

논문 2026-63-1-3

포토리소그래피 공정의 성능 향상을 위한 머신러닝 기반 최적화 기법과 DOE의 비교 분석

(Comparative Analysis of Machine Learning-based Optimization and
DOE for Performance Enhancement in Photolithography Process)

김 채 린*, 정 유 진**, 최 규 철***, 이 승 철***, 이 종 육****

(Charin Kim, Yujin Jung, Gyucheol Choi Seungcheol Lee, and Jongwook Lee^④)

요 약

포토리소그래피 공정의 정밀도 향상을 위한 기존 DOE 기반 최적화의 한계를 보완하고자, 본 연구에서는 변수 간 비선형 상호 작용을 효과적으로 반영하는 Gradient Boosting Regression(GBR) 기반 공정 최적화 기법을 제안하였다. 회전 속도, 노광 시간, 현상 시간을 변수로 설정해 수집된 데이터에 DOE와 머신러닝 기법을 적용하였다. 그 결과, 머신러닝 기반 최적화 조건은 DOE 대비 주요 품질 지표에서 전반적으로 우수한 성능을 보였다. 다만, 미세 패턴에서는 높은 공정 민감도로 인해 모델 정밀도 향상과 추가적인 데이터 확보가 필요한 것으로 나타났다. 본 연구는 머신러닝 기반 최적화가 공정 변수 간 복잡한 상호작용을 정밀하게 반영함을 실험적으로 입증하였으며, 미세 패턴 대응을 위한 개선 방향을 제시함으로써 반도체 양산 공정 최적화에 기여 가능성을 확인하였다.

Abstract

To overcome the limitations of conventional DOE-based optimization in enhancing photolithography precision, this study proposes a Gradient Boosting Regression (GBR) method that effectively captures nonlinear interactions among process variables. Experiments using RPM, exposure time, and develop time compared DOE and machine learning techniques on collected data. The machine learning approach yielded superior performance across major quality indicators versus DOE. However, for fine patterns, high sensitivity to process variations necessitates improved model precision and expanded data. This study demonstrates that machine learning-based optimization can accurately model complex process interactions and suggests directions for further enhancement in semiconductor mass production.

Keywords : Photolithography, Process optimization, Design of experiments, Machine learning, Semiconductor manufacturing

I. 서 론

포토리소그래피는 반도체 제조 공정에서 패턴을 형성하는 핵심 단계로, 공정 변수의 최적화를 통해 패턴 전사 정확도를 확보하는 것이 매우 중요하다^[1]. 특히, 공정 조건의 미세한 변화는 패턴 형성 품질에 결정적인

영향을 미치므로, 최적화된 공정 조건의 도출은 반도체 양산 공정의 수율 및 품질을 결정짓는 핵심 요소로 작용한다. 따라서 균일한 패턴 형성과 변동성 최소화를 위한 체계적인 공정 최적화 방법론이 요구된다.

기존에는 실험계획법(Design of Experiments, DOE)을 활용하여 최적의 공정 조건을 최적화하는 방식이 널

*비회원, 경희대학교 생체의공학과(Department of Biomedical Engineering, Kyung Hee University)

정회원, *비회원, 경희대학교 전자공학과(Department of Electronic Engineering, Kyung Hee University)

****정회원, 반도체공정기술교육원(Semiconductor Process Technology Academy)

④ Corresponding Author(E-mail : jongwook.lee@sptakorea.com)

Received ; March 28, 2025

Revised ; April 21, 2025

Accepted ; November 12, 2025

리 사용되어 왔다^[2]. 그러나 DOE는 실험 데이터가 제한적인 경우 변수 간의 비선형적인 관계를 충분히 반영하지 못하고, 이로 인해 최적 조건 도출의 정확성이 낮아지는 한계를 가진다^[3]. 이러한 한계를 보완하기 위한 대안으로 최근에는 머신러닝 기반의 공정 최적화 기법이 주목받고 있으며, 보다 정밀하고 안정적인 패턴 형성을 가능하게 할 수 있는 방법으로 제시되고 있다^[4].

본 연구는 DOE 기반의 공정 최적화와 머신러닝 기반 접근법을 비교·분석하여, 반도체 양산 공정에 실질적으로 적용 가능한 최적화 방법론을 제안하고자 한다. 이를 위해 포토리소그래피 공정의 주요 변수인 RPM, Exposure Time, Develop Time을 실험 변수로 선정하고, 각각의 기법을 적용하여 최적 조건을 도출하였다. 나아가 도출된 조건을 실제 공정에 적용하고, 패턴 형성 결과를 정량적으로 평가하여 머신러닝 기반 최적화 기법의 실효성을 검증하였다.

II. 실험 방법

1. 실험 환경 및 장비

본 연구는 일반적인 반도체 제조 환경에서 사용되는 포토리소그래피 장비를 기반으로 실험을 수행하였다. 실험은 웨이퍼 준비부터 감광제(Resist) 도포, 노광(Exposure), 현상(Develop), CD(Critical Dimension) 측정 순으로 진행되었으며, 각 단계에서 사용된 주요 장비는 다음과 같다.

웨이퍼 표면의 수분 제거 및 감광제 접착력 향상을 위해 위해 SH SCIENTIFIC사의 Drying Oven을 사용하여 Pre-Bake 공정을 수행하였다. 이어서, PRO WIN사의 Spin Coater (SP-6)를 이용해 감광제를 도포한 후, 핫플레이트에서 Soft Bake 공정을 진행하였다.

노광 공정은 PRO WIN사의 Mask Aligner (M-150)를 사용하였으며, PEB(Post Exposure Bake) 후에는 TMAH(Tetra-Methyl Ammonium Hydroxide) 기반 현상액을 적용하여 패턴을 형성하였다. 마지막으로, Hard Bake를 통해 패턴 안정성을 향상시켰다.

형성된 패턴의 치수 및 균일성을 분석하기 위해 SUNNY KOREA사의 MX4R 광학 현미경을 이용하여 ADI CD를 측정하였다. 이를 통해 공정의 품질 지표를 산출하고 정량적으로 평가하였다.

2. 웨이퍼 패턴

실험에 사용된 마스크는 다양한 크기의 미세 구조를

포함하고 있으며, 주로 $100\mu\text{m}$, $50\mu\text{m}$, $10\mu\text{m}$ 크기의 패턴을 중심으로 분석을 진행하였다. 다양한 크기의 패턴을 활용함으로써 공정 조건이 패턴 형성에 미치는 영향을 체계적으로 분석하고, 최적의 공정 조건을 도출하는 데 집중하였다.

마스크 디자인은 동일한 패턴이 다이(Die) 단위로 배열된 형태이며, 웨이퍼 전체에 균등하게 전사되도록 설계되었다. 그림 1은 마스크 마스크 전체 분포(a)와 단일 다이 내 패턴 구조(b)를 각각 보여준다.

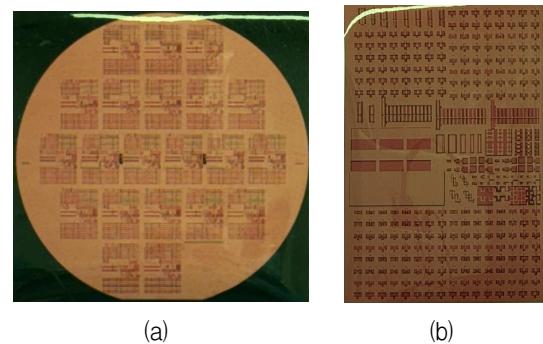


그림 1. 웨이퍼 상의 마스크 패턴: (a) 마스크 전체 패턴; (b) 단일 다이(Die) 패턴

Fig. 1. Mask pattern on the wafer: (a) Full mask pattern; (b) Single die pattern.

3. 품질 평가 지표

패턴 형성 품질을 평가하기 위해 ADI CD 값을 기준으로 다양한 지표를 활용하였다. 먼저, 목표 패턴 크기 (Target)와의 차이를 정량화하기 위해 상대 오차 (Relative Error, RE)를 산출하였다. 상대 오차는 아래 식으로 정의된다:

$$RE(\%) = \left| \frac{ARICD - Target}{Target} \right| \times 100 \quad (1)$$

공정의 반복성과 재현성을 평가하기 위해 동일 조건에서 반복 실험을 진행하였으며, 각 조건의 표준편차 (Standard Deviation, Stdev)를 계산하였다. 표준편차는 데이터의 분산을 나타내며, 값이 작을수록 공정 안정성이 높음을 의미한다. 표준편차는 다음과 같이 정의된다:

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \mu)^2} \quad (2)$$

여기서 N은 샘플 개수, X_i 는 개별 측정값, μ 는 평균 값을 나타낸다.

또한, 공정의 신뢰성과 변동성을 분석하기 위해 신호

대 잡음비(Signal-to-Noise Ratio, S/N Ratio)를 적용하였으며, 본 연구에서는 Smaller-the-Better 특성을 기준으로 다음과 같이 정의하였다.

$$S/N \text{ Ratio} = -10 \log_{10} \left(\frac{1}{N} \sum_{i=1}^N X_i^2 \right) \quad (3)$$

마지막으로, 공정 일관성과 품질 기준 충족 여부를 종합적으로 평가하기 위해 공정 능력 지수(Process Capability Index, Cpk)를 도출하였다. 공정 능력 지수는 아래와 같이 정의된다:

$$Cpk = \min \left(\frac{USL - \mu}{3\sigma}, \frac{\mu - LSL}{3\sigma} \right) \quad (4)$$

여기서 USL과 LSL은 각각 공정의 상한 및 하한 규격이며, μ 는 평균값, σ 는 표준편차를 의미한다.

4. 데이터 분석 방법

포토리소그래피 공정의 최적 조건을 도출하기 위해 본 연구에서는 Minitab 기반 DOE와 머신러닝(Machine Learning) 기법을 함께 활용하여 데이터를 분석하였다. 수집된 실험 데이터를 정량적으로 평가하고 공정 변수들이 패턴 형성에 미치는 영향을 체계적으로 분석하기 위해 다양한 통계 및 최적화 기법을 적용하였다.

먼저, Minitab을 이용하여 실험을 설계하고 실험 데이터를 수집하여 각 공정 변수(RPM, Exposure Time, Develop Time)가 ADI CD에 미치는 영향을 분석하였다. 분산 분석(Analysis of Variance, ANOVA)을과 결정계수(R^2)를 통해 변수의 유의성과 모델의 적합성을 검토하였으며, 반응 최적화(Response Optimization)를 통해 최적 조건을 도출하였다.

보다 정밀한 최적화를 위해 머신러닝 기법 분석을 추가로 수행하였다. 최근 연구에서도 딥러닝 기반 접근을 통해 리소그래피 공정 최적화의 예측 정확도가 향상된 바 있으며^[5], 본 연구에서는 Gradient Boosting Regression(GBR) 모델을 적용하였다. 이는 비선형 관계를 효과적으로 반영할 수 있는 트리 기반 앙상블 학습 기법이다^[6]. 분석 결과 및 최적 조건 도출은 III장에서 상세히 설명하고자 한다.

III 본 론

1. 실험 설계 및 수행

본 연구에서는 포토리소그래피 공정의 최적 조건을 도출하기 위해 DOE를 기반으로 실험을 설계하고 수행

하였다. 공정 변수는 RPM, Exposure Time, Develop Time으로 설정하였으며, 각 변수는 3개의 수준(Level)으로 구성하였다. 실험에서 사용된 변수 및 수준은 표 1에 정리되어 있다.

Full Factorial Design을 적용하여 총 $3^3 = 27$ 개의 실험 조건을 구성하였고(표 2), 각 조건에 대해 3회의 반복 실험을 수행하여 총 81개의 데이터 세트를 확보하였다. 모든 실험은 동일한 4인치 실리콘 웨이퍼를 사용하여 진행되었으며, 실험 결과로부터 ADI CD, 표준 편차, 상대 오차, S/N Ratio, Cpk 등의 품질 지표를 산출하였다. 실험 결과의 일부를 표 3에 제시하였다.

표 1. 실험 변수 및 수준

Table 1. Experimental Variables and Levels.

	Level 1	Level 2	Level 3
RPM	3000	5000	7000
Exposure Time (sec)	5	15	45
Develop Time (sec)	2	10	40

표 2. 실험 설계

Table 2. Experimental Design.

No.	RPM	Exposure Time (sec)	Develop Time (sec)
1	3000	5	2
2	3000	5	10
3	3000	5	40
4	3000	15	2
5	3000	15	10
6	3000	15	40
7	3000	45	2
8	3000	45	10
9	3000	45	40
10	5000	5	2
11	5000	5	10
12	5000	5	40
13	5000	15	2
14	5000	15	10
15	5000	15	40
16	5000	45	2
17	5000	45	10
18	5000	45	40
19	7000	5	2
20	7000	5	10
21	7000	5	40
22	7000	15	2
23	7000	15	10
24	7000	15	40
25	7000	45	2
26	7000	45	10
27	7000	45	40

표 3. 실험 수행 후 수집된 데이터
Table 3. Collected Experimental Data.

Pattern Size	No.	Y_1	Y_2	Y_3	Avg Diameter	Stdev	RE (%)	S/N Ratio
$100\mu m$	3	99.43525	99.40828	99.41598	99.41984	0.013893	0.580165	39.9495
	8	98.19419	96.43948	98.33333	97.65567	1.055544	2.344333	39.7945
	13	102.1056	100.3045	100.3431	100.9177	1.028884	0.917727	40.0798
	16	103.6361	99.21455	99.7943	100.8817	2.402978	0.881653	40.0787
	21	99.99528	99.91025	100.1963	100.0339	0.14687	0.03393	40.003
	22	101.7191	101.7423	100.4282	101.2965	0.752091	1.296497	40.1121
$50\mu m$	3	49.39587	49.36504	49.40743	49.38945	0.021911	1.221102	33.8727
	8	47.95692	46.75877	48.15017	47.62195	0.753758	4.756093	33.5572
	13	52.18523	50.13678	51.08	51.134	1.025292	2.268007	34.1759
	16	51.60548	49.19372	49.68844	50.16255	1.273864	0.325093	34.0104
	21	49.98991	50.08267	49.95899	50.01052	0.064365	0.021047	33.9812
	22	51.33493	51.49726	52.03063	51.62094	0.363967	3.24188	34.2567
$10\mu m$	3	9.159372	8.955145	9.036065	9.050194	0.102844	9.498061	19.1337
	8	8.01601	6.29995	7.73	7.348653	0.919394	26.51347	17.3916
	13	10.83	9.37649	10.83	10.3455	0.839184	3.454967	20.3235
	16	10.11857	8.84312	9.36103	9.440907	0.641466	5.590933	19.5203
	21	9.91759	9.61612	9.54655	9.69342	0.197229	3.0658	19.7313
	22	10.73697	12.19794	11.4404	11.45844	0.730652	14.58437	21.2001

이후, 확보된 데이터를 바탕으로 Minitab을 이용한 DOE 분석과 머신러닝 기반 최적화 기법을 각각 적용하여 공정 변수의 영향력을 분석하고, 두 접근법의 성능을 비교 평가하였다.

2. Minitab 기반 최적화 분석

DOE 기반 분석에서는 선형 회귀 모델을 구성하고, 각 공정 변수가 ADI CD에 미치는 영향을 분석하였다. 분석 결과는 표 4에 제시하였다. 분산 분석을 통해 변수의 유의성을 평가한 결과, Exposure Time과 Develop Time은 ADI CD의 변동성에 통계적으로 유의미한 영향을 미치는 것으로 나타났다($p < 0.05$). 반면, RPM은 모든 패턴 크기에서 통계적으로 유의미하지 않은 것으로 분석되었다($p > 0.05$). 이는 포토리소그래피 공정에서 Exposure Time과 Develop Time이 패턴 형성에 더 큰 영향을 미친다는 것을 시사한다.

회귀 분석 결과를 바탕으로 반응 최적화를 수행한 결과, RPM 3000, Exposure Time 5초, Develop Time 21.98초일 때 종합 만족도(Desirability) 0.9271을 만족하는 최적 조건이 도출되었다(표 5). 다만, DOE는 변수 간의 비선형 상호작용을 충분히 반영하지 못한다는 점에서 한계가 존재하며, 데이터가 제한적인 경우 모델

의 일반화 성능도 저하될 수 있다. 따라서 이러한 점을 보완하기 위해 머신러닝 기법을 병행 적용하였다.

3. 머신러닝 기반 최적화 분석

포토리소그래피 공정 최적화에 있어 머신러닝 기반 기법은 최근 연구에서 DOE보다 높은 예측 정확도와 성능을 입증하고 있다^[7]. 본 연구에서는 이러한 머신러닝 기법 중 하나인 GBR을 적용하였다. GBR은 트리 기반 양상을 알고리즘으로, 비선형 관계 및 변수 간 복잡한 상호작용을 효과적으로 학습할 수 있어 공정 조건이 출력 변수에 미치는 영향을 정밀하게 반영할 수 있다^[8].

모델 학습에는 실험 데이터를 활용하였으며, 입력 변수로는 RPM, Exposure Time, Develop Time을, 목표 변수로는 ADI CD를 사용하였다. 성능 평가는 평균 절대 오차(MAE), 평균 제곱 오차(MSE), 평균 제곱근 오차(RMSE), 결정계수(R^2)를 기준으로 수행되었으며, GBR 모델은 R^2 값이 0.97 이상으로 높은 설명력을 보였다(표 6). 이는 실험 데이터를 기반으로 복잡한 변수 간 관계를 효과적으로 학습하였음을 시사한다.

학습된 모델을 바탕으로 도출한 최적 조건은 RPM 3524.87, Exposure Time 25.26초, Develop Time 15.77초로 나타났으며, 종합 만족도는 0.9726으로 분

표 4. 회귀 분석 결과(ANOVA 분석)

Table 4. ANOVA Analysis Results for Regression.

Pattern Size	Source	DF	Adj SS	Adj MS	F-value	P-value
100 μ m	Regression	3	46.9595	15.6532	19.81	0.000
	RPM	1	0.6399	0.6399	0.81	0.378
	Exposure Time	1	21.0560	21.0560	26.65	0.000
	Develop Time	1	26.0700	26.0700	33.00	0.000
	Error	22	17.3803	0.7900	-	-
50 μ m	Regression	3	50.9045	16.9682	26.03	0.000
	RPM	1	0.3626	0.3626	0.56	0.464
	Exposure Time	1	23.1686	23.1686	35.54	0.000
	Develop Time	1	28.4863	28.4863	43.70	0.000
	Error	22	14.3401	0.6518	-	-
10 μ m	Regression	3	54.6585	18.2195	29.07	0.000
	RPM	1	0.6302	0.6302	1.01	0.327
	Exposure Time	1	25.9861	25.9861	41.46	0.000
	Develop Time	1	29.0617	29.0617	46.37	0.000
	Error	22	13.7881	0.6267	-	-

표 5. Minitab 기반 최적 조건 분석 결과

Table 5. Optimization Results Based on Minitab.

RPM	Exposure Time (sec)	Develop Time (sec)	Desirability
3000.0	5.0	21.9794	0.9271

표 6. 머신러닝 모델 평가 지표

Table 6. Performance Metrics of Machine Learning Model.

Model Type	MAE	MSE	RMSE	R^2
Normalized RE Prediction Model	0.132269	0.046748	0.216213	0.979966
S/N Ratio Prediction Model	0.051767	0.006641	0.081494	0.999913

표 7. 머신러닝 기반 최적 조건 분석 결과

Table 7. Optimization Results Based on Machine Learning.

RPM	Exposure Time (sec)	Develop Time (sec)	Desirability
3524.87	25.26	15.77	0.9726

석되었다(표 7). 이는 기존 DOE 기반 조건보다 높은 만족도를 나타내며, 머신러닝 기법이 공정 변수 간의 관계를 정밀하게 반영하여 최적화 성능을 향상시킬 수 있음을 보여준다.

4. 최적화 결과 비교 및 분석

각 최적화 방법의 성능을 비교하기 위해 Minitab과 머신러닝 기법으로 도출된 조건을 실제 공정에 적용하여 결과를 평가하였다. Minitab 기반 분석에서는 RPM 3000, Exposure Time 5초, Develop Time 21.9794초가 최적 조건으로 도출되었으며, 머신러닝 기반에서는 RPM 3524.87, Exposure Time 25.26초, Develop Time 15.77초가 도출되었다. 실험에는 반올림된 수치를 적용하였으며, 실제 장비 설정값은 표 8에 정리하였다.

두 조건을 기반으로 공정을 수행한 후, 패턴 형성 결과를 측정하고 ADI CD, 표준편차, 상대 오차, S/N Ratio, Cpk 등의 품질 지표를 산출하였다. 각각의 실험 데이터는 표 9 및 표 10에, 정량적 비교 결과는 표 11에 제시하였다.

머신러닝 기반 최적 조건은 평균 CD 값이 목표 치수에 더 근접하고, 표준편차가 작아 공정 변동성이 감소한 것으로 나타났다. 상대 오차 또한 낮게 나타났으며, S/N Ratio는 높아 공정의 안정성이 향상되었음을 확인할 수 있었다. 특히, 100 μ m 및 50 μ m 패턴에서는 공정 능력 지수가 1.33을 초과하여 산업적 공정 안정성 기준을 만족하였다.

머신러닝 기반 최적화가 더 우수한 성능을 보인 이유는 다음과 같다. 우선, Minitab 기반 DOE는 변수 간 독립성과 선형성을 전제로 하지만 실제 공정에서는 다양

표 8. 미니탭과 머신러닝 최적 조건 비교 및 실제 기계 세팅 값

Table 8. Comparison of Optimal Conditions from Minitab and Machine Learning with Actual Machine Settings.

	RPM	Exposure time (sec)	Develop time (sec)
Minitab Optimal Conditions	3000.0	5.0	21.9794
Machine Setting	3000	5	22
ML Optimal Conditions	3524.87	25.26	15.77
Minitab Setting	3500	25	16

표 9. 미니탭 최적 조건에서 수행한 실험 데이터

Table 9. Experimental Data Obtained Under Minitab Optimal Conditions.

Pattern Size	Y_1	Y_2	Y_3	Avg Diameter	Stdev	RE (%)	S/N Ratio
100 μ m	102.09	101.93	100.05	101.3567	1.134431	1.356667	40.1176
	102.34	102.2	102.24	102.26	0.072111	2.26	40.1941
	101.84	102.22	102.23	102.0967	0.222336	2.096667	40.1803
	101.22	101.94	101.89	101.6833	0.402036	1.683333	40.1451
	102.14	101.74	102.07	101.9833	0.21362	1.983333	40.1706
	101.84	103.87	102.23	102.6467	1.077234	2.646667	40.2274
50 μ m	50.87	51.32	51.27	51.15333	0.246644	2.306667	34.1776
	50.92	51.72	51.31	51.31667	0.400042	2.633333	34.2054
	51.24	50.99	49.5	50.57667	0.940762	1.153333	34.0805
	51.2	51.73	50.56	51.16333	0.585861	2.326667	34.1797
	51.23	51.05	50.56	50.94667	0.346747	1.893333	34.1425
	50.92	51.81	51.14	51.29	0.463573	2.58	34.201
10 μ m	10.39	11.01	10.42	10.60667	0.349619	6.066667	20.5163
	10.4	10.32	10.51	10.41	0.095394	4.1	20.3494
	10.34	10.95	10.25	10.51333	0.380832	5.133333	20.4405
	10.41	10.06	10.26	10.24333	0.175594	2.433333	20.2101
	10.44	10.26	10.32	10.34	0.091652	3.4	20.2908
	10.41	10.81	10.41	10.54333	0.23094	5.433333	20.4616

표 10. 머신러닝 최적 조건에서 수행한 실험 데이터

Table 10. Experimental Data Obtained Under Machine Learning Optimal Conditions.

Pattern Size	Y_1	Y_2	Y_3	Avg Diameter	Stdev	RE (%)	S/N Ratio
100 μ m	99.44875	98.6849	100.0294	99.38769	0.674343	0.612307	39.9469
	99.75273	100.73	100.0606	100.1811	0.499654	0.181114	40.0158
	99.94759	99.75273	99.78781	99.82938	0.103868	0.170624	39.9852
	99.5228	100.805	100.084	100.1373	0.642747	0.137255	40.0121
	100.0333	100.6218	100.6881	100.4477	0.360408	0.447732	40.0389
	101.2	100.5517	100.2282	100.6599	0.494873	0.659949	40.0572
50 μ m	49.61688	48.98822	49.89938	49.50149	0.466415	0.99701	33.8928
	49.88745	48.8967	49.80389	49.52935	0.549477	0.941306	33.8978
	49.87551	49.81981	49.84766	49.84766	0.027852	0.304682	33.9529
	49.19512	50.53601	51.24	50.32371	1.038839	0.647419	34.0373
	51.62623	50.67527	50.35696	50.88615	0.66039	1.772304	34.1327
	50.21372	50.48428	50.26942	50.32247	0.142872	0.644949	34.0353
10 μ m	9.85351	10.07324	9.81992	9.915557	0.137587	0.844435	19.9272
	9.616134	9.681165	10.23622	9.844505	0.340787	1.554947	19.8691
	9.97462	9.91759	9.741736	9.877982	0.121389	1.220183	19.894
	9.912669	9.875678	9.76631	9.851553	0.076104	1.484475	19.8704
	9.819599	9.827234	10.40093	10.01592	0.333448	0.159199	20.0186
	10.65284	10.7691	10.77879	10.73358	0.070091	7.335756	20.6151

표 11. 최종 실험 성능 비교

Table 11. Final Performance Comparison of Experimental Results.

Pattern Size	Method	Avg Diameter	Stdev	RE (%)	S/N ratio	Cpk
100 μ m	Minitab	102.0044	0.520295	2.004444	40.1724	1.91914
	ML	100.1072	0.462649	0.368163	40.0093	3.525216
50 μ m	Minitab	51.07444	0.497271	2.148889	34.1643	0.955585
	ML	50.06847	0.480974	0.884612	33.9913	1.685141
10 μ m	Minitab	10.44278	0.220672	4.427778	20.3773	0.086436
	ML	10.03985	0.179901	2.099832	20.0317	0.852602

한 비선형적 상호작용이 존재한다. 머신러닝 기법은 이러한 관계를 효과적으로 학습하여 보다 정밀한 조건 예측이 가능하다.

변수 중요도 분석 결과, Exposure Time과 Develop Time이 ADI CD에 큰 영향을 미치는 주요 인자로 확인되었다. Minitab 분석에서는 Develop Time이 22초로 도출된 반면, 머신러닝 기반 조건에서는 16초로 감소하였다. 이는 충분한 Exposure Time이 확보된 상태에서 Develop Time이 과도하게 길어질 경우 오버 에칭(over-etching) 현상이 발생할 수 있음을 반영한 결과로 해석된다.

RPM 조건에서도 차이를 보였다. ANOVA 분석 결과에서는 RPM 단독 효과는 통계적으로 유의하지 않은 것으로 나타났으나, 머신러닝 기반 최적화에서는 약 3500rpm의 조건이 도출되었다. 이는 머신러닝 기법이 변수 간의 비선형적 상호작용이나 복합적인 영향 관계를 반영하기 때문으로 해석된다. 실제로 감광제 도포 속도가 증가하면 감광제의 두께가 얇아지게 되고, 이는 보다 균일한 패턴 전사에 유리한 조건이 될 수 있다. 머신러닝 모델은 이러한 미세한 공정 변수 간의 관계를 학습하여, 보다 적절한 RPM 값을 예측한 것으로 판단된다.

한편, 10 μ m 패턴에서는 머신러닝 기반 조건에서도 Cpk가 1.33에 미치지 못하여 산업적 공정 안정성 기준을 충족하지 못하는 결과가 나타났다. 이는 미세 패턴 일수록 공정 변수의 작은 변화에도 민감하게 반응하며, 최적화가 더욱 까다롭다는 것을 의미한다^[9]. 향후 연구에서는 공정 노이즈에 강건한 모델 구조 설계, 변수 간 고차 상호작용 반영을 위한 입력 변수 확장, 그리고 다양한 공정 조건에 대한 고해상도 데이터 확보를 통해 미세 패턴에서도 안정적인 공정 조건을 도출할 수 있는 고도화된 최적화 기법 개발이 필요하다.

IV. 결 론

본 연구에서는 포토리소그래피 공정의 최적화를 위해 DOE와 머신러닝 기법을 비교·분석하였다. 실험 결과, 머신러닝 기반 최적 조건이 다양한 품질 지표에서 전반적으로 더 우수한 성능을 보였다. 머신러닝은 변수 간의 비선형적 상호작용을 반영하여 보다 정밀한 조건 예측이 가능하며, 일부 패턴에서는 산업적 공정 안정성 기준도 만족하였다. 다만, 미세 패턴에서는 여전히 개선 여지가 존재하였다.

향후에는 공정 변수와 데이터 수집 범위를 확대하고, 실시간 모니터링 및 양산 환경에서의 적용 가능성을 고려한 연구를 통해 머신러닝 기반 최적화 기법의 실효성을 더욱 강화할 필요가 있을 것이다. 또한, 본 연구는 수십 마이크로미터 수준의 패턴을 대상으로 실험을 수행하였기 때문에, 나노 단위 패턴에 대한 적용 가능성은 후속 연구를 통해 추가적으로 검토되어야 한다. 다만, 본 연구에서 분석한 공정 변수 간의 상호작용 구조나 최적화 접근 방식은 패턴 크기와 무관하게 적용 가능한 보편적 방법론으로, 그 의미는 유효하다고 판단된다. 이러한 한계를 보완하고 적용 범위를 확대한다면, 머신러닝 기반 최적화 기법은 차세대 반도체 공정에서 요구되는 고정밀·고안정성 조건 확보에 기여할 수 있을 것이다.

REFERENCES

- [1] H. I. Smith and M. L. Schattenburg, "Large-area high-resolution deep-ultraviolet interference lithography," *J. Vac. Sci. Technol. B*, vol. 11, no. 6, pp. 2718-2722, Nov. 1993.
- [2] G. E. P. Box and N. R. Draper, *Empirical Model-Building and Response Surfaces*, Wiley, pp. 1-50, 1987.
- [3] D. C. Montgomery, *Design and Analysis of*

Experiments, 9th ed., Wiley, pp. 1–70, 2017.

[4] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Springer, pp. 1–30, 2009.

[5] K. Limam, S. Cheema, S. Mouhoubi, and F. D. Freijedo, “Deep learning-based visual recognition for inline defects in production of semiconductors,” *IEEE J. Emerg. Sel. Topics Ind. Electron.*, vol. 5, no. 1, pp. 203–211, Jan. 2024.

[6] J. H. Friedman, “Greedy function approximation: A gradient boosting machine,” *Ann. Stat.*, vol. 29, no. 5, pp. 1189–1232, Oct. 2001.

[7] Rongbo Zhao, Yayi Wei, Hong Xu, and Xiangming He, “Process optimization of line patterns in extreme ultraviolet lithography using machine learning and simulated annealing,” *Appl. Opt.*, vol. 62, no. 4, pp. 927–932, Feb. 2023.

[8] C. I. Lang, *Applications of Probabilistic Machine Learning Models to Semiconductor Fabrication*, Massachusetts Institute of Technology, pp. 1–200, 2022.

[9] R. Pal, A. Chen, X. Zhang, S. Muralidharan, et al., “Cpk based variation reduction in 14nm FinFET technology,” in *Proc. SEMICON West*, pp. 1–4, San Francisco, CA, USA, July 2014.

저자 소개



김 채 린(비회원)
2025년 경희대학교 생체의공학과
학사 졸업

<주관심분야: 반도체, 나노공학, 임베디드 시스템, 생체 신호처리>



최 규 철(비회원)
2025년 경희대학교 전자공학과
학사 졸업.
2025년~현재 경희대학교
전자공학과 석사 과정

<주관심분야: 반도체, 컴퓨터, 로봇>



정 유 진(정회원)
2025년 경희대학교 전자공학과
학사 졸업

<주관심분야: 반도체, 임베디드 시스템, 머신러닝, 로봇공학>



이 승 철(비회원)
2019년~현재 경희대학교
전자공학과 학사 과정.

<주관심분야: 반도체, 회로>



이 종 융(정회원)
IEEE Senior Member
1996년 한국과학기술원
전기및전자공학과
박사 졸업
1996년~2000년 하이닉스 근무
2000년~2003년 NEC 근무

2003년~2014년 삼성전자 근무
2014년~2020년 아주대학교 전자공학과 교수
2020년~현재 반도체공정기술교육원 대표
<주관심분야: 반도체 소자, 반도체공정, 3D 칩적층, 교육>