습 데이터 환경에서도 안정적인 학습 성능을 확보하였다.

훈련 데이터는 정상 나사산과 결함이 포함된 나사산 영상으로 구성되었으며, 나사산 시작점의 불규칙성과 형상 변화 특성을 반영하기 위해 다양한 촬영 조건에서 획득된 이미지를 학습에 활용하였다. 이러한 데이터 구성은 제한

된 학습 데이터 환경에서도 모델의 일반화 성능을 확보하는 데 기여한다.




Fig. 8. Threaded cases used as training data

모델 학습은 GPU 기반 딥러닝 환경에서 수행되었으며, 학습률(learning rate), 배치 크기(batch size), 에폭(epoch) 수와 같은 주요 학습 파라미터를 조정하여 안정적인 수렴을 유도하였다. 손실 함수 기반의 최적화 기법을 적용하였으며, 훈련 과정 중 검증 데이터를 활용한 성능 모니터링을 통해 과적합을 방지하였다. 이러한 학습 전략과 파라미터 설정을 통해 나사산 오류 검출에 적합한 모델을 구축하였다.

Table 2. Comparison of learning conditions based on the number of training data and learning parameters

Experimental number	Number of training data	Learning Rate	Batch Size	Epoch	Training Time (min)
Case 1	500	0.001	16	30	18
Case 2	1,000	0.001	16	30	32
Case 3	1,000	0.0005	16	40	45
Case 4	2,000	0.0005	32	40	68
Case 5	2,000	0.0001	32	50	95

4.4. Analysis of experimental results and performance

제안된 나사산 오류 검출 시스템의 성능을 검증하기 위해, 학습된 CNN 모델을 이용한 시험을 수행하였다. 시험은 정상 나사산과 결함 나사산 영상 데이터를 대상으로 진행되었으며, 모델의 판정 성능을 정확도를 포함하여 Precision과 Recall 관점에서 함께 분석하였다.

Table 3. Performance evaluation of thread defect detection using accuracy, precision, and recall

Class	Training Data	Test Data	Precision (%)	Recall (%)	Accuracy(%)
Normal thread	200	50	86.0	86.0	-
Defective thread	150	50	85.2	85.2	-
Overall	350	100	85.6	85.6	85.6

Accuracy는 전체 시험 데이터에 대한 정상 및 결함 나사산 분류의 전반적인 정확도를 나타내며, 제안된 모델이 다양한 촬영 조건에서도 안정적인 판정을 수행할 수 있음을 보여준다. 한편 Precision은 결함으로 판정된 나사산 중 실제 결함 비율을 의미하며, 이는 오검출(false positive)을 최소화하는 측면에서 제조 공정 자동화 환경에서 중요한 지표이다. Recall은 실제 결함 나사산 중 모델이 올바르게 검출한 비율을 나타내며, 미검출(false negative)로 인한 불량 유출을 방지하는 데 핵심적인 지표이다.

실험 결과, 제안된 CNN 기반 모델은 제한된 학습 데이터 환경에서도 Precision과 Recall 지표에서 균형 잡힌 성능을 보였으며, 이는 반복적이고 미세한 나사산 구조에 대한 안정적인 특징 학습이 가능함을 의미한다. 또한 촬영 위치 및 조명 조건 변화에도 비교적 안정적인 판정 성능을 유지함을 확인하였다. 이는 영상 획득 단계에서의 광학적 설계와 CNN 기반 계층적 특징 학습 구조가 결합된 결과로 판단된다.

특히 데이터 수집 제약이 존재하는 제조 현장 환경에서도 본 시스템이 신뢰성 있는 자동 나사산 오류 검출 시스템으로 실용적으로 적용될 수 있음을 시사한다.

Table 4. Performance comparison with baseline and deep learning models

Class	Training Data	Test Data	Precision (%)	Recall (%)	Accuracy(%)
Normal thread	200	50	86.0	86.0	-
Defective thread	150	50	85.2	85.2	-
Overall	350	100	85.6	85.6	85.6

본 연구에서 사용한 CNN 기반 모델의 선택 타당성을 검증하기 위해 전통적인 규칙 기반 방법 및 다른 CNN 기반 딥러닝 모델과의 성능 비교를 수행하였으며, 그 결과 ResNet-34 기반 모델이 제한된 학습 데이터 환경에서도 가장 안정적인 학습 특성과 우수한 검출 정확도를 나타내어 제조 공정 자동화 환경에 적합함을 확인하였다.

V. Conclusions

본 논문에서는 제조 공정 자동화 환경에서 체결 부품의 품질 신뢰성을 향상시키기 위해 딥러닝 기반 나사산 오류 검출 시스템을 제안하였다. 기존 외관 결함 검출 연구가

볼트 및 너트의 존재 여부나 표면 결함 판별에 초점을 두었던 반면, 본 연구는 체결 성능에 직접적인 영향을 미치는 나사산 구조 자체의 오류를 영상 기반으로 자동 판정하는 것을 목표로 하였다. 이를 위해 하드웨어 외형과 촬영 환경을 고려한 시스템 구성을 기반으로, 영상 획득 단계와 CNN 기반 딥러닝 분석 단계를 통합적으로 설계하여 반복적이고 미세한 나사산 구조에 대한 안정적인 특징 표현을 확보하고자 하였다.

또한, 제조 현장에서 빈번히 발생하는 제한된 학습 데이터 환경을 고려하여, CNN의 계층적 특징 학습 특성과 전이학습 개념을 활용한 나사산 검출 전략을 적용하였다. 그 결과 대규모 데이터 확보가 어려운 조건에서도 나사산 오류 검출이 가능함을 확인하였으며, 제안된 시스템이 안정적인 자동 판정 성능을 보임을 확인하였다.

향후 연구에서는 다양한 규격과 형상의 나사산을 포함한 데이터셋 확장을 통해 제안된 시스템의 일반화 성능을 강화할 예정이다. 또한 실제 생산 라인 환경을 고려하여 추론 시간, 연산 복잡도 및 메모리 요구량에 대한 분석을 수행하고, 이를 기반으로 실시간 나사산 오류 검출 시스템으로의 확장을 검토할 계획이다. 아울러 조명 변화, 오염, 마모 등 실제 제조 환경에서 발생할 수 있는 다양한 외란 조건을 고려한 강건한 나사산 검출 기법으로의 확장을 목표로 한다.

ACKNOWLEDGEMENT

This research was supported by the Regional Innovation System & Education (RISE) program through the Daejeon RISE Center, funded by the Ministry of Education (MOE) and the Daejeon Metropolitan City, Republic of Korea. (2025-RISE-06-013)

REFERENCES

- [1] L. Xiao, B. Wu, and Y. Hu, "Missing Small Fastener Detection using Deep Learning," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 1-9, 2021. DOI: 10.1109/TIM.2020.3023509
- [2] E. S. Noh, S. R. Lee, M. S. Kim and S. M. Hong, "Identification of Bolt Coating Defects Using CNN and Grad-CAM," *Journal of Mechanical Science and Technology*, vol. 44, no. 11, pp. 835-842, 2020. DOI: 10.3795/KSME-A.2020.44.11.835
- [3] L. Liu, J. Zhao, Z. Chen, B. Zhao, and Y. Ji, "A New Bolt Defect Identification Method Incorporating Attention Mechanism and Wide Residual Networks," *Sensors*, Vol. 22, no. 19, art. 7416, Sep. 2022. DOI: 10.3390/s22197416.
- [4] J. Yang and C. H. Lee, "Real-Time Data-Driven Method for Bolt Defect Detection and Size Measurement in Industrial Production," *Actuators*, vol. 14, no. 4, art. 185, 2025. DOI: 10.3390/act14040185
- [5] M. J. Kim, "AI model development for surface defect detection from image", M.S. Theses, Chosun univ., Gwangju, Republic of Korea, 2020
- [6] S. B. Lee and S. S. Lee. "Image Classification of Damaged Bolts using Convolution Neural Networks." *JOURNAL OF AEROSPACE SYSTEM ENGINEERING*, vol. 16, no.4, pp.109-115, 2022. DOI: 10.20910/JASE.2022.16.4.109
- [7] H. S. Shin "Improving Accuracy and Inference Speed for Deep Learning-based Visual Inspection in Manufacturing Process" Professional Master's Thesis, Seoul National University, Seoul, Republic of Korea, 2020.
- [8] Cabrera, M.L., Zouhri, W., Zimmer-Chevret and S. et al. "An overview of strategies for identifying manufacturing process window through design of experiments and machine learning techniques while considering the uncertainty associated with." *Int J Adv Manuf Technol* 134, 4981-5019 (2024).
- [9] V. Pandhare, M. Miller, G. W. Vogl, and J. Lee "Ball Screw Health Monitoring with Inertial Sensors" *IEEE Transactions on Industrial Informatics* Vol. 19, no.6 pp. 7323-7334, 2022. DOI: 10.1109/TII.2022.3210999
- [10] T. Y. Lee. "Smart Management System in NPP based on IoT and UAV (1)" Master's Thesis, Hanyang University, Graduate School, Seoul, Republic of Korea, 2014
- [11] X. Zhao, Y. Zhang, J. Wang, and L. Chen, "A review of convolutional neural networks in computer vision," *Artificial Intelligence Review*, vol. 57, no. 3, pp. 1-45, 2024, doi: 10.1007/s10462-024-10721-6.
- [12] D. J. Lee, S. J. Jeon, and D. H. Lee, "Comparative analysis of pre-trained CNN models based on deep learning for image classification," *Journal of the Korean Institute of Communications and Information Sciences Conference Proceedings*, vol. 26, no. 1, pp. 370-373, 2022.
- [13] Y. H. Choi, "Implementation of an IoT-Based Monitoring System for Smart Factory," Master's Thesis, Inha University, Incheon, Republic of Korea, 2021.
- [14] J. P. Kim, "A Study on the Advancement of Smart Factories Based on Real-Time Big Data Collection and AI Modeling Analysis," Ph.D. Dissertation, Hansung University, Seoul, Republic of Korea, 2022.

Authors



Yeong-Seo Lee received the B.S. degree in Information and Communication Engineering from Hannam University, Korea. She is currently pursuing the M.S. degree at Soongsil University, Korea.



Seongbae Eun received the B.S. degree in Computer Engineering from Seoul National University, Korea, in 1985, and the M.S. and Ph.D. degrees in Computer Science from Korea Advanced Institute of Science and

Technology (KAIST), Korea, in 1987 and 1995, respectively. He is currently a Professor at Hannam University, Korea. His research interests include embedded systems.



Dong-beom Shin received the B.S., M.S., and Ph.D. degrees from Chungnam National University, Korea, in 1991, 1993, and 2010, respectively. He worked as a Researcher at Agency for Defense Development (ADD),

Korea, from 1993 to 2000. He has been a Principal Researcher at Electronics and Telecommunications Research Institute (ETRI), Korea, since 2000.



Jae-Heum Lee received the B.S. degree in Computer Science from Soongsil University, Korea, in 1983, and the M.S. degree in Computer Science from Hannam University, Korea, in 1993.

From March 1983 to December 2024, he was a Principal Researcher with the Electronics and Telecommunications Research Institute (ETRI), Korea. During his tenure at ETRI, he focused on wired and wireless networks, router protocols, RFID/USN, and IoT, as well as various technology convergence projects. Since January 2025, he has been serving as the Research Director (Research Institute Head) at Netvision Telecom. His research interests include AI-based security and safety solutions, smart factory technologies, and industrial inspection systems.