한국정밀공학회지 제 43 권 제 6 호 pp. 531-540 June 2026 / 531
J. Korean Soc. Precis. Eng., Vol. 43, No. 6, pp. 531-540 http://doi.org/10.7736/JKSPE.026.00028
ISSN 1225-9071 (Print) / 2287-8769 (Online)

• 특집 • 자율제조(Autonomous Manufacturing) II

자율 제조를 위한 공정정보 통합 기반의 CNC 가공 공정계획 지능화 시스템 개발

Development of Intelligent Process Planning System for CNC Machining based on Process Data Integration for Autonomous Manufacturing

박시우[1], 윤주성[1,#]
Si Woo Park[1] and Joo Sung Yoon[1,#]

1 경남대학교 기계공학부 (School of Mechanical Engineering, Kyungnam University)
Corresponding Author / E-mail: jsyoon@kyungnam.ac.kr, TEL: +82-55-249-2623
ORCID: 0009-0002-9546-1266

KEYWORDS: CNC milling (CNC 가공), Intelligent manufacturing (지능형 제조), STEP-NC data model (STEP-NC 데이터 모델), Process planning (공정계획), Feature recognition (형상 인식), Cutting condition optimization (절삭조건 최적화)

As AI transformation expands in manufacturing, intelligent technologies are increasingly applied to CNC machine tools and machining processes. In multi-product, small-batch production environments, frequent product changes require flexible and autonomous process planning. This study proposes a standard data integration-based intelligent process planning system that automatically performs the entire process from 3D model input to NC code generation. To enable intelligent process planning, data across all stages—from feature recognition to machining execution—must be integrated into a unified flow and connected with AI-based decision-making. The proposed system uses an ISO 14649-based XML schema to sequentially link data generated by each module, ensuring standardized information flow. Based on this framework, rule-based feature recognition, constraint-based process planning, and machine learning-based cutting condition optimization are implemented. A prototype system was developed to validate the approach, automatically generating NC code for industrial parts and performing actual CNC machining. Experimental results confirmed the feasibility and validity of the proposed system. This study demonstrates that standardized data integration combined with AI technologies can enable autonomous, flexible, and efficient process planning for advanced manufacturing environments.

Manuscript received: March 16, 2026 / Revised: April 23, 2026 / Accepted: April 26, 2026

1. 서론

산업현장에 스마트제조 및 DX/AX 추세가 가속화됨에 따라 ICT (Information and Communication Technology) 융합기술들이 제조산업에 광범위하게 도입되면서, CNC 공작기계 및 절삭가공 프로세스에도 다양한 지능화 기술들이 활용되고 있다[1]. 특히 다품종 소량생산 환경에서는 부품 설계 및 가공 프로세스의 유연성 및 민첩성이 매우 중요한 이슈이며, 제품 교체에 따른 공정계획의 다양성은 기하급수적으로 증가하여 보다 자율적으로 유연하게 최적의 공정계획을 수립할 수 있는 절삭가공 공정계획의 지능화가 요구되고 있다[2].

일반적으로 절삭가공에 대한 공정계획 과정에서는 설계 형상에서 가공특징형상(Machining Feature)을 추출하고, 공정을 매칭하여, 각 공정별로 공구 선정 및 절삭조건 설정 후 공구경로를 생성한다[3]. 이러한 공정 전개 과정에서 가공 품질, 가공시간 등에 따라, 정확성, 안전성, 효율성, 경제성 등의 고차원 트레이드오프가 요구된다[4]. 특히, 사용 공구 및 절삭조건에 대하여 공구의 유무 및 셋팅 시간, 가공 소요 시간, 공구 파손 및

Copyright © The Korean Society for Precision Engineering
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.

표면 품질 등을 종합적으로 고려하여 절삭조건을 설정해야 하므로 전문가 의존도가 높으며, 전 과정이 전문가의 경험과 지식을 바탕으로 수행되기 때문에 많은 시간과 비용이 소요된다[1,5]. 여기에 전문인력 감소와 같은 산업현장의 문제를 고려하면 시스템적 접근을 통해 공정계획 과정을 지능화할 수 있는 방법이 필요하다.

절삭가공 공정계획 지능화를 위해서는 데이터 관점에서 해결되어야 할 기술적 이슈들이 존재한다. 지능화를 위해 주로 활용되는 머신러닝이나 딥러닝 등 AI 학습 모델 적용에는 학습 데이터가 필수적이지만, 공정계획 과정에서 사용되는 다수의 소프트웨어 간 데이터 교환 시 포맷 변환에 따른 정보 소실 문제와 CAD (Computer-Aided Design), CAPP (Computer-Aided Process Planning), CAM (Computer-Aided Manufacturing) 단계로 순차 운용됨에 따른 정보의 단절 문제가 발생하여 공정 데이터 확보에 어려움이 존재한다. 뿐만 아니라, NC 코드 생성 과정에서 공정계획에 대한 의사결정 정보는 유실되며 전문가의 직관을 데이터화 하기 어려운 한계점도 존재한다.

공정계획 지능화 관련 연구는 개별 요소를 중심으로 활발히 진행되고 있으나, 이를 하나의 파이프라인으로 통합하는 연구는 미흡하다[6]. 전 공정 데이터 통합 차원에서 절삭가공 공정정보 표준으로 ISO 14649 데이터 모델이 제정되었으나 제어기에 적용하기에는 데이터 스키마의 복잡도가 높아 상용화에 이르지 못하고 있으며[7], 범용 STL (Standard Tessellation Language) 기반 공구경로 자동 생성 연구[3]에서는 형상 기반 공구경로 생성에 집중하여 가공 공정 정보가 내부 로직으로 한정된다. 개별 요소 연구에서도 데이터 통합 관점은 미흡하다. 형상 인식에서는 GNN (Graph Neural Network) 기반으로 가공특징형상을 분류하는 연구[8]가 있었으나 형상의 데이터 체계에 따라 성능 편차의 한계를 보였으며, 공정 전개에서는 CBR (Case-Based Reasoning) 및 LLM (Large Language Model) 기반 접근[9,10]이 시도되었으나 형상 정보를 부피나 토큰화된 설명 문장 수준으로만 반영하여 새로운 형상에 대한 대응이 어려운 문제가 나타났다. 절삭조건 선정에서는 사전 정보를 입력해 스핀들 회전수와 이송속도를 추론하는 인공신경망 기반 전문가 시스템 연구[11]와, 마이크로 밀링 가공 중 절삭력과 표면거칠기 데이터를 학습하여 가공 파라미터를 최적화한 연구[12]가 수행되었으나, 형상·공정 정보와 연계되지 않아 절삭조건을 개별 대입하는 방식의 한계가 있다.

이러한 공정계획 과정에서의 정보 단절 및 손실 문제를 해결하고 표준 기반 데이터 체계로 전 공정을 통합 운영하여 공정계획을 지능화된 방식으로 자동 전개할 수 있도록, 본 연구에서는 CAD에서 CNC 가공을 연결하는 공정계획 통합 지능화 시스템을 제안한다. 제안하는 시스템은 ISO 14649 표준 기반의 XML 스키마를 중심으로 형상 인식, 공정 전개, 절삭조건 선정에 순차적으로 연계함으로써 모듈 간 정보 흐름을 확보하고, 실가공 데이터 학습 기법을 적용하여 절삭조건을 결정한다. 이를 통해 공구경로 생성 및 NC 코드 출력까지의 전 과정을 자동 수행하여

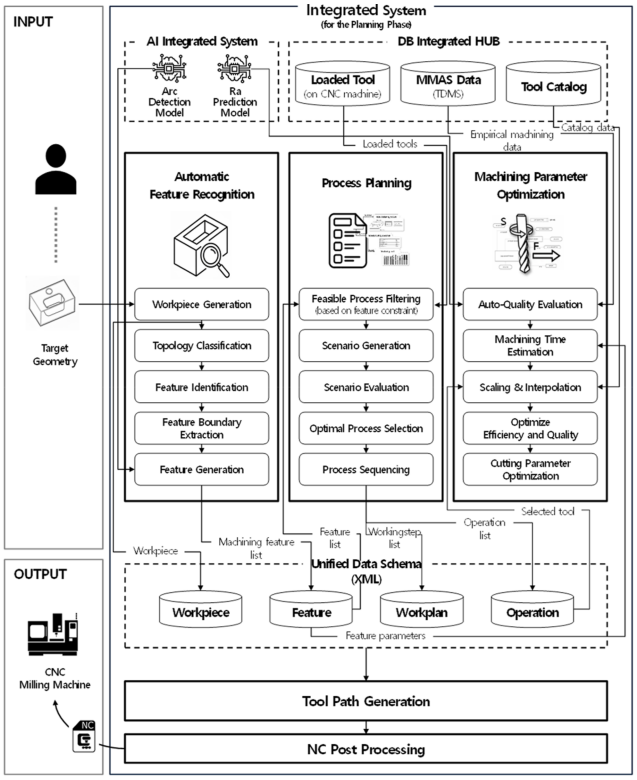


Fig. 1 Integrated system architecture for the process planning

전문가의 개입을 줄이고 빈번한 제품 교체에 대한 생산성을 확보하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 제안하는 시스템의 전체 아키텍처와 XML 스키마 기반 데이터 모델을 설계하고, 3장에서는 형상 인식, 공정 전개, 절삭조건 최적화의 세부 모듈에 대한 구현 결과를 제시한다. 4장에서는 실험 및 검증 결과를 통해 제안된 시스템의 유효성을 확인하고 5장에서는 연구결과의 요약 및 향후 연구를 제시한다.

2. 공정계획 통합 지능화 시스템 설계

2.1 시스템 아키텍처

제안하는 시스템은 공정계획 과정을 통합하여 형상 입력만으로도 형상 인식부터 NC 코드 출력까지의 과정을 자동으로 수행한다. 전체 구성은 Fig. 1과 같이 시스템 지능화를 위한 ML모델을 관리하는 AI Integrated System, 가공 데이터 및 공구 정보를 관리하는 DB Integrated HUB, 입력 형상에 대한 가공에 필요한 정보를 생성하는 Automatic Feature Recognition 모듈, Process Planning 모듈, Machining Parameter Optimization 모듈, 이를 바탕으로 공구경로 및 NC 프로그램을 생성하는 Tool Path Generation 모듈과 NC Post Processing 모듈로 구성된다. 모든 과정에서 생성되는 데이터는 ISO 14649(STEP-NC)에 기반한 XML 데이터 스키마에 따라 저장되며 입력 형상은 범용적으로

활용 가능한 STL 형식을 사용한다.

사용자가 가공할 형상에 대한 STL을 입력하면, Automatic Feature Recognition 모듈은 먼저 STL의 메쉬로부터 소재 사이즈를 자동 계산하여 XML의 Workpiece 엔티티를 생성한다. 이후 메쉬 간 연결성을 분석하여 같은 형상을 이루는 메쉬들로 분류하고, 분류된 메쉬 그룹에서 가공 영역, 바닥 상태, 보스 유무 등의 정보와 형상 경계의 점 배열로부터 기하학적 정보를 추출한다. 이때 형상 경계는 Arc Detection Model을 통해 단순 점 배열에서 원호와 직선의 파라메트릭한 치수 정보로 변환되며, 추출된 결과는 XML의 Feature 엔티티 속성값으로 저장된다.

Process Planning 모듈에서는 생성된 Feature 엔티티 리스트와 Loaded Tool DB에 저장된 CNC 등록 공구 정보를 입력 받아 제약 기반 탐색 알고리즘을 적용하여 가공특징형상 기반 최적 공정계획을 도출한다. 각 가공특징형상에 직접 대응하는 공구들을 추출하고 공구별로 가능한 공정을 매칭하여 이를 조합한 가공 시나리오를 생성하며, 각 시나리오에 대하여 정량적으로 우선순위를 평가하여 형상별 최적의 공정 시나리오를 선택한다. 선택된 최적 시나리오들은 규칙 기반 정렬을 통해 최종 순서가 결정되고 Workingstep 리스트를 속성으로 갖는 Workplan 엔티티로 저장된다.

Workingstep이 정의되면서 Operation의 기본 구조도 정의되는데, 이때 Machining Parameter Optimization 모듈에서 Feedrate, Spindle Speed, 절입량(Axial Cutting Depth, Ap), 절삭폭(Radial Cutting Depth, Ae)에 대한 최적 값을 할당하여 Operation을 완성한다. 구체적으로, MMAS Data DB에 저장된 가공 실험 데이터에서 Ra Prediction Model로 각 절삭조건별 표면조도(Ra) 값을 예측하고, 인식된 가공특징형상 정보를 기반으로 가공 예측 시간을 계산하여 실가공 데이터셋을 구축한다. 이후 Tool Catalog DB의 상용 공구 정보를 연계하여 실가공 데이터셋의 절삭조건들을 현재 사용할 공구와 맞는 조건으로 보정하고, 이를 적용하여 표면 품질과 가공 시간에 따른 최적 절삭조건을 도출한다.

각 모듈의 결과로 완성된 XML 파일은 Tool Path Generation 모듈에서 입력 받아 공구경로를 생성하고, NC Post Processing 모듈을 통해 NC 코드로 변환한다. 사용자가 NC 코드를 사용하여 CNC 가공을 수행하는 것으로 전체 프로세스는 종료된다.

2.2 데이터 구조

본 시스템의 통합 데이터 구조는 ISO 14649 표준을 기반으로 공구경로 생성에 필요한 가공 정보를 손실 없이 표현하도록 한다. 다만 ISO 14649는 인스턴스 참조 기반으로 전용 파서(Parser)가 필요한데, 단위까지 엔티티로 분리하고, 특히 형상 정보는 ISO 10303의 기하 엔티티가 계층적으로 연결된 구조이므로 복잡도가 높다. 이에 ISO 14649의 정보 체계를 유지하면서 내부 운용에 적합한 계층적 트리 구조의 XML 스키마를 제시한다.

스키마는 Fig. 2와 같이, Workpiece, Feature, Workplan, Workingstep, Operation으로 구성된다. Workpiece는 소재 경계

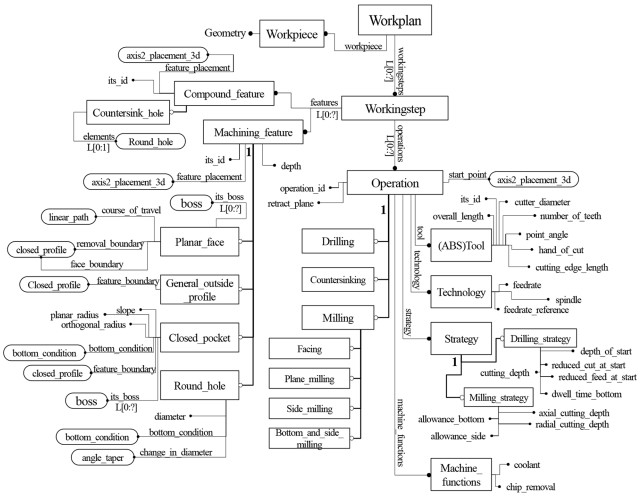


Fig. 2 XML schema of integrated process planning system

영역과 셋업 좌표계를, Feature는 형상의 유형, 경계, 깊이, 바닥조건, 보스(Boss) 등 파라메트릭 정보를 포함한다. Workplan은 가공 순서가 결정된 Workingstep 리스트를 관리하며, 각 Workingstep은 대응하는 Feature와 Operation을 연결하여 하나의 단위로 정의한다. Operation은 가공 유형, 공구, Feedrate, Spindle Speed, Ap, Ae 등의 절삭조건과 가공전략 등을 포함한다.

전체 구조는 데이터 재사용성과 파싱 효율성의 균형을 위해 참조 방식과 임베딩 방식을 혼합한다. Workpiece, Feature, Operation등 독립적으로 재사용되는 상위 객체는 Workingstep에서 ID로 참조하여 중복을 방지하고, ISO 10303-42 기반 기하 정보(axis2_placement_3d, cartesian_point, bounded_curve 등) 및 Tool, Technology와 같은 종속적 하위 데이터는 상위 객체 내부에 임베딩하여 참조 해석 단계를 제거함으로써 파싱 복잡도를 줄인다. 이를 통해 ISO 14649의 완전성을 유지하면서도, 송신과 수신 양측이 표준 XML 파서로 처리할 수 있도록 데이터 교환 방식을 효율화 하였다.

3. 시스템 상세 모듈 구현

3.1 Automatic Feature Recognition 모듈

Automatic Feature Recognition 모듈의 상세 구조는 Fig. 3과 같다. STL 파일을 입력 받아 Workpiece Generation, Topology Classification, Feature Identification, Feature Boundary Extraction, Feature Generation의 단계를 거쳐, Feature 엔티티 스키마에 부합하는 정보를 생성하고 XML 구조로 저장한다.

Workpiece Generation 단계에서는 입력되는 STL을 파싱 하여 메쉬 배열을 추출하고 각 메쉬에서의 법선 벡터 분포를 분석하여 주축 방향과 셋업 좌표계를 인식하여 전체 형상의 바운딩 박스 계산으로 소재 크기를 정의한다.

Topology Classification 단계에서는 메쉬 간 위상 관계가

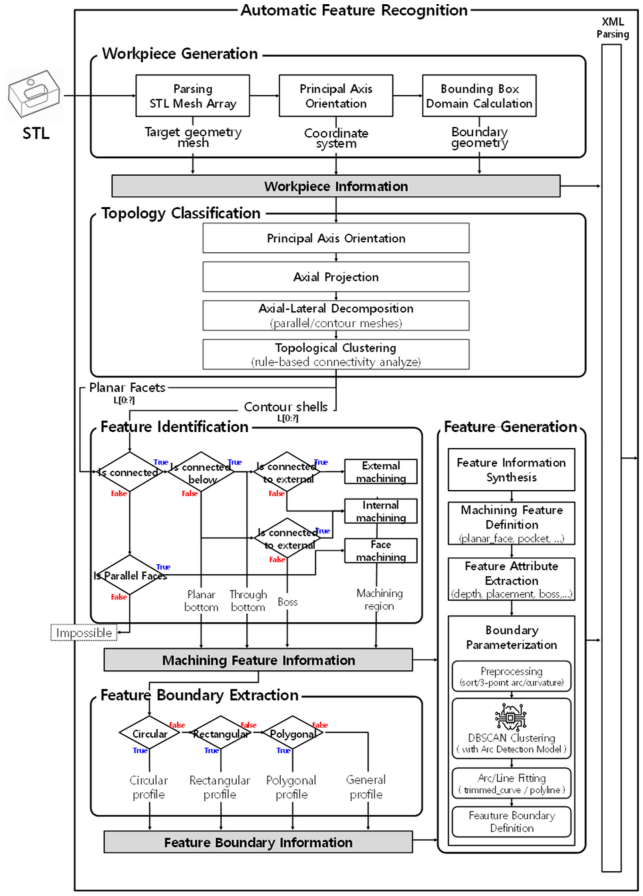


Fig. 3 Workflow of automatic feature recognition module

정의되어 있지 않은 단순 배열에서 의미 있는 형상 그룹으로 분류한다. 먼저 형상 전처리 단계로 셋업 좌표계의 Z축을 기준으로 축 방향 투영을 수행하여 2.5D 가공이 불가능한 영역을 배제하고, 식(1)의 근사 조건을 만족하는 각 메쉬 법선 벡터 n_i 와 셋업 Z축 단위 벡터 $\hat{u}$ 의 외적 결과를 통해, 주축 평행 메쉬 그룹과 윤곽 메쉬 그룹으로 분류한다.

분류된 메쉬 그룹은 각각 Topological Clustering 단계에서 공유 엣지 기반 인접성 그래프를 구축하고, BFS (Breadth-First Search) 탐색으로 연결된 삼각형들을 클러스터링 하여 Planar Facets 리스트와 Contour Shells 리스트를 출력한다.

$$\left\| n_i \times \hat{u} \right\| \le \varepsilon, (\varepsilon = 0.003) \tag{1}$$

Feature Identification 단계에서는 Contour Shell 단위로 루프를 순회하며 Planar Facet과의 연결 여부 및 배치 관계를 순차 검사하여 형상 바닥조건(Planar/Through)과 Boss 유무, 가공영역(External/Internal/Face)을 식별하여, 목표 형상을 이루는 가공특징형상 인식 정보를 반환한다. Fig. 4는 ISO 14649 2.5D 형상 중에서 산업 활용도가 높은 Planar Face, General Outside Profile, Round Hole, Closed Pocket, Countersink Hole의 가공특징형상 인식을 보여준다.

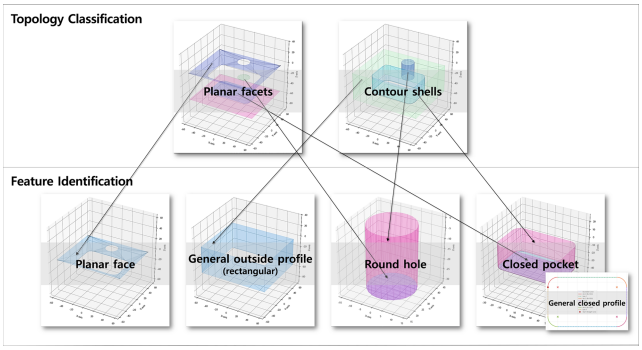


Fig. 4 Example of feature identification based on mesh topology classification

위에서 도출한 인식 정보는 하나의 형상을 이루는 메쉬 그룹끼리 합쳐져, 파라메트릭한 속성을 추출하게 되는데, 이를 Feature Boundary Extraction에서도 입력 받으며, 원형도 계산을 통해, 형상 경계 유형을 정의한다. 구체적으로, 입력되는 형상 메쉬에서 경계를 이루는 2차원 점군을 추출하여 최소제곱법에 따라 중심과 반지름을 계산한다. 이후 중심에서부터 형상 경계까지 거리의 표준편차 σ에 따라 원형도를 계산하며, 원형도 0.98을 기준으로 형상 경계 유형을 정의하여 Feature Generation 단계로 정보를 전달한다.

Feature Generation에서는 이전 과정에서 생성된 정보들을 입력 받아, 가공특징형상이 가지는 세부 속성을 XML 구조의 Feature 엔티티 하위 요소로 변환한다. Feature Information Synthesis에서 가공 유형, 바닥조건, 보스 유무 등을 종합하고, Machining Feature Definition에서 XML 스키마를 기반으로 최종 형상 유형을 결정한 뒤, Feature Attribute Extraction에서 깊이, 위치, 보스 조건 등의 속성을 추출한다.

타입이 구분된 상태의 형상 경계 점군 데이터는 Arc Detection Model을 기반으로 파라메트릭 정보로 변환되는 과정을 거친다. 먼저 정렬된 경계 점 배열에서 연속된 세 점을 추출하여, 외접원의 중심과 반지름을 구하고 인접하는 두 점으로 구성되는 두 개의 벡터의 사잇각을 두 벡터의 평균 거리로 나누어 곡률을 구하는 전처리 과정을 거친다. 전처리 결과는 Arc Detection Model로 입력되어 같은 원호를 이루는 구간별로 라벨링 되는데, DBSCAN (Density-Based Spatial Clustering of Applications with Noise)기반의 클러스터링 알고리즘을 활용하였다. 라벨링된 결과는 클러스터별로 곡률 임계값을 기준으로 ㄷ자 형태 등을 추가 구분하고 최소제곱법 기반 원 피팅으로 원 중심점, 반지름, 시작/종료각을 산출하여 Trimmed_curve 엔티티를 생성하며, 나머지 직선 부분들은 Polyline 엔티티를 생성한다. 생성된 결과는 Feature Boundary Definition 단계에서 종합하여 Closed_profile 엔티티를 생성하고, Feature Attribute Extraction 단계에서 생성한 형상 하위 속성들과 함께 XML Parsing을 거쳐 XML의 Feature 엔티티로 저장된다.

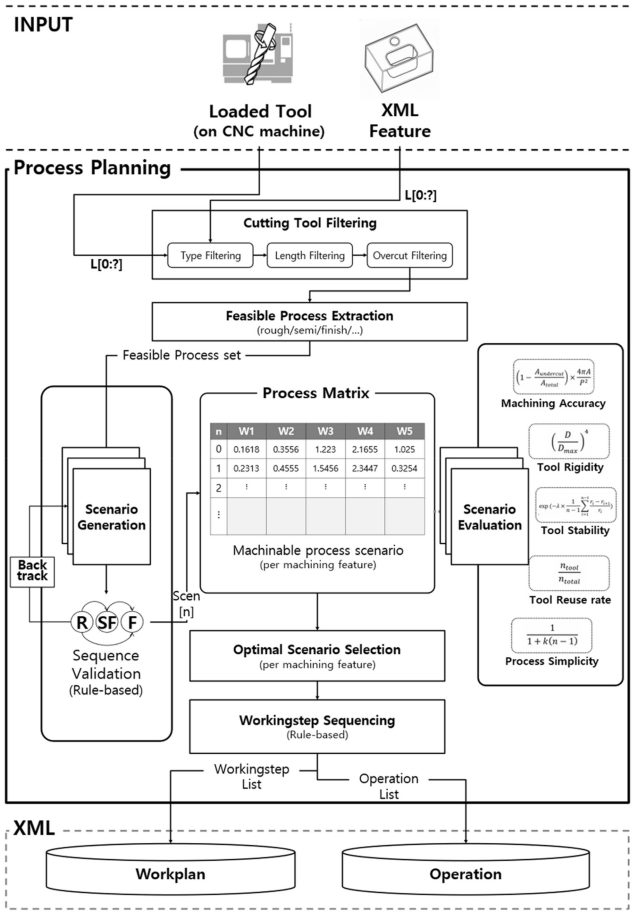


Fig. 5 Implementation architecture for process planning module

3.2 Process Planning 모듈

Process Planning 모듈 상세 구조는 Fig. 5와 같다. 본 모듈은 Loaded Tool DB의 공구 리스트와 XML 구조의 형상 리스트를 입력 받아 Cutting Tool Filtering, Feasible Process Extraction, Scenario Evaluation, Optimal Scenario Selection, Workingstep Sequencing 단계를 거쳐, XML 구조의 Workplan 엔티티와 Operation 엔티티를 생성한다.

Cutting Tool Filtering 단계에서는 각 형상에 대해 공구 유형, 길이, 과삭 조건을 순차 검사하여 가공 불가능한 공구를 제외한다. 1차 유형 필터링에서는 형상 유형별로 대응 가능한 공구 타입을 내부 규칙으로 지정하여 필터링하고, 2차 길이 필터링에서는 형상 전체 깊이와 XML 구조의 Tool 엔티티 하위 속성인 Overall_length를 비교하여 충돌 위험 공구를 제외한다.

3차 오프셋 필터링에서는 형상 경계를 공구의 반지름만큼 가공 방향으로 오프셋 하여 공구 반지름이 가공 영역보다 커서 오프셋이 불가능한 공구를 제거한다. 이때, 공구 반지름이 경계의 원호나 홈보다 클 경우 경계가 소실되는 특성을 이용하여, 오프셋 후 동일 거리로 복구하는 이중 오프셋 검증을 통해 원본 대비 경계의 면적 소실 비율 20% 이상인 공구를 과삭 위험으로 판별하여 제거한다. 통과한 공구들은 Feasible Process Extraction 단계에서 이전의 경계 소실 비율을 기준으로 적용 가능한 가공 공정과 매칭되어 공정-공구의 쌍으로 형상별 Feasible Process Set에 저장된다.

Table 1 Machining process evaluation indices

Evaluation indices	
Machining accuracy	$\left(1-\frac{A_{undercut}}{A_{total}}\right)\times\frac{4\pi A_{boundary}}{P_{boundary}^{2}}$ Area-based IoU × isoperimetric circularity (A: area, P: perimeter)
Tool rigidity	$\left(\frac{D}{D_{max}}\right)^{4}$ 2nd moment of area ratio for circular cross-section
Tool stability	$\begin{cases} 0.3, & (n=1) \\ \exp\left(\left(-\lambda\times\frac{1}{n-1}\sum_{i=1}^{n-1}\frac{r_i-r_{i+1}}{r_i}\right)\right), & (n\geq 2) \end{cases}$ Exponential decay of tool radius variation between consecutive processes (λ: sensitivity factor)
Tool reuse rate	$\frac{n_{tool}}{n_{total}}$ Relative frequency of tool usage
Process simplicity	$\frac{1}{1+k(n-1)}, (k=0.2)$ Efficiency decay by number of process steps

$$C = 1-\frac{\sigma^2}{r} \tag{2}$$

제약 기반 탐색 알고리즘에 따라 Feasible Process Set의 개별 공정-공구 쌍들을 조합해 공정 시나리오를 생성하고 검증하며 평가한다. 구체적으로, 단일 공정부터 다 공정 조합의 모든 시나리오를 탐색하되, 가공 순서에 대한 규칙 위반이나 후속 공정 공구가 전 공정보다 큰 경우 등의 가공 부적합이 감지되면 해당 분기를 중단하고 백트래킹으로 시나리오를 재생성한다. 검증을 통과한 시나리오는 전 공정에 대한 Process Matrix에 반영되어 Table 1의 형상, 공구, 공정에 대한 정보를 수치화한 다섯 가지 지표로 평가된다. 이때 각 지표는 XML Feature의 파라메트릭 정보와 시나리오별 공구 정보를 기반으로 내부 수식을 통해 산출된다.

정량 지표로 평가된 시나리오는 Optimal Scenario Selection 단계에서 가중 합 계산을 통해 형상별 최적 시나리오로 선정된다. 선정된 시나리오는 Workingstep Sequencing 단계에서 공정-공구 쌍으로 분해된 뒤 규칙 기반 정렬을 거쳐 전체 가공 순서로 재구성되며, 최종적으로 Workplan 및 Operation 엔티티가 생성된다.

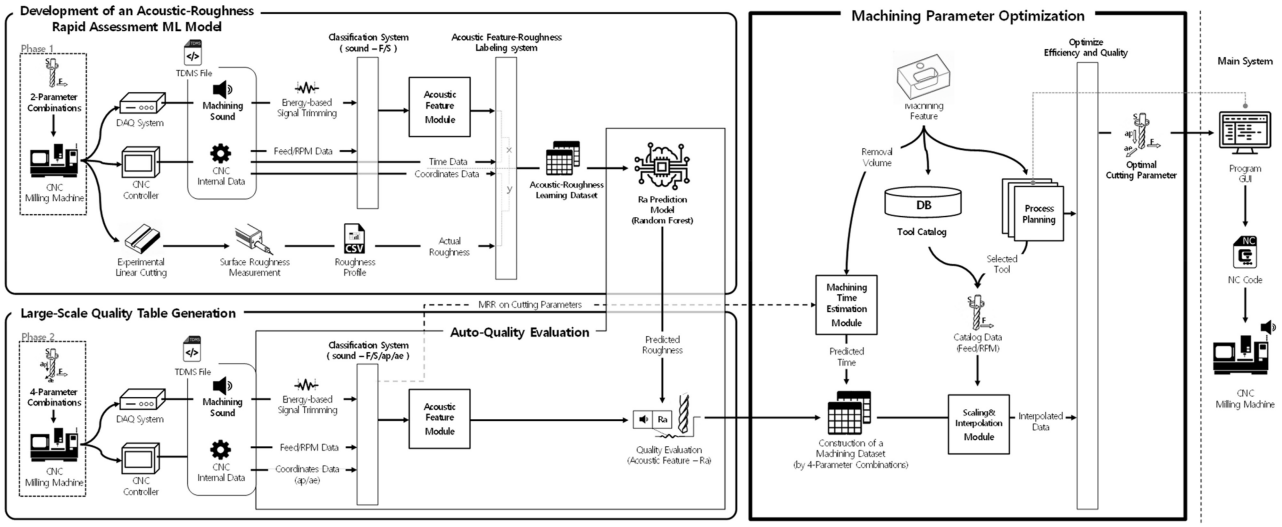


Fig. 6 Pipeline for large-scale machining quality database construction and machining parameter optimization

3.3 Machining Parameter Optimization 모듈

Machining Parameter Optimization 모듈은 표면품질을 고려하여 가공 시간을 최소화하는 최적 절삭조건을 도출하며, Fig. 6과 같이 음향 기반 품질 평가 모델 개발과 대규모 품질 평가 테이블 구축의 두 단계 오프라인 가공 실험을 통해 구성된다. 숙련된 가공자가 소리로 가공 상태를 판별하는 방식을 반영하기 위해 가공 음향 데이터 기반의 Ra 예측 모델(Ra Prediction Model)을 개발하고, 이를 대규모 조건 실험에 적용하여 조도 측정 없이 품질 데이터를 자동 수집하는 파이프라인을 구축함으로써, 자동 구축되는 실가공 데이터를 기반으로 절삭조건을 제공한다.

1차 음향 기반 Ra 예측 모델은 Table 2(a)의 Spindle Speed, Feedrate의 2변수 조건에 따라 36개 조합의 직선 가공 실험을 진행하여 얻은 모니터링 시스템의 가공 음향과 CNC 내부 데이터를 학습하여 구축된다. 수집된 음향 신호는 노이즈 제거 후, 에너지 기반으로 가공 구간만 추출되고, CNC 내부 데이터를 통해 각각의 변수 조합으로 라벨링 되어, Table 3과 같이 Acoustic Feature Module을 통해 시간, 주파수, 켑스트럼, 피치 기반의 4개 영역에서 총 9종의 음향 특징으로 전처리 된다. 전처리 된 음향 데이터는 CNC 시계열을 기준으로 정렬하고, 실제 측정한 Ra 값은 CNC 좌표를 기준으로 정렬하여 음향-조도 학습 데이터셋을 구축한다. Random Forest 회귀모델을 적용하여 Ra 예측 모델을 개발하였으며, 모델 성능 검증 후 최적 절삭조건 도출 과정에 활용한다.

2차 대규모 품질 평가 테이블 구축 과정에서는 1차의 Ra 예측 모델을 내장한 Auto-Quality Evaluation 프로세스를 구성하여 음향 평가 데이터셋을 구축한다. Auto-Quality Evaluation은 Table 2(b)와 같이 변수를 확장한 Spindle Speed, Feedrate, Ap, Ae의 4변수 조합 가공 실험에서 수집된 음향 데이터와 CNC 내부 데이터를 입력 받아, 1차와 동일한 전처리 및 Ra 라벨링을 자동 수행한다. 다만 Ra 매칭 시에는 실측 과정을 거치지 않고 1차에서 개발한 예측 모델을 적용하여 자동으로 라벨링된다. 구체적으로,

Table 2 Machining conditions for experiments

(a) 1st Experiment

Spindle speed [rev/min]	Feedrate [mm/min]
2500	750
2600	850
2700	950
2800	1050
2900	1150
3000	1250

(b) 2nd Experiment

Spindle speed [rev/min]	Feedrate [mm/min]	Ap [mm]	Stepover [%]
2500	750	1	50
2600	850		60
2700	950	2	70
2800	1050		80
2900	1150	3	90
3000	1250		100

Table 3 Acoustic features and extraction parameters

Domain	Feature	Parameters
Time	RMS energy	-
	Zero crossing rate	-
Frequency	Spectral centroid	-
	Spectral rolloff	roll percent = 0.85
	Spectral bandwidth	-
	Spectral contrast	n bands = 6
Cepstrum	MFCC	n mfcc = 13
Pitch-based	Chroma STFT	n_chroma = 12
	Tonnetz	chroma feature

Table 4 Libraries of the integrated system

Category	Library
Geometry	trimesh, Shapely
Computation	SciPy
ML / Signal	scikit-learn (DBSCAN, RandomForestRegressor), librosa, noisereduce
XML	xml.etree.ElementTree, xml.dom

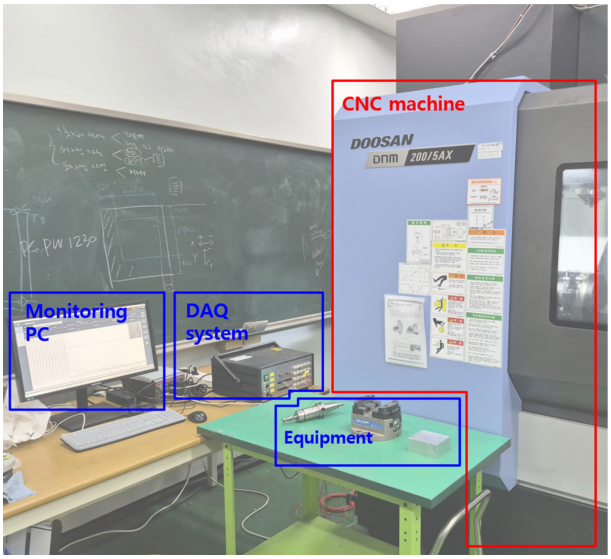


Fig. 7 Experimental environment for machining data acquisition

Table 2(b)에 따라 총 648개 조합의 직선 가공을 수행하고, 각 가공 경로에 대해 0.5 mm 단위로 약 116,640건의 Ra를 매칭하여 4개 절삭조건 조합별 Ra 예측 데이터셋을 구축하였다.

$$T_{total} = \frac{A_{boundary} \times D_{feature}}{Feedrate \times AP \times AE}(min) \quad (3)$$

$$Ra_{target} \geq Ra_{pred}(S, F, AP, AE) \quad (4)$$

절삭조건 최적화 모듈에서는 위의 자동 품질평가로 예측한 Ra와, MRR (Material Removal Rate) 기반으로 계산한 가공 시간으로 대규모 Machining Dataset을 구축한 후, 이를 3.2절에서 선택된 공구에 맞춰 공구 카탈로그 기반으로 스케일링 및 보간하여, 품질과 시간을 최적화하여 절삭조건을 추천한다. 이때 식(3) 및 식(4)와 같이 가공 시간은 목적 함수로, Ra는 제약 조건으로 사용된다. 도출된 4개의 절삭조건 데이터는 3.2절에서 생성한 Operation 엔티티의 속성으로 저장된다.

4. 통합 시스템 구현 및 검증

4.1 개발 환경 및 실험 환경 구축

제안된 시스템의 유효성과 적용성을 검증하기 위해 프로토타입 시스템을 개발하고 검증 실험을 수행하였다. 개발환경은 Python 3.13.5 기반 Anaconda에서 Spyder IDE를 사용하였으며 Table 4의 라이브러리를 적용하였다. Ra 예측 모델 구축을 위한 가공 실험 환경은 Fig. 7과 같이 CNC 장비(DOOSAN DNM 200/5AX), DAQ 시스템(NI cDAQ-9189), 모니터링 시스템(MMAS)으로 구성하였으며, WIDIN WAR3032010 Φ20 엔드밀과 AL 6061 소재로 가공 실험을 진행하였다. 가공 이후 Ra 측정에서는 Mitutoyo의 SURFTEST SV-2100을 사용하였다.

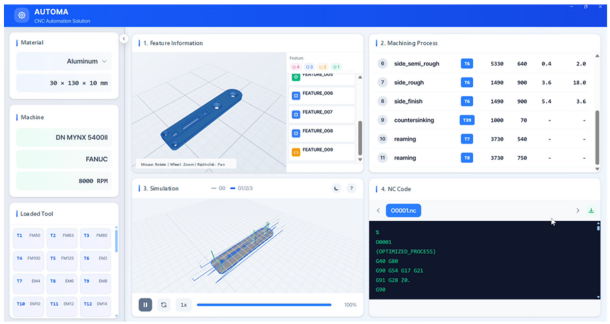


Fig. 8 Screen shot of prototype program

4.2 시스템 구현 및 프로토타입 개발

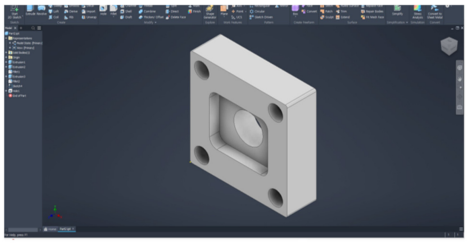
2장의 통합 시스템 아키텍처와 3장의 상세 모듈 설계를 기반으로 시스템을 개발하고 프로토타입 프로그램을 구현하였다. 사용자가 STL 형상을 입력하면 형상 인식, 공정 전개 및 절삭조건 추천, 공구경로 생성이 순차적으로 자동 실행되며, 각 단계의 XML 정보가 가시화된다. Fig. 8과 같이 인식된 형상, 공정 및 절삭조건, 공구경로, NC 코드를 단일 화면에서 시각적으로 확인할 수 있도록 구성하였다.

4.3 시스템 평가 및 검증

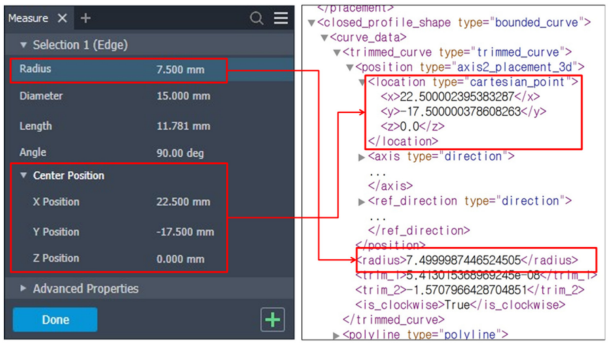
시스템이 STL 입력으로부터 실제 가공에 적용 가능한 수준의 결과를 도출하는지 검증하였다. 시스템 내 두 머신러닝 모델의 성능을 평가하여 생성 XML의 신뢰성을 확보하고, 해당 XML 기반 NC 코드로 CNC 실가공을 수행하여 결과물이 허용 공차와 Ra를 만족하는지 평가하였다.

4.3.1 형상 인식에 대한 Arc Detection Model 평가

먼저 3.1절의 Arc Detection Model이 STL 메쉬로부터 정확한 파라메트릭 치수정보를 생성하는지 확인함으로써 개발된 시스템이 정확한 치수의 형상 정보를 생성하는지 검증하였다. 검증 대상 형상은 실제 CNC 가공으로 제작하는 몰드 베이스 부품으로 선정하였으며, Figs. 9(a) 및 9(b)와 같이 시스템이 생성한 XML의 정보를 3D CAD 모델링 데이터와 비교하였다. 인식된 General_outside_profile 및 Closed_pocket의 내부 형상 경계에서 각각 4개의 Trimmed_curve를 탐지하여 XML 스키마로 저장하고 있음을 확인하였으며, 각 원호의 중심점 좌표와 반지름을 Fig. 9(b)와 같이 전부 10^{-3} μm 수준으로 재현하고 있음을 확인하였다.

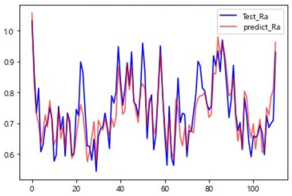


(a) Example feature in Inventor

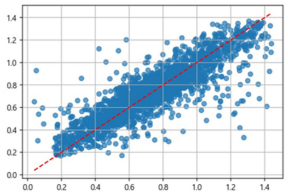


(b) Screen shot of CAD design and XML feature

Fig. 9 Comparison of arc detection results between CAD and XML



(a) Line plot of surface roughness



(b) Scatter plot of predicted-measured

Model	N_estimators	Max_depth	Min_samples_split	Structure
Random Forest	100	20	5	Ensemble

(c) ML model configuration

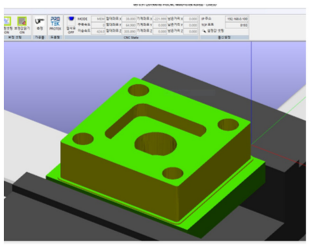
Index	Performance
MSE	0.0114 μm²
RMSE	0.049 μm
MAE	0.082 μm
R^2	0.893

(d) Prediction performance comparison

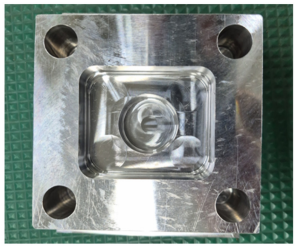
Fig. 10 Surface roughness prediction model evaluation results

4.3.2 절삭조건 최적화에 대한 Ra Prediction Model 평가

3.3절에서 개발한 Ra Prediction Model 성능을 평가하여, 절삭조건 최적화 모듈에서 제약조건으로 적용되는 Ra 예측의 신뢰성을 검증하였다. 학습에 사용되지 않은 20%의 테스트셋으로 평가한 결과 Fig. 10과 같이 결정계수 0.893의 예측 성능을 확보하였다. Random Forest 모델이 적절한 성능을 나타내는 것으로 확인했으며, 이는 이진 분할 알고리즘 기반으로 변수 절삭조건에 따른 고유 주파수 학습에 유리하기 때문인 것으로 보이고, 해석 가능성과 소규모 데이터에 대한 안정성 측면에서도 적합한 것으로 판단된다.



(a) ProCNC simulation



(b) Machining results of target geometry

Feature	Nominal Dimension	Actual (mean)	Error (mean)	KS	Ra (mean)	ISO
	mm			IT	μm	N
General outside profile	100.00 * 95.00	99.92 * 95.04	0.07	9	0.775	6
Closed pocket	60.00 * 50.00	59.96 * 49.92	0.06	9	0.3	5
Round hole 1	Ø 30.00	30.10	0.1	11	1.095	7
Round hole 2	Ø 15.00	14.97	0.03	9	0.6	6
Round hole 3	Ø 15.00	14.97	0.03	9	0.5	6
Round hole 4	Ø 15.00	15.00	0.00	~5	0.7	6
Round hole 5	Ø 15.00	14.97	0.03	9	1.2	7
Mean			0.0457	8.71	0.739	6.14

(c) Summary of machining quality evaluation

Fig. 11 CNC machining results

4.3.3 CNC 실가공을 통한 시스템 유효성 검증

제안된 시스템의 유효성을 검증하기 위해, Figs. 11(a) 및 11(b)와 같이 시스템이 자동 생성한 NC 코드를 ProCNC 가공 시뮬레이션으로 사전 검증한 후 실제 CNC 밀링 가공에 적용하였다. 대상 형상은 외곽 프로파일, 포켓, 원형 홀의 가공 결과에 대한 치수 및 Ra를 측정하여 표준 등급으로 분류한 결과를 Fig. 11(c)에 정리하였다. 측정 결과, 등급 평균 IT8.71(일반 끼워 맞춤 부품 수준), N6.14(0.8이하 정밀 다듬질 수준)로 제안된 시스템이 전문가 개입 없이 자동 생성한 공정 계획 및 NC 코드가 실제 가공에서 적용할 수 있는 수준임을 확인하였다.

5. 결론

본 연구에서는 STL 형상 입력만으로 형상 인식, 공정 전개, 절삭조건 최적화, 공구경로 생성, NC 코드 출력까지의 CNC 절삭가공 공정계획 단계를 자동 수행하는 통합 지능화 시스템을 개발하였다. 규칙 기반 형상 인식과 제약 기반 공정 전개 알고리즘으로 전문가 의존도를 최소화하였으며, 음향 기반 자동 품질 평가 모델을 통한 실가공 실험 데이터를 기반으로 절삭조건 최적화를 구현하였다. 뿐만 아니라 전체 아키텍처를 기반으로 프로토타입 시스템을 개발하여 각 모듈별로 생성되는 XML 결과를 가시화하여 제공하고, 이를 통해 생성된 NC 코드를 CNC 가공에 적용하여 제안된 시스템을 검증하였다.

본 연구를 통해 개발된 시스템은 기존 공정 계획 과정에서 엔지니어의 경험과 지식이 개입되어야 할 가공특징형상 지정, 사용 공구 설정, 공정 및 가공전략 할당, 최적 절삭조건 선정 등의 과정을 머신러닝 기법과 최적화 모델, 룰 기반 시스템 등을 활용하여 자율적으로 처리함으로써 형상 입력만으로도 NC 프로그램 생성이 가능함을 보여 주었으며, 이를 통해 공정 계획

과정에 소요되는 시간 및 전문성에 따른 비용 측면에서 개선 효과가 나타날 것으로 기대된다. 또한 STL 포맷으로 CAD 소프트웨어 간 비표준화 및 CAD-CAM 호환성 문제를 해소하고, STL 기반 ISO 14649 가공 형상 추출을 통해 설계-가공 간 형상 정보 변환의 비효율성을 해결할 수 있다. 나아가 전 공정을 ISO 14649 기반 XML로 통합하여 운용함으로써, CAD, CAPP, CAM 등 다수의 소프트웨어 운용에 따른 정보 파편화를 해소하고, 데이터 연속성을 확보하여 설계에서 가공 사이의 체계적인 공정 전개를 가능하게 한다.

다만 본 연구에서 개발된 형상 인식 기능은 ISO 14649의 기본 2.5D 가공특징형상 유형을 다루었으므로, 향후 인식 가능한 가공특징형상 유형을 다양화하고 형상 인식 방식에 그래프 기반의 인공신경망을 도입하여 스플라인 등 경계 곡선 인식 기능을 강화할 필요가 있다. 또한 제안된 시스템의 자율화 수준을 높이기 위해 STEP-NC 데이터와 실가공 데이터를 학습하고 LLM과 연계하여 공정 전개 과정을 고도화하는 연구를 수행하고 있으며, Ra 예측에 인공신경망 학습을 적용하여 산업현장의 소음 등 다양한 환경적 노이즈에 대한 제어 강건성을 확보하고 신뢰성을 강화하는 연구도 필요하다.

ACKNOWLEDGEMENT

본 연구는 산업통상자원부의 산업기술알키미스트 프로젝트 사업의 지원으로 수행되었음[과제명: 생각으로 하는 제조: LLM 연계 생성형 AI 기반 자율 설계·생산 플랫폼 기술(No. 2410015743)].

REFERENCES

1. Yoon, J. S., Park, I. H., Lee, D. Y., (2025), A review of intelligent machining process in CNC machine tool systems, International Journal of Precision Engineering and Manufacturing, 26(9), 2243-2268.
2. Al-wswasi, M., Ivanov, A., Makatsoris, H., (2018), A survey on smart automated computer-aided process planning (ACAPP) techniques, The International Journal of Advanced Manufacturing Technology, 97(1), 809-832.
3. Hirayama, T., Nakatsuji, H., Nishida, I., (2024), Automated process planning system considering machining feature recognition suitable for end-milling using CAD models in STL format, Journal of Advanced Mechanical Design, Systems, and Manufacturing, 18(7), 1-12.
4. Besharati-Foumani, H., Lohtander, M., Varis, J., (2019), Intelligent process planning for smart manufacturing systems: a state-of-the-art review, Procedia Manufacturing, 38, 156-162.
5. Tonejca, L., Trautner, T., Slimane, E., Peso, N., Zulehner, J., Bleicher, F., (2024), Automated design of experiments supporting feature-based optimisation of manufacturing processes, Procedia CIRP, 130, 1611-1616.
6. Simonič, M., Palčič, I., Klančnik, S., (2025), Advancing intelligent toolpath generation: A systematic review of CAD–CAM integration in industry 4.0 and 5.0, Strojniški vestnik - Journal of Mechanical Engineering, 71(9-10), 328-336.
7. ISO 14649-1, (2003), Industrial automation systems and integration — Physical device control — Data model for computerized numerical controllers — Part 1: Overview and fundamental principles.
8. Lee, J. W., Yeo, C. M., Cheon, S. U., Park, J. H., Mun, D. H., (2023), BRepGAT: Graph neural network to segment machining feature faces in a B-rep model, Journal of Computational Design and Engineering, 10(6), 2384-2400.
9. Nishida, I., Shirase, K., (2018), Automatic determination of cutting conditions for NC program generation by reusing machining case data based on geometric properties of removal volume, Journal of Advanced Mechanical Design, Systems, and Manufacturing, 12(4), 1-9.
10. Stathatos, E., Benardos, P., Vosniakos, G. C., Gross, D., Spieker, H., Gotlieb, A., (2026), Large language models for high-level computer-aided process planning in a distributed manufacturing paradigm, Robotics and Computer-Integrated Manufacturing, 100, 103233.
11. Gwon, T., Kwon, O. J., (2023), A study on artificial neural network learning using decimal data of CNC cutting conditions for aluminum, Journal of Industrial Technology Research, 28(1), 25-34.
12. Cevik, Z. A., Ozsoy, K., Ercetin, A., Sariisik, G., (2025), Machine learning-driven optimization of machining parameters optimization for cutting forces and surface roughness in micro-milling of AlSi10Mg produced by powder bed fusion additive manufacturing, Applied Sciences, 15(12), 6553.



Si Woo Park
B.Sc. candidate in the School of Mechanical Engineering, Kyungnam University. His research interest is intelligent manufacturing system and machine data analytics.
E-mail: rightime0220@gmail.com



Joo Sung Yoon
Associate Professor in the School of Mechanical Engineering, Kyungnam University. His research interest is smart machine tool system and intelligent machining process.
E-mail: jsyoon@kyungnam.ac.kr