

수요 맞춤형 웨이퍼의 수율 개선을 위한 데이터 기반 웨이퍼 기울기 조정 방안에 대한 연구*

길준혁 · 배장원†

한국기술교육대학교 산업경영학과

A Study on Data-based Wafer Slope Adjustment Strategies for Yield Improvement in Customized Wafer Manufacturing*

Jun Hyeok Gil · Jang Won Bae

School of Industrial Management, Korea University of Technology and Education

■ Abstract ■

With advancements in technology, the importance of customized wafer manufacturing has been increasing, particularly as the demand for precise manufacturing requirements, such as wafer slope, continues to expand. However, relying solely on simple statistical analysis or empirical approaches has limitations in effectively improving the yield of customized production. Therefore, manufacturers must adopt a data-based approach to respond effectively to these evolving requirements. This study explores the key factors influencing wafer slope adjustment for yield improvement by effectively responding to wafer slope requirements through a predictive model based on manufacturing process data. To achieve this, multiple linear regression and deep learning models were developed to control the manufacturing process for precise wafer slope implementation, and their performance was comparatively analyzed. The experimental results indicate that the key factors influencing wafer slope and their effects vary depending on wafer slope requirements and product type. Additionally, it was found that effective data collection and utilization, along with selecting an appropriate model, are essential for accurately representing product-specific requirements. Through this study, various considerations regarding data utilization for demand-driven quality management were examined, and the findings are expected to contribute to the development of strategies for improving the yield of related manufacturing processes.

Keywords : Wafer Slope, Yield, Customized Wafer, Multiple Linear Regression, Deep Learning

논문접수일 : 2025년 02월 06일 논문게재확정일 : 2025년 03월 28일

논문수정일(1차 : 2025년 02월 20일, 2차 : 2025년 03월 16일)

* 이 논문은 2024년도 한국기술교육대학교 교수 교육연구진흥과제 지원에 의하여 연구되었음

† 교신저자, jangwon_bae@koreatech.ac.kr

1. 서 론

전 세계 반도체 파운드리(Foundry) 시장 규모는 계속 성장할 것으로 예상되며, 반도체 장치가 소형화 되고 복잡해짐에 따라 고객의 다양한 요구사항을 충족시키는 것이 중요해지고 있다[19]. 예를 들어 Intel과 AWS(Amazon Web Services)는 Intel 제품과 웨이퍼를 포함하는 맞춤형 칩 설계(Custom Chip Design)에 대해 다년간 공동 투자할 계획을 발표하였다[22].

이러한 중요성의 확대는 ICT(Information and Communication Technology) 제품 전반의 확장과 관련이 깊다. ICT 관련 제품의 소량화 및 다양화로 인해 웨이퍼의 기율기, 박막화, 평탄도 등 세부 제조 공정에 대한 요구사항과 수요는 증가하고 있다[17]. 특히 반도체 웨이퍼의 정밀한 기율기 조정은 반도체 성능 및 집적도를 높이는 데 중요한 역할을 하며, 이러한 공정은 반도체의 품질 및 수율 향상에 매우 중요한 역할을 한다[8]. 그러나 반도체 산업의 이러한 변화는 반도체 제조사 입장에서는 다른 문제를 야기한다. 다양한 수요에 대한 적절한 수준의 품질을 유지하기 위해서는 그에 비례하여 다양해진 공정과 장비 변수를 고려해야 한다. 즉 제조 수율의 요인을 파악하기 어려울 뿐만 아니라 단순 통계 분석이나 경험적 기술로는 수율을 향상하는 데 한계를 지니고 있다[1]. 또한 웨이퍼 품질에 대한 산업 기준 역시 까다로워지고 있기에 맞춤형 생산이 더욱 어려워지고 있다[2].

이러한 점에서, 반도체 제조의 경우 품질 데이터에 기반한 수율 예측과 공정 관리가 중요해지고 있다[6]. 따라서 반도체 제조사들은 높은 품질을 달성하고 고객의 요구사항을 충족시키기 위해 데이터 기반 분석 방법 적용의 필요성이 높아지고 있다.

본 연구에서는 제품별로 요구되는 웨이퍼의 기율기를 효과적으로 조정하여 웨이퍼의 수율을 향상시키기 위해 데이터 분석 방법을 적용한다. 기율기를 포함한 웨이퍼의 요구사항은 제품별로 상이하기에 각 제품의 웨이퍼 기율기를 조정하기 위한 주요 요인

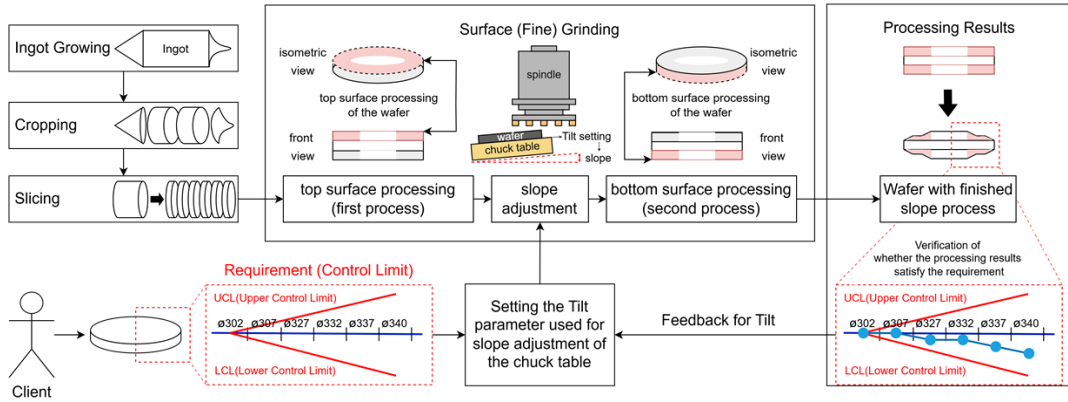
탐색을 수행하였다. 이를 위해 웨이퍼의 기율기를 조정하는 장비의 최적 설정값(Tilt)을 추정하기 위한 다중선형회귀 모델 및 딥러닝 모델을 개발하고 제품별로 두 모델의 성능을 비교분석 하였다. 분석 결과 제품 특성에 대한 영향을 파악하고 제품별 효과적으로 기율기를 조정하기 위한 적절한 데이터와 모델을 사용하는 것이 필요함을 확인하였다. 본 연구의 결과를 통해 수요 맞춤형 웨이퍼의 품질관리에 대한 데이터 활용 방안을 다각적으로 살펴보고, 궁극적으로는 제조 공정의 수율을 높이는 방안 개발에 활용될 수 있을 것으로 기대한다.

2. 배경지식 및 선행 연구


2.1 웨이퍼 기율기 가공 공정

<Figure 1>은 본 연구에서 고려하는 웨이퍼 기율기 조정의 전체 과정을 표현한 것이다. 첫 번째 단계인 잉곳 성장(Ingot Growing)은 다결정 실리콘을 고온으로 녹인 뒤 단결정 실리콘 잉곳으로 성장시키는 공정으로 기둥 형태의 잉곳을 제작하는 작업이다. 두 번째 단계인 절단(Cropping)은 잉곳의 표면을 매끄럽게 다듬은 뒤 블록 단위로 절단하는 공정으로 잉곳을 두꺼운 원기둥 모양으로 자르는 단계이다. 세 번째 단계인 슬라이싱(Slicing)은 가공된 잉곳에 와이어를 사용하여 일정한 두께로 절단하는 단계로 공정 결과 얇은 원판 모양의 웨이퍼가 만들어진다. 네 번째 단계인 표면 연삭(Surface Grinding) 단계는 Fine Grinding으로도 불리며, 웨이퍼의 기율기를 조정하는 단계이다.

본 연구에서 고려하는 웨이퍼는 <Figure 2>와 같이 도넛 모양으로 구성되어 있으며, 웨이퍼 기율기 측정을 위해서 웨이퍼의 외곽을 따라 총 8개의 측정 Point가 시계 방향으로 배치되어 있다. 이 Point에 웨이퍼의 기율기를 측정하는 구간인 PCD(Pitch Circle Diameter)를 웨이퍼 중앙에서 외곽으로 지정한다. 예를 들어, <Figure 2>에는 8개의 Point에 PCD가 6개씩 설정되어 있다.



〈Figure 1〉 The Entire Process of Wafer Slope Adjustment



〈Figure 2〉 PCD(Pitch Circle Diameter) Point on the wafer

웨이퍼의 기울기는 식 (1)과 같이 계산한다. I 는 각 Point의 PCD 집합을, k 는 웨이퍼의 8개 Point 중 하나를 의미한다. $PCD_{i,k}$ 는 k 번째 Point에 위치한 PCD 중 i 구간의 두께 값을 의미한다. $Average\ Difference_i(AD_i)$ 는 8개 Point에 대해 특정 $PCD_{i,k}$ 와 기준값으로 사용되는 $PCD_{ø302,k}$ 간 차이의 평균값으로, 이를 통해 각 PCD 별 평균 두께 차이를 측정할 수 있다. 또한 $\min$ 과 $\max$ 는 모든 PCD의 $Average\ Difference_i$ 값 중 최솟값과 최댓값을 의미한다. 이를 통해 두께의 평균적인 차이가 가장 작은 값과 큰 값을 각각 구할 수 있으며, $\min$ 값과 $\max$ 값을 더해 두께의 변동성을 계산하여 웨이퍼의 기울기를 파악하였다.

$$slope = \min_{i \in I} (AD_i) + \max_{i \in I} (AD_i) \quad (1)$$

$$Average\ Difference_i(AD_i) = \frac{1}{8} \sum_{k=1}^8 (PCD_{i,k} - PCD_{ø302,k})$$

$$I = \{ø302, ø307, ø312, ø317, ø322, ø327, ø332, ø337, ø340\}$$

표면 연삭(Surface Grinding) 단계는 wafer chuck table에 웨이퍼를 고정한 후, spindle에 장착된 grinding wheel을 사용하여 웨이퍼 표면을 가공하며, 총 2번의 공정을 수행한다. 1차 공정(first process)은 웨이퍼의 상면(top surface)을 가공하여 기울기를 조정하는 단계이며, 1차 공정 이후 측정된 웨이퍼의 기울기를 기반으로 Tilt를 설정하여 2차 공정에서의 기울기 조정을 준비한다. 웨이퍼의 기울기는 웨이퍼 연삭 장비인 chuck table과 spindle의 연삭 각도를 조정하는 파라미터인 Tilt를 설정하여 웨이퍼의 두께 총 변동(TTV, Total Thickness Variation)을 통해 조정한다[18]. 즉, Tilt는 chuck table axis와 spindle axis 사이의 각도를 조정하는 값으로, 웨이퍼의 표면을 PCD에 따라 특정 각도로 연삭하여 원하는 웨이퍼의 기울기를 형성하도록 한다. 반도체 제조사는 고객의 웨이퍼 기울기 요구사항을 충족시켜야 하며, 웨이퍼가 기울기 요구사항 범위 내에서 정밀하게 제조될수록 불량률이 감소하여 수율이 향상된다. 따라서 수율 증대를 위해서는 Tilt 값 설정을 통해 웨이퍼의 기울기를 조정하여 고객의 요구사항을 반영하는 것이 필요하다.

<Table 1> Detailed Information on Product(wafer) Types

Product Type	Data size	Thickness (μm)	The number of PCDs used	Wafer slope requirements	
				UCL(μm) (Upper Control Limit)	LCL(μm) (Lower Control Limit)
A	3,086	4.2	6	0, 0.3, 1.6, 2, 2.3, 2.5	0, -0.7, -3.3, -3.9, -4.6, -5
B	2,516	3.3	9	0, 0.3, 0.7, 1, 1.3, 1.6, 2, 2.3, 2.5	0, -0.7, -1.3, -2, -2.6, -3.3, -3.9, -4.6, -5
C	487	2.7			
D	2,656	2.3	7	0, 0.4, 0.7, 1.4, 1.8, 2.1, 2.5	0, -0.7, -1.4, -2.9, -3.6, -4.3, -5

<Table 1>은 본 연구에서 고려한 제품(웨이퍼)의 상세 정보와 요구사항을 나타낸다. 총 4개의 제품(A, B, C, D)을 대상으로 진행하였으며, 데이터의 양, 웨이퍼의 두께, 사용되는 PCD 구간 및 고객의 요구사항은 제품별로 차이가 있다. 특히 고객의 요구사항은 PCD 구간마다 유효한 두께의 최댓값(UCL, Upper Control Limit)과 최솟값(LCL, Lower Control Limit)으로 구성되며, 각 PCD 지점 사이의 두께 변화를 통해 웨이퍼의 기울기를 측정한다. 또한, 동일한 PCD 구간이라도 제품에 따라 요구되는 두께 값이 다를 수 있으나, 제품 B와 C는 동일한 PCD 구간과 요구사항을 갖는다.

2차 공정(second process)은 웨이퍼의 하면(bottom surface)을 설정된 Tilt를 기반으로 가공하여 기울기를 조정하는 단계이다. 최종적으로 두 번의 공정 과정을 통해 고객의 기울기 요구사항이 반영된 웨이퍼가 만들어진다.

따라서 본 연구에서는 제품별 웨이퍼 기울기에 대한 고객 요구사항을 충족시켜 수율을 향상시키기 위해 고려해야 하는 요인들을 탐색하였다. 이에 Tilt를 종속변수로 설정하여 적절한 값을 도출하는 다중선형회귀 모델과 딥러닝 모델을 개발하여 두 모델의 성능을 비교분석 하였다.

2.2 선행 연구

본 절에서는 웨이퍼의 기울기 조정에 관한 선행 연구를 비교분석하고, 본 연구와의 차이점을 제시한다.

Lee et al.[14]은 웨이퍼 평탄도를 결정하는 마지막 공정인 단면 래핑(single side lapping)에서 사용

되는 각각의 공정 인자들이 웨이퍼의 평탄도에 미치는 영향을 분석하고, 이러한 인자들을 이용하여 웨이퍼의 평탄도를 향상시킬 수 있는 방법을 탐색하였다. 이를 위해 정반의 온도, 웨이퍼의 가압 헤드, 정반의 회전 속도비, 헤드의 압력 분포와 같은 인자들을 사용하였다. 실험은 다이아몬드 연마액을 공급하여 웨이퍼를 연마였다. 실험 결과 각각의 공정 인자들이 특정 조건에서 평탄도를 개선할 수 있음을 확인하였다.

Kim et al.[3]은 초기 와이어의 변형이 웨이퍼의 두께 변동에 영향을 주며, 이는 제조 공정에서 가공 시간과 비용 증가를 초래한다는 점을 분석하였다. 이를 위해 와이어 장력, 와이어 속도, 초기 와이어 편향성, 잉곳 피딩 속도와 같은 변수들을 사용한 실험을 하였다. 이를 통해 웨이퍼의 두께 변화에 영향을 주는 변수를 발견하였고 초기 와이어의 변형을 조정하여 웨이퍼의 두께가 통제 가능하다는 것을 확인하였다.

Kim et al.[4]은 웨이퍼 연삭 공정의 특성상 필연적으로 발생하는 불균일 요소로 인해 웨이퍼 평탄도가 약화되는 것을 보완하는 방법으로 틸팅각 조정을 활용하였다. 웨이퍼 형상을 제어하고 평탄도를 개선하기 위해 틸팅각 변화에 따른 웨이퍼 형상을 임의로 제어하는 형상 시뮬레이션을 개발하였다. 이를 통해 웨이퍼 연삭 과정에서의 최적화 및 품질 향상과 수율 증대에 기여하였다.

Liu et al.[18]은 웨이퍼 뒷면 연삭 공정에서 수율 증대와 품질 관리를 강화하기 위한 효과적인 해결책을 제시하고, 점차 엄격해지는 요구사항을 충족하기 위해 기계 구조 설계와 구성 최적화를 위한 가이드를 제공하였다. 웨이퍼 뒷면 연삭 공정에서의 TTV 제어

이론과 방법에 중점을 두었다. 연삭 기계의 최적 구성 방식 하에서 웨이퍼의 TTV 형상을 얻기 위해 수치적 모델을 수립하였다. 또한 시뮬레이션 모델을 기반으로 웨이퍼 TTV 특징들을 수치화할 수 있었고, 이에 대한 효과를 분석하였다. 이러한 연구 결과는 웨이퍼 두께 균일성을 개선하고 TTV를 $1\mu\text{m}$ 이하로 낮춤으로써, 수율 증대와 품질 관리 요구를 충족시키는 데 기여하였다.

Lee et al.[15]은 사파이어 웨이퍼의 수율 향상을 위해서 플레이트(platen) 형태가 TTV 생성에 미치는 영향을 연구하였다. 웨이퍼와 플레이트 사이의 거리 및 재료 제거율과의 관계를 시뮬레이션하고, 마찰열로 인한 플레이트의 열 변형을 고려하여 TTV를 분석하였다. 실험을 통해 이론적으로 예측된 TTV와 실제 결과가 일치함을 확인하였으며, 이러한 연구는 TTV 생성

메커니즘에 대한 이해를 높이고 웨이퍼 제조 공정의 품질을 개선하는 데 기여하였다.

Ahn and Jung[10]은 반도체 웨이퍼의 표면을 연마하여 평탄화하는 CMP(Chemical Mechanical Planarization) 공정에서 MRR(Material Removal Rate)을 예측하기 위해 머신러닝 기법들을 사용하였다. 구체적으로 시계열 센서 데이터에서 추출한 다양한 통계적 특징들을 기반으로 XGBoost 모델을 사용하여 MRR을 예측하였다. 또한 RuleCOSI 알고리즘을 사용하여 CMP 공정에서 높은 MRR을 달성하기 위해 중요한 변수와 조건을 도출하였다. 이 결과를 통해 CMP 공정에서 높은 MRR을 유지하기 위한 최적의 공정 조건을 제시하였다.


<Table 2>에 선행 연구의 특성을 정리하였다. 선행 연구는 TTV와 관련된 다양한 공정 변수와 영향 요인

<Table 2> Comparison and Analysis of Previous Studies

Author	Purpose	Method	Data
Lee et al. [14]	- Analyze processing factors in single-side lapping - Improve wafer flatness	- Perform single-side lapping experiments. - Adjust and control key process factors	- Substrate temperatures - The rotation speed ratio of the wafer pressing head and substrate - The pressure distribution of the head
Kim et al. [3]	- Investigate initial wire deflection effects on thickness variation	- Conducted experiments to analyze thickness variation. - Parameter control to evaluate effects	- Wire tension - Wire speed - Ingot feeding speed - Initial wire deflection condition
Kim et al. [4]	- Improve wafer flatness and wafer shape predicting using tilting angle	- Develop wafer shape simulation model - Analyze tilting angle effects on TTV	- Wafer speed - Wheel speed - Feed rate - Stock removal
Liu et al. [18]	- Propose TTV control theory and method in wafer back grinding process	- Develop mathematical model for TTV control. - Simulate TTV variations under different process conditions.	- Grinding Wheel - Wheel rotation speed - Chuck table rotation speed - Final feeding speed - Coolant
Lee et al. [15]	- Analyze the effect of platen shape on TTV generation	- Simulated the relationship between platen shape, material removal rate, and TTV	- Slurry - Lapping platen - Slurry flow rate - Rotational speed - Pressure
Ahn and Jung [10]	- Develop predictive MRR model for CMP process	- SVR(Support Vector Regression), XGBoost, RuleCOSI	- Semiconductor CMP process dataset

을 분석하고, 이를 개선하기 위해 방법들을 탐색하였다. 그러나 선행 연구들은 분석에 적은 수의 공정 변수만을 활용하였으며, 여러 제품별 특성을 충분히 반영하지 못하였다. 또한 대부분의 연구에서는 머신러닝 기법을 활용하거나 결과를 비교하여 성능 평가를 진행하지 못하였고, 특히 딥러닝 모델을 사용한 연구는 찾아보기 어려웠다. 반면, 본 연구는 다양한 공정 변수를 독립변수로 설정하고, 제품 특성에 따라 Tilt에 미치는 영향을 분석하였다. 더 나아가 다중선형회귀 모델과 딥러닝 모델을 활용하여 두 모델의 Tilt 추정 결과를 비교 분석한다는 점에서 기존 연구들과의 차이점을 가진다.

<Table 3>과 같은 제품별 공정 데이터를 사용하여 Tilt를 추정할 수 있도록 개발하고 두 모델의 성능을 비교 분석하여 제품별로 적합한 모델을 확인하였다.



<Figure 3> Analysis Process for Multiple Linear Regression and Deep Learning

3. 제안 연구 방법론 및 결과

3.1 전체 분석 프로세스

<Figure 3>은 웨이퍼 기울기 조정을 위해 적절한 Tilt 값을 설정하는 다중선형회귀 모델과 딥러닝 모델의 분석 프로세스를 보여준다. 두 모델 모두


3.2 다중선형회귀 모델(Multiple Linear Regression Model)

<Figure 4>는 다중선형회귀 모델에 대한 세부 프로세스를 도식화한 그림이다. 다중선형회귀 모델의 통계적 유의성을 확보 및 검증하기 위해 독립성 검증, 이상치 탐색, 단계적 변수 선택법, 잔차의 정규성

<Table 3> Description of Variables

Variable Type	Variables Name	Unit	Description
Independent Variable	Min_thickness_first Min_thickness_second	mm	The minimum point-by-point thickness of each PCD in the first or second process
	Max_thickness_first Max_thickness_second	mm	The maximum point-by-point thickness of each PCD in the first or second process
	Avg_thickness_first Avg_thickness_second	mm	The average point-by-point thickness of each PCD in the first or second process
	Min_PCD_deviation_first Min_PCD_deviation_second	mm	Minimum value of point-by-point thickness for each PCD in the first or second process minus point-by-point thickness of PCD 302
	Max_PCD_deviation_first Max_PCD_deviation_second	mm	Maximum value of point-by-point thickness for each PCD in the first or second process minus point-by-point thickness of PCD 302
	Avg_PCD_deviation_first Avg_PCD_deviation_second	mm	Average value of point-by-point thickness for each PCD in the first or second process minus point-by-point thickness of PCD 302
	undulation_first undulation_second	mm	The maximum deviation in wafer thickness (Max_thickness_first - Min_thickenss_first) (Max_thickness_second - Min_thickness_second)
	slope_first slope_second	mm	The slope of the wafer in the first or second process calculated using <formula 1>
	slope_difference	mm	The amount of the slope change (slope_second - slope_first)
Dependent Variable	Tilt	-	The parameter values used in the slope adjustment equipment before performing the second process to meet the wafer slope requirements

검정, 잔차의 등분산성 검정을 수행하였다.



〈Figure 4〉 Detail Process for Multiple Linear Regression

본 연구에서는 가장 먼저 다중공선성과 자기상관을 확인하여 독립성을 검정하였다. 모든 변수를 대상으로 VIF(Variance Inflation Factor) 값을 통해 다중공선성을 확인하였다. 가장 높은 VIF 값을 가진 변수를 단계적으로 제거하여 최종적으로 모든 변수의 VIF 값이 기준치인 10 이하가 되도록 하였다. 이후 선정된 변수들을 대상으로 Durbin-Watson 검정을 사용하여 자기상관을 확인하였다.

검정 결과는 <Table 4>와 같으며, 모든 제품의 자기상관은 귀무가설을 기각할 수 없다고 판단할 수 있는 기준값 2에 근접하여 독립성을 모두 충족함을 확인하였다[7].

다음으로 추정 회귀식으로부터 관측치가 얼마나 떨어져 있는지를 나타내는 표준화 잔차(ZRE, Standardized Residuals)와 영향력 통계량을 나타내는 표준화 DFFIT(Standardized Difference in Fits)를 사용하여 이상치를 확인하였다[16]. 제품별 공정 데이터 중 기준치를 벗어난 데이터는 제거한 후 회귀분석을 시행하였다. 이상치를 제거하여 제품별로 회귀분석에 사용한 데이터의 수는 제품 A는 3,086개에서 77개를 제거하여 3,009개, 제품 B는 2,516개에서 68개를 제거하여 2,448개, 제품 C는 487개에서 3개를 제거하여 484개, 제품 D는 2,656개에서 102개를 제거하여 2,554개로 감소하였다.

이후 다중선형회귀 모델에서 종속변수를 가장 잘 설명할 수 있는 독립변수 조합을 탐색하기 위해 단계적 변수 선택법(Stepwise Variable Selection)을 적용하였다. 변수 선택의 기준이 되는 지표는 일반적으로 선형모형에서 독립변수를 선택할 때 유용하게 사용되는 AIC(Akaike Information Criterion)를 사용

〈Table 4〉 VIF Values and Autocorrelation Results

Product Type	Variables	VIF	Auto correlation
A	undulation_first	3.04	1.94
	Min_PCD_deviation_first	2.63	
	Max_PCD_deviation_first	1.32	
	undulation_second	4.63	
	Min_PCD_deviation_second	3.7	
	Max_PCD_deviation_second	1.04	
B	Min_PCD_deviation_first	3.19	1.98
	Max_PCD_deviation_first	1.08	
	undulation_second	3.36	
	Min_PCD_deviation_second	2.12	
	Max_PCD_deviation_second	1.51	
C	undulation_first	5.97	2.06
	Min_PCD_deviation_first	4.66	
	Max_PCD_deviation_first	1.2	
	undulation_second	3.63	
	Min_PCD_deviation_second	1.96	
	Max_PCD_deviation_second	1.16	
D	undulation_first	3.44	1.98
	Min_PCD_deviation_first	3.02	
	Max_PCD_deviation_first	1.22	
	undulation_second	4.3	
	Min_PCD_deviation_second	2.71	
	Max_PCD_deviation_second	1.27	

하여 적은 수의 변수로 높은 설명력을 가지는 변수 조합을 탐색하였으며, 식 (2)와 같이 계산하였다[12]. 변수 선택 결과는 <Table 5>와 같이 나타났음을 확인하였다.

$$AIC = -2\ln(L) + 2k \quad (2)$$

L : Maximum Likelihood

$\ln(L)$: Natural logarithm of the maximum likelihood

k : The number of model parameters, representing model complexity

〈Table 5〉 Stepwise Variable Selection Process

Product Type	Variables	AIC
A	Min_PCD_deviation_first	10325.33
	Max_PCD_deviation_first	
	Min_PCD_deviation_second	
B	Min_PCD_deviation_first	8442.48
	Max_PCD_deviation_first	
C	Min_PCD_deviation_first	1661.19
	Max_PCD_deviation_first	
	Min_PCD_deviation_second	
D	Min_PCD_deviation_first	8854.25
	Max_PCD_deviation_first	

〈Table 6〉은 제품별 다중선형회귀 분석에 의한 종속변수 Tilt의 추정 결과를 나타낸 것이다. 제품 A의 Min_PCD_deviation_first의 표준화 계수(Standardized Coefficient, β)는 -0.8477로 나타나 종속변수에 가장 큰 영향을 미치는 변수임을 보여준다. 특히 Min_PCD_deviation_first는 모든 제품에서 표준화 계수가 가장 높은 것으로 나타났다. 이는 종속변수에 가장 큰 영향을 미치는 주요 변수임을 나

타낸다. 추가적으로 제품 C의 경우 Max_PCD_deviation_first의 비표준화 계수(Coefficient, B)의 절댓값이 제일 큰 것을 볼 수 있지만, 표준화 계수의 절댓값 크기는 그렇지 않은 것을 볼 수 있다. 반면 제품 A, B, D의 경우 비표준화 계수와 표준화 계수의 절댓값 크기가 가장 큰 변수는 동일한 것을 볼 수 있다. 이는 제품 C에서 Max_PCD_deviation_first 값의 범위가 넓어 비표준화 계수의 값이 크지만, 표준화 후에는 영향력이 감소한 것으로 보이기에 변수 간 스케일 차이가 크다고 판단할 수 있다. 반면 제품 A, B, D에서는 변수 간 스케일 차이가 크지 않거나, 해당 변수들이 Tilt에 미치는 실제 영향력이 일관되게 나타난 결과로 해석된다.

모든 제품에서 각 독립변수의 p-value의 경우, 절편을 제외한 모든 변수에서 0.05보다 작은 값을 가지고 있으며, 이는 모든 독립변수가 종속변수에 유의한 영향을 미치는 것을 의미한다. 또한 t-statistic의 경우, 제품별로 표준화 계수가 가장 큰 변수의 t-statistic 절댓값이 가장 커 독립변수와 종속변수 간의 관계가 통계적으로 유의미함을 보여준다.

3,009개로 가장 많은 데이터를 가진 제품 A의 R^2

〈Table 6〉 Result of Multiple Linear Regression Model


Product Type	Variables	Coefficient (B)	Standardized Coefficient (β)	t-statistic	R^2	Adjusted R^2	RMSE
A	Min_PCD_deviation_first	-6592.8964*	-0.8477	-313.3535	0.9841	0.9841	2.801
	Max_PCD_deviation_first	-6579.1525*	-0.2643	-94.5248			
	Min_PCD_deviation_second	517.4946*	0.0295	15.0941			
	Intercept	16.0786	-	0.3298			
B	Min_PCD_deviation_first	-5131.4821*	-0.9911	-882.0181	0.9847	0.9847	2.880
	Max_PCD_deviation_first	-4064.1644*	-0.0065	-2.1759			
	Intercept	-7.9491	-	-0.0042			
C	Min_PCD_deviation_first	-6629.2189*	-0.9396	-129.2946	0.9591	0.9587	2.958
	Max_PCD_deviation_first	-6767.3025*	-0.0998	-9.148			
	Min_PCD_deviation_second	661.9260*	0.0604	6.2432			
	Intercept	20.3745	-	0.1665			
D	Min_PCD_deviation_first	-6935.3322*	-0.8953	-512.3882	0.9815	0.9815	2.915
	Max_PCD_deviation_first	-6719.5096*	-0.1945	-62.4407			
	Intercept	14.5186	-	0.1191			

*p-value < 0.05.

와 RMSE(Root Mean Square Error)는 모든 제품 중 상대적으로 좋은 결과를 나타냈으며, 484개로 가장 적은 데이터를 가진 제품 C는 가장 좋지 않은 결과를 나타냈다. 이는 제품별 데이터 수에 따라 모델의 성능에 차이가 발생한다는 것을 나타낸다. 또한 제품 B와 D의 데이터 수는 각각 2,448개와 2,554개로 비슷하지만, 사용되는 PCD 구간은 9개와 7개로 차이가 있다. 측정 구간이 많은 제품 B는 제품 D보다 R^2 와 RMSE 측면에서 더 좋은 결과를 나타냈다. 이는 웨이퍼를 더욱 구체적으로 나타낼 수 있도록 데이터를 수집하는 것이 중요하다고 판단할 수 있다.

3.3 딥러닝 모델(Deep Learning Model)

딥러닝(Deep Learning)은 데이터로부터 특징을 학습하고, 고차원 데이터에서 다층의 비선형 구조를 반영하는 특징을 가지고 있다[23]. 따라서 본 연구에서는 딥러닝 모델을 통해 다중선형회귀 모델에서 알기 어려운 데이터의 비선형적 특징들을 파악하여 Tilt 값을 추정하였다. 다만 딥러닝 모델은 사용자에게 내부 의사결정 과정을 설명하지 않는 블랙박스(black box)의 성질을 가지기에, 모델 결과만으로는 종속변수들이 Tilt에 미치는 영향력을 파악하기 어렵다[5]. 이에 본 연구에서는 딥러닝 모델의 설명 가능성을 확보하기 위해 XAI(Explainable Artificial Intelligence) 기법 중 독립변수들이 서로 영향을 미칠 가능성을 고려하면서 예측값에 미치는 영향을 정량적으로 분석할 수 있는 SHAP(SHapley Additive exPlanations)를 적용하였다[20, 9, 13].



<Figure 5> Deep Learning Model for Product B

딥러닝 모델은 17개의 독립변수를 모두 입력 변수로 사용하여 학습하였으며, 종속변수인 Tilt를 추정하도록 모델을 구성하였다. 심층 신경망(Deep Neural Network)을 기반으로 한 딥러닝 모델을 구

축한 후, 제품별로 최적의 학습 성능을 달성하기 위해 다양한 하이퍼파라미터를 조정하였다. 대표적으로 제품 B의 모델 구조는 <Figure 5>와 같으며, 512개, 256개, 128개, 64개, 32개, 16개, 8개 노드를 사용하는 7개 은닉 레이어와 출력 레이어로 구성하였다. 이러한 제품별 맞춤형 설정을 통해 딥러닝 모델의 정확도와 학습 효율성을 향상시킬 수 있었다.

딥러닝 모델의 성능 평가는 기존의 다중 선형회귀 모델과 동일하게 RMSE, R^2 , 그리고 Adjusted R^2 을 사용하여 모델 간 비교가 가능하도록 하였다. 또한 Train Loss와 Test Loss를 통해 모델이 학습되지 않은 데이터에 대해 얼마나 일반화가 잘 되었는지 판단할 수 있도록 하였다.

<Table 7> Result of Deep Learning Model

Product Type	Train Loss	Test Loss	RMSE	R^2	Adjusted R^2
A	8.5134	7.4749	2.734	0.9858	0.9858
B	10.167	8.5611	2.926	0.9850	0.9849
C	9.3986	7.4676	2.733	0.9626	0.9624
D	8.8339	8.5611	2.926	0.9817	0.9817

<Table 7>은 제품별 딥러닝 모델의 결과를 나타낸다. 모든 제품에서 R^2 와 Adjusted R^2 의 차이는 거의 없는 것으로 나타나, 모델이 전반적으로 잘 학습되었음을 확인할 수 있다. 그러나 Train Loss와 Test Loss의 차이를 분석한 결과, 제품별로 과적합 여부에 차이가 있을 가능성이 있음을 확인할 수 있었다. 제품 C는 Train Loss와 Test Loss의 차이가 1.931로 가장 크며, 이는 학습 데이터에 과적합 되었을 가능성을 나타낸다. 반면, 제품 D는 Loss의 차이가 0.2728로 가장 작아 과적합 가능성이 낮으며, 테스트 데이터에서도 안정적인 성능을 유지하고 있음을 보여준다.

또한 가장 많은 데이터를 가지는 제품 A는 Train Loss와 Test Loss의 차이가 1.0385로 상대적으로 낮은 편에 속하며, R^2 값이 가장 높게 나타났다. 반면, 가장 적은 데이터를 가지는 제품 C는 Loss의 차이가 가장 크며, R^2 값이 가장 작기에 과적합 가능성이 가장 높다고 볼 수 있다. 이는 데이터의 양이 충분하지

않을 경우, 모델이 데이터의 세부 패턴에 과적합될 가능성이 높아질 수 있음을 나타낸다.

추가적으로 제품 B와 D는 데이터 수가 비슷함에도 불구하고 제품 B의 R^2 값이 더 높게 나타났다. 하지만 Train Loss와 Test Loss의 차이가 제품 B에서는 1.6059로 상대적으로 크게 나타난 반면, 제품 D에서는 가장 작게 나타났다. 이는 제품 B의 학습 데이터의 패턴이 더 복잡했거나, 모델이 학습 데이터에 지나치게 최적화되었을 가능성을 나타낸다.


또한 PCD 구간의 수가 6개인 제품 A와 9개인 제품 B를 비교하고, 제품 A와 PCD 구간의 수가 7개인 제품 D를 비교할 때 측정 구간이 제일 낮은 제품 A의 R^2 가 더 높고 RMSE는 더 낮음을 확인할 수 있다. 반면, 제품 B와 제품 D 사이에는 PCD 구간의 수가 더 많은 제품 B의 R^2 가 더 높은 것을 알 수 있다. 이는 PCD 구간의 수가 무조건 많다고 좋은 결과를 나타내는 것은 아니며 제품별로 요구사항을 적절히 반영할 수 있는 PCD 구간을 사용하는 것이 적절하다고 판단할 수 있다.

<Figure 6>은 SHAP 분석 결과를 beeswarm plot 형태로 시각화한 것이다. beeswarm plot의 x축은 특정 변수의 유무에 따른 예측값의 변화를 통해 계산할 수 있는 SHAP value를 나타내며, 독립변수가 예측값에 미친 영향의 크기와 방향(양/음)을 알 수 있다[11]. y축은 독립변수를 평균 절댓값 SHAP value 기준으로 나열한 것이다. 또한 그래프 위의 점은 각 입력 데이터의 SHAP value를 나타내

며, 점의 색상은 독립변수의 범위에 맞춰 정규화되어 높은 값은 빨간색, 낮은 값은 파란색으로 표시된다[21]. 이를 통해 딥러닝 모델의 설명 가능성을 높이고, 제품별로 각 독립변수가 Tilt 값에 미치는 영향력을 파악하였다.

분석 결과, 모든 제품에서 slope_first, slope_difference가 공통적으로 가장 높은 영향력을 보였다. 제품 A에서는 slope_first가 가장 영향력 있는 것으로 나타났으며, 제품 B, C, D에서는 slope_difference가 가장 영향력 있는 것으로 확인되었다. 또한 deviation과 관련된 변수(Min_PCD_deviation_first, Avg_PCD_deviation_first, Avg_PCD_deviation_second) 역시 모든 제품에서 높은 영향력을 보였다. 이러한 변수들이 주요 변수로 도출된 이유는 다음과 같이 해석할 수 있다. slope_first는 2차 공정에서의 기울기 조정을 위해 1차 공정 이후 Tilt를 설정할 때 활용되기 때문이라고 판단되며, slope_difference는 1차 공정과 2차 공정 사이의 기울기 변화를 나타내기 위해, Tilt 값 설정을 통한 웨이퍼 기울기 조정 과정에서 의도한 대로 조정되었는지 측정할 수 있기 때문이라고 해석된다. 또한 deviation 관련 변수들은 웨이퍼 기울기를 계산하는 과정에서 직간접적으로 활용되므로 주요 변수로 선택된 것으로 판단된다. 이러한 결과는 해당 변수들이 제품별 웨이퍼 기울기 조정에서 일관되게 중요한 역할을 하고 있음을 나타낸다.

한편, Max_PCD_deviation_first는 제품별 영향력에 차이를 보였다. 제품 A에서는 6위, 제품 D에서



<Figure 6> SHAP(SHapley Additive exPlanations) Beeswarm Plot Results for Each Product

는 8위로 나타났으나, 제품 B와 제품 C에서는 각각 15위, 9위로 비교적 낮은 영향력을 보였다. 이는 Tilt에 대한 특정 변수의 영향력이 PCD 구간 수 혹은 웨이퍼 두께와 같은 제품별 특성과 요구사항에 따라 달라질 수 있음을 나타내며, 정밀한 웨이퍼 기율기 조정을 위해서는 제품별 맞춤형 접근이 필요하다고 판단할 수 있다.

또한 모든 제품에서 slope_difference는 값이 커질수록 Tilt에 양의 방향으로의 기여를 보인 반면, 대부분의 다른 변수들은 값이 작아질수록 Tilt에 양의 영향을 보였다. 이는 1차 공정 이후 높은 Tilt 값을 적용하면 웨이퍼는 큰 각도로 연삭되어 2차 공정 이후 웨이퍼 기율기 차이가 커지게 되므로 공정 간 기율기 변화량을 나타내는 slope_difference 값이 증가하는 것으로 해석할 수 있다. 반면 slope 및 deviation 관련 변수들은 값이 작아질수록 웨이퍼의 두께 편차가 작아지거나 평탄도가 높아지기에 웨이퍼의 기율기 조정을 위해 높은 Tilt 값이 적용된 것으로 해석할 수 있다.

3.4 다중선형회귀 모델과 딥러닝 모델의 비교

<Table 8>은 다중선형회귀 모델과 딥러닝 모델에서 주요 변수의 영향력 순위를 제품별로 비교한 표이다. 다중선형회귀 모델은 표준화 계수를 기준으로, 딥러닝 모델은 SHAP 분석 결과를 기준으로 순위를 도출하였다. 두 모델을 비교한 결과, Tilt 값에 영향을 미치는 주요 변수들에서 크게 세 가지의 특징을 확인하였다.

첫 번째로, 두 모델에서 공통적으로 도출된 주요 변수 중 가장 영향력 있는 변수인 Min_PCD_deviation_first의 영향력 방향성은 동일하였다. 다중선형회귀 모델의 경우 음(-)의 표준화 계수를 가지며, SHAP 분석에서는 값이 작을수록 Tilt에 양(+)의 영향을 주는 것으로 나타났다. 이는 두 모델 모두 해당 변수의 값이 작을수록 Tilt 값이 더 높아진다는 점에서 일치하였다.

두 번째로, 모델의 특징에 따라 도출되는 주요 변

<Table 8> Comparison of Key Variable Influence Rankings between Multi Linear Regression and Deep Learning Models by Product

Product Type	Variables	Multi Linear Regression Model	Deep Learning Model
		Rank	Rank
A	slope_first	-	1
	slope_difference	-	2
	Min_PCD_deviation_first	1	3
	Avg_PCD_deviation_second	-	4
	Avg_PCD_deviation_first	-	5
	Max_PCD_deviation_first	2	6
B	Min_PCD_deviation_second	3	8
	slope_difference	-	1
	slope_first	-	2
	Min_PCD_deviation_first	1	3
	Avg_PCD_deviation_first	-	4
C	Avg_PCD_deviation_second	-	5
	Max_PCD_deviation_first	2	15
	slope_difference	-	1
	slope_first	-	2
	Min_PCD_deviation_first	1	3
	Avg_PCD_deviation_second	-	4
D	Avg_PCD_deviation_first	-	5
	Min_PCD_deviation_second	3	7
	Max_PCD_deviation_first	2	9
	slope_difference	-	1
	slope_first	-	2
	Min_PCD_deviation_first	1	3
E	Avg_PCD_deviation_first	-	4
	Avg_PCD_deviation_second	-	5
	Max_PCD_deviation_first	2	8
	Min_PCD_deviation_second	3	7

<Table 9> Performance comparison of Multiple Linear Regression and Deep Learning models across products
 Bold* values indicate the best performance for each metric(RMSE, R^2 , Adjusted R^2)

Product Type	Multiple Linear Regression Model			Deep Learning Model		
	RMSE	R^2	Adjusted R^2	RMSE	R^2	Adjusted R^2
A	2.801	0.9841	0.9841	2.734*	0.9858*	0.9858*
B	2.880*	0.9847	0.9847	2.926	0.9850*	0.9849*
C	2.958	0.9591	0.9587	2.733*	0.9626*	0.9624*
D	2.915*	0.9815	0.9815	2.926	0.9817*	0.9817*

수와 영향력에 차이가 있었다. 다중선형회귀 모델에서 다중공선성 문제로 인해 사용되지 않은 변수 slope_first , slope_difference 는 딥러닝 모델에서 1~2위로 높은 영향력을 보였다. 또한 $\text{Min_PCD_deviation_first}$ 의 경우 모든 제품에서의 영향력 순위는 다중선형회귀 모델은 1순위, 딥러닝 모델은 3순위로 평가되었다. 이러한 차이는 선형성, 비선형성 관계와 변수 간 상호작용에 대한 두 모델의 구조적 특징에 의한 것으로 판단된다.

세 번째로, $\text{Max_PCD_deviation_first}$ 는 제품별로 유사한 영향력 차이를 보였다. 다중선형회귀 모델에서는 $\text{Max_PCD_deviation_first}$ 의 표준화 계수의 절댓값이 제품 A에서 0.8477로, 가장 컸고, 그 뒤로 제품 D, C, B 순으로 나타났다. 딥러닝 모델의 SHAP 분석 결과 $\text{Max_PCD_deviation_first}$ 의 영향력 순위는 제품 A에서 6위, 제품 D에서 8위, 제품 C에서 9위, 제품 B에서 15위로, 두 모델 모두 동일한 순서로 변수의 영향력을 평가하였다. 이러한 결과는 두 모델이 서로 다른 분석 방법임에도 불구하고, 제품별 변수의 상대적 영향력을 비슷하게 평가했음을 보여준다.

또한 <Table 9>는 다중선형회귀 모델과 딥러닝 모델의 성능 비교를 요약한 것이다. 다중선형회귀 모델과 딥러닝 모델 중 RMSE의 경우 가장 낮은 값, R^2 와 Adjusted R^2 의 경우 가장 높은 값을 굵은 글씨로 표시하였다.

R^2 와 Adjusted R^2 의 경우 딥러닝 모델이 모든 제품에서 가장 높은 설명력을 나타냈다. 이는 딥러닝 모델이 종속변수와 독립변수 간의 비선형 관계를 효과적으로 학습할 수 있음을 보여준다. 또한 RMSE

의 경우 제품 A, C는 다중선형회귀 모델과 비교하여 딥러닝 모델에서 더 낮은 RMSE 값을 기록하였으나, 제품 B, D에서는 그렇지 못했음을 확인할 수 있다. 이러한 결과는 일부 제품에서 상대적으로 선형적 특성이 더 반영될 가능성을 나타내며, 특정 제품에서는 딥러닝 모델보다 다중선형회귀 모델이 더 적합할 수 있음을 나타낸다.

추가적으로 데이터 수가 가장 적은 제품 C의 경우 RMSE가 다중선형회귀 모델에서는 가장 높았으며, 딥러닝 모델에서는 가장 낮은 것을 확인할 수 있다. 이는 딥러닝 모델이 다중선형회귀 모델에 비해 제품의 데이터의 수, 비선형성을 더 효과적으로 학습할 수 있다는 가능성을 나타낸다. 이를 통해 데이터의 크기와 특성을 고려하여 모델을 선택해 분석하는 것이 중요한 요소임을 나타낸다고 판단할 수 있다.

4. 실험 결과 고찰

본 연구의 실험 결과에서 확인할 수 있었던 주요한 사항은 크게 세 가지로 요약될 수 있다. 첫 번째로 제품 특성에 따라 종속변수에 영향을 주는 주요 요인들이 다르다는 점이다. 다중선형회귀 모델에 최종적으로 사용된 변수 조합은 제품 A와 C, 제품 B와 D가 각각 동일하게 나타났으나, 제품 A, C와 제품 B, D 간에는 변수 조합의 차이가 존재하였다. 표준화 계수를 비교한 결과, $\text{Min_PCD_deviation_first}$ 는 모든 제품에서 가장 높은 영향력을 보이는 변수로, 모든 제품에서 공통으로 드러나는 주요 요인이 존재한다는 것을 확인하였으나, 표준화 계수의 값은 제품별로 모두 상이하게 나타난 것을 확인하였다. 또한 딥러닝

모델의 SHAP 분석 결과, 변수의 영향력 순위는 slope_first의 경우 제품 A에서 가장 중요한 변수로 나타난 반면, slope_difference는 제품 B, C, D에서 가장 중요한 변수로 도출되었다. 이를 통해 제품의 특징에 따라 독립변수들의 영향력에 차이가 발생할 수 있음을 확인할 수 있었다.

두 번째로 제품별로 적합한 데이터를 사용하는 것이 필요하다는 점이다. 데이터 수에 큰 차이가 없는 제품 B와 D의 경우 다중선형회귀 모델과 딥러닝 모델에서 PCD 구간이 더 많은 제품 B의 성능이 더 좋았음을 확인하였다. 반면 딥러닝 모델에서 PCD 구간이 가장 적은 제품 A가 제품 B, D에 비해 성능이 더 좋았음을 확인하였다. 이는 제품별로 요구사항에 따른 종속변수를 더 잘 표현할 수 있는 PCD 구간의 수가 존재함을 나타내며, 적합한 데이터의 수집 및 사용이 중요하다는 것을 나타낸다.

세 번째로 제품별로 적합한 모델을 사용하는 것이 필요하다는 점이다. 본 연구에서는 제품별로 좋은 결과를 나타내는 모델이 서로 달랐다. 딥러닝 모델이 모든 제품에서 R^2 및 Adjusted R^2 가 더 높았으며, RMSE는 제품 A, C는 딥러닝 모델, 제품 B, D는 다중선형회귀 모델에서 더 낮게 나타났다. 특히 데이터 수가 제일 적은 제품 C는 딥러닝 모델에서 RMSE가 가장 낮았지만, 다중선형회귀 모델에서는 가장 높았음을 확인하였다. 또한 모델마다 변수 간 관계를 해석하는 방식이 다르기에, 다양한 모델을 활용함으로써 공통적으로 영향력이 있다고 도출되는 변수를 확인할 수 있었다. 특히, Min_PCD_deviation_first의 영향력 순위는 다중선형회귀 모델과 딥러닝 모델에서 각각 1순위, 3순위로 나타나 상대적으로 중요한 변수임을 확인하였다. 이와 더불어, 특정 모델에서는 확인하기 어려운 변수들도 다른 모델에서는 주요 변수로 도출될 수 있음을 확인하였다. 예를 들어 slope_first, slope_difference는 다중회귀모델에서 다중공선성 문제로 인해 배제되었지만, 딥러닝 모델에서는 중요한 변수로 확인되었다. 따라서 Tilt를 효과적으로 추정하기 위해서는 제품별로 데이터의 크기와 변수 간 다중공선성 여부, 선형적 특성을 고려

하여 적합한 모델을 탐색 및 선택하는 것이 필요하다는 것을 확인할 수 있었다.

5. 결 론

본 연구는 웨이퍼 공정에서 기울기에 대한 요구사항이 있을 때, 이를 효과적으로 만족시켜 수율을 향상시키기 위해 고려해야 하는 요인들을 탐색하였으며, 종속변수를 Tilt로 설정하여 적절한 Tilt 값을 추정하기 위해 다중선형회귀 모델과 딥러닝 모델을 구성하여 각 모델의 성능을 비교 분석하였다. 분석 결과 제품 특성에 따라 종속변수에 영향을 주는 요인이 다르게 나타났으며, 적절한 데이터와 모델을 사용하는 것이 필요하다는 것을 확인하였다.

본 연구의 의의는 수요 맞춤형 웨이퍼의 품질 관리에 대한 데이터 활용 방안을 다각적으로 살펴본 것에 있다. 특히 웨이퍼 기울기에 영향을 미칠 수 있는 다양한 공정 변수들을 체계적으로 분석하고, 다중선형회귀 모델 및 딥러닝 모델을 병행하여 활용하였다. 이를 통해 정량적 분석을 통한 주요 요인 선정과 Tilt 추정이 가능해져, 고객의 요구사항을 충족시키는 웨이퍼 기울기 조정을 효과적으로 수행할 수 있다. 이는 웨이퍼 제조 불량을 감소시켜 수율 향상에 기여할 수 있을 것으로 기대된다.

더 나아가, 고객의 요구사항을 충족시키는 실질적인 사례를 제공할 수 있으며, 향후 유사한 공정 설계 및 개선 연구에 있어 활용 가능한 기초 데이터를 제공할 수 있을 것으로 기대된다.

참 고 문 헌

- [1] 고관주, 김나연, 김용수(2019), “전력반도체의 수율향상을 위한 최적 공정조건 결정에 관한 연구,” 품질경영학회지, 47(4), 725-737.
- [2] 김경진, 박종운(2014), “실리콘 웨이퍼 연마헤드의 강제구동 방식이 웨이퍼 연마 평탄도에 미치는 영향 연구,” 반도체디스플레이기술학회지, 13(1), 13-17.

- [3] 김도연, 김형재, 이상직, 정해도(2015), "Effect of initial deflection of diamond wire on thickness variation of sapphire wafer in multi-wire saw," *International Journal of Precision Engineering and Manufacturing-Green Technology*, 2(2), 117-121.
- [4] 김상철, 이상직, 정해도, 이석우, 최현중(2003), "실리콘 웨이퍼 연삭의 평탄도 특성 평가," *대한기계학회 춘추학술대회*, 2003.11, 151-156.
- [5] 김성훈, 김우진, 장연주, 김현철(2021), "설명 가능한 AI 학습 지원 시스템 개발," *컴퓨터교육학회 논문지*, 24(1), 107-115.
- [6] 김주영, 김광재(2022), "관측치 간 공간적 유사성과 변수의 상관관계를 고려한 반도체 웨이퍼 테스트 데이터의 결측치 대체 방법 개발," *대한산업공학회 추계학술대회 논문집*, 인천, 2022. 11.04., 1108-1115.
- [7] 민인식(2009), "선형회귀모형과 관련된 가설검정(2)," *The Korean Journal of Stata (KJS)*, 2(1), 11-18.
- [8] 박민형, 신승준(2022), "불량 웨이퍼 탐지를 위한 함수형 부정 탐지 지지 벡터기계," *응용통계연구*, 35(5), 593-601.
- [9] 안재현(2020), XAI 설명 가능한 인공지능, 인공지능을 해부하다, 위키북스, 파주.
- [10] 안정연, 정재운(2019), "머신러닝을 이용한 반도체 웨이퍼 평탄화 공정품질 예측 및 해석 모형 개발," *한국빅데이터학회학회지*, 4(2), 61-71.
- [11] 윤연아, 이승훈, 김용수(2021), "SHAP를 활용한 중요변수 파악 및 선택에 따른 잔여유효수명 예측 성능 변동에 대한 연구," *한국산업경영시스템학회지*, 44(4), 1-11.
- [12] 이용희(2014), "교차실험에서 AIC를 이용한 혼합모형 선택법의 비교," *Journal of The Korean Data Analysis Society*, 16(1), 155-163.
- [13] 이재준, 이유린, 임도현, 안현철(2021), "XGBoost와 SHAP 기법을 활용한 근로자 이직 예측에 관한 연구," *정보시스템연구*, 30(4), 21-42.
- [14] 이태경, 김형재, 이상직, 김도연, 박철진, 정해도(2012), "웨이퍼 평탄도 향상을 위한 단면래핑 공정 인자 제어," *한국정밀공학회 학술발표대회 논문집*, 제주, 2012.05.30., 149-150.
- [15] 이태경, 정해도, 김형재, 이상직, 김도연(2016), "Effect of platen shape on evolution of total thickness variation in single-sided lapping of sapphire wafer," *International Journal of Precision Engineering and Manufacturing-Green Technology*, 3(3), 225-229.
- [16] 황신범, 김상호, 이창희(2019), "지방하천시설물에 대한 손실함수 개발에 관한 연구," *한국방재학회논문집*, 19(6), 187-205.
- [17] Brett, B., Sanjiv, A., Nicolas, R., Khalid, S., Laurence, N., Jerome, B., Ramya, K. P., Sroddha, P., and Subrahmanyam, K.V.J (2025), "The semiconductor industry in the AI era," *Capgemini*, 2025.01.07. (<https://www.capgemini.com/insights/research-library/semi-conductors/>).
- [18] Li, G., Xiao, C., Zhang, S., Sun, R., and Wu, Y.(2022), "An experimental investigation of silicon wafer thinning by sequentially using constant-pressure diamond grinding and fixed-abrasive chemical mechanical polishing," *Journal of Materials Processing Technology*, 301, 117453.
- [19] Liu, Y., Tao, H., Zhao, D., and Lu, X.(2022), "An investigation on the total thickness variation control and optimization in the wafer backside grinding process," *Materials*, 15(12), 4230.
- [20] Lundberg, S.M. and Lee, S. I. (2017), "A unified approach to interpreting model predictions," *Advances in Neural Information Processing Systems*, 30.
- [21] Ponce-Bobadilla, A.V., Schmitt, V., Maier, C.S., Mensing, S., and Stodtmann, S.(2024),

- “Practical guide to SHAP analysis: Explaining supervised machine learning model predictions in drug development,” Clin Transl Sci, 17(11), e70056.
- [22] Sunanda, G.(2023), “Semiconductor Foundry Market Size, Share, Growth & Industry Analysis, By Technology Node (7nm and below, 10nm-20nm, 20nm-45nm, 45nm and above), By Foundry (Pure Play Foundry, IDMs), By Application (Telecommunication, Automotive, Consumer Electronics & Others), and Regional Analysis, 2024-2031,” Kings Research, 2024.09.(<https://www.kingsresearch.com/semiconductor-foundry-market-1089>).
- [23] Yann, L., Yoshua, B., and Geoffrey, H.(2015), “Deep learning,” nature, 521(7553), 436-444.