



3차원 포인트 클라우드 기반 객체 탐지와 공간 데이터 후처리 알고리즘을 활용한 선박 블록 지지대 설치 정확도 검사

정기석¹·박본영²·이동건^{3,†}

국립목포해양대학교 대학원 해양시스템공학과¹

국립목포해양대학교 첨단해양모빌리티학과²

국립목포해양대학교 조선해양공학과^{3,†}

Inspection of Ship Block Support Installation Accuracy using Object Detection and Spatial Data Post-processing Algorithms based on 3D Point Cloud

Ki-Seok Jung¹·Bon-Yeong Park²·Dong-Kun Lee^{3,†}

Department of Ocean System Engineering, Graduate School, Mokpo National Maritime University¹

Department of Ocean Mobility and Smart Engineering, Mokpo National Maritime University²

Department of Naval Architecture and Ocean Engineering, Mokpo National Maritime University^{3,†}

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.

Precise support installation is critical for ship structural safety. However, conventional inspection methods are inefficient due to the time-consuming nature of point-by-point measurement and limitations caused by line-of-sight obstructions in confined block environments. To address these issues, this study proposes an automated inspection methodology utilizing 3D point cloud data and spatial data post-processing. The proposed approach consists of robustly detecting support regions from 3D scans and applying DBSCAN and RANSAC-based shape fitting to extract precise coordinates. These as-built measurements are then registered with design CAD data to quantitatively calculate installation errors. Validation in an actual shipyard demonstrated that the system accurately distinguishes between normal and defective installations with millimeter-level precision, effectively removing noise from field data to ensure reliability. By digitizing manual quality control through 3D spatial technology, this study offers a practical foundation for smart shipyard automation and high-precision digital twin construction.

Keywords : Smart shipyard(스마트 조선소), 3D point cloud(3차원 포인트 클라우드), Object detection(객체 탐지), Spatial data post-processing(공간 데이터 후처리), Ship block support(선박 블록 지지대)

1. 서론

4차 산업혁명 기술의 도입과 함께 조선해양 산업은 생산성 향상과 공정 최적화를 목표로 하는 스마트 조선소(smart shipyard)로의 전환을 가속화하고 있다. 특히 선박 건조 공정 전반을 가상 공간에 구현하여 모니터링하고 제어하는 디지털 트윈(digital twin) 기술이 주목받고 있으며 Iwańkiewicz and Rutkowski (2023)는 이

러한 디지털 트윈 구축의 핵심 선결 과제로 설계 치수와 실제 제작 치수를 일치시키는 치수 품질 관리(dimensional quality control)의 중요성을 강조하였다. 그러나 대형 구조물인 선박 블록의 특성상 용접 변형 등으로 인한 오차가 빈번하게 발생하며 이를 검사하는 과정은 여전히 작업자의 수작업에 크게 의존하고 있는 실정이다. 이에 따라 Poggi et al. (2020)이 언급한 바와 같이 최근 조선업계에서는 작업자의 안전을 확보하고 검사 효율을

높이기 위해 로봇 및 자율 시스템을 활용한 원격 자동 검사 기술 도입이 시급한 과제로 대두되고 있다. 현재 조선소 현장에서는 선박 블록의 치수 정밀도를 검사하기 위해 광파기(Total station)를 주로 사용하고 있으나 Wang et al. (2020)은 광파기 기반의 점(Point) 단위 계측 방식이 대량의 측정 데이터를 확보하기 어렵고 과도한 검사 시간이 소요된다는 한계를 지적하며 이에 대한 대안으로 고속 3차원 레이저 스캐닝(Terrestrial Laser Scanning, TLS) 기술과 CAD 모델 정합 기법의 도입 필요성을 제기하였다. 실제로 Yoon et al. (2015)은 대형 해양 구조물의 조립 단계에서 3차원 포인트 클라우드 데이터를 활용한 형상 관리 기법을 제안하여 그 효용성을 입증하였으며 Lee and Park (2023)은 이를 소형 선박의 목업 및 몰드 제작 단계에 적용하여 정량적 품질 관리 프로세스를 정립하는 등 조선해양 분야에서의 3차원 스캐닝 활용 연구가 활발히 진행되고 있다.

이처럼 계속된 3차원 포인트 클라우드는 비정형 대용량 데이터라는 특성상 유의미한 정보를 추출하기 위해서는 고도화된 처리 알고리즘이 필수적이며 건설 및 제조 분야에서는 이미 딥러닝과 기하학적 알고리즘을 융합한 연구가 선행되고 있다. Wu et al. (2024)은 건설 현장의 거푸집 검사를 위해 RANSAC 및 DBSCAN 알고리즘을 활용한 자동 검사 프레임워크를 제안하였으며 Guo et al. (2025)은 판금 부품 제조에서, Ben Abdallah et al. (2019)은 항공기 배선 조립체 검사에서 각각 3차원 스캔 데이터와 CAD 모델을 비교하여 정밀한 형상 오차를 분석하는 기술을 선보였다. 또한, Hsieh and Ruan (2023)은 실내 포인트 클라우드의 의미론적 분할(semantic segmentation) 정확도를 높이기 위해 딥러닝 결과에 기하학적 후처리를 결합하는 하이브리드 접근법의 유효성을 증명한 바 있다. 그러나 조선소 환경은 타 산업에 비해 구조물이 훨씬 복잡하고 협소하며 반사나 분진으로 인한 데이터 노이즈가 심하다는 특수성이 있다. Ha and Ku (2024)는 이중 선체(double hull) 블록 내부와 같은 극한 환경에서 로봇의 장애물 인식을 위해 RANSAC과 복셀화 기법을 적용하였으나 이는 주행을 위한 거시적 형상 인식에 그쳤다. 품질 관리 측면에서는 Lee et al. (2021)이 딥러닝(PointNet)을 활용해 LNGC 화물창의 비계 시스템을 탐지하는 연구를 수행하였으나 벽면을 비계로 오인하는 등의 오차를 완전히 배제하지 못해 정밀 계측을 위해서는 추가적인 기술적 보완이 요구되었다.

또한 선행 연구를 통해 조선소 데이터에 최적화된 전처리 및 후처리 방법론은 지속적으로 연구되어 왔다. Jung and Lee (2025)는 딥러닝 기반 객체 탐지 성능을 유지하기 위한 최적의 포인트 클라우드 밀도 기준을 제시하였으며 Jung et al. (2025)은 오픈 소스 기반의 노이즈 제거 및 다운샘플링 알고리즘을 통해 대용량 선박 블록 데이터의 처리 효율을 극대화하는 방안을 확립하였다. 본 연구에서는 이러한 선행 연구들의 기술적 토대 위에서 선박 블록의 형상 유지와 하중 분산에 핵심적인 역할을 하는 지지대(support)의 설치 정확도를 자동으로 검사하는 통합 방법론을 제안한다. 기존 연구들이 대형 구조물의 전체 형상 관리나 단순 객체 탐지에 머물렀다면 본 연구는 객체 탐지(object detection)와 공간 데이터 후처리(spatial data post-processing)




Fig. 1 Example of supports installed beneath a ship block

를 결합하여 mm 단위의 설치 오차를 정량적으로 산출한다는 점에서 차별성을 갖는다. 이를 통해 수작업에 의존하는 기존 검사 방식의 비효율성 문제를 해결하고 나아가 스마트 조선소의 디지털 트윈 구축을 위한 실용적인 기반 기술을 제공하고자 한다.

2. 선박 블록 지지대 검사

Fig. 1과 같이 선박 건조 공정 중 대형 블록의 조립 및 탑재 단계에서 지지대는 거대한 중량물인 선박 블록의 하중을 지면으로 안전하게 분산시키고 설계된 형상을 유지하게 하는 핵심 기재이다. 수백 톤에 달하는 선박 블록은 자체 중량으로 인해 중력 방향으로 처짐이나 비틀림이 발생하기 쉬우며 이는 후속 공정인 탑재와 조립 시 치명적인 단차를 유발하는 원인이 된다. 따라서 지지대가 계산된 위치와 높이에 설치되어 선박 블록을 지지하고 있는지 검증하는 것은 선박의 구조적 안전성과 생산 품질을 결정짓는 필수적인 과정이라 할 수 있다.

그러나 현재 산업 현장에서 수행되는 지지대 품질 관리는 여전히 한계점을 지니고 있다. 첫째, 검사 범위의 타협과 정밀도의 부재이다. 통상적으로 하나의 선박 블록을 지지하기 위해 수십 개에서 수백 개의 지지대가 설치되는데 이를 제한된 시간 내에 광파기로 전수 계측하는 것은 막대한 공수를 요구한다. 이로 인해 현장에서는 선박 블록 자체의 전체적인 수평이나 높이만 맞으면 함격으로 간주하고 개별 지지대의 정확한 설치 위치는 작업자의 육안 검사에 의존하는 타협적인 방식이 빈번하게 이루어진다. 하지만 선박 블록의 전체 수평이 유지되더라도 개별 지지대가 누락되거나 설계 위치를 벗어나 있다면 특정 지지점에 하중이 집중되거나 이탈이 발생하여 선박 블록의 구조적 변형을 초래할 수 있다. 즉, 전체 형상뿐만 아니라 개별 지지대 하나하나가 정확한 위치에 시공되었는지 검증하는 절차가 반드시 수반되어야 한다. 둘째, 작업자의 안전 문제이다. 검사 작업은 대형 선박 블록 하부의 협소하고 어두운 공간에서 이루어지므로 검사자가 낙하물이나 구조물 충돌과 같은 안전사고 위험에 상시 노출되어 있다. 셋째, 데이터 관리의 부재이다. 수기 중심의 검사 기록은 실제 물리적 형상 정보를 디지털화하여 관리하기 어려워 향후 공정 최적화나 시공 오차 원인 분석에 활용하는데 제약이 있다.

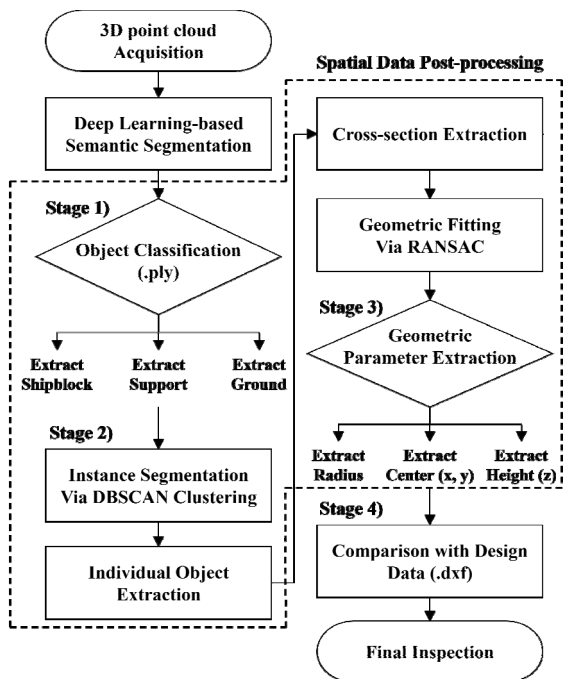


Fig. 2 Flowchart of the proposed support installation accuracy inspection method

이러한 문제점들은 조선소의 생산성을 저해하는 요인으로 작용하고 있으며 이를 해결하기 위해 3차원 공간 정보를 활용한 비접촉식 검사 체계로의 전환이 필요하다고 판단하였으며 본 연구에서는 이러한 산업적 요구를 반영하여 3차원 LiDAR 스캐닝을 통해 획득한 데이터를 기반으로 설치 정확도를 검사하였다.

본 연구에서는 3차원 포인트 클라우드 데이터를 활용하여 지지대의 설치 상태를 정량적으로 분석하고 이를 설계 기준과 비교·검증하는 방법을 제안하였다. 본 방법은 육안이나 수작업에 의존하던 기존 방식을 탈피하여 딥러닝과 기하학적 알고리즘을 통해 객체 정보를 추출하고 지지대(Support), 지면(Ground), 선박 블록(Ship block) 간의 공간적 관계를 수치적으로 계산하는데 주안점을 두었다. 제안하는 방법은 Fig. 2에 나타낸 바와 같이 검사에 필요한 객체의 분류, 개별 객체 분할, 형상 정보 추출, 그리고 설계 데이터와 비교 분석으로 크게 4단계 과정으로 구성된다.

첫 번째 객체의 분류 단계는 딥러닝 모델의 예측 결과를 기반으로 전체 장면(scene)을 구성하는 각 객체를 의미 단위로 분리하는 과정이다. 본 연구에서는 딥러닝 모델이 예측한 각 객체가 색상으로 구분되어 의미론적 분할 결과를 제공하기 때문에 검사 대상인 지지대뿐만 아니라 설치 높이 검사의 기준이 되는 지면과 선박 블록을 포인트 클라우드의 색상 정보를 통해 각각의 객체로 분류하였다. 이러한 다중 객체 분류 과정은 지지대의 절대 좌표뿐만 아니라 주변 구조물과의 상대적인 이격 거리를 계산하기 위한 데이터 전처리 단계로서 수행되었다.

두 번째 단계의 경우 분류된 지지대의 포인트 클라우드는 다수의 지지대 객체들이 공간상에 혼재된 상태이므로 개별 지지대 단위의 정밀 계측을 위해 개별 객체 분할을 수행하였다. 이를 위해 DBSCAN(Density-Based Spatial Clustering of Applications with

Noise) 알고리즘을 적용하여 밀도가 높은 포인트 그룹을 독립적인 군집으로 정의하였으며 이 과정은 개별 지지대를 식별하는 동시에 작업 현장의 분진이나 레이저 반사로 인해 발생한 비정상적인 노이즈(noise)를 군집에서 배제함으로써 데이터의 신뢰도를 확보한다.

세 번째 단계에서는 분할된 개별 지지대 객체로부터 정밀한 형상 정보를 도출하였다. 지지대의 수평 단면(cross-section) 데이터를 추출한 후 RANSAC(Random Sample Consensus) 기반의 원형(circle) 추정 알고리즘을 적용하여 기하학적 형상 모델링을 수행한다. RANSAC 알고리즘은 데이터 내의 이상치에 강건한 특성이 있어 노이즈가 포함된 현장 데이터에서도 최적의 모델을 추정할 수 있으며 이를 통해 지지대의 중심 좌표(x, y), 높이 좌표(z), 반경과 같은 핵심 기하학적 파라미터를 산출하였다.

마지막 단계는 산출된 형상 정보의 정밀도를 검증하고 결과를 시각화하는 과정으로 평면 위치 정확도와 수직 설치 적합성의 두 가지 측면에서 분석이 이루어진다. 첫째, 평면 위치 정확도 검사에서는 추출된 지지대의 실측 중심 좌표를 설계 도면(.dxf) 데이터와 정렬하여 평면상의 시공 오차($\Delta x, \Delta y$)를 정량적으로 계산하였다. 둘째, 수직 설치 높이 검증에서는 전 단계에서 획득한 지면과 선박 블록 바닥면의 좌표 정보를 활용하여 지지대 설치 위치에서의 수직 이격 거리를 산출하였다. 이를 위해 본 연구에서는 Open3D 및 NumPy 라이브러리를 기반으로 3차원 포인트 클라우드 분할과 기하학적 형상 추정 알고리즘을 구현하였으며 수치적 오차 데이터와 함께 지지대가 선체를 적절한 높이에서 지지하고 있는지를 직관적으로 파악할 수 있도록 구현하였다.

3. 딥러닝 기반 지지대 객체 탐지

대용량의 3차원 포인트 클라우드 데이터에서 지지대의 설치 정확도를 검사하기 위해서는 먼저 전체 데이터 중 검사 대상인 지지대 객체와 높이 측정의 기준이 되는 지면 객체를 효과적으로 분리해내는 과정이 선행되어야 한다. 조선소 현장 데이터는 다양한 구조물과 설비가 혼재되어 있고 비정형성이 강해 단순한 기하학적 필터링만으로는 객체 식별이 매우 어려우며 이에 따라 본 연구에서는 포인트 클라우드의 공간적 특징을 학습할 수 있는 딥러닝 모델을 도입하여 의미론적 분할을 수행하였다.

3.1 딥러닝 데이터셋 구축

딥러닝 모델의 일반화 성능은 학습 데이터의 정제된 품질뿐만 아니라 실제 적용 환경의 특성을 얼마나 포괄하고 있는지의 여부에 따라 결정된다. 본 연구에서는 Fig. 3과 같이 실제 선박 건조 환경을 정밀하게 모사하기 위해 데이터셋 구축 과정을 데이터 획득, 데이터 후처리, 공간 분할, 클래스 정의 및 라벨링의 4단계로 체계화하여 수행하였다.

먼저 Fig. 3(a)의 데이터 획득(data acquisition) 단계에서 데이터는 국내 조선소에서 실제 건조 중인 선박 블록을 대상으로

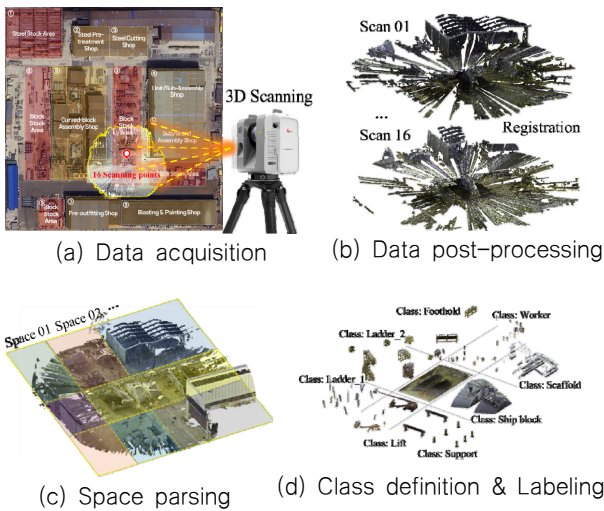


Fig. 3 Overall procedure for constructing the shipyard point cloud dataset

획득하였으며 계측 장비로는 초고속 3차원 LiDAR 스캐너인 Leica RTC360을 사용하였다. 선박 블록 하부는 수많은 지지대와 구조물이 밀집되어 있어 단일 지점 계측 시 객체 상호 간의 가림 현상에 의한 데이터 소실이 심각하게 발생한다. 이를 극복하고 사각지대 없는 고밀도 데이터를 확보하기 위해 본 연구에서는 선박 블록 외부의 주요 지점을 포함하여 총 16개 지점에서 다중 스캐닝을 수행하여 현장의 3차원 형상 정보를 수집하였다.

다음 Fig. 3(b)의 데이터 후처리(data post-processing) 단계에서는 획득된 원본 데이터를 학습 가능한 형태의 고품질 데이터로 변환하기 위해 체계적인 후처리 과정을 수행하였다. 첫째, 정합(registration) 과정을 수행하여 16개 지점에서 개별적으로 획득된 스캔 데이터를 하나의 통합 좌표계로 일치시켜 온전한 형태의 선박 블록 건조 장면의 포인트 클라우드를 획득하였다. 둘째, 데이터 경량화 및 노이즈 제거를 수행하였으며 정합된 데이터는 수억 개의 포인트로 구성되어 연산 효율이 떨어지므로 복셀 그리드 샘플링(voxel grid sampling)을 적용하여 경량화를 수행하였다. 이를 통해 지지대의 핵심 형상 특징은 보존하면서 데이터량을 효율적으로 감축하였다. 또한, 이상치 제거(outlier removal) 필터를 적용하여 공중 부유 분진이나 센서 난반사로 인한 이상치를 제거함으로써 데이터의 품질을 향상시켰다.

후처리된 전체 포인트 클라우드 데이터는 여전히 방대한 공간 정보를 담고 있어 딥러닝 모델이 한 번에 학습하기에는 공간적 범위가 너무 넓은 문제를 가지고 있다. 따라서 Fig. 3(c)의 단계에서는 전체 장면을 학습 가능한 크기로 나누는 공간 분할(space parsing) 과정을 수행하였다. 이를 위해 대표적인 3차원 포인트 클라우드 벤치마크 데이터셋인 S3DIS(Stanford Large-Scale 3D Indoor Spaces)의 단일 최대 공간 크기를 참고하여 전체 조선소 작업 공간을 최대 24m x 22m x 14m의 단위로 분할하였다. 이를 통해 딥러닝 모델이 지역적인 기하 패턴을 효과적으로 학습하면서도 전체적인 공간 문맥을 유지할 수 있도록 하였다.

마지막 Fig. 3(d)의 클래스 정의 및 라벨링(class definition &

labeling) 단계에서는 학습을 위한 정답 데이터(ground truth)를 생성하기 위해 검사 목적에 부합하는 의미론적 클래스를 정의하고 라벨링을 수행하였다. 특히 조선소 현장은 지지대와 유사한 파이프 형상의 비계나 사다리 등이 혼재되어 있으며 이를 단순 배경으로 처리할 경우 오탐지가 발생할 가능성이 매우 높다. 따라서 본 연구에서는 객체 간의 경계를 명확히 학습시키기 위해 전체 포인트 클라우드를 총 13개의 세부 객체로 구분하여 라벨링을 수행하였으며 정의된 13개의 클래스를 Fig. 4에 나타내었다.

본 연구의 핵심 목적인 지지대 설치 정확도 검사를 위해 13개 클래스 중 Label 0 (Ground), Label 6 (Support_1), Label 10 (Ship block)의 3가지 핵심 객체만을 의미론적 분할 대상으로 선정하여 후속 검사 프로세스에 활용하였다. 이처럼 딥러닝 모델은 다양한 선박 블록을 학습하여 객체가 가질 수 있는 형태적 다양성을 일반화할 수 있으며 지면 및 지지대 상부에 위치한 거대 구조물이라는 객체 간의 상대적 위치와 공간 문맥을 파악하여 서로 다른 블록을 동일한 클래스로 분류할 수 있다. 한편, 검사에 직접 활용되지 않는 나머지 객체 또한 별도의 클래스로 정의하여 학습시킨 것은 딥러닝 모델의 변별력을 극대화하기 위함이다. 특히 비계나 사다리와 같이 지지대와 기하학적 형상이 유사하거나 주변에 밀접하게 위치한 방해물들을 단순한 배경이 아닌 다른 객체로 학습시킴으로써 딥러닝 모델이 복잡한 현장 데이터 속에서도 혼동 없이 지지대만을 검출해내는 분할 성능을 확보하였다.

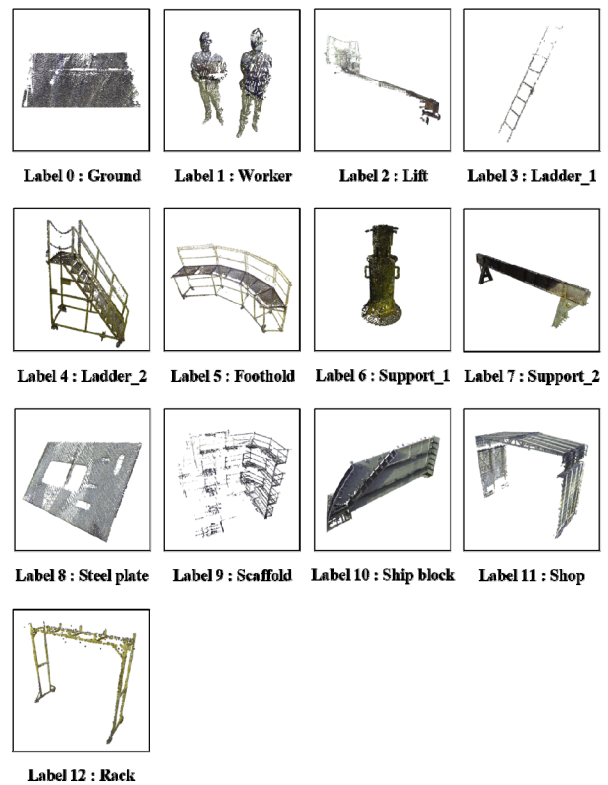


Fig. 4 Visualization of the 13 semantic classes defined for the shipyard dataset

3.2 객체 탐지 정확도 분석

본 연구에서는 3차원 포인트 클라우드 기반 딥러닝 모델인 PointVector를 활용하여 학습하였으며 검증 데이터셋에 대한 예측 결과를 정량적으로 분석하였다. 학습 과정에서 모델은 Epoch 258 시점에 가장 우수한 일반화 성능을 기록하였으며 이때의 평균 IoU는 78.58%를 달성하였다. Fig. 5와 Fig. 6은 각각 13개 클래스에 대한 IoU 성능과 시각화 결과이다. 본 연구의 핵심 검사 대상인 주요 객체들의 성능을 중점적으로 분석하면 다음과 같다. 첫째, 높이 측정의 기준이 되는 지면 객체는 97.43%의 매우 높은 IoU를 기록하였다. 이는 지면이 넓은 면적을 차지하고 평탄한 기하학적 특징이 뚜렷하여 딥러닝 모델이 이를 매우 강건하게 학습했음을 의미하며 후속 공정한 설치 높이 산출 시 신뢰할 수 있는 기준면으로 활용 가능하다. 둘째, 지지대와 접촉하여 하중을 지탱하는 선박 블록 또한 83.68%의 양호한 인식률을 보였다. 선박 블록은 다양한 곡률을 가진 비정형 곡면을 포함하는 객체임에도 불구하고 대형 객체로서의 전체적인 형상 특징이 효과적으로






Fig. 5 Per-class IoU performance for inspection objects and background objects



(a) Raw point cloud with RGB color visualization



(b) Inference result by the deep learning model

Fig. 6 Visualization of object detection performance in a complex shipyard environment

학습되어 안정적인 분할 성능을 확보하였다. 셋째, 정밀 계측의 주 대상인 지지대는 79.08%의 IoU를 기록하였으며 이는 최근 3차원 의미론적 분할 성능을 입증한 Point Transformer v3 모델이 S3DIS나 SemanticKITTI와 같은 대규모 실제 환경 데이터에서 통상 70~75% 수준의 mIoU를 보이고 있음을 고려할 때 노이즈와 가림 현상이 극심한 조선소 현장 데이터에서 달성한 IoU 성능은 준수한 수준이라 판단된다(Wu et al., 2024). 하지만 mm 단위의 설치 오차를 검사해야 하는 목적을 고려할 때 딥러닝 모델의 예측 결과만으로는 정밀도에 한계가 존재한다. 구체적으로 지지대는 지면과 선박 블록 사이에 견고하게 밀착되어 설치되므로 상하부 접점 영역에서 경계가 모호해지는 현상이 발생하며 작업 효율을 위해 현장에 설치된 비계(Scaffold, 58.41%)나 사다리(Ladder_1, 34.26%) 등의 기자재들이 지지대와 공간적으로 인접하게 배치되어 있어 특징 추출에 간섭을 유발한다.

하지만 본 연구의 목적은 산업 현장의 모든 객체들을 완벽하게 분할해내는 것이 아니며 주변 간섭 객체들을 지지대와 명확히 구분되는 별도의 클래스로 정의함으로써 지지대의 오탐지 가능성을 최소화하였다. 따라서 주변 간섭 객체들의 낮은 IoU 정확도가 지지대 설치 검사를 달성하는데 저해되는 치명적인 요인은 아니라고 판단된다. 결과적으로 지지대 객체의 IoU 79.08%는 검사를 수행하기 위한 객체를 한정하는 역할로서 충분한 유효성을 가진다. 다만 최종적인 설치 검사 단계에서 요구되는 정밀도를 충족하기 위해 딥러닝 예측 결과만을 사용하는데 한계가 있으며 이에 본 연구에서는 딥러닝 모델의 예측 결과에 이어 4장의 공간 데이터 후처리 과정을 연계하였다. 이를 통해 딥러닝 모델이 예측한 다소 불완전한 객체의 형상에서도 설치 위치 및 높이 검사에 필요한 핵심 기하 정보를 추출하였다.

4. 공간 데이터 후처리

앞선 3장의 딥러닝 모델을 통해 전체 포인트 클라우드 장면에서 검사 대상인 지지대 객체를 효과적으로 탐지하였다. 그러나 딥러닝 모델이 예측한 결과는 모든 지지대의 포인트가 동일한 Label 6 (Support_1) 클래스로 분류된 상태이므로 이 정보만으로는 개별 지지대의 정확한 위치 좌표와 높이를 산출할 수 없다. 또한 딥러닝 예측 결과에는 센서의 난반사나 학습 데이터의 한계로 인한 미세한 오탐지 및 노이즈가 여전히 포함되어 있어 이를 그대로 검사에 활용하기에는 한계가 있다. 따라서 본 장에서는 딥러닝 모델이 1차적으로 탐지한 검사 대상 객체를 기반으로 최종적인 품질 검사 정보를 추출하기 위한 기하학적 공간 데이터 후처리 과정을 기술한다. 제안하는 후처리 프로세스는 크게 두 단계로 구성된다. 첫째, DBSCAN 클러스터링을 통해 통합된 지지대 포인트들을 독립적인 개별 객체로 분할하고 이상치를 제거한다. 둘째, 분할된 각 객체에 대해 RANSAC 기반의 원형 추정 알고리즘을 적용하여 중심 좌표와 직경 정보를 산출한다. 이러한 접근 방식을 통해 딥러닝의 불완전한 예측 결과를 보정하고 mm급 정밀도를 요구하는 검사 기준을 충족하고자 한다.

4.1 DBSCAN 기반 개별 객체 분할

딥러닝 모델에 의해 추출된 지지대 객체의 포인트 클라우드는 공간상에 다수의 지지대가 동일한 클래스로 산재해 있는 형태이다. 본 연구에서는 이들을 개별 객체 단위로 분리하기 위해 DBSCAN 알고리즘을 적용하였다. DBSCAN은 K-means와 같이 군집의 개수를 사전에 지정할 필요가 없고 데이터의 공간적 밀도 분포에 따라 유연하게 군집을 형성하므로 지지대와 같이 불규칙하게 산재된 객체를 분리하는데 매우 효과적이다. 특히, 밀도가 낮은 포인트들을 노이즈로 분류하여 자동으로 제거할 수 있다는 장점은 현장 데이터의 품질을 높이는데 결정적인 역할을 한다. DBSCAN 알고리즘의 군집화 성능과 노이즈 제거 효율은 두 가지 핵심 파라미터인 탐색 반경과 최소 포인트 수의 설정에 의해 좌우되며 본 연구에서는 지지대 객체가 고밀도 포인트 클라우드로 구성되지만 객체 상호 간에는 작업 공간 확보를 위해 수 미터 이상 이격되어 있다는 물리적 배치 특성에 착안하여 파라미터를 최적화하였다. 우선, 탐색 반경은 개별 지지대 내부의 포인트들을 하나의 군집으로 견고하게 결속하되 인접한 다른 지지대와는 병합되지 않도록 공간적 분리능을 확보하는 것이 중요하다. 이에 유클리드 거리 임계값을 0.3m ~ 0.5m 범위로 설정하여 독립적인 객체 단위의 명확한 분할을 유도하였다. 또한, 최소 포인트 수는 유효한 객체로 인정받기 위한 최소한의 밀도 기준으로 딥러닝 모델이 오탐지한 공중 부유 분진이나 미세 노이즈들이 상대적으로 낮은 밀도와 적은 개수를 가진다는 점을 이용하였다. 본 연구에서는 이를 30~50개로 설정함으로써 해당 기준을 충족하지 못하는 희소한 포인트 그룹을 이상치로 간주하여 자동으로 소거하는 필터링 효과를 거두었다.

Fig. 7은 딥러닝 예측 결과와 DBSCAN 알고리즘 적용 후의 결과를 비교하여 보여준다. Fig. 7(a)는 딥러닝 모델의 의미론적 분할 결과로 6개의 지지대가 공간상에 떨어져 있으나 이는 지지대가 모두 결합된 하나의 객체 상태이다. 반면, DBSCAN을 적용한 Fig. 7(b)는 하나로 결합된 지지대 객체들을 개별 객체로 분할하여 6개의 지지대가 독립적인 객체이며 이를 통해 각 객체의 중심 좌표 추출이 가능하다. 특히 Fig. 7(b)의 붉은색 점선 원으로 표시된 영역을 살펴보면 지지대 주변에 존재하던 노이즈 포인트들이 유효한 군집에 포함되지 못하고 이상치로 분류되어 제거된 것을 확인할 수 있다. 이러한 밀도 기반 필터링 과정은 데이터의 품질을 높여 후속 단계인 원형 추정 시 알고리즘의 수렴 안정성을




Fig. 7 Comparison of segmentation results before and after applying DBSCAN

확보하고 중심 좌표 산출의 정밀도를 향상시키는 핵심적인 전처리 역할을 수행한다.

4.2 RANSAC 기반 형상 정보 추출

DBSCAN 알고리즘을 통해 개별 객체로 분할된 포인트 클라우드는 여전히 수천 개의 3차원 비정형 좌표 데이터로 구성되어 있어 그 자체로는 검사에 필요한 정량적 수치인 중심 좌표와 직경 정보를 제공하지 못한다. 또한, 3.2절에서 서술한 바와 같이 딥러닝 모델의 분할 결과에는 객체 경계면에서의 미세한 오탐지나 센서 노이즈가 포함되어 있을 가능성이 높다. 이러한 상황에서 만약 모든 포인트와의 거리 오차를 최소화하려는 일반적인 수학적 회귀 방식을 적용한다면 치명적인 문제가 발생할 수 있다. 이 방식은 데이터의 좋고 나쁨을 가리지 않고 모든 포인트를 공평하게 계산에 반영하기 때문에 딥러닝이 걸러내지 못한 소수의 이상치가 섞여 있을 경우 원의 중심이 이상치 쪽으로 끌려가거나 직경이 비정상적으로 커지는 형상 왜곡이 발생하게 된다. 이에 본 연구에서는 전체 데이터 중 다수를 차지하는 정상 데이터만을 선별하여 모델을 만드는 RANSAC 알고리즘을 도입하여 이상치의 영향을 줄이고 지지대의 핵심 기하 정보를 강건하게 추출하였다.

형상 정보 추출 과정은 크게 단면 슬라이싱(slicing) 및 투영과 원형 추정의 두 단계로 수행된다. 먼저, 전체 지지대 형상 중 구조적 변형이 적고 형상 특징이 뚜렷한 높이 구간을 설정하여 단면 포인트들을 슬라이싱하고 이를 2차원 평면으로 투영하여 차원을 축소함으로써 연산 효율성을 확보하였다. 이후 투영된 2차원

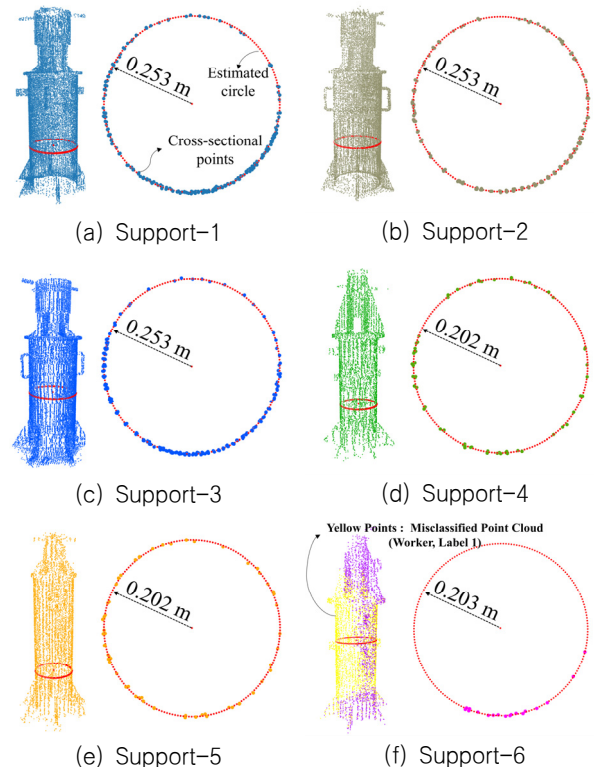


Fig. 8 Visualization of estimated circle for each support

포인트 집합에 대해 RANSAC 알고리즘을 적용하였으며 이 알고리즘은 무작위로 선택된 최소 샘플을 사용하여 수학적 원형 모델을 수립하고 전체 포인트 중 해당 모델과의 거리 오차가 허용 임계값 이내인 유효 데이터의 비율을 계산한다. 이 과정을 반복 수행하여 유효한 포인트의 개수가 최대화되는 최적의 파라미터를 최종 해로 결정함으로써 이상치를 효과적으로 배제한 지지대의 단면 형상을 추출하였다.

Fig. 8과 Table 1에는 RANSAC 알고리즘을 실제 현장 데이터에 적용하여 추출된 6개 지지대 객체(Support-1 ~ Support-6)의 형상 및 추출 정보를 나타내었다. 적용 결과 추출된 지지대의 반지름은 약 0.25m와 0.20m의 두 가지 그룹으로 명확히 구분되었으며 이는 실제 현장에 설치된 두 종류의 지지대 규격(∅ 500mm, 400mm)을 정확하게 반영하고 있음을 확인하였다. 특히 본 연구에서 주목할 점은 포인트 밀도의 변화에 따른 알고리즘의 강건성이다. Support-1의 경우 225개의 충분한 포인트 수를 확보하여 이상적인 원형 추정 결과를 보인 반면 Fig. 8 (f)와 같이 Support-6는 딥러닝 예측 과정에서 객체의 상당 부분이 작업자(Worker) 클래스로 오분류되어 전체 둘레 중 극히 일부인 18개의 희소한 포인트만이 지지대 클래스로 획득되었다. 이처럼 형상 복원이 매우 어려운 수준의 데이터 결손이 발생했음에도 불구하고 RANSAC 알고리즘은 소수의 유효 데이터만으로도 원의 기하학적 제약 조건을 만족하는 수학적 모델을 효과적으로 추정하였다. 그 결과 불완전한 형상의 Support-6도 다른 동일 규격 지지대와 오차 범위 내에서 일치하는 0.203m의 반지름을 성공적으로 산출하였으며 이는 본 연구에서 제안하는 기하학적 후처리 방식이 딥러닝 모델의 부분적 예측 실패로 인한 데이터 소실 상황에서도 기하학적 형상을 추출해 낼 수 있음을 시사한다.


Table 1 Geometric parameters of supports extracted via RANSAC

Support object	Center coordinate (x, y)	Radius (m)	Number of points
1	(15.6, 5.1)	0.253	225
2	(21.9, 5.2)	0.253	177
3	(28.1, 5.4)	0.253	216
4	(18.1, 12.6)	0.202	64
5	(21.7, 12.6)	0.202	59
6	(26.1, 12.8)	0.203	18

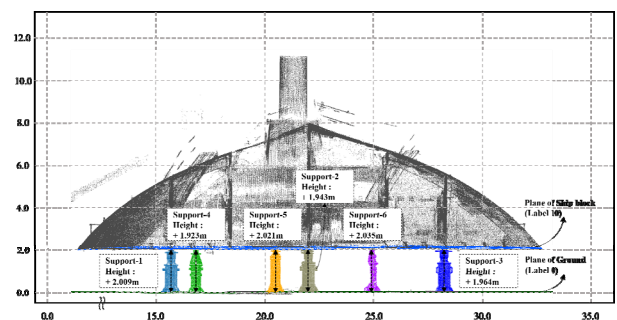
4.3 지지대 설치 정확도 검사

본 연구에서 제안하는 검사 방법의 최종 목표는 전 단계에서 추출된 지지대의 기하 정보를 설계 데이터와 비교하여 설치 오차를 정량적으로 산출하고 품질 기준 만족 여부를 판별하는 것이다. 이를 위해 4.2절에서 획득한 각 지지대의 추정 중심 좌표 및 형상 정보를 활용하여 평면 위치 정확성과 설치 높이 적정성에 대한 검사를 수행하였다.

일반적으로 설치 오차를 정밀하게 측정하기 위해서는 해당 블



(a) Visualization of planar alignment errors between the synthesized design references (blue circles) and the estimated centers (red crosses)



(b) Vertical height measurement results derived from the perpendicular distance between the ground plane and the Ship block plane

Fig. 9 Results of the support installation accuracy inspection

록의 실제 CAD 도면이 기준 데이터로 요구된다. 그러나 본 연구 수행 과정에서 보안상의 제약으로 인해 원본 설계 도면을 확보하는데 현실적인 어려움이 있었으며 본 연구에서는 제안하는 알고리즘의 오차 검출 성능을 검증하기 위한 대안으로 실제 스캔된 데이터의 배치 형상을 기반으로 가상의 설계 도면(synthesized design layout)을 생성하고 이를 기준 좌표로 설정하였다. 비록 실제 설계값과의 비교는 아니지만 본 접근 방식은 알고리즘이 기준 좌표와 실측 좌표 간의 상대적인 편차를 얼마나 정밀하게 검출해낼 수 있는지를 검증하는 데에는 충분한 유효성을 가진다고 판단하였다. Fig. 9(a)는 가상 설계 도면상의 기준 위치(파란색)와 본 알고리즘을 통해 추정된 지지대 중심(빨간색) 간의 정합 오차를 시각화한 결과이다. 분석 결과 각 지지대별로 x, y 축에 대한 편차(Δx, Δy)가 정량적으로 산출되었으나 가상 도면의 한계로 인해 해당 수치의 절대적 정밀도를 평가하는 것은 본 연구 범위에서 제외하였다. 대신 본 실험에서 가장 주목할 점은 알고리즘의 강건성이며 특히 Support-6의 경우 딥러닝 모델의 오분류로 인해 데이터가 극심하게 소실되었음에도 불구하고 제안하는 공간 데이터 후처리 과정을 통해 원형 형상을 복원하였으며 다른 정상적인 지지대들과 기하학적 배열이 일치하는 중심 좌표를 성공적으로 산출해내었다. 이는 본 방법이 데이터 품질이 저하되거나 노이즈가 심한 열악한 현장 조건에서도 검사 기능을 안정적으로 유지할 수 있음을 입증하는 결과라 판단된다.

지지대의 평면 위치뿐만 아니라 선박 블록을 지지하는 높이가 적절하게 시공되었는지 확인하는 것은 선박 블록의 구조적 변형을 방지하기 위해 필수적이다. 이를 위해 본 연구에서는 3장의 딥러닝 모델이 분류한 의미론적 클래스 정보를 활용하여 높이에 대한 검사를 수행하였다. 구체적으로 지면(Ground, Label 0) 클래스와 선박 블록(Ship block, Label 10) 클래스로 분류된 포인트 집합에 대해 각각 RANSAC 기반의 평면 피팅(plane fitting)을 적용하여 지면으로부터 추출된 평면과 선박 블록으로부터 추출된 평면의 방정식을 도출하였다. 이후 각 지지대의 중심 좌표 (x, y) 위치에서 두 평면 사이의 수직 거리를 계산하여 개별 지지대의 설치 높이를 산출하였다.

Fig. 9(b)는 이러한 과정을 통해 예측된 각 지지대의 높이 정보를 보여준다. 분석 결과 지지대의 설치 높이가 1.923m에서 2.035m까지 위치별로 상이하게 나타남을 확인하였다. 이는 RANSAC 알고리즘을 통해 평면을 추출하였으나 실제 조선소 바닥면이 배수 등을 위해 경사를 가지고 있거나 추출된 평면 모델 자체에 미소한 기울기 오차가 존재하여 지지대의 위치에 따라 기준 높이가 달라졌기 때문으로 분석된다. 또한 이러한 기하학적 요인 외에도 선박 블록 하부의 구조적 깊이 차이나 작업자의 레벨링(leveling) 조정 결과가 복합적으로 반영된 것으로 유추된다. 이는 본 시스템이 산출한 데이터가 단순한 수치를 넘어 현장의 지형적 특성과 시공 상태를 다각도로 해석할 수 있는 기초 자료로 활용될 수 있음을 시사한다.

5. 결론

본 연구에서는 조선소 지지대 검사 자동화를 위해 3차원 포인트 클라우드 기반의 딥러닝 객체 탐지와 기하학적 후처리 알고리즘이 결합된 방법을 제안하였다. 이 시스템은 대용량 스캔 데이터로부터 지지대의 정밀한 형상 정보를 추출하여 설치 품질을 검증하는 것을 목적으로 하며 주요 연구 성과는 다음과 같다.

첫째, 딥러닝 모델을 도입하고 현장의 방해물들을 지지대 외의 객체도 함께 학습시켜 지지대 탐지의 오탐지율을 최소화하였다. 이를 통해 복잡한 산업 환경 속에서도 79.08%의 IoU를 달성하여 정밀 검사를 위한 관심 객체를 성공적으로 확보하였다. 둘째, DBSCAN 및 RANSAC 기반의 후처리 프로세스를 구축하여 딥러닝 결과의 정확도 한계를 보완하였다. 실험 결과 딥러닝 오분류로 인해 데이터 소실이 심각했던 객체(Support-6, 18개 포인트)에 대해서도 강건하게 형상을 복원해냄으로써 데이터 밀도가 불균일한 열악한 계측 환경에서도 안정적인 정보 추출이 가능함을 입증하였다. 셋째, 추출된 기하 정보를 바탕으로 가상 설계 도면과의 비교를 통해 평면 위치 오차와 설치 높이를 정량적으로 산출하였다. 특히 높이 계측 결과에서 나타난 편차는 조선소 지면의 미세한 경사 및 작업자의 시공 레벨링 상태가 복합적으로 반영된 것으로 분석되어 단순 수치를 넘어 현장의 시공 상황을 역추적할 수 있는 데이터로서의 가치를 확인하였다.

결론적으로 본 연구는 딥러닝의 객체 탐지 능력과 수학적 모델

링의 정밀성을 결합하여 mm급 정밀도를 요구하는 선박 품질 검사의 자동화 가능성을 제시하였다. 향후 실제 CAD 도면과의 연동 및 검사 대상 확장을 통해 조선업의 디지털 트윈 구축을 가속화하는 방향으로 연구를 발전시킬 계획이다.

References

- Ben Abdallah, H., Orteu, J.J., Jovančević, I. and Dolives, B., 2019. Three-dimensional point cloud analysis for automatic inspection of complex aeronautical mechanical assemblies. *Journal of Electronic Imaging*, 28(5), Article 051205.
- Guo, J., Tan, D., Guo, S., Chen, Z. and Liu, R., 2025. Digital inspection technology for sheet metal parts using 3D point clouds. *Sensors*, 25(15), Article 4827.
- Ha, S. and Ku, N., 2024. Development and validation of a point cloud data processing algorithm for obstacle recognition in double hull block. *Journal of Ocean Engineering and Technology*, 38(5), pp.210–217.
- Hsieh, C.S. and Ruan, X.J., 2023. Automated semantic segmentation of indoor point clouds from close-range images with three-dimensional deep learning. *Buildings*, 13(2), Article 468.
- Iwańkiewicz, R. and Rutkowski, R., 2023. *Digital twin of shipbuilding process in shipyard 4.0. Sustainability*, 15(12), Article 9733.
- Jung, K.S. and Lee, D.K., 2025. Analysis of object detection accuracy based on the density of 3D point clouds for deep learning-based shipyard datasets. *International Journal of Naval Architecture and Ocean Engineering*, 17, Article 100648.
- Jung, K.S., Kim, J.S., Park, B.Y. and Lee, D.K., 2025. Post-processing methods and applications for ship block 3D scanning data based on open-source point cloud algorithms. *Journal of the Society of Naval Architects of Korea*, 62(1), pp.57–66.
- Lee, D.K., Ji, S.H. and Park, B.Y., 2021. Object detection and post-processing of LNGC CCS scaffolding system using 3D point cloud based on deep learning. *Journal of the Society of Naval Architects of Korea*, 58(5), pp.303–313.
- Lee, D.K. and Park, B.Y., 2023. A case study for 3D scanning-based quantitative quality control during key stages of composite small craft production. *International Journal of Naval Architecture and Ocean Engineering*, 15, Article 100534.
- Poggi, L., Gaggero, T., Gaiotti, M., Ravina, E. and Rizzo, C.M., 2020. Recent developments in remote inspections of

ship structures. *International Journal of Naval Architecture and Ocean Engineering*, 12, pp.881–891.

Wang, J., Huo, S., Liu, Y., Li, R. and Liu, Z., 2020. Research of fast point cloud registration method in construction error analysis of hull blocks. *International Journal of Naval Architecture and Ocean Engineering*, 12, pp.605–616.

Wu, K., Prieto, S.A., Mengiste, E. and García de Soto, B., 2024. Automated quality inspection of formwork systems using 3D point cloud data. *Buildings*, 14(5), Article 1177.

Wu, X., Jiang, L., Wang, P.S., Liu, Z., Liu, X., Qiao, Y., Ouyang, W., He, T. and Zhao, H., 2024. Point transformer v3: Simpler, faster, stronger. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp.4840–4851.

Yoon, D.H., Kang, H.J., Choi, J., Kim, D.E. and Huang, X., 2015. 3D point cloud data basis shape management for assembly of modularized large and complicated marine structures. *International Journal of Manufacturing Engineering*, 2015, Article 129428.

Authorship Contribution Statement

Ki-Seok Jung: Formal analysis, Methodology, Visualization; **Bon-Yeong Park:** Data curation, **Dong-Kun Lee:** Conceptualization, Project administration.

