

반도체 설비 예방 정비 복구 시간 단축을 위한 설정 값 예측 연구

이진경¹, 임희석¹¹ 고려대학교 컴퓨터정보통신대학원somnium89@korea.ac.kr, limhseok@korea.ac.kr

A Study on the Prediction of Setpoint Value for Preventive Maintenance Time Reduction of Semiconductor Equipment

Jin-Kyeong Lee¹, HeuiSeok Lim¹¹Graduate School of Computer & Information Technology, Korea University

요 약

반도체 제조업은 정해진 시간 내에 최고의 품질의 반도체를 대량 생산해 내는 것을 목표로 한다. 생산량을 높이기 위해 유휴 시간을 최소화하는 연구가 꾸준히 진행 중이며 가장 대표적인 유휴 시간은 예방 정비이다. 예방 정비는 설비의 문제가 발생하기 전 예방하는 작업으로 품질 향상에 높은 영향을 미치는 작업인 반면 생산량이 크게 떨어지는 작업이다. 이 작업 시간을 최소화하기 위하여 작업 후 복구되는 시간에서 중복되는 작업을 최소화하는 방법을 선택한다. 샘플 테스트를 반복하며 조율해 나가던 작업을 연구 모델을 이용해 종말점 설정 값의 예측한 값을 바로 적용하여 최소한의 샘플 테스트를 거쳐 신뢰 구간 달성 후 생산에 재 합류하는 것을 목표로 한다. 설비에서 수집된 데이터를 학습하여 종말점 설정 값 예측 모델에 대하여 연구한다. 연구 모델을 사용한 예측 결과가 신뢰 구간에 포함되어 샘플 테스트 개수를 줄이는데 유효한 효과가 있음을 확인한다.

1. 서론

최근 인공지능, 데이터 마이닝 기법들이 제조업에 도입되는 스마트 팩토리(Smart Factory) 사례가 크게 증가하고 있다. 이러한 빅데이터 시대에 맞춰 반도체 산업의 자동화 기술이 더욱 고도화되며 품질 향상과 더불어 생산량, 생산 속도가 크게 증가하고 있다. 반도체 제조는 웨이퍼(Wafer) 제조, 산화, 포토, 식각, 증착 및 이온 주입, 금속 배선, 웨이퍼 자동 선별, 패키징 등의 크게 8 대 공정으로 나누어지며 여러 번의 공정 반복으로 생산되어진다. 빅데이터가 반도체 제조업에 적용하게 된 것은 정해진 시간 내에 최고의 품질의 반도체를 대량 생산해 내는 것을 목표로 한다. 초 단위의 공정 시간을 줄이고 그것이 반복되어 생산량이 증가하는 것을 궁극적 목표로 하고 있다.

생산량의 증가를 위한 시간 단축은 크게 두가지로 나눌 수 있다. 첫째, 공정 시간 자체를 단축시키는 레시피(Recipe)를 적용하는 방법이 있다. 하지만 이 방법은 공정 엔지니어의 기술을 바탕으로 하고 있으며 이미 최적의 시간을 가지고 있다고 가정한다. 두번째

로 반도체 설비의 유휴 시간(Idle Time)을 줄이는 방법이 있다. 대표적으로 설비의 노후화된 부품의 수명을 예측해 미리 정리하여 문제를 사전에 예방하는 [1] 예방 정비(Preventive Maintenance; PM)에 많은 시간을 소비하고 있어 이와 관련된 시간 단축 시 큰 효과를 가지고 올 수 있다. 예방 정비 이후 샘플 테스트를 거쳐 평가 지표가 신뢰 구간에 도달하여야 생산에 재 합류할 수 있다. 이 과정에서 빠르게 신뢰 구간에 도달하도록 설정 값을 미리 예측 후 해당 값을 적용하여 생산 합류 시간을 단축시키는 것을 목표로 한다.

본 논문은 샘플 테스트의 빠르게 통과하는 방법을 제안하여 시간을 단축하고 생산량을 증가시키는 방법에 대해 제시한다. 8 대 공정 중 식각(Etch) 공정 설비에 대하여 해당 방법을 연구한다.

2. 관련 연구

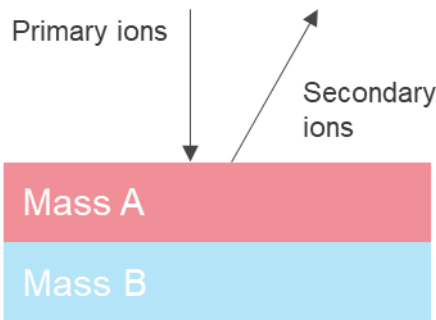
2.1 식각(Etch) 공정

식각 공정은 회로 패턴이 그려진 감광막(Photo Resist; PR)을 제외한 나머지 부분을 제거하는 과정이


다. 패턴을 만들 타겟(Target) 막을 충분히 깎아내지 못할 경우(Under Etch) 이온 주입 시 불순물 입자들이 막혀 제대로 주입이 되지 못한다. 반대로 막을 과다하게 깎게 될 경우(Over Etch) 하부 막질에 물리적 손상이 생기게 된다.

막을 같은 시간동안 식각 하더라도 플라즈마 이온 가스양에 의해 그 양이 달라지게 된다. 따라서 식각의 종료 기준을 시간으로 설정하는 것은 부정확하다.

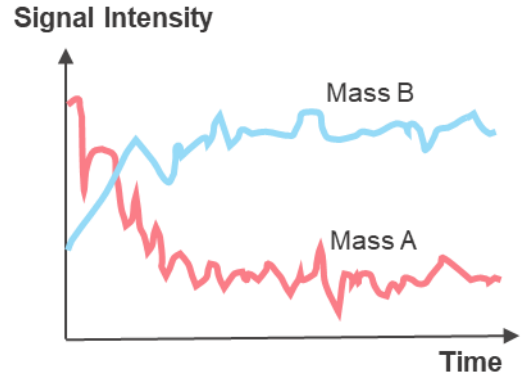
[2] 식각의 종말점(End Point)은 막이 바뀌는 시점으로 물질의 파장을 이용해 모니터링 하는 방법(End Point Detection; EPD)이 있다. (그림 1)은 식각이 진행되지 않은 상태로 Mass A의 파장이 방출되어 나온다. (그림 2)는 Mass A를 식각 하기 전의 상태로 Mass A 다음 층인 Mass B의 파장이 방출되어 나온다. 이때의 신호 강도(Signal Intensity)를 시간의 흐름에 따라 나타낸 그래프가 (그림 3)이다. Mass A와 Mass B의 신호 강도가 교차되는 지점이 물질의 층이 바뀌는 시점으로 이 값을 참고하여 식각의 최적의 시점을 계산한다.



(그림 1) Mass A 식각 전의 상태, Mass A의 파장 방출



(그림 2) Mass A 식각 후의 상태, Mass B의 파장 방출




(그림 3) Mass A와 Mass B의 시간에 따른 신호 강도

2.2 예방 정비(Preventive Maintenance; PM)

반도체 설비는 스마트 공장과 더불어 오랜 시간 연속 가동되며, 항상 일정한 조건을 유지하여야 생산 품질을 유지할 수 있다. 식각 설비의 경우 식각 과정을 거치며 챔버(반도체 공정이 진행되는 공간, Chamber) 내의 소모품이 닳아 교체 작업을 빈번하게 진행한다. 또한 식각 과정에서 동반되는 화학 작용으로 인해 나온 부산물이 챔버에 남아 내부의 조건이 변화하게 된다. 이 변화에 의해 생산 품질이 저하될 수 있다.

조건 변화에 따른 생산 품질에 영향이 발생하기 이전에 미리 예방 정비를 진행한다. 플라즈마가 켜진 시간에 따라 정기적으로 진행하기도 하고, 소모품의 상황에 따라 비정기적으로 진행을 하여 챔버당 약 월 1회의 예방 정비를 한다. 예방 정비 소요 시간은 평균적으로 12시간의 작업 시간이 소요된다. 이 작업이 진행되는 동안 반도체의 생산이 중단되기 때문에 생산량이 급감하게 된다. 따라서 예방 정비 작업을 얼마나 빠르고 정확하게 완료하는지가 반도체 생산량에 큰 영향을 미친다.

예방 정비는 (그림 4)와 같이 크게 수동 예방 정비(Physical PM), 시즈닝(Seasoning), 샘플 테스트를 거쳐 생산에 재 합류하게 된다. 수동 예방 정비는 사람이 직접 챔버를 열어 소모품을 교체하고 세척하는 작업이다. 사람이 직접적으로 하는 활동이기에 데이터 상으로 시간을 단축시킬 수 없는 작업으로 간주할 수 있다. 시즈닝은 웨이퍼가 없는 챔버 상태에서 내부를 진공 상태로 만들고 가스를 주입하고 온도를 높여 공정이 바로 진행될 수 있는 챔버의 상태로 예열하는 작업이다. 마지막으로 샘플 테스트는 터미 웨이퍼를 넣은 상태로 공정을 진행하여 해당 결과가 신뢰 구간의 상태를 달성하는 단계가 될 경우 해당 챔버는 생산에 재 합류하게 된다.



(그림 4) 예방 정비 작업 절차

예방 정비 전과 후를 비교해 보면 챔버의 조건이 상당히 변화된다. 이때 식각의 종말점 값도 크게 바뀌어 종말점(Endpoint)의 설정 값을 재조정해주어야 한다. 이 값은 샘플 테스트 단계에서 진행하며 일정 범위의 목표 값에 포함될 때까지 반복 진행 후 만족할 경우 생산에 합류하게 된다.

3 실험 설정

3.1 실험 데이터 구성

제조 데이터는 설비에 부착된 센서에서 공정이 진행되는 동안 측정된 값들의 집합이다. 빅데이터가 적용된 제조 공장은 효율적 운영을 위하여 설비에 수많은 센서가 부착되어 있다. 압력, 온도, 진동 등 다양한 공정 변수의 수치 변화를 측정해 설비의 상태를 실시간 진단한다. 이 데이터는 시계열의 데이터 형태를 가지며 한 웨이퍼에 대해 100ms 단위로 수집된다. 공정 시간은 평균적으로 8 분이 소요되어 센서당 480(60 x 8)개의 데이터 포인트를 얻는다. 한 챔버에는 429 개의 센서가 있어 480 x 429 개의 포인트 데이터를 가지고 있다. [3] 다 변량 변수를 다루는 일에는 차원의 저주라는 어려움이 존재한다. 이 문제점을 해결하기 위해 데이터의 차원을 줄일 필요가 있다. 센서별로 전체 시간 값의 평균을 취하여 하나의 포인트 데이터를 얻는다. 즉, 한 장의 웨이퍼로 진행된 데이터는 429 개(센서 개수)의 데이터 값을 얻게 된다.

Sensor1	Sensor2	Sensor3	...	Sensor429	EPD Setpoint
64.31	-89.4	14621.99		9	74900
65.01	-89.5	14641.87		9	70800
64.93	-89.5	14558.69		9	68500
64.97	-88.8	14730.33		9	72300
64.97	-88.8	14692.57		9	71900
64.85



Sensor1	Sensor2	Sensor3	...	Sensor429	EPD Setpoint
64.838	-89.2	14649.09		9	71680

<표 1> 한 장의 웨이퍼에서 추출된 데이터

<표 1>과 같이 수집된 변수의 평균 특징을 유지하여 간단한 정보 데이터로 변환하고, 위와 동일한 형태로 여러 장의 웨이퍼 데이터를 병합하여 식각 종말점 설정 값(EPD Setpoint) 예측을 위한 하나의 데이터 셋을 구성한다.

3.2 데이터 전 처리

429 개의 센서 중 EPD Setpoint 예측에 큰 영향을 미치는 특징 변수(Feature)를 골라내어 가중치를 부여하는 모델을 만든다. 다음과 같은 변수를 제외하고 나머지 변수만을 수집하여 준비 작업한다.

- 1) 공백(Null) 값이 포함된 변수
- 2) 특정 설정 값(Setpoint)의 변수
- 3) 값의 변화가 없는 변수

해당 제외 작업을 통하여 변수의 개수가 125 개로 크게 축소되었다.

각 변수의 범위 차이가 클 경우 값의 가중치를 반영하지 못하는 현상이 있다. 해당 현상을 해결하기 위해 변수들을 0 과 1 사이의 값으로 최소-최대 정규화(Min-Max Normalization)를 하여 변환시켜준다. 모든 변수의 범위가 동일하게 만들어 모델을 위한 준비를 한다.

3.3 설정 값 예측 모델 설계

특징 변수의 개수보다 데이터 포인트의 수가 더 많은 형태가 좋은 학습 결과를 가지고 있는 데이터이다. 하지만 반도체 설비 데이터 특성상 데이터의 수보다 특징 변수의 수가 더 많다. 이러한 조건의 데이터를 사용하여 회귀 모델을 만들 경우 정규화 방법을 사용하여 선형 회귀의 단점을 보완하고 범용성을 부여하는 것이 일반적이다.

정규화 모델은 크게 라쏘(Lasso) 모델과 리지(Ridge) 모델로 나눌 수 있으며 두 가지 모델에 [4]격자 탐색(Grid Search)을 적용하여 설정 값을 예측한다. 격자 탐색은 해당 모델의 잠재적 매개변수(Hyper Parameter)의 후보군들의 조합 중 가장 좋은 값을 찾아내는 기능이다. 준비된 학습 데이터를 사용하여 종말점 설정 값 예측을 위한 격자 탐색 후 모델과 잠재적 매개변수를 선별한다. 학습된 정규화 모델을 위한 변수 단위의 계수를 저장하여 재사용 될 수 있도록 준비한다.

4 모델 평가

학습에 사용되지 않은 새로운 데이터를 얻어 모델의 예측 정확도를 평가한다. 예측/회귀 모델의 평가 방법은 MSE, RMSE, MAE, MAPE 등이 있으며 이러한 값들은 결국 오차(Error)를 나타내기 때문에 해당 값이 작을수록 모델의 성능이 좋다는 것을 의미한다. 모델의 평가 기준은 평균 제곱근 편차(Root Mean Square Error; RMSE)를 사용하며 실제 값과 예측 값의 차이를 제공하여 평균한 값이다. RMSE 가 50 이하일

경우 해당 모델 사용이 유효한 효과가 있다고 평가한다. 이 오차 범위의 기준은 실제 공정 결과를 테스트기에 넣어 확인하였을 때, 품질의 합격/불합격이 나누어지는 기준치이다. 공정의 종류에 따라 해당 기준값은 변경될 수 있으나 본 논문에서 테스트한 공정의 기준은 RMSE 가 50 이하일 경우 신뢰구간에 속한다고 정의한다.

테스트 결과 <표 2>와 같이 평가 지표가 모두 50 이하의 유효한 값을 가지고 있어 종말점 설정 값 예측이 정확하게 되는 모델로 해석할 수 있다. 미리 예측 적용하여 샘플 테스트의 수를 크게 줄일 수 있다는 것을 의미한다.

Real	Prediction	RMSE
74800	73834	31.08054054
71800	69825	44.44097209
68700	68557	11.95826074

<표 2> 실제 값과 예측 값의 평가 지표. RMSE 값이 50 이하일 경우 유효한 예측 성능의 모델로 분류

참고문헌

[1] S.Dellagi, N.Rezg , X. Xie “Preventive maintenance of manufacturing systems under environmental constraints”
 [2] Ho-Taek Noh, Young-Kook Park, Seung-Soo Han “Real Time Endpoint Detection in Plasma Etching Using Decision Making Algorithm” 2nd
 [3] Christiansen, Bo. Ensemble Averaging and the Curse of Dimensionality. Journal of climate, vol.31, no.4, 1587-1596
 [4] Petro Liashchynskiy, Pavlo Liashchynskiy “Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS”

5 결론 및 향후 연구 과제

반도체 제조 공장은 정해진 시간 내에 최고의 품질의 반도체를 대량 생산하는 것을 목표로 한다. 설비의 유휴 시간이 크게 증가하는 예방 정비 시간을 줄이는 것이 생산량 증가에 중요한 방법이며 이것을 해결하는 연구를 진행한다.

예방 정비 후 샘플 테스트 단계에서 종말점을 조정하는 시간을 줄일 수 있도록 예측한 설정 값을 적용하여 결과 값이 신뢰구간에 빠르게 포함되는 효과를 가져왔다.

하지만 RMSE 가 50 과 가까운 값도 포함되어 있어 예측 결과가 50 을 넘어갈 경우가 발생할 가능성도 존재한다고 판단되어 에러를 줄이는 추가 방법에 대하여 고려해 볼 필요가 있다. 전처리를 통해 특징 변수를 줄이기는 하였으나 여전히 125 개의 변수가 남아 다중 공선성 문제 가능성이 있다. 다중 공선성을 측정하여 높은 수치를 가지는 변수를 줄여본 뒤 해당 모델의 성능 평가를 진행하여 보다 안정적이고 높은 정확도의 예측 방법에 대해서 연구할 것이다.