

# 센서 기반 데이터 분석과 머신러닝을 활용한 니켈 도금 공정의 최적 도금 두께 예측 및 공정 최적화에 관한 연구

김지유\*, 조진표\*, 정봉준\*, 표수지\*, 조승열\*, 김광희\*  
\*인하대학교 제조혁신전문대학원, 인하대학교 RISE  
e-mail : kimjiyu8600@inha.edu

## A Study on the Prediction of Optimal Nickel Plating Thickness and Process Optimization Using Sensor-Based Data and Machine Learning

Ji-You Kim\*, Jin-Pyo Cho\*, Bong-Jun Jeon\*, Su-Ji Pyo\*, Seung-yeol Cho\*, Kwang-Hee Kim\*  
\*Manufacturing Innovation School, Inha University

### 요약

본 연구는 니켈 도금 공정에서 발생하는 도금 두께 편차 문제를 해결하기 위하여 센서 기반 데이터 수집과 머신러닝 분석을 활용한 공정 최적화 방법을 제안한다. 기존 도금 공정은 작업자의 경험에 의존한 조건 설정과 사후 검사 중심의 품질 관리 방식으로 운영되어 공정 중 실시간 대응이 어려우며, 도금 두께의 균일성 확보에 한계를 가진다. 특히 전류밀도, 도금 시간, 온도, pH 등 다수의 공정 변수들이 복합적으로 작용하여 도금 두께가 변동하는 비선형 특성을 가지므로 정량적 분석과 예측 모델 구축이 요구된다.

이에 본 연구에서는 니켈 도금 공정의 주요 변수인 전류밀도, 도금 시간, 시편 재질 및 두께 등을 변화시키며 실험을 수행하고, 도금 전후 질량 차이를 기반으로 도금 두께를 산출하였다. 또한 공정 중 발생하는 pH, 온도, 전류 등의 데이터를 실시간으로 수집할 수 있는 PLC-HMI 기반 센서 시스템을 구축하여 데이터베이스화하였다. 수집된 데이터는 머신러닝 알고리즘(Random Forest)을 적용하여 공정 변수와 도금 두께 간의 상관관계를 분석하고 예측 모델을 개발하였다.

분석 결과, 도금 두께는 전류밀도와 도금 시간에 의해 가장 큰 영향을 받는 것으로 나타났으며, 이는 전기화학적 Faraday 법칙과 일치하는 결과를 보였다. 또한 머신러닝 모델은 높은 예측 성능( $R^2$  약 0.9 수준)을 나타내어 공정 변수 기반 도금 두께 예측이 가능함을 확인하였다. 본 연구 결과는 도금 공정의 품질 안정성 향상, 원자재 절감, 생산성 향상에 기여할 수 있으며, 향후 AI 기반 스마트 도금 공정 및 자동 제어 시스템 구축의 핵심 기반 기술로 활용될 수 있다.

### 1. 서론

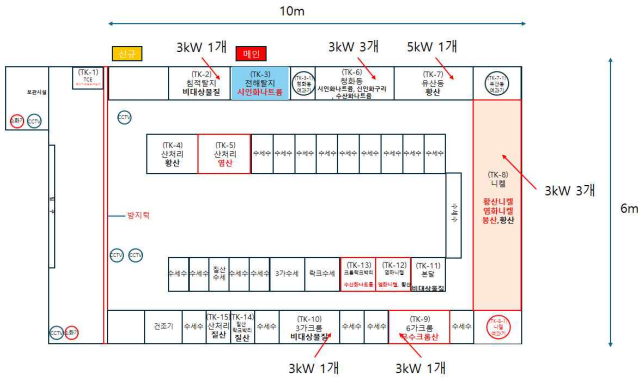
니켈 도금 공정은 금속 표면의 내식성, 내마모성 및 외관 품질을 향상시키기 위한 대표적인 전기화학적 표면처리 기술로 자동차 부품, 전자부품 및 산업기계 분야에서 광범위하게 활용되고 있다. 특히 정밀 부품 산업에서는 도금 두께의 균일성과 공정 안정성이 제품의 품질과 신뢰성에 직접적인 영향을 미치므로 공정 조건의 정밀 제어가 필수적이다. 그러나 현재 산업 현장에서 적용되고 있는 대부분의 도금 공정은 정류기를 기반으로 설정된 조건에 따라 반복 수행되는 구조로, 공정 중 발생하는 다양한 변수 변화에 대한 실시간 대응이 어렵고, 작업자의 경험과 노하우에 의존하는 한계를 가진다.

니켈 도금 공정에서는 전류밀도, 도금 시간, 온도, pH, 전해액 조성 등 다양한 공정 인자가 복합적으로 작용하며, 이들의 상호 작용에 따라 도금 두께뿐만 아니라 표면 품질과 내부 응력 특성

도 변화하게 된다. 이러한 다변수 시스템은 비선형 특성을 가지기 때문에 단순한 경험 기반 접근으로는 공정 최적화가 어렵고, 공정 변동 원인을 정량적으로 분석하기 위한 데이터 기반 접근이 요구된다.

최근 제조업에서는 IoT 센서 기술과 인공지능(AI) 기반 데이터 분석 기술의 발전으로 공정 데이터를 실시간으로 수집하고 이를 기반으로 품질을 예측 및 제어하는 스마트 제조 기술이 빠르게 확산되고 있다. 특히 공정 변수와 결과 간의 복잡한 상관관계를 학습할 수 있는 머신러닝 기법은 공정 최적화 및 품질 예측 분야에서 효과적인 방법으로 주목받고 있다. 이러한 기술을 도금 공정에 적용할 경우 공정 중 이상 징후를 사전에 감지하고 최적 운전 조건을 도출함으로써 품질 안정성과 생산 효율을 동시에 향상시킬 수 있다.

본 연구에서는 니켈 도금 공정에서 발생하는 주요 공정 데이터를 센서를 통해 실시간으로 수집하고, 이를 기반으로 머



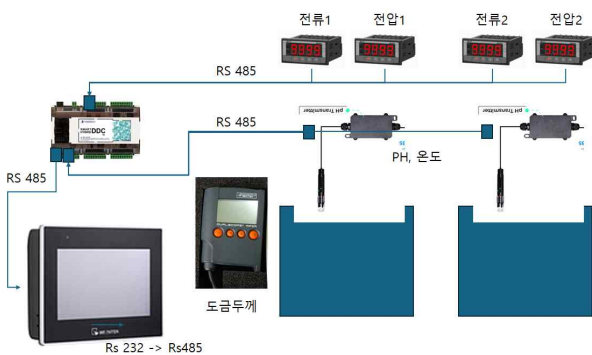
[그림 1] 삼풍금속 도금공장 공정 레이아웃

신러닝 모델을 구축하여 도금 두께를 예측하고자 한다. 또한 공정 변수와 도금 두께 간의 정량적 관계를 분석하여 최적 공정 조건을 도출하고, 향후 공정 자동 제어 및 스마트 도금 시스템으로 확장 가능한 기반 기술을 제시하는 것을 목적으로 한다. 이를 통해 기존 경험 중심 공정에서 데이터 기반 지능형 공정으로의 전환 가능성을 검증하고자 한다. 그림 1에는 삼풍금속의 도금 공정 레이아웃을 나타내었다.

## 2. 도금 공정 모니터링 시스템 구축 및 머신러닝 기반 데이터 분석

### 2.1 도금 공정 모니터링 시스템 구축

본 연구에서는 니켈 도금 공정의 주요 변수들을 실시간으로 측정하고 분석하기 위하여 센서 기반 모니터링 시스템을 구축하였다. 시스템은 센서-PLC-HMI-데이터 저장부로 구성되며, 전류, 온도, pH, 전압 등 공정 품질에 직접적인 영향을 미치는 변수들을 중심으로 데이터를 수집하였다. 전류 및 전압은 정류기 출력단에서 측정하였으며, 온도는 도금조 내부에 설치된 열전대 센서를 통해 실시간으로 측정하였다. 또한 pH 센서를 활용하여 전해액 상태를 지속적으로 모니터링함으로써 공정 안정성을 확보하였다. 수집된 데이터는 RS-485 기반 Modbus 통신을 통해 PLC로 전달되며, PLC에서는 데이터 필터링 및 1차 가공을 수행한다. 이후 HMI(Weintek)를 통해 실시간 공정 상태를 시각화하고, 이상



[그림 2] 센서 설치 및 데이터 측정 방법



[그림 3] 시편제작 및 랙 작업

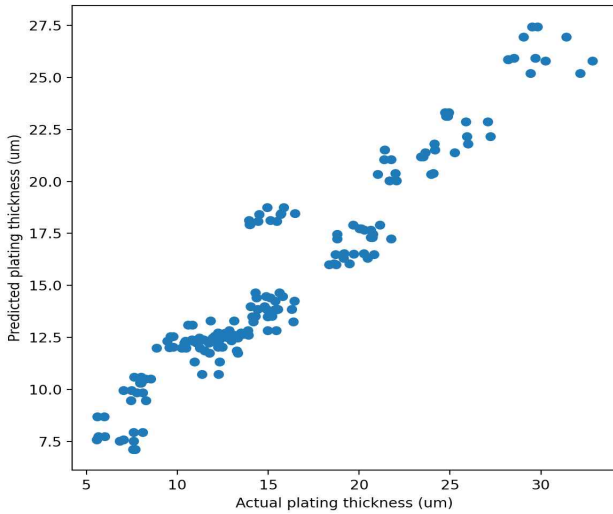
발생 시 알람 기능을 통해 작업자에게 즉각적인 대응을 가능하도록 설계하였다. 그림 2에 센서 설치 및 데이터 측정 시스템을 나타내었다. 최종적으로 모든 데이터는 외부 데이터베이스로 저장되어 장기적인 품질 분석 및 머신러닝 학습 데이터로 활용된다. 이러한 시스템은 공정의 가시성을 확보하고 데이터 기반 의사결정을 가능하게 하는 핵심 인프라로 작용한다.

### 2.2 시험 데이터 수집 및 전처리

그림 3에는 제작된 시편의 랙 작업을 보여준다. 시편은 가로 5cm, 세로 5cm 시편 상면에 4mm 타공을 하였다. 도금 두께 예측을 위한 데이터셋 구축을 위해 다양한 공정 조건에서 반복 실험을 수행하였다. 주요 변수로는 재질(Steel, Al), 시편 두께(Al : 1.5, 2.0 mm, Steel : 1.0, 1.2, 1.6, 2 mm), 전류밀도(4.6, 6, 8, 10, 12 A/dm<sup>2</sup>), 도금 시간(10, 15, 20 min), 온도(51.5°C)를 설정하였다. 이때, 도금조의 PH 농도는 4.8 이었다. 각 조건별로 도금 전후 무게를 정밀 저울(0.001 g 수준)을 이용하여 측정하고, 그 차이를 통해 도금량을 산출하였다. 이후 Faraday 법칙을 기반으로 도금 두께를 계산하여 정량 데이터로 변환하였다. 수집된 데이터는 머신러닝 적용을 위해 구조화된 형태로 재정리되었으며, 범주형 변수(재질)는 수치형으로 변환하였다. 일부 측정 과정에서 발생할 수 있는 이상치(outlier)는 통계적 기준(평균±3σ)을 적용하여 제거하였으며, 결측 데이터는 보간법 또는 평균값 대체 방식으로 처리하였다. 또한 변수 간 스케일 차이를 최소화하기 위해 정규화(Min-Max Scaling)를 적용하여 학습 안정성을 확보하였다. 이러한 전처리 과정은 모델의 예측 성능 향상과 과적합 방지를 위한 필수 단계로 작용한다.

### 2.3 머신러닝 기반 도금 두께 예측 및 공정 분석

본 연구에서는 니켈 도금 공정 변수와 도금 두께 간의 비선형 관계를 정량적으로 분석하기 위하여 XGBoost 기반 머신러닝 모델을 적용하였다. 입력 변수는 전류밀도



[그림 4] 실제값과 예측값 비교 (XGBoost 모델)

(current\_density\_A\_dm2), 도금 시간(time\_min), 시편 두께(specimen\_thickness\_mm), 재질(material), 전체면적(total\_area\_cm2), 온도(temperature\_C)로 구성하였으며, 출력 변수는 도금 두께로 설정하였다. 데이터는 학습용과 검증용으로 분리하여 모델의 일반화 성능을 평가하였다. 그림 4에 XGBoost 모델의 실제값과 예측값 비교 그래프를 나타 내었다.

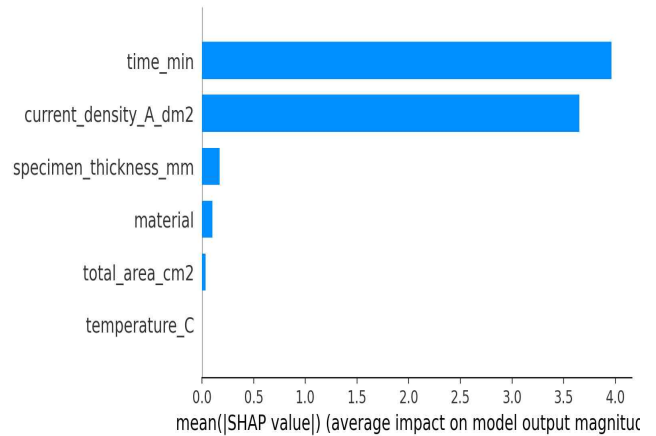
모델의 예측 성능을 평가하기 위해 실제 도금 두께와 예측값을 비교한 결과, 대부분의 데이터가 대각선 방향으로 밀집되어 분포하는 것을 확인하였다. 이는 모델이 도금 두께를 높은 정확도로 예측하고 있음을 의미하며, 공정 변수 기반 품질 예측이 가능함을 보여준다.

이러한 결과는 도금 공정이 전류밀도와 시간에 따라 비교적 안정적인 증가 경향을 가지며, 머신러닝 모델이 해당 패턴을 효과적으로 학습했음을 의미한다. 일부 구간에서 예측 오차가 발생하지만 전체적으로 선형 상관관계가 매우 높은 수준으로 나타났다.

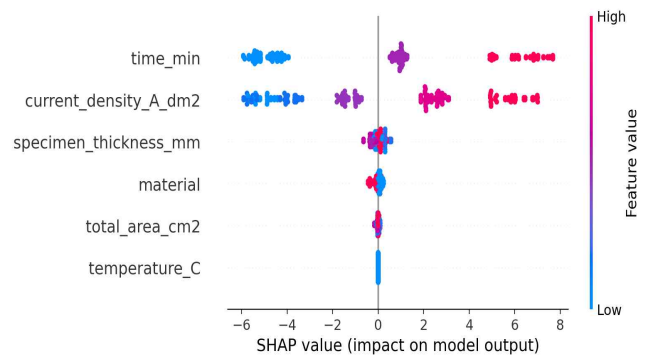
다음으로 Feature Importance 분석을 통해 각 공정 변수가 도금 두께에 미치는 상대적 영향을 평가하였다. 분석 결과, 도금 시간(time\_min)이 약 0.67로 가장 높은 영향도를 나타냈으며, 전류밀도(current\_density\_A\_dm2)가 약 0.31로 두 번째로 중요한 변수로 확인되었다. 반면, 시편 두께, 재질, 온도 등의 변수는 상대적으로 낮은 영향도를 보였다.

이는 Faraday 법칙에 따라 도금량이 전류와 시간에 비례한다는 전기화학적 원리와 일치하는 결과로, 모델의 물리적 타당성을 확보할 수 있다.

보다 정밀한 변수 영향 분석을 위해 SHAP(SHapley Additive exPlanations) 기법을 적용하였다. 그림 5에 분석 결과 그래프를 나타내었다. SHAP 분석 결과, 도금 시간과 전류



[그림 5] SHAP 변수 중요도 분석 (평균 영향도)



[그림 6] SHAP summary plot (변수별 영향 분포)

밀도는 도금 두께 증가 방향으로 큰 양의 영향을 미치며, 특히 고 전류밀도 및 장시간 조건에서 도금 두께가 급격히 증가하는 경향을 확인할 수 있었다.

또한 SHAP summary plot을 통해 개별 데이터 수준에서 변수 영향도를 분석한 결과, 도금 시간이 증가할수록 SHAP 값이 양의 방향으로 이동하며 도금 두께 증가에 직접적인 영향을 미치는 것을 확인하였다. 전류밀도 역시 유사한 경향을 보이며, 두 변수 간 상호작용이 도금 품질을 결정하는 핵심 인자임을 확인하였다.

반면 온도와 재질 변수는 대부분 SHAP 값이 0 근처에 분포하여 상대적으로 영향이 미미한 것으로 나타났다. 이는 본 실험에서 온도 조건이 일정하게 유지되었기 때문이며, 재질 또한 동일 범주 내에서 큰 차이를 보이지 않았기 때문으로 판단된다.

종합적으로, 머신러닝 분석 결과 도금 공정에서 가장 중요한 제어 변수는 도금 시간과 전류밀도로 도출되었으며, 이는 공정 최적화 시 우선적으로 고려해야 할 핵심 인자이다. 본 모델은 공정 조건 입력만으로 도금 두께를 사전에 예측할 수 있으며, 향후 실시간 공정 데이터와 연계할 경우 폐루프 제어 기반 자동 최적화 시스템으로 확장이 가능하다.

### 3. 결론

본 연구에서는 니켈 도금 공정에서 도금 두께의 변동성을 정량적으로 분석하고, 공정 최적화를 위한 데이터 기반 접근 방법을 제시하였다. 이를 위해 전류밀도, 도금 시간, 시편 두께, 재질 등의 주요 공정 변수를 변화시키며 실험을 수행하고, 도금 전후 무게 차이를 기반으로 도금 두께를 산출하였다. 또한 센서 기반 모니터링 시스템을 구축하여 공정 데이터를 실시간으로 수집하고, 이를 데이터베이스화하여 머신러닝 분석에 활용하였다.

머신러닝 분석에서는 Random Forest, Gradient Boosting, XGBoost 모델을 적용하였으며, 그 중 XGBoost 모델이 가장 우수한 예측 성능을 나타냈다. 실제값과 예측값 비교 결과 높은 선형 상관성을 확인할 수 있었으며, Feature Importance 및 SHAP 분석을 통해 도금 시간과 전류밀도가 도금 두께에 가장 큰 영향을 미치는 핵심 변수임을 확인하였다. 이는 Faraday 법칙에 기반한 전기화학적 이론과도 일치하는 결과로, 본 연구의 분석 결과가 물리적 타당성을 갖는다는 점에서 의미가 있다.

또한 본 연구를 통해 구축된 모델은 공정 조건 입력만으로 도금 두께를 사전에 예측할 수 있으며, 이를 활용하여 최적 공정 조건 도출이 가능함을 확인하였다. 특히 공정 변수 중 영향도가 낮은 요소를 식별함으로써 불필요한 공정 제어 요소를 줄이고, 핵심 변수 중심의 효율적인 공정 설계가 가능할 것으로 판단된다.

향후 연구에서는 실시간 센서 데이터와 머신러닝 모델을 연계한 폐루프 제어 시스템을 구축하여 공정 자동화 수준을 더욱 향상시키고, 다양한 도금 조건 및 재질에 대한 확장 연구를 수행할 필요가 있다. 이를 통해 니켈 도금 공정의 품질 안정성 확보뿐만 아니라 생산성 향상 및 스마트 제조 시스템 구현에 기여할 수 있을 것으로 기대된다.

[후기]

본 논문은 인하대학교 제조혁신전문대학원 석사학위 프로젝트 진행과 학위논문 제출을 위해 발표한 논문입니다.

#### 참고문헌

- [1] Schlesinger, M., and Paunovic, M. (eds.), *Modern Electroplating*, 5th ed., John Wiley & Sons, 2010. DOI: 10.1002/9780470602638
- [2] Dini, J. W., *Electrodeposition: The Materials Science of Coatings and Substrates*, Noyes Publications, 1993.
- [3] Cotell, C. M., Sprague, J. A., and Smidt, F. A. (eds.), *ASM Handbook, Volume 5: Surface Engineering*,

ASM International, 1994. DOI: 10.31399/asm.hb.v05.9781627081702

- [4] ASTM International, *ASTM E384-22: Standard Test Method for Microindentation Hardness of Materials*, ASTM International, 2022. DOI: 10.1520/E0384-22
- [5] ISO, *ISO 1456:2009 Metallic and other inorganic coatings — Electrodeposited coatings of nickel*, International Organization for Standardization, 2009.
- [6] Breiman, L., "Random Forests," *Machine Learning*, Vol. 45, No. 1, pp. 5-32, 2001. DOI: 10.1023/A:1010933404324
- [7] Friedman, J. H., "Greedy Function Approximation: A Gradient Boosting Machine," *Annals of Statistics*, Vol. 29, No. 5, pp. 1189-1232, 2001. DOI: 10.1214/aos/1013203451
- [8] Chen, T., and Guestrin, C., "XGBoost: A Scalable Tree Boosting System," *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 785-794, 2016. DOI: 10.1145/2939672.2939785
- [9] Lundberg, S. M., and Lee, S.-I., "A Unified Approach to Interpreting Model Predictions," *Advances in Neural Information Processing Systems (NeurIPS)*, 2017. arXiv: 1705.07874
- [10] Montgomery, D. C., *Design and Analysis of Experiments*, 9th ed., John Wiley & Sons, 2017.