

# 우리나라 제조업 품질관리 머신러닝 적용 연구의 국제적 수준 분석

정성환<sup>†</sup>

유한대학교 유한생명바이오학과

## An Analysis of the International Level of Machine Learning Application Research in Korean Manufacturing Quality Management

Sung Hwan Jung

Department of Yuhan Biotechnology, Yuhan University

This study evaluates South Korea's global competitiveness in machine learning applications for manufacturing quality management in the context of the transition to 'Quality 4.0' using a bibliometric analysis. A total of 1,624 articles, including 99 Korean studies, published between 2010 to 2025 were analyzed using Scopus data and a two-stage AI-assisted screening process. This study introduces a novel three-stage Machine Learning Maturity Framework (Level 1~3) and an time constraints analysis to enable an in-depth assessment of qualitative maturity levels. The results show that Korea ranks fifth globally in research volume and demonstrates world-class competitiveness in Level 1 (Defect Detection) and Level 2 (Virtual Metrology), particularly in the semiconductor and electronics industries, which primarily drive this competitiveness. However, whereas global research is increasingly shifting toward process optimization across diverse domains, Korea exhibits a relatively low proportion of Level 3 (Control) studies. Furthermore, although online monitoring of field data is prevalent (45.5%), real-time closed-loop control remains limited (20.2%), indicating a technological gap between sensing and control. Consequently, this study leverages Korea's strengths in data infrastructure and inspection technologies to propose an industry-specific roadmap for transitioning from monitoring-centric toward explainable autonomous control and PMQ (Production-Maintenance-Quality) integrated systems.

**Keywords:** Bibliometric Analysis, Machine Learning, Manufacturing Quality Management, Korean Research Trends, Autonomous Process control, PMQ Integration

### 1. 서 론

Industry 4.0의 도래와 함께 글로벌 비즈니스 환경의 복잡성이 증가하고 디지털 기술이 급격히 발전함에 따라, 제조업 분야는 근본적인 변화의 시기를 맞이하고 있다(Lee *et al.*, 2019). 오늘날의 경쟁적인 글로벌 시장에서 기업은 민첩성과 유연성을 갖춰야 하며, 특히 혁신적이고 복잡한 제품에 대한 고객의 요

구가 증가함에 따라 결함 없는 제품을 시장에 공급하는 품질 관리 역량은 기업의 생존과 직결되는 핵심 요소로 부상하였다(Bousdekis *et al.*, 2023). 과거의 품질관리가 주로 제품의 결함을 사후에 감지하거나 예방하는데 초점을 맞추었다면, 데이터 집약적인 현대의 제조 환경에서는 기존의 방법론만으로는 효율성과 신뢰성을 담보하기 어려워졌다. 이에 따라 품질경영 시스템은 단순한 공정 관리를 넘어, 빅데이터 분석, 스마트 센

<sup>†</sup> 연락저자 : 정성환 부교수, 14780 경기도 부천시 소사구 경인로 590 유한대학교 유한생명바이오학과, Tel : 02-2610-0792, Fax : 02-2610-0899, E-mail : jsh5810@yuhan.ac.kr

2026년 1월 12일 접수; 2026년 2월 18일 수정본 접수; 2026년 3월 3일 게재 확정.

서, 인공지능(AI)과 같은 첨단 디지털 기술을 활용하여 인과관계를 분석하고 실시간 의사결정을 수행할 수 있는 살아있는 생태계로 진화하고 있다(Mat Deli *et al.*, 2025)

제조 공정과 품질 측정 데이터의 결합이 가능해지면서, 품질관리에서 머신러닝과 딥러닝 기술을 적용하려는 시도가 폭발적으로 증가하고 있다(Tercan and Meisen, 2022). 이러한 흐름은 ‘Quality 4.0’ 혹은 ‘디지털 품질경영(DQM)’이라는 새로운 패러다임으로 정의되며, 이는 전통적인 품질 도구에 디지털 기술을 결합하여 프로세스의 정확도를 높이고 변동성을 줄이는 것을 목표로 한다(Kim *et al.*, 2024; Mat Deli *et al.*, 2025). 특히 최근의 연구들은 공정 데이터를 기반으로 제품의 품질을 데이터 주도로 추정하는 ‘예측 품질(Predictive Quality)’로 나아가고 있다(Tercan and Meisen, 2022). 인공신경망(Artificial Neural Network, ANN), 서포트 벡터 머신(Support Vector Machine, SVM), 랜덤 포레스트(Random Forest, RF) 등의 알고리즘은 결함 탐지, 예지 보전(Predictive Maintenance), 공정 최적화 등 다양한 품질관리 영역에서 그 유효성을 입증하고 있으며, 합성곱신경망(Convolutional Neural Network, CNN)을 이용한 이미지 기반 결함 탐지나 센서 데이터 분석을 통한 이상 탐지 기술은 인간의 개입을 최소화한 고속·고정밀의 품질 검사를 가능하게 하여 제조 효율성을 극대화하고 있다(Kausik *et al.*, 2025).

제조업 강국인 대한민국이 글로벌 경쟁력을 지속하기 위해서는 현재의 기술 개발이 국제적인 연구 흐름과 궤를 같이하고 있는지, 혹은 선도적인 위치에 있는지를 객관적으로 파악할 필요가 있다. 계량서지학(Bibliometrics)은 방대한 학술 문헌을 정량적으로 분석하여 연구 분야의 지적 구조, 진화 패턴, 그리고 국가 및 기관 간의 협력 네트워크를 규명하는 데 유용한 도구이다(Mat Deli *et al.*, 2025). 최근 중국, 인도, 미국 등이 제조 품질 연구에서 높은 출판 성과를 보이고 있는 가운데, 국내 연구가 이러한 글로벌 트렌드 속에서 어느 정도의 위상을 차지하고 있는지에 대한 체계적인 비교 분석은 미비한 실정이다.

따라서 본 연구는 제조업 품질관리 분야에 머신러닝을 적용한 연구들을 대상으로 계량서지학적 분석을 수행하고자 한다. 이를 위해 구체적으로 이 분야에서 다음과 같은 질문에 대한 분석을 시도한다.

- 1) 이 분야에서 국제 연구와 비교하여 우리 나라 연구의 양적 증가 추세는 어떠한가?
- 2) 이 분야 연구의 선도적 위치를 차지하는 국가는 어디이며, 한국의 위상은 어떠한가?
- 3) 이 분야의 선도적 저널들은 무엇이며, 연구의 질적 측면에서 한국의 수준은 어떠한가?
- 4) 이 분야에서 우리나라 연구의 강점과 단점은 무엇인가?
- 5) 국제적 연구 흐름에 비추어 이 분야에서 우리나라 향후 연구의 방향은 어떻게 해야 하는가?

본 연구는 기존 계량서지학 연구들과 차별화되는 다음과 같

은 세 가지 학술적 기여를 제공한다. 첫째, 제조 품질관리의 특성을 반영하여 9가지 핵심 활동을 정립하고 이를 ‘3단계 머신러닝 성숙도 프레임워크(ML Maturity Framework)’로 체계화하였다. 기존 연구들이 주로 알고리즘 유형이나 단위 공정 중심의 분류에 집중했던 것과 달리, 본 연구는 품질 활동을 ‘감지(Descriptive)’, ‘예측(Predictive)’, ‘제어(Prescriptive)’의 가치 창출 단계로 구조화하고, 각 단계에 해당하는 9가지 세부 활동(결함 탐지, 가상 예측, 공정 제어 등)을 매핑하여 기술의 질적 고도화 수준을 진단하는 구체적인 방법론적 틀을 제시한다. 둘째, ‘기술 적용의 시간 제약(Time Constraints)’이라는 새로운 분석 차원을 도입하여 현장 적용성을 평가한다. 머신러닝 적용 시점을 Offline(사후 분석), Online(실시간 모니터링), Real-time(폐루프 제어)으로 세분화함으로써, 연구실 수준의 성과와 실제 제조 현장 적용 간의 간극을 규명하는 독창적인 지표로 활용한다. 셋째, 국가 단위의 연구 생태계 특성을 진단하고 구조적 편중을 해소하기 위한 전략적 로드맵을 제시한다. 글로벌 연구와 국내 연구의 지적 구조(Intellectual Structure) 차이를 네트워크 분석으로 시각화하여, 한국 연구의 특징과 장단점을 실증하고 이를 개선하기 위한 구체적인 실행 전략을 도출한다.

본 연구의 구성은 다음과 같다. 제2장에서 제조업에 머신러닝을 적용한 연구들의 경향 분석을 수행한 기존 연구들을 살펴본다. 제3장에서 본 연구의 분석방법을 설명한다. 제4장은 분석의 결과로서 연도별 게재 논문수, 국가별, 저널별 분석, 키워드 분석 등의 결과를 제시한다. 아울러 선별된 국내 연구에 대한 질적 분석을 시도하고 시사점과 발전 방향성을 도출한다. 5장에서 전체 내용을 요약하며 결론을 맺는다.

## 2. 머신러닝을 적용한 제조 품질 분야 연구 동향

2020년대 이후에 인공지능의 발전이 가속화되면서 제조업에서도 머신러닝에 대한 적용이 활발히 이루어졌으며, 다양한 관점과 초점을 가지고 제조업에 머신러닝을 적용한 연구에 대한 체계적 문헌 고찰 또는 계량서지학적 분석 연구가 발표되었다. <Table 1>에 관련 연구를 정리하였다. 본 절에서는 이들의 연구를 종합하여 제조업 품질관리 분야에서 머신러닝 적용 연구의 흐름과 발전 양상, 그리고 한계점을 정리하였다.

먼저 머신러닝 알고리즘의 적용 현황을 보면, 라벨링된 데이터를 활용하는 지도학습(Supervised Learning)이 가장 널리 사용되고 있으며, 특히 인공신경망(ANN)과 CNN은 이미지 기반의 결함 탐지에서 탁월한 성능을 보여 주류로 자리 잡고 있음을 확인할 수 있다(Kausik *et al.*, 2025; Kim *et al.*, 2024). 반면, SVM과 RF는 고차원 센서 데이터를 처리해야 하는 예지 보전(Predictive Maintenance)이나 공정 파라미터 최적화와 같은 영역에서 높은 정확도와 계산 효율성을 입증하며 널리 활용되고 있다(Kausik *et al.*, 2025). 또한, 동적인 제조 환경에서

**Table 1.** Literature Reviews on Machine Learning Applications in Manufacturing

| Author                            | Research Subject                                                                          | Scope                                                                                  |
|-----------------------------------|-------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------|
| Tercan and Meisen(2022)           | Predictive Quality using ML/DL in Manufacturing Processes (Cutting, Joining, etc.)        | Systematic review of 81 publications (2012-2021).                                      |
| Bousdekis <i>et al.</i> (2023)    | Data Analytics within Quality 4.0 for Manufacturing Operations (Maintenance, Quality)     | Systematic literature review of 48 papers (2012-2020).                                 |
| Paraschos and Koulouriotis (2024) | Learning-based Scheduling & Control in Smart Manufacturing Systems                        | Meta-analysis of 108 papers (1995-2024) covering production, maintenance, and quality. |
| Ördek <i>et al.</i> (2024)        | ML-supported Manufacturing Functions (Mechanical Engineering aspects)                     | Review of 114 journal articles focusing on process selection, monitoring, and QC.      |
| Manta-Costa <i>et al.</i> (2024)  | Industrial ML (I-ML) characterization in Manufacturing Scenarios (PdM, AD, PPS, QI, HRI)  | PRISMA review of 29 Q1 journal articles (2019-2023).                                   |
| Mat Deli <i>et al.</i> (2025)     | Bibliometric Trends of Quality Management in the Manufacturing Sector                     | Bibliometric analysis of 2,501 Scopus documents (2020-2024).                           |
| Kausik <i>et al.</i> (2025b)      | ML Algorithm Performance in Manufacturing Quality Assurance (QA)                          | Systematic review of 300+ peer-reviewed studies (last two decades).                    |
| Mota <i>et al.</i> (2025)         | Integration of AI Systems for Production, Maintenance, and Quality (PMQ) in Manufacturing | PRISMA review of 214 studies (2017-2024).                                              |
| AlKhader <i>et al.</i> (2025)     | Thematic Evolution of Quality in Manufacturing Research (Pre vs. Post-I4.0)               | LDA topic modeling of 122,043 Scopus documents (1970-2023).                            |
| Kim <i>et al.</i> (2024)          | ML Research Patterns from a Digital Quality Management (DQM) Perspective                  | Systematic review of ~110 papers (2015-2022)                                           |

의 실시간 스케줄링 및 제어 문제를 해결하기 위해 심층 강화 학습(Deep Reinforcement Learning)의 적용이 최근 급격히 증가하고 있는 추세이다(Mota *et al.*, 2025; Paraschos and Koulouriotis, 2024).

구체적인 적용 분야를 보면, 머신러닝은 품질 검사, 공정 모니터링, 예지 보전 등 다양한 영역으로 확장되고 있다. 로봇 기반의 품질 관리에서는 머신 비전뿐만 아니라 열화상, X-ray, 초음파 등 다양한 비파괴 검사 기술이 로봇과 결합되어 자동화된 검사를 수행하고 있다(Papavasileiou *et al.*, 2025). 특히 적층 제조 분야에서는 머신러닝을 통해 공정 파라미터와 최종 제품의 물성 간의 복잡한 비선형 관계를 규명하고 공정을 최적화하려는 연구가 폭발적으로 증가하고 있다(AlKhader *et al.*, 2025; Mota *et al.*, 2025).

그러나 이러한 기술적 진보에도 불구하고 현장 적용에는 여전히 한계가 존재한다. 제조 현장에서는 양질의 라벨링된 데이터를 확보하기 어렵고, 불량 데이터가 정상 데이터에 비해 현저히 적은 클래스 불균형 문제가 심각하여 지도학습 모델의 성능 저하 원인이 되고 있다(Manta-Costa *et al.*, 2024). 이를 해결하기 위해 유사한 공정이나 제품에서 학습된 모델을 새로운 도메인에 적용하는 전이 학습(Transfer Learning)이나, 라벨링 비용을 절감할 수 있는 자기 지도 학습(Self-supervised Learning), 그리고 합성 데이터 생성(Synthetic Data Generation)과 같은 데이터 효율적인 방법론에 대한 연구 필요성이 제기되고 있다(Kausik *et al.*, 2025; Ördek *et al.*, 2024).

또한, 딥러닝 모델은 높은 예측 정확도를 제공하지만 의사 결정 과정을 설명하기 어려운 ‘블랙박스(Black-box)’ 성격을

띠고 있어, 신뢰성이 중요한 제조 현장 도입에 걸림돌이 되고 있다. 이에 따라 모델의 판단 근거를 사람이 이해할 수 있는 형태로 설명하는 ‘XAI(eXplainable AI)’ 기술 개발이 중요한 과제로 대두되고 있으며, 이는 운영자의 신뢰를 높이고 근본 원인 분석을 용이하게 하는 데 필수적이다(Mota *et al.*, 2025).

통합적 관점에서 볼 때, 기존 연구들은 생산 계획, 유지보수, 품질 관리를 개별적으로 최적화하는 데 집중해 왔으나, 최근에는 이들 요소를 통합적으로 고려한 ‘결합 최적화(Joint Optimization)’ 연구가 미약하지만 등장하고 있다. 예를 들어, 예지 보전 시스템이 기계의 고장 확률을 예측하면 이를 바탕으로 생산 스케줄을 동적으로 조정하고 품질 검사 빈도를 변경하는 식의 유기적인 통합 시스템 구축이 시도되고 있는 것이다(Mota *et al.*, 2025).

### 3. 분석 대상 선정

본 연구는 머신러닝을 활용한 제조 품질 관리 분야의 연구 동향과 주제 패턴을 분석하는 것을 목적으로 한다. 이에 따라 원문(full text)에 대한 체계적 문헌고찰은 수행하지 않았다. 대신, 제목, 초록 및 키워드를 기반으로 관련 문헌을 식별하고 선별하기 위해 PRISMA(Preferred Reporting Items for Systematic Reviews and Meta-Analyses) 프레임워크를 수정·적용하여 선별 절차를 수행하였다(Page *et al.*, 2021). 이를 위해 분석 범위 설정을 통한 대상 문헌 식별 후, AI 기반 자유 가속 선별(Liberal Accelerated Screening) 방법론을 통해서 최종 분석 대

상 문헌을 선별하였다(Hamel *et al.*, 2021).

### 3.1 분석 범위

본 연구는 질적 수준이 보장된 연구 문헌만을 대상으로 삼기 위해 Scopus 데이터베이스에서 등록된 문헌 중 학술대회 proceeding이나 Book 시리즈는 제외하고, 출처 유형이 ‘저널(Journal)’인 ‘영어(English)’로 게재된 ‘논문(Article)’만을 대상으로 하였다.

제조업 분야 논문을 선별하기 위해서 제목, 초록, 키워드 검색 시 “manufactur\*”을 검색어로 사용하였다(Kim *et al.*, 2024; Ördek *et al.*, 2024). 또한 머신러닝 관련 논문을 선별하기 위해서 “\*learning”을 검색어로 사용하였다(Ördek *et al.*, 2024; Paraschos and Koulouriotis, 2024).

품질 분야는 국제표준과 문헌에 따라 그 범위와 개념이 다양하여 정확한 범위를 규정하는게 용이하지는 않으나, 가능한 ISO 9000:2015 표준에서 규정하고 있는 품질경영(quality management)의 개념에 속하는 연구는 다 포함되도록 다소 포괄적인 다음의 “quality control” OR “quality management” OR “quality improvement” OR “quality assurance” OR “quality monitoring” 단어들을 검색어로 사용하였다(Bousdekis *et al.*, 2023).

논문의 검색 기간은 2010년부터 논문 검색 시점인 2025년 10월 30일로 설정하였다.

### 3.2 최종 분석 대상 선정

분석 범위 결정에 의해 총 1,833개의 논문이 최초로 식별되었다. 이 중에서 제목, 초록, 키워드에 우연히 분석 범위 검색어가 포함된 다른 분야의 논문을 선별 및 제외하기 위해서 AI를 활용한 1차 선별(Screening)작업을 실시하였다. 1차 선별작업에 사용한 AI는 ChatGPT 5.2 모델이다.

AI의 논문 선별작업의 신뢰성을 확보하기 위해서 본 연구에서는 식별된 1,883개 문헌의 약 11%에 해당하는 206개의 논문을 연구자가 직접 제목, 초록, 키워드를 읽고 논문이 본 연구 대상 분야에 포함되는지 여부를 판단하여 초기 파일럿 훈련 세트(Initial Training Set)를 구성하였다. 이후 AI에게 논문선별작업을 위한 프롬프트를 제공하고, AI의 논문 선별능력이 일정 수준에 수렴할 때까지 선별결과를 분석하여 30여 회에 걸쳐 다음과 같은 프롬프트 고도화 작업을 수행하였다.

프롬프트 고도화 초기에는 ‘제조’, ‘품질’, ‘머신러닝’ 관련 키워드를 단순 매칭시키는 규칙기반(Rule-based) 방식을 시도하였다. 이 방식은 관련 논문을 놓치지 않고 찾아내는 재현율(Recall)은 높았으나, 판단 논리가 단순하고 맥락을 고려하지 않아 키워드는 포함하지만 실제 관련성이 없는 논문을 포함시키는 오탐(False Positive) 비율이 높았다. 이를 개선하고자 판단과정을 ‘제목’ 분석과 ‘초록 및 키워드’ 분석으로 단계화하고, 머신러닝 적용 품질 활동의 정의와 예시 제공을 통해 맥락

적 조건을 강화한 프롬프트를 적용해 보았으나 그 결과 기준이 너무 엄격하여 유효한 논문들이 대거 제외(False Negative)되는 문제가 발생하였다.

결과적으로 최종 프롬프트는 판단 논리를 최적화하여 ‘제조’ 및 ‘머신러닝’ 관련성은 AI가 직접 판단하게 하되, ‘품질’ 관련성은 ‘맥락적 관련성 높음’과 ‘품질관련 키워드 포함’ 중 하나만 만족해도 되는 ‘OR’ 조건을 적용하여 판단의 유연성을 부여하였다. 아울러 ‘이미지 및 음성 품질’, ‘조직학습’, 단순 통계기법, 트렌드 분석 논문 등은 명확한 제외 기준(Exclusion)으로 설정함으로써 오탐을 방지하고 모델의 신뢰성을 확보하였으며, 최종 프롬프트는 부록에 수록하였다.

최종 프롬프트 적용 결과 AI가 포함(include)이라고 판정한 것 중 실제로 포함에 해당하는 비율인 정밀도(Precision)는 97.7%를 달성하였다. 그러나, 실제 포함되어야 할 대상 중 AI가 놓치지 않고 찾아낸 비율인 재현율(Recall)은 94.5%로 비교적 낮게 수렴되었다. 이는 AI가 포함시킨 논문은 본 연구 분야와 관련성이 없을 확률은 매우 낮으나, AI가 제외한 논문 중에는 실제 본 연구 대상 분야와 관련성이 높은 논문이 상당수 포함될 수 있음을 의미한다고 할 수 있다. 따라서, 1차 선별작업 결과로 제외된 논문 266개를 대상으로 실제 본 연구 대상과 관련성 높은 논문을 다시 한번 확인하기 위한 2차 선별작업을 또 다른 AI를 통해 진행하였다. 이때 사용된 AI는 Gemini 3 Pro 모델이다. 2차 선별작업에서는 1차 선별작업과 동일한 프롬프트를 사용하였다.

1차 및 2차 AI 논문 선별작업의 최종 분류 성능은 Cohen Kappa 지수 0.88, 95%신뢰구간(0.757~0.973)을 달성하였다. 이것은 관행적 기준에 따라 인간 분류 작업과 거의 완벽한(Almost perfect) 일치라고 할 수 있으며, 보수적으로 봐도 상당한(Substantial) 일치로 신뢰할만한 수준으로 평가된다(Landis and Koch, 1977). 2차 선별작업에서 관련 연구로 평가되어 재포함된 논문의 수는 64개이다. 최종적으로 머신러닝을 활용한 제조 품질 관련 논문으로 선별된 논문은 1,624개이며, 이 중 우리나라(South Korea)에 속한 기관의 저자가 게재한 논문은 99개로 확인되었다. <Figure 1>에서 분석 대상 선정 과정을 도식화하였다.




Figure 1. Process for Selecting Relevant Articles.

## 4. 분석 결과

### 4.1 연도별 논문 수 분석

<Figure 2>는 2010년 이후 머신러닝을 적용한 제조 품질분야 전 세계 및 우리나라 논문 출판 추이를 나타내고 있다. 전 세계 출판 추이는 2010년부터 2016년까지는 연간 10-16건으로 정체되어 있었으나 2017년을 기점으로 폭발적인 성장세를 보이고 있다.

우리나라도 2017년 본격적인 연구 궤도에 진입한 이래 연평균 성장률(CAGR) 32.8%를 기록하며 꾸준한 성장세를 이어오고 있다. 그러나 2017년 이후 전 세계 논문출판 규모가 연평균 44.6%로 급격히 팽창함에 따라, 초기 진입 시점 대비 우리나라의 상대적 점유율은 다소 축소되었다.

전 세계 성장을 주도한 국가는 중국으로, 2017년부터 2025년까지 연평균 56.0%의 성장률을 기록하며 규모와 속도면에서 모두 압도적인 영향력을 행사하고 있다. 특히, 최근 3년(2023~2025) 성장률은 74.5%에 달해 가속화 추세가 뚜렷하다. 인도 역시 논문 규모는 우리나라와 유사하나, 최근 3년(2023~2025) 60.1%의 높은 성장세를 보이고 있다. 반면 미국(9.8%)과 독일(-12.7%)은 최근 3년간 성장 둔화세가 뚜렷하다. 이와 대조적으로 우리나라는 최근 3년 연평균 성장률이 46.8%로 급반등하며 동기간 전 세계 성장률(35.2%)을 상회하였다. 이는 국내 연구 생태계와 인프라가 견고하게 구축됨에 따라 향후에도 지속적인 성장이 가능함을 시사한다.




Figure 2. Number of Articles Per Year (til Oct. 2025).

### 4.2 국가별 기여도 분석

<Figure 3>은 주저자(Corresponding Author)가 속한 국가를 기준으로 머신러닝을 적용한 제조 품질분야 논문 수 상위 10개 국가를 나타낸 것이다. 중국(420편)과 미국(221편)이 초대형 생산국으로서 압도적 최선두 그룹을 지키고 있으며, 우리나라(85편)는 세계 점유율 5위로 독일(101편), 인도(94편)와 함께 핵심 기여국 클러스터를 형성하고 있다. 이는 영국(60편), 캐나다(35편), 일본(26편) 등 주요 선진국을 상회하는 수치로,

해당 분야에서 한국이 양적으로 우수한 연구 역량을 확보하고 있음을 시사한다.

우리나라의 단일국가연구(SCP) 비중은 약 81%로 높은 편인데, 이는 국내에 연구할 수 있는 인프라, 데이터, 연구진 등 연구 생태계가 잘 갖추어져 있음을 시사한다. 반면에 국제협력 연구(MCP) 비중은 약 18.8%로 미국(19.0%)이나 일본(19.2%)과 유사한 수준이나 영국(38.8%), 캐나다(42.9%) 등 서구권 국가들에 비해 상대적으로 낮았다. 이는 향후 글로벌 협력의 확장으로 연구의 질적 영향력을 높일 여지가 있는 것으로 평가된다.




Figure 3. The Top 10 Contributing Research Countries.

### 4.3 저널별 기여도 분석

<Table 2>는 브래드퍼드의 법칙(Bradford's law)에 따라 전 세계 631개 저널 중 누적 논문 수의 33.4%를 차지하는 영역 1(zone1)의 상위 20개 핵심 저널을 SJR(SCImago Journal Rank) 순으로 정렬하여 4개의 그룹으로 묶은 것으로 저널별 JIS(Journal Impact Score) 지표와 우리나라 논문이 게재된 편수를 함께 제시한 것이다.

우리나라는 논문 99편 중 38편(38.4%)이 상위 핵심 저널군에 게재되어, 상위권 연구 역량은 세계적인 수준임을 알 수 있다. 특히 'Journal of Manufacturing Systems'에서는 한국 논문 비중이 20%로, 최상위 저널에서도 경쟁력이 확인된다. 다만 'Sensors', 'Applied Sciences', 'IEEE Access' 등 중·하위권 및 포괄적(Open Access) 저널에 상대적으로 집중되는 경향이 있으며, 'IEEE Transactions' 계열, 'Additive Manufacturing' 등 일부 최상위 대표 저널에서는 게재가 0건으로 제한적이다. 이는 우리나라 연구가 가시성은 높으나, 전통적 최상위 저널 전반으로의 확산이 향후 과제로 남아 있음을 시사한다.

본 연구는 단순 빈도 분석을 넘어 연구 생태계의 지적 구조를 규명하기 위해 VOSviewer 1.6.20을 활용한 동시 인용(Co-citation) 분석을 수행하였다. 분석 단위는 '인용된 저널(Cited Source)', 가중치 산정은 '전수 계산(Full Counting)' 방식을 적용하여 글로벌과 한국의 학문적 토대와 구조적 차이를 비교 분석하였다.




**Table 2.** Top 20 Global Journals in Machine Learning Applications for Manufacturing Quality

| Grade      | Journal                      | SJR   | JIS   | NP | Korea NP | Korea NP% |
|------------|------------------------------|-------|-------|----|----------|-----------|
| Top-tier   | J. Manuf. Syst.              | 3.633 | 17.62 | 35 | 7        | 20.0%     |
|            | IEEE Trans. Ind. Inform.     | 3.416 | 13.3  | 16 | 0        | 0.0%      |
|            | Addit. Manuf.                | 2.877 | 11.83 | 16 | 0        | 0.0%      |
|            | Int. J. Prod. Res.           | 2.242 | 10.94 | 15 | 1        | 6.7%      |
|            | Comput. Ind.                 | 2.209 | 12.45 | 21 | 1        | 4.8%      |
| High-tier  | IEEE Trans. Autom. Sci. Eng. | 1.918 | 9.41  | 21 | 0        | 0.0%      |
|            | Expert Syst. Appl.           | 1.854 | 10.48 | 20 | 2        | 10.0%     |
|            | J. Intell. Manuf.            | 1.763 | 10.94 | 57 | 1        | 1.8%      |
|            | Eng. Appl. Artif. Intell.    | 1.652 | 10.23 | 16 | 3        | 18.8%     |
|            | Comput. Ind. Eng.            | 1.628 | 8.07  | 23 | 1        | 4.3%      |
| Mid-tier   | J. Manuf. Process.           | 1.556 | 7.43  | 32 | 1        | 3.1%      |
|            | IEEE Trans. Instrum. Meas.   | 1.471 | 6.46  | 16 | 0        | 0.0%      |
|            | Measurement                  | 1.244 | 6.34  | 19 | 0        | 0.0%      |
|            | IIESE Trans.                 | 0.851 | 3.38  | 12 | 1        | 8.3%      |
|            | IEEE Access                  | 0.849 | 5.31  | 44 | 6        | 13.6%     |
| Lower-tier | Sensors                      | 0.764 | 4.62  | 44 | 7        | 15.9%     |
|            | Int. J. Adv. Manuf. Technol. | 0.706 | 3.72  | 53 | 1        | 1.9%      |
|            | J. Manuf. Sci. Eng.          | 0.7   | 3.41  | 21 | 0        | 0.0%      |
|            | Manuf. Lett.                 | 0.551 | 2.6   | 22 | 0        | 0.0%      |
|            | Appl. Sci.                   | 0.521 | 3.15  | 39 | 6        | 15.4%     |
| Total      |                              |       | 542   | 38 | 7.0%     |           |

<Figure 4>의 글로벌 네트워크는 ‘Additive Manufacturing’, ‘Journal of Manufacturing Systems’, ‘CIRP Annals’ 등 제조 공학의 권위 있는 저널들이 ‘IEEE Access’나 ‘Sensors’와 같은 응용 저널과 중앙에서 밀접하게 얹혀 있는 통합된 생태계를 보여준다. 이는 글로벌 연구가 전통적인 제조 이론과 최신 AI 적용 기술을 유기적으로 결합하여 학제 간 융합을 주도하고 있음을 시사한다.

반면, <Figure 5>의 한국 연구 네트워크는 명확히 구분되는 도메인 특화형 구조를 보인다. 글로벌 맵에서는 두드러지지 않았

던 ‘IEEE Transactions on Semiconductor Manufacturing’과 ‘International Journal of Precision Engineering and Manufacturing’이 우측에 거대한 독립 클러스터를 형성하고 있는데, 이는 한국 연구의 지적 토대가 반도체 및 정밀 가공이라는 특정 주력 산업에 깊게 뿌리내리고 있음을 구조적으로 입증한다. 또한, 좌측에는 ‘Additive Manufacturing’과 ‘Materials & Design’ 등 소재·공정 중심의 저널들이 위치하며, 이 두 개의 이질적인 도메인은 ‘Applied Sciences’나 ‘IEEE Access’와 같은 포괄적 저널을 매개로 하여 느슨하게 연결된 형태를 띤다.

**Figure 4.** Global co-citation Network of Cited Sources in Manufacturing Quality Related Research (Citations threshold 8).




Figure 5. Korean Co-citation Network of Cited Sources in Manufacturing Quality Related Research (Citation threshold 3).

이러한 구조적 차이는 한국 연구의 성격이 이론적 융합보다는 ‘실용적 적용’에 무게를 두고 있음을 방증한다. 한국 네트워크는 반도체나 재료 공학이라는 확실한 산업 도메인을 기반으로 하여, AI 기술을 현장 문제 해결을 위한 ‘도구(Tool)’로서 활용하는 경향이 강하다. 즉, 한국 연구자들은 해당 산업 분야의 전문 저널과 빠른 게재가 가능한 응용 저널을 주로 교차 인용하며, 구체적인 제조 현장의 데이터를 기반으로 한 실증적 연구 성과를 축적하고 있는 것으로 분석된다.

#### 4.4 주제 진화 및 키워드 분석

본 절에서는 이 분야 지식의 흐름과 구조적 변화를 규명하기 위해, Bibliometrix 5.0(Biblioshiny 4.1)의 ‘Thematic Evolution 기능을 활용하여 시계열 분석을 수행하였다. 분석 시 글로벌(N=1,525)과 국내(N=99) 데이터의 양적 차이로 인한 편향을 방지하고자, 데이터셋 크기 대비 출현 비율을 반영한 ‘정규화된 빈도(Normalized Frequency)’와 차등적 임계값을 적용하였다. 이를 통

해 집단 규모와 무관하게 핵심 주제를 동등한 수준에서 포착하였으며, 시기 구분(Time Slices) 또한 데이터 밀도에 맞춰 최적화하여 분석의 신뢰도를 확보하였다.

<Figure 6>의 글로벌 연구 주제 진화 맵(Sankey Diagram)은 다수의 주제가 복잡하게 얽히며 진화하는 ‘다대다(Many-to-Many)’의 생태계적 구조를 보여준다. 초기(2010-2016)의 포괄적인 ‘Learning’ 개념은 중기(2017-2019)에 이르러 ‘Additive manufacturing’, ‘Fabric defect detection’ 등 다양한 제조 도메인으로 구체화되었으며, 최근(2020-2025)에는 ‘Deep learning’, ‘Industry 4.0’, ‘Transfer learning’ 등으로 다시 융합되는 양상을 띤다. 이는 글로벌 연구가 특정 공정에 국한되지 않고, AI 기술과 다양한 제조 이론이 유기적으로 결합하며 연구 지평을 확장하고 있음을 시사한다.

이와 대조적으로 <Figure 7>의 국내 연구 진화 맵은 소수의 핵심 줄기가 굵게 이어지는 뚜렷한 선형적 궤적을 나타낸다. ‘Machine learning’에서 시작된 단일 흐름은 2020-2022년의 ‘Object detection’ 및 ‘CNN’을 거쳐, 2023-2025년의 ‘Anomaly




Figure 6. Thematic Evolution of Global Research Based on Normalized Keyword Frequency(2010-2025).

detection’으로 직결된다. 이러한 구조는 주제의 확산보다는 심화에 초점을 맞춘 것으로, 한국 연구가 다양한 제조 응용 분야를 탐색하기보다는 주력 산업의 핵심 난제인 시각적 불량 검출의 정확도를 극대화하는 방향으로 연구 역량을 집중하고 있음을 구조적으로 입증한다.

이러한 구조적 차이는 최근 문헌의 키워드 빈도 분석에서도 구체적으로 재확인된다. <Table 3>은 2020년 이후 글로벌과 한국 문헌에서 출현 빈도가 높은 상위 5개 키워드를 연도별로 제시한 것이다. 2022년 이후 ‘CNN’과 ‘이상탐지(anomaly de-

tection)’가 양측 모두에서 공통 상위 키워드로 수렴하는 특징을 보이는데, 이는 제조 도메인과 무관하게 딥러닝 기반의 이상탐지 파이프라인이 품질 검사의 글로벌 표준(Paradigm)으로 자리 잡았음을 방증한다. 그러나 세부적인 도메인 키워드에서는 확연한 차이가 드러난다. 글로벌 트렌드는 2022년 이후 ‘적층 제조(additive manufacturing)’ 및 ‘레이저 분말 소결(laser powder bed fusion)’과 같은 플랫폼 공정 기술의 최적화와 ‘결함 탐지(defect detection)’ 연구가 주류를 이룬다. 반면, 한국은 2023년 이후 ‘객체 탐지(object detection)’와 함께 ‘반도체




Figure 7. Thematic Evolution of Korean Research Based on Normalized Keyword Frequency(2017-2025).

Table 3. Top 5 Most Frequent Author Keywords in Global and Korean Articles

| Year | Global keywords(freq.)                                                                                                                                 | Korean keywords(freq.)                                                                                                                            |
|------|--------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------|
| 2025 | additive manufacturing (32),<br>defect detection (31),<br>convolutional neural network (27),<br>anomaly detection(13),<br>laser powder bed fusion (12) | object detection (3),<br>semiconductor (3),<br>anomaly detection (2),<br>convolutional neural network (2),<br>directed energy deposition (2)      |
| 2024 | additive manufacturing (38),<br>defect detection (24),<br>anomaly detection (11),<br>convolutional neural network (11),<br>transfer learning (11)      | object detection (4),<br>convolutional neural network (3),<br>anomaly detection (2),<br>semiconductor (2),<br>augmentation (1)                    |
| 2023 | additive manufacturing (31),<br>convolutional neural network (14),<br>defect detection (12),<br>anomaly detection (11),<br>process monitoring (9)      | anomaly detection (3),<br>convolutional neural network (3),<br>object detection (2),<br>semiconductor (2),<br>wire arc additive manufacturing (2) |
| 2022 | additive manufacturing (15),<br>convolutional neural network (11),<br>anomaly detection (8),<br>defect detection (8),<br>quality prediction (7)        | convolutional neural network (3),<br>anomaly detection (2),<br>machine vision (2),<br>smart factory (2),<br>3d printing (1)                       |
| 2021 | convolutional neural network (11),<br>additive manufacturing (9),<br>defect detection (5),<br>ensemble learning (4),<br>internet of things (3)         | anodization (1),<br>autoencoder (1),<br>big data (1),<br>blockchain technology (1),<br>casting product (1)                                        |




(semiconductor)’가 반복적으로 최상위 키워드에 등장한다. 이는 앞서 주체 진화 분석에서 확인한 바와 같이, 국내 연구가 반도체 등 특정 주력 산업 도메인의 검사 과업 해결에 연구 자원을 집중하는 경향을 통계적으로 뒷받침한다.

#### 4.5 국내 연구 내용 및 질적 수준 분석

##### (1) 산업영역 분석

<Figure 8>은 우리나라 연구가 대상으로 삼은 산업군별 연구빈도를 나타낸 것이다. 전자·반도체(21.2%), 기계·산업설비(18.2%), 철강·금속·건설(15.2%) 산업이 전체 연구의 절반 이상을 차지하며 뚜렷한 집중 양상을 보였다. 이는 해당 산업들이 고정밀 공정, 고부가 제품, 그리고 대규모 센서·비전 데이터 인프라를 갖추고 있어 머신러닝 기반 품질 분석의 실증 가능성이 높기 때문으로 해석된다. 반면 식품, 화장품, 섬유 등 소비재 산업은 데이터 표준화와 공정 계측 인프라의 제약으로 인해 연구 빈도가 상대적으로 낮게 나타났으며, 이는 향후 데이터 구축 및 품질 특성 정량화를 통해 확장 가능한 잠재적 연구 공백 영역으로 평가된다. 바이오/헬스케어 산업은 연구빈도는 아직 낮지만 한국이 바이오 산업을 미래 전략산업으로 육성하고 있는 만큼, 향후 이 분야에서 엄격한 품질 규제(Good Manufacturing Practice, GMP)를 준수하기 위한 AI 도입 연구가 빠르게 증가할 가능성이 높게 예상된다.



**Figure 8.** Distribution of Korean Studies on Machine Learning Applications in Manufacturing Quality by Industry Sector

##### (2) 머신러닝 품질영역 활용 수준 분석

본 연구는 기존 문헌들의 파편화된 분류를 통합하여, 제조업 품질관리 전주기를 포괄하는 9가지 핵심 머신러닝 활동을 도출하였다. 또한, 이 활동들이 기술적 난이도와 가치 창출 단계에 따라 어떻게 진화하는지 파악하기 위해, Bousdekis *et al.* (2023)의 데이터 분석 성숙도 모델과 AlKhadar *et al.* (2025)의 전략적 품질 경영 관점을 차용하여 <Table 4>와 같은 분석 프레임워크를 수립하였다. Level 1(Descriptive)은 현상을 감지하고 설명하는 검사, 모니터링 단계이며, Level 2(Predictive)는 원

**Table 4.** Proposed Analytical Framework for ML Applications in Manufacturing Quality

| Maturity Level        | Category               | Application Area                  | Concept & Scope                                                                                                                    | Representative Korean References                       |
|-----------------------|------------------------|-----------------------------------|------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------|
| Level 1: Descriptive  | Sensing & Detection    | 1. Quality Inspection             | Automated defect detection using vision/sensors<br>e.g. CNN, Surface inspection                                                    | Park <i>et al.</i> (2024)                              |
|                       |                        | 2. Process Monitoring             | Real-time tracking of process states & anomalies<br>e.g. Statistical Process Control(SPC), Fault Detection and Classification(FDC) | Shim and Kang (2022)                                   |
| Level 2: Predictive   | Diagnosis & Prediction | 3. Quality Prediction             | Virtual Metrology(VM) & Yield prediction based on process parameters                                                               | Kang(2018)                                             |
|                       |                        | 4. Root Cause Analysis            | Identifying defect causes via XAI or causal inference<br>e.g. Fault diagnosis)                                                     | Obregon <i>et al.</i> (2021), Lee <i>et al.</i> (2025) |
|                       |                        | 5. Predictive Maintenance         | Forecasting equipment Remaining Useful Life(RUL) to prevent quality degradation (PdM)                                              | Choi <i>et al.</i> (2025)                              |
| Level 3: Prescriptive | Optimization & Control | 6. Process Control                | Closed-loop adjustment of parameters for quality consistency<br>e.g. Advanced Process Control(APC)                                 | Kim <i>et al.</i> (2025a, 2025b)                       |
|                       |                        | 7. Process Optimization           | Finding optimal parameters/scheduling for max quality & efficiency.                                                                | Han <i>et al.</i> (2024), Zhang <i>et al.</i> (2025)   |
|                       |                        | 8. Design Quality Improvement     | Enhancing product design/materials for manufacturability (DfM)                                                                     | Lee <i>et al.</i> (2024)                               |
| Strategic             | System & Strategy      | 9. Quality Management Perspective | Holistic Quality 4.0 strategy, Sustainability, and Human-in-the-loop support.                                                      | Cho <i>et al.</i> (2024)                               |

인을 진단하고 미래를 예측하는 예측, 예지보전, 원인분석 단계이다. 가장 고도화된 Level 3(Prescriptive)은 최적의 조치를 처방하고 제어하는 최적화, 설계로 정의하였다. 마지막으로, 개별 기술 단위를 넘어선 조직적/전략적 차원의 접근은 ‘Strategic Level’로 별도 분류하여 분석의 포괄성을 확보하였다.

<Figure 9>는 국내 제조업 머신러닝 품질관련 논문을 Table 4에서 정의한 3단계 성숙도 모델과 산업 분야의 매트릭스로 매핑하여 시각화한 결과이다. 버블의 크기는 해당 영역에 속하는 논문의 수를 나타낸다. <Table 4>에 수록된 대표적 논문과 Figure 9를 통해 국내 연구의 구조적 특징과 산업별 진화 특징을 분석할 수 있다.




Figure 9. Mapping of Korean ML Research: Industry vs. Maturity Level.

국내 연구는 전체적으로 Level 1 단계에 거대한 버블이 형성되어 있어 ‘결함탐지’ 중심의 연구 구조임을 확인할 수 있다. 그러나 이를 산업별로 분해해 보면 질적인 차이가 드러난다.

전자·반도체 산업은 압도적인 품질 검사(Quality Inspection) 역량을 바탕으로 기술적 깊이를 더해가며, 가상계측(Virtual Metrology, VM) 기술을 통해 Level 1에서 Level 2로의 전환이 이루어지고 있다. Park *et al.*(2024)은 반도체 릴 패키지의 미세 부품을 엑스레이 이미지로 실시간 탐지하는 기술을 구현함으로써 작은 물체 탐지의 한계를 구조적으로 극복하고 고속 생산라인에서의 현장 적용 가능성을 입증하는 성과를 보였다. Kang(2018)과 Shim and Kang(2022)은 전이 학습과 능동 학습(Active Learning)을 결합하여, 반도체 공정의 고질적인 데이터 부족 및 비용 문제를 해결하는 한국만의 강점 기술을 보여주었으며 이는 글로벌 VM 연구를 선도하는 수준으로 평가된다.

기계·장비 산업에서는 설비의 건전성을 진단하고 잔여 수명을 예측하려는 예지 보전(Predictive Maintenance) 연구가 활발하다. Choi *et al.*(2025)은 CNC 머시닝 센터의 시계열 음향 데이터를 LSTM(Long Short-Term Memory)과 생성형 모델(AnoGAN)로 분석하여 고장을 사전에 예측하고 근본 원인을

식별하는 모델을 개발하였다.

화학 및 철강 등 연속 공정 산업은 연구빈도는 낮지만 Level 3 영역의 비중이 상대적으로 높다. Kim *et al.* (2025a)은 FINEX 공정의 석탄 품질을 예측하고 이를 기반으로 슬라이딩 게이트를 자동 제어하는 시스템을 구축하여, 국내에서도 머신러닝 기반 폐루프 제어(Closed-loop Control)의 실현 가능성을 입증하였다. 또한, Kim *et al.*(2025b)은 확산 모델(Diffusion Model)을 활용하여 사출 성형의 최적 공정 조건을 역으로 추론(Inverse Design)하는 생성형 AI 기반 제어 시스템을 제안하였는데, 이는 국제적으로도 매우 선도적인 연구 주제에 해당한다.

자동차 산업은 안전과 양산 효율성을 위해 실시간 결함 탐지 및 설계 검증 자동화에 주력하고 있다. Lee *et al.*(2024)은 전문가 개입없이 Faster R-CNN과 CAD를 자동 연동한 지그재그 프로세스로 자동차 트리밍 금형 설계 검사 과정을 자동화하였는데 이는 다양한 CAD 플랫폼에 적용될 수 있어 제조 현장에서의 생산성 향상에 기여하였다.

한편 최근 국제 연구에서는 AI의 ‘블랙박스’ 문제를 해결하기 위한 XAI가 핵심 화두로 떠오르고 있으며, 국내 연구 또한 이러한 흐름에 적극적으로 동참하고 있다. Obregon *et al.*(2021)은 사출 성형 공정의 결함 탐지 결과를 규칙 기반(Rule-based)으로 설명하는 프레임워크를 제안하여 근본 원인 분석(Root Cause Analysis)을 수행하였다. Lee *et al.*(2025)은 LIME(Local Interpretable Model-agnostic Explanations)과 Grad-CAM(Gradient-weighted Class Activation Mapping) 동시에 활용하여 모델의 판단 근거를 시각화함으로써 현장 운영자가 AI의 결정을 신뢰하고 검토할 수 있는 XAI 환경을 구축하였다.

<Table 5>는 우리나라 연구 내용을 품질영역별로 ‘기술적용의 시간제약 빈도’로 정리한 것이다. “오프라인(Offline)” 적용

Table 5. Frequency of Time Constraints in Technology Applications Across Quality Areas

| ML Application Area in Quality Management | Freq. (Offline-Online-Real time) |
|-------------------------------------------|----------------------------------|
| Quality Inspection                        | 54 (20-24-10)                    |
| Process Monitoring                        | 16 (0-12-4)                      |
| Quality Prediction                        | 10 (4-4-2)                       |
| Quality Management Perspective            | 4 (2-0-2)                        |
| Process Optimization                      | 3 (2-1-0)                        |
| Predictive Maintenance                    | 3 (1-2-0)                        |
| Process Control                           | 3 (0-2-1)                        |
| Design Quality Improvement                | 3 (3-0-0)                        |
| Process Control/Optimization              | 1 (1-0-0)                        |
| Quality Prediction/Process Optimization   | 1 (1-0-0)                        |
| Process Monitoring/Optimization           | 1 (0-0-1)                        |
| Total                                     | 99 (34-45-20)                    |

은 공정 종료 후 과거 또는 배치 데이터를 활용하여 모델을 학습·분석하고, 그 결과를 설계 개선이나 향후 공정 계획 수립과 같은 사후 의사결정에 활용하는 방식이다. “온라인(Online)” 적용은 제조 공정이 진행되는 동안 데이터를 수집·분석하여 공정 상태를 모니터링하고 이상이나 품질 변화를 감지하지만, 출력은 자동 제어가 아닌 경보·의사결정 지원 정보로 활용되는 방식이다. “실시간(Real time)”적용은 데이터 수집-모델 추론-제어 동작이 공정 주기 내에서 수행되어, 모델의 출력이 인간 개입 없이 즉시 공정 파라미터를 자동 조정하는 폐루프 제어 방식이라고 할 수 있다.

적용 시간 측면에서 온라인 환경이 45.5%로 오프라인(34.3%)을 상회하고 있다. 이는 국내 연구가 실험실 데이터를 분석하는 오프라인 수준을 넘어 제조 현장의 스트림 데이터를 모니터링하는 현장 적용 단계로 진입했음을 시사한다. 반면 실시간 적용 비중은 20.2%에 그쳐, 공정 제어(Process Control) 및 최적화(Process Optimization) 관련 연구는 아직 매우 제한적임을 확인할 수 있다.

### (3) 활용된 머신러닝 기법 분석

<Table 6>은 국내 연구의 품질관리 영역별로 적용된 머신러닝 기법과 그 사용빈도를 정리한 것이다. 국내 연구는 ‘품질 검사’ 영역에 과반수가 집중됨에 따라 이미지 처리에 특화된 CNN과 실시간 탐지를 위한 YOLO(You Only Look Once) 계열 모델이 핵심 기술로 자리 잡고 있음이 확인된다. 반면, 공정 모니터링 및 예지 보전 분야에서는 센서 데이터의 시계열 특성을 반영하기 위해 RNN(Recurrent Neural Network)/LSTM이나 이상 탐지(Anomaly Detection)를 위한 Autoencoder, SVM이 주로 활용되는 기술적 이원화 현상이 뚜렷하다. ‘품질 예측’ 영역에서는 복잡한 인과관계를 학습할 수 있는 심층신경망(Deep Neural Network, DNN)이 주로 사용되었다. 또한 제조 현장의 데이터 불균형(Data Imbalance) 문제를 극복하기 위해 GAN(Generative Adversarial Networks)을 활용한 데이터 증강이나 전이 학습과 같은 고도화된 기법의 도입이 등장하고 있

다는 특징이 있다. ‘설계 품질 개선’ 및 ‘예지보전’ 분야는 유전 알고리즘, 몬테카를로 시뮬레이션, 군집화 등 다양한 기법이 소수 사례로 분산되어 나타나 탐색적 연구 단계에 머무르고 있다.

## 4.6 우리나라 연구의 특성 진단 및 향후 방향성

본 연구의 계량서지학적 분석 결과, 한국은 세계 5위의 연구 규모와 높은 단일국가연구(SCP, 81%) 비중을 바탕으로 독자적인 연구 생태계를 구축하였으나, 연구 주제와 기술 적용 단계에서 뚜렷한 구조적 불균형을 보인다. 글로벌 연구가 적층 제조(Additive Manufacturing) 등 신공정 최적화로 다변화되는 반면, 국내 연구는 주력 산업인 ‘반도체·전자’ 분야의 ‘결함 탐지(Detection)’에 역량이 과도하게 집중되어 있다. 기술적 성숙도 측면에서도 현장 데이터를 실시간 감지하는 ‘온라인(Online)’ 수준은 탁월하나, 이를 공정 제어로 연결하는 ‘실시간 폐루프(Real-time Closed-loop)’ 역량은 20.2%에 불과하여 ‘감지(Inspection)’에서 ‘제어(Control)’로 나아가는 연결 고리의 단절이 확인되었다. 이에 본 연구는 확인된 구조적 편중을 해소하고 글로벌 리더십을 확보하기 위해, 국내 주력 산업의 데이터 특성과 공정 특수성을 고려한 산업별 맞춤형 고도화 로드맵과 공통 기반 기술 확장 전략을 제안한다.

### (1) 산업별 특화 고도화 로드맵

우선, 반도체·전자 산업은 세계적 수준인 ‘결함 탐지’와 ‘가상 계측’ 역량을 기반으로 자율 공정 제어 단계로의 진입을 목표로 해야 한다. 현재 국내 연구는 Park *et al.* (2024)과 같이 엑스레이 및 비전 검사를 통한 미세 결함 탐지(Level 1)와 Kang (2018), Shim and Kang(2022)의 전이 학습 기반 가상 계측(Level 2) 분야에서 독보적인 성과를 보이고 있다. 향후 연구는 이러한 예측 모델을 물리적 모델(Physics-based)과 결합하여 신규 레시피 도입 시 발생하는 데이터 부족(Cold-start) 문제를 해결하고, 예측된 품질 데이터를 설비 파라미터 자동 보정에 즉

Table 6. Machine Learning Techniques Applied across Quality Management Areas

| Application Area                          | ML Main Techniques (Freq.)                                          |
|-------------------------------------------|---------------------------------------------------------------------|
| Quality Inspection                        | CNN (33), SVM (9), YOLO (9), Transfer Learning (4), Ensemble (3)    |
| Process Monitoring                        | CNN (6), RNN/LSTM (3), SVM (2), GAN (2), Random Forest (1)          |
| Quality Prediction                        | ANN/DNN/MLP (4), Autoencoder (1), SAX (1), Transfer Learning (1)    |
| Design Quality Improvement                | Genetic Algorithm (1), CNN (1), Random Forest (1), Monte Carlo (1)  |
| Predictive Maintenance                    | RNN/LSTM (2), Autoencoder (1), Continuous Learning (1), K-Means (1) |
| Process Optimization                      | ANN/DNN/MLP (4), CNN (1), Regression (1)                            |
| Process Control                           | CNN (1), YOLO (1), Autoencoder (1), Generative Model (1)            |
| Quality Management Perspective            | CNN (3), Reinforcement Learning (1), LDA (1)                        |
| Quality Prediction / Process Optimization | Genetic Algorithm (1), Swarm Optimization (1)                       |
| Process Monitoring / Optimization         | CNN (1), YOLO (1)                                                   |
| Process Control / Optimization            | GAN (1)                                                             |

각 반영하는 런투런(Run-to-Run) 제어 시스템으로 확장해야 한다. 이 과정에서 Lee *et al.*(2025)이 제안한 설명 가능한 AI(XAI) 기술을 제어 시스템에 통합하여 엔지니어의 신뢰를 확보하는 것이 필수적이다. 궁극적으로는 Han *et al.* (2024)의 연구와 같이 품질 변동에 따라 공정 스케줄과 레시피를 동적으로 변경하는 지도 학습 또는 강화 학습(Reinforcement Learning) 기반 완전 자율 운영 팩(Autonomous Fab) 구축을 지향해야 한다.

자동차·기계 산업은 단위 공정의 최적화를 넘어 설계와 생산 데이터 간의 단절을 극복하는 데 주력해야 한다. Lee *et al.* (2024)은 AI가 감지한 금형 설계 오류를 CAD 시스템에 즉시 피드백하여 수정을 자동화하는 ‘지그재그(Zigzag) 프로세스’를 통해 설계-제조 데이터의 환류 가능성을 입증하였다. 향후 연구는 이를 확장하여 양산 중 발생하는 품질 결함 데이터를 설계 도면의 자동 수정에 반영하는 ‘품질을 고려한 생성형 설계(Generative Design for Quality)’ 체계로 발전시켜야 한다. 또한, 설비 관리에 있어서는 Choi *et al.*(2025)이 CNC 설비 연구에서 적용한 미분방정식 기반의 시계열 모델링을 고도화하여, 설비의 상태 변화가 가공 정밀도에 미치는 영향을 실시간으로 예측하고 공구 교체 시점이나 가공 속도를 스스로 조절하는 동적 예지 보전(Dynamic PdM) 시스템을 구축해야 한다 (Paraschos and Koulouriotis, 2024).

철강·화학 산업은 연속 공정의 특성을 활용하여 생성형 AI 기반의 공정 역설계 및 디지털 트윈 제어 기술을 선도해야 한다. 국내에서는 Kim *et al.*(2025)의 연구와 같이 확산 모델을 이용해 사출 성형의 최적 조건을 생성하거나, Kim *et al.*(2025)과 같이 FINEX 공정에서 자동 제어를 구현하는 등 Level 3(제어) 연구가 가장 활발하다. 향후에는 이러한 생성형 AI 모델을 주력 라인 전반으로 확산하여 목표 물성을 만족하는 최적의 원료 배합비와 공정 조건을 역으로 추론하는 시스템을 정착시켜야 한다. 나아가 Mota *et al.*(2025)이 제안한 바와 같이, 실제 플랜트와 동기화된 디지털 트윈 상에서 강화학습 에이전트가 다양한 제어 시나리오를 선행 학습하고 검증된 정책을 현장에 적용하는 Sim-to-Real 기술을 통해 제어의 안전성과 효율성을 동시에 확보해야 할 것이다.

## (2) 글로벌 트렌드 대응 및 공통 기반 기술 확장

산업별 특화 전략과 더불어, 글로벌 연구 트렌드에 발맞추기 위해 국내 연구진이 공통적으로 강화해야 할 핵심 영역은 다음과 같다. 첫째, 설명 가능한 AI(XAI)의 표준화이다. AI의 판단 근거를 시각화하는 것을 넘어, Lee *et al.*(2025)의 사례처럼 예측의 신뢰도(Confidence Score)와 해석 정보를 품질 성적서에 의무적으로 포함시키는 ‘설명 가능한 품질 보증’ 프로세스를 정립하여 현장의 불신을 해소해야 한다. 둘째, 연합 학습(Federated Learning)을 통한 데이터 장벽 해소이다. 제조 데이터의 기밀성 문제를 극복하기 위해, Mota *et al.*(2025)과 Kausik *et al.*(2025)이 강조한 연합 학습 기술을 도입하여 원청과 협력

사 간에 민감한 데이터 공유 없이도 공동의 불량 탐지 모델을 고도화하는 생태계를 조성해야 한다. 셋째, PMQ(Production-Maintenance-Quality) 통합 자율 운영이다. 개별 최적화를 넘어, 설비의 고장 징후(Maintenance)가 포착되면 즉시 생산 스케줄을 조정하고(Production), 품질 검사 빈도를 높이는(Quality) 등 세 가지 기능이 유기적으로 연동되는 통합 자율 제어 시스템이 한국형 스마트 팩토리의 최종 지향점이 되어야 한다.

## 5. 결 론

본 연구는 ‘Quality 4.0’으로의 전환기 속에서 머신러닝을 적용한 제조업 품질관리 분야의 글로벌 연구 동향과 대한민국의 위상을 객관적으로 규명하였다. 이를 위해 2010년부터 2025년까지의 Scopus 논문을 대상으로 AI 모델(ChatGPT, Gemini)을 활용한 2단계 선별 과정을 거쳐, 총 1,624편(국내 99편)의 유효 문헌을 확정하고 체계적인 분석을 수행하였다.

본 연구의 주요 결과와 시사점은 다음과 같다.

첫째, 본 연구가 제안한 ‘제조 품질 머신러닝 성숙도 프레임워크’를 통해 한국이 ‘Level 1(결함 탐지)’과 ‘Level 2(가상 예측)’ 영역에서 세계적 기술 우위를 점하고 있음을 확인하였다. 특히 전자·반도체 산업(21.2%)을 중심으로 CNN 기반 검사와 전이 학습을 활용한 가상 예측 분야에서 독보적 성과를 보였다. 그러나 공정 변수를 능동적으로 최적화하는 ‘Level 3(제어)’ 연구 비중은 상대적으로 낮아, 향후 단순 판정을 넘어선 자율 제어 단계로의 질적 도약이 요구된다.

둘째, ‘기술 적용의 시간 제약(Time Constraints)’이라는 새로운 차원을 도입하여 한국 연구의 높은 현장 적용성과 기술적 병목 구간을 동시에 규명하였다. 분석 결과, 현장 데이터를 실시간 모니터링하는 ‘온라인(Online)’ 적용 비중이 45.5%로 가장 높아 실험실 수준(Offline)을 벗어난 현장 밀착형 연구가 주를 이루고 있음이 입증되었다. 반면, 감지된 정보를 제어로 연결하는 ‘실시간 폐루프(Real-time Closed-loop)’ 적용은 20.2%에 그쳐, ‘빠른 감지’를 ‘자동 조치’로 전환하는 과정에서 기술적 단절이 존재함을 시사한다.

셋째, 국가 연구 생태계의 구조적 특징을 진단하고, 이에 기반한 실천적 로드맵을 도출하였다. 주제진화 및 키워드 네트워크 분석 결과, 글로벌 연구가 다양한 도메인으로 확장되는 ‘다대다(Many-to-Many)’ 구조인 반면, 한국은 반도체와 객체 탐지에 집중된 ‘선형적 심화’ 구조를 보였다. 이에 대한 해결책으로 본 연구는 산업별 특성을 반영한 단계별 발전 로드맵을 제시함으로써 구조적 편중 해소 방안을 구체화하였다.

종합적으로, 한국은 세계 5위의 연구 규모와 견고한 독자적 생태계를 갖춘 ‘제조 AI 강국’이다. 본 연구는 이러한 데이터 인프라와 검사 기술의 강점을 레버리지(Leverage)하여, 현재의 ‘모니터링 중심’ 연구를 글로벌 트렌드인 ‘자율 제어’ 및 ‘시스템 통합(PMQ)’으로 전환하기 위한 전략적 나침반을 제

공했다는 점에서 의의를 갖는다.

## 참고문헌

- AlKhader, W., Jayaraman, R., Salah, K., Antony, J., and Omar, M. (2025), Transformations in manufacturing quality in the Industry 4.0 era: A Semi-centennial Review using Latent Dirichlet Allocation, *Computers and Industrial Engineering*, 208.
- Bousdekis, A., Lepenioti, K., Apostolou, D., and Mentzas, G. (2023), Data Analytics in Quality 4.0: Literature Review and Future Research Directions, *International Journal of Computer Integrated Manufacturing*, 36(5), 678-701.
- Cho, S. W., Lim, Y. H., Seo, K. M., and Kim, J. (2024), Integration of Eye-tracking and Object Detection in a Deep Learning System for Quality Inspection Analysis, *Journal of Computational Design and Engineering*, 11(3), 158-173.
- Choi, J., Xiong, Z., and Kang, K. (2025), Long Short-Term Memory-Based Computerized Numerical Control Machining Center Failure Prediction Model, *Mathematics*, 13(7).
- Hamel, C., Hersi, M., Kelly, S. E., Tricco, A. C., Straus, S., Wells, G., Pham, B., and Hutton, B. (2021), Guidance for Using Artificial Intelligence for Title and Abstract Screening while Conducting Knowledge Syntheses, *BMC Medical Research Methodology*, 21(1).
- Han, J. H., Jeong, S. hoon, Hwang, G., and Lee, J. Y. (2024), Machine Learning-based Dispatching for a Wet Clean Station in Semiconductor Manufacturing, *Journal of Manufacturing Systems*, 77, 341-355.
- Kang, S. (2018), On Effectiveness of Transfer Learning Approach for Neural Network-Based Virtual Metrology Modeling, *IEEE Transactions on Semiconductor Manufacturing*, 31(1), 149-155.
- Kausik, A. K., Rashid, A. Bin, Baki, R. F., and Jannat Maktum, M. M. (2025), Machine Learning Algorithms for Manufacturing Quality Assurance: A Systematic Review of Performance Metrics and Applications, *Array*, 26.
- Kim, I., Park, W., Shim, Y., Kim, T., and Han, S. (2025a), FINEX Process: Coal Briquette Quality Prediction and Automatic Control using CNN-LSTM and YOLOv11, *ISIJ International*, 65(10), 1471-1480.
- Kim, J. Y., Kim, H., Nam, K., Kang, D., and Ryu, S. (2025b), Development of an Injection Molding Production Condition Inference System Based on Diffusion Model, *Journal of Manufacturing Systems*, 79, 162-178.
- Kim, Y.-E., Song, J., and Shin, S. (2024), Analysis of Machine Learning Research Patterns from a Quality Management Perspective, *Journal of Korean Society of Quality Management*, 52(1), 77-93.
- Landis, J. R. and Koch, G. G. (1977), The Measurement of Observer Agreement for Categorical Data, *Biometrics*, 33(1), 159-174.
- Lee, J. S., Kim, T. H., Jeon, S. H., Park, S. H., Kim, S. H., Lee, E. H., and Lee, J. H. (2024), Automation of Trimming Die Design Inspection by Zigzag Process Between AI and CAD Domains, *Engineering Applications of Artificial Intelligence*, 127.
- Lee, Jieun, Ju, Y., Lim, J., Hong, S., Baek, S. W., and Lee, J. H. (2025), Enhancing Confidence and Interpretability of a CNN-Based Wafer Defect Classification Model Using Temperature Scaling and LIME, *Micromachines*, 16(9).
- Lee, S. M., Lee, D., and Kim, Y. S. (2019), The Quality Management Ecosystem for Predictive Maintenance in the Industry 4.0 Era, *International Journal of Quality Innovation*, 5(1).
- Manta-Costa, A., Araújo, S. O., Peres, R. S., and Barata, J. (2024), Machine Learning Applications in Manufacturing - Challenges, Trends, and Future Directions, *IEEE Open Journal of the Industrial Electronics Society*, 5, 1085-1103.
- Mat Deli, M., Norliyana Harun, S., and Ayu Purwati, A. (2025), Bibliometric Analysis for Quality Management in the Manufacturing Sector: 2020 TO 2024, *Journal of Applied Engineering and Technological Science*, 6(2).
- Mota, B., Faria, P., Ramos, C., and Vale, Z. (2025), Review of Manufacturing Integration between Production, Maintenance and Quality Artificial Intelligence Systems, *Journal of Industrial Information Integration*, 47.
- Obregon, J., Hong, J., and Jung, J. Y. (2021), Rule-based Explanations Based on Ensemble Machine Learning for Detecting Sink Mark Defects in the Injection Molding Process, *Journal of Manufacturing Systems*, 60, 392-405.
- Ördek, B., Borgianni, Y., and Coatanea, E. (2024), Machine Learning-Supported Manufacturing: A Review and Directions for Future Research, *Production and Manufacturing Research*, 12(1).
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... and Moher, D. (2021), The PRISMA 2020 Statement: An Updated Guideline for Reporting Systematic Reviews, *British Medical Journal*, 372.
- Papavasileiou, A., Michalos, G., and Makris, S. (2025), Quality Control in Manufacturing-Review and Challenges on Robotic Applications, *International Journal of Computer Integrated Manufacturing*, 38(1), 79-115.
- Paraschos, P. D. and Koulouriotis, D. E. (2024), Learning-based Production, Maintenance, and Quality Optimization in Smart Manufacturing Systems: A literature review and trends, *Computers and Industrial Engineering*, 198.
- Park, J., Lee, J., and Jeong, J. (2024), YOLOv5 Based Object Detection in Reel Package X-ray Images of Semiconductor Component, *Heliyon*, 10(5).
- Presciuttini, A., Cantini, A., Costa, F., and Portioli-Staudacher, A. (2024), Machine Learning Applications on IoT Data in Manufacturing Operations and their Interpretability Implications: A Systematic Literature Review, *Journal of Manufacturing Systems*, 74, 477-486.
- Shim, J. and Kang, S. (2022), Domain-adaptive Active Learning for Cost-effective Virtual Metrology Modeling, *Computers in Industry*, 135.
- Tercan, H. and Meisen, T. (2022), Machine Learning and Deep Learning Based Predictive Quality in Manufacturing: A Systematic Review, *Journal of Intelligent Manufacturing*, 33(7), 1879-1905.
- Zhang, H., Yu, Y., Liu, X., Liang, N., Kim, Y., Shin, D., Moon, S. K., and Choi, J. P. (2025), Autonomous Printing Process Optimization and in-situ Anomaly Detection in Fused Deposition Modelling Using an Integrated Data-driven Approach, *Virtual and Physical Prototyping*, 20(1).



## A. 부록: 논문 선별을 위한 AI 프롬프트

**[ROLE]** You are a senior academic researcher with a PhD in Manufacturing Engineering and Quality Management, specialized in machine learning applications for manufacturing quality. In this task, you must NOT act as an individual paper interpreter. You must act strictly as a rule-based batch screener, applying identical, conservative criteria to every paper. Do NOT relax, expand, reinterpret, or infer beyond the stated rules. Do NOT compare papers with each other. Evaluate each paper independently using ONLY the specified input fields.

### **[INPUT DATA]**

Each paper contains the following columns:

A: Paper ID, B: Title, C: Abstract, D: Author Keywords, E: Index Keywords

### **[OUTPUT FORMAT - STRICT COMPLIANCE]**

Column F: Include or Exclude (exactly one word)

Column G: write a short reason according to Judgment1-Judgment2

Do NOT add explanations, comments, or notes outside columns F and G.

### **[MANDATORY STEP-BY-STEP SCREENING PROCEDURE]**

You MUST follow the steps below in the given order.

**Criterion 1)** [Manufacturing-domain relevance criterion] From column C (Abstract), the research target has high relevance to manufacturing industry.

**Criterion 2)** [Quality-related relevance criterion] From column C (Abstract), the research target has high relevance to the following quality-related activities, OR quality-related keywords are included in column B (Title), C (Abstract), D (Author Keywords), or E (Index Keywords).

Quality-related activities: Quality Inspection (e.g., defect detection/classification, visual or sensor-based inspection) Process Monitoring (e.g., SPC, control charts, anomaly detection in process or equipment variables) Process Control (e.g., feedback/feedforward control for quality, parameter adjustment to maintain quality) Process Optimization (e.g., quality-driven parameter optimization, simulation-based design or adaptive optimization) Quality Prediction (e.g., prediction of yield or CTQ quality characteristics such as strength, roughness, dimension) Root Cause Analysis (e.g., explainable AI (XAI), causal analysis of quality degradation) Design Quality Improvement (e.g., material selection & property prediction, design-for-quality using ML) Predictive Maintenance (e.g., remaining useful life prediction, fault prognosis affecting quality) Quality Management with ML (e.g., Quality 4.0 strategies, enterprise-level ML integration for quality, joint optimization of production-maintenance-inspection, ML application at company level)

Quality-related keywords(case-insensitive, singular/plural ignored): quality management, quality control, quality assurance, total quality management, TQM, statistical quality control, SQC, statistical process control, SPC, control chart, X-bar chart, R chart, S chart, individuals chart, moving range chart, process capability, Cp, Cpk, Cpm, Pp, Ppk, process performance, defect rate, defect density, defect per million opportunities, DPMO, yield rate, first pass yield, rolled throughput yield, rework rate, scrap rate, nonconformance, nonconformity, corrective action, preventive action, CAPA, root cause analysis, RCA, fishbone diagram, Ishikawa diagram, Pareto analysis, Pareto chart, failure mode and effects analysis, FMEA, PFMEA, DFMEA, risk priority number, RPN, hazard analysis, fault tree analysis, FTA, hazard identification, HAZID, hazard and operability study, HAZOP, design of experiments, DOE, Taguchi method, orthogonal array, response surface methodology, RSM, robust design, process optimization, parameter tuning, tolerance design, measurement system analysis, MSA, gauge R&R, repeatability, reproducibility, calibration, metrology, virtual metrology, inline metrology, in-situ measure-

ment, inspection system, automated inspection, visual inspection, machine vision, surface defect detection, anomaly detection, outlier detection, novelty detection, quality prediction, defect classification, quality classification, defect diagnosis, quality monitoring, quality forecasting, predictive quality, prescriptive quality, smart quality, digital quality management, quality 4.0, real-time monitoring, online quality control, closed-loop quality control, MPC, data-driven quality, manufacturing analytics, data quality, data preprocessing, multivariate statistical process control, MSPC, Hotelling's T-squared, SPE, Q statistic, quality knowledge discovery, rule-based quality diagnosis, quality dataset, labeled defect data, key performance indicator, KPI, overall equipment effectiveness, OEE, availability, quality rate, downtime analysis, production loss, Six Sigma, DMAIC, DMADV, Kaizen, continuous improvement, PDCA cycle, ISO 9001, IATF 16949, quality audit, internal audit, incoming quality control, IQC, in-process quality control, IPQC, outgoing quality control, OQC, lot traceability, batch quality, genealogy tracking, traceability system, recall management, product liability, reliability engineering, reliability analysis, Weibull analysis, accelerated life testing, ALT, failure rate, mean time between failure, MTBF, mean time to repair, MTTR, degradation modeling, Prognostics and Health Management, PHM, remaining useful life, RUL, condition-based maintenance, CBM, predictive maintenance, maintenance analytics, equipment health monitoring, alarm management, alarm flood, false alarm reduction, quality cost, cost of poor quality, COPQ, prevention cost, appraisal cost, internal failure cost, external failure cost, process monitoring, ARL, Average Run Length

**Criterion 3)** [Machine learning technique application criterion] Machine-learning-related keywords must appear in column B, C, D, or E.

**Exclusion 1)** Column B (Title) contains words implying review-type research such as: review, survey, systematic analysis, overview, bibliometric, state of the art, recent advances, emerging trends, benchmark study, taxonomy, framework, mapping study, scientometric analysis, etc.

**Exclusion 2)** From column C (Abstract), the quality target is not a product or manufacturing domain (e.g., image quality, voice quality, communication quality).

**Exclusion 3)** Column B, C, D, or E contains: Human Resources, sustainable performance, business sustainable, supply issue.

**Exclusion 4)** Column C, D, or E contains education / psychology / organizational management terms such as: organizational learning, learning organization, learning curve, distance learning, collaborative learning, organizational culture.

**Exclusion 5)** Only simple statistical terms are present in C, D, or E and no machine-learning-related keywords appear.

**Judgment 1)** If Criterion1-3 are all satisfied and none of Exclusion1-5 applies, mark "Include" in column F.

**Judgment 2)** If any of Criterion1-3 is not satisfied, or any of Exclusion1-5 applies, mark "Exclude" in column F and write the unsatisfied condition in column G.

## 저자소개

**정성환:** 정성환은 서울대학교 산업공학과에서 1996년 학사, 1998년 석사학위를 취득하고 동대학교에서 산업공학 박사학위를 취득하였다. 삼성에스디에스에서 수석컨설턴트를 역임하고, 2013년부터 유한대학교에서 재직하고 있다. 연구분야는 품질경영(QM) 및 품질관리(QC), 산업안전관리 등이다.