

Time Series Support Vector Machine을 이용한 Reactive Ion Etching의 오류검출 및 분석

박영국* · 한승수* · 홍상진**

명지대학교 정보공학과*, 명지대학교 전자공학과**

Fault Detection of Reactive Ion Etching Using Time Series Support Vector Machine

Young-Kook Park* · Seung-Soo Han* · Sang J. Hong**

*Myongji University Department of Information Engineering

**Myongji University Department of electronics Engineering

E-mail : ypk2001@mju.ac.kr, shan@mju.ac.kr, samhong@mju.ac.kr

요 약

현재 고밀도 반도체제작 환경에서는 Reactive Ion Etching (RIE) 과정에서의 생산성을 극대화하기 위해서 비이상적인 공정장비를 발견하는 것이 매우 중요하다. 생산과정에서 오류발견의 중요성을 설명하기 위해 Support Vector Machine (SVM)은 실시간으로 공정오류에 대한 판단에 대한 도움을 주기위해 사용되었다. baseline run으로부터 얻은 데이터로 SVM 모델을 구성하고 정상인 run 데이터와 비정상 run 데이터로 SVM 모델을 검증한다. 통계적 공정제어에서 흔히 이용되는 control limits를 도입하여 정상데이터가 내재하고 있는 램덤 변화율이 반영된 SVM 모델 기반의 control limits를 수립하고, 그 control limits를 바탕으로 오류발견을 실행한다. SVM을 이용함으로써 RIE의 오류발견은 run to run 기반에 정상인 run데이터는 0% 오류율이 증명되었다.

ABSTRACT

Maximizing the productivity in reactive ion etching, early detection of process equipment anomaly became crucial in current high volume semiconductor manufacturing environment. To address the importance of the process fault detection for productivity, support vector machines (SVMs) is employed to assist the decision to determine process faults in real-time. SVMs for eleven steps of etching runs are established with data acquired from baseline runs, and they are further verified with the data from controlled (acceptable) and perturbed (unacceptable) runs. Then, each SVM is further utilized for the fault detection purpose utilizing control limits which is well understood in statistical process control chart. Utilizing SVMs, fault detection of reactive ion etching process is demonstrated with zero false alarm rate of the controlled runs on a run to run basis.

키워드

SVM, RIE, PCA, Fault Detection

1. 서 론

오류 검출은 단지 장비 중단시간 뿐만 아니라 결함이 있는 상태에서 수행된 오류공정을 줄이기 위해서 필요하다. 반도체 가공 장비와 공정과정은 점차 정교해지고 있으며 그 핵심에는 오류가 없는 공정을 유지하는 것이다. 불완전한 공정은 때

때로 신뢰할 수 없는 장비의 상태로부터 발생되기도 한다. 비록 장비 동작에서 일정한 양의 랜덤 변수는 피할 수 없을 지라도, 중요한 동작의 변화는 이 변화가 크게 일어날 때 발생한다. 장비가 허용할 수 있는 수준을 넘어 동작상태의 변화를 신뢰할 수 없을 때, 모든 웨이퍼 품질은 급격히 떨어진다. 오류발견은 신뢰할 수 없는 장비상태를

나타내 주는 것 중에 하나이다. 그러므로 오류가 발생한 시점에서의 오류검출은 제조비용을 줄이기 위한 큰 이점을 줄 수 있다 [1].

Reactive Ion Etching (RIE)는 chamber안에 물리적 이온 충격과 화학반응이 결합된 플라즈마 식각 기술이다. 플라즈마 공정의 복잡성 때문에 advanced process control (APC)의 준비로서 fault detection and classification (FDC)는 차세대 반도체 공정에서 도전과제로 남아있다. 이번 연구에서 SVMs은 다양한 공정 파라미터들의 시계열 모델링을 위한 도구로서 사용되었다. 그리고 만들어진 모델은 반도체 제조공정의 FDC를 위해 이용되었다. 이 논문은 다음과 같이 구성되어있다. 2절은 데이터 습득과 차원을 줄이기 위한 전처리 과정. 3절은 SVM 대해 간략하게 설명하였다. 모델을 통한 실험방법과 FDC의 결과 및 결론들은 각각 4절 5절에 설명하였다.

2. Advanced Process Control을 위한 오류발견

Statistical process control (SPC) 기술은 전통적으로 통계적으로 수립된 control limit을 이용하여 반복적인 공정에서의 오류 발견을 설명해 준다 [2]. 그것은 허용 가능한 공정 변화범위를 한정한다. 특정한 작동을 끝마치자마자 후반부에 공정처리에서 계량데이터를 가져오게 되고 이 데이터는 공정처리를 어떻게 할 것인지를 판단하기 위해 사용된다. 후공정 계량데이터가 control limit에 위치할 때 그것은 SPC에 통제된 것으로 생각한다. 그러나 한계선을 넘어선 계량데이터는 SPC의 통제를 벗어났다고 생각하다. 그리고 이것은 공정이 잘못된 것을 가르쳐 준다. 더욱이 공정에서 드리프트 (drift)가 신뢰할 수 없는 장비의 상태에서부터 발생할 때 SPC는 상대적으로 간단한 관리도로 드리프트를 발견할 수 있다. 그러나 전통적인 SPC는 공정단계가 끝날 때까지 그런 드리프트를 발견하기에는 충분하지 않다는 문제가 있다. 이런 문제 때문에 plasma etching을 위한 실시간 SPC가 제안되었다 [3]. SPC에서 몇몇의 고유의 제한을 완화하기 위해 APC기술이 고안되었다. APC는 모델기반인 공정 제어와 FDC를 포함하며 FDC는 plasma etching에서 공정장비상태 데이터와 계량데이터를 이용한다 [4-5]. 그리고 principal component analysis (PCA)는 주로 다차원의 입력 데이터의 차원을 줄이기 위한 한 방법으로 제시되며, Model-based PCA 또한 nMOS 제작에서 FDC에 적용 되었다 [6].

2.1 데이터 습득

실험 Run들은 10개의 baseline run들로 구성되어 있고, 10개의 test run은 3개의 순수한 정상 run과 7개의 비정상 run들이 있다. 비정상 run들

은 자연적인 장비 상태의 변화를 가정하여 chamber 환경을 인위적으로 조정하여 그 상태가 기록된 것이다. 제안된 FDC 방법을 설명하기 위

표 1. 10개의 baseline 중에 3개의 정상run과 7개의 비정상 run을 나타냄 (BL: baseline and TT: test)
Table 1. Description of 10 baseline runs, 3 control runs, and 7 perturbed runs.

BL run	Testing runs
BL-01	TT-01 Unperturbed control run
BL-02	TT-02 -0.5mT
BL-03	TT-03 +0.5mT
BL-04	TT-04 -1% MFC conversion shift
BL-05	TT-05 +1% MFC conversion shift
BL-06	TT-06 Source RF cable: loss simulation
BL-07	TT-07 Unperturbed control run
BL-08	TT-08 Bias RF Cable: power delivered
BL-09	TT-09 Unperturbed control run
BL-10	TT-10 Added chamber leak rate:1.3mT/m

해서 59개의 시스템 변수들로부터 데이터들이 DPS-II etcher로부터 10Hz로 동시에 수집되었다. 각각의 run은 초기 안정화단계와 de-chuck 단계를 포함한 11개의 다른 스텝으로 구성된다. 그리고 SVM 모델을 만든 baseline과 정상 run들의 목록뿐만 아니라 이번 연구에서 사용된 비정상 run들의 설명은 표1에서 설명한다.

2.2 Principal Component Analysis (PCA)

이번 연구에서 우선 도전 과제는 수집된 데이터와 etch 처리과정 상태 사이의 관계를 수립하기 위해 방대한 양의 도구데이터에 대해 설명 한다. 이 관계를 완화하기 위해 PCA는 데이터들의 차원을 줄이기 위한 도구로서 사용되었다. PCA는 통계적 기술이 잘 수립되어있다. 이전에도 통계적 기술을 이 목적을 위해 사용되었다 [1].

3. Support Vector Machine

SVM은 회귀(regression)문제를 평가하기 위해 사용될 때 그것은 3개의 분명한 특징들을 가지고 있다. 첫째, SVM은 선형분류기들의 학습을 위한 알고리즘이다. 둘째, SVM들은 최대마진의 개념으로 동기가 부여되었다. 셋째, SVM은 커널들을 사용함으로써 비선형 SVM으로 확장될 수 있다. 실제 응용에서는 신경망과 같이 보다 복잡한 구조의 패턴 분류를 요구한다.

4. 실험

본 논문에서 SVM은 많은 머신의 학습문제를 해결하기 위해 empirical risk minimization (ERM) 원칙을 구현한 신경망보다 더 높은 일반화 수행

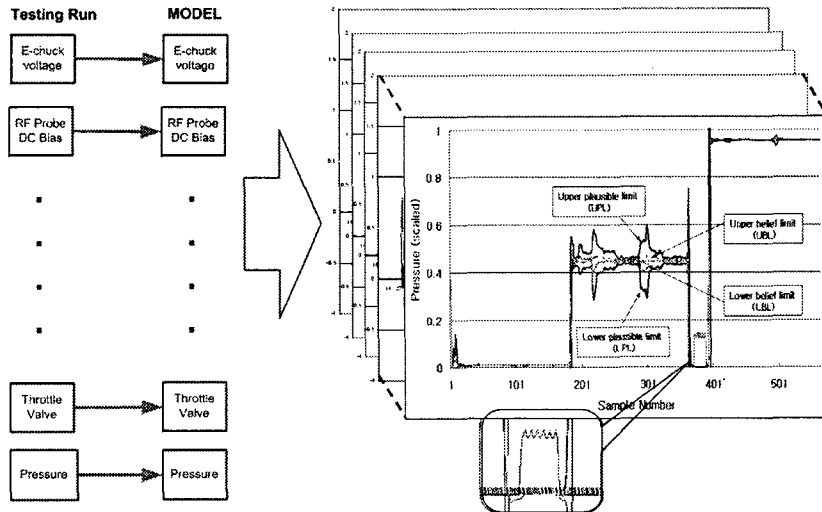


그림 1 파라미터 결과 UBL(Upper belief limit), LBL(Lower belief limit), UPL(Upper plausible limit), LPL(Lower plausible limit)
 Fig. 1 Result of parameter UBL(Upper belief limit), LBL(Lower belief limit), UPL(Upper plausible limit), LPL(Lower plausible limit)

한다. 이러한 접근법은 반도체 공정분야 경우에 유용할지도 모른다. 그러나 SVM의 단점은 학습 시간이 학습샘플들이 많을수록 증가한다는 것이다. Baseline 안에는 장비의 정상동작 조건 상태에서 원하는 공정 상태를 고려했다. 그러나 10개의 baseline run에서 습득된 데이터는 꼭 같지는 않다. 모든 baseline run들의 평균값을 계산한 것은 특정 baseline run 들을 선택된 것보다 랜덤변화를 줄여 SVM 학습에 이용하기 위해서이다.

Baseline으로부터 각 파라미터의 평균데이터가 최상의 표현임을 가정하면, 각 공정 파라미터에 대한 SVM 모델이 수립된다. 그러나 가정을 한 것은 모든 정상 run들을 포함하는 모델을 이끌어내기 위한 것이지만 그것은 랜덤변화를 다 포함한다고 말하기는 어렵다. Pressure의 파라미터를 위한 SVM 모델이 생성된 후에 압력에 응답하는 baseline run들은 SVM 모델을 통하여 예측된다. 그리고 예측값의 최대 최소값이 기록된다. 예측된 예측값의 최대, 최소 사이의 영역은 원래의 정상 baseline 데이터 그룹의 최대, 최소 구간이 중복될지도 모른다. 그러나 그것은 공정 랜덤한 변화 뿐만 아니라 모델의 예측오류 또한 포함한다.

예측값은 최대, 최소 구간에 오류점이 들어가 있는 것이 중요하다. 왜냐하면 이 최대 최소 구간 사이에 예측값이 있다면 공정이 정상이라는 것을 뒷받침 해주는 영역이다. SPC와 비슷한 명칭으로 최소값의 그룹은 "lower belief limit (LBL)"로 최대값의 그룹은 "upper belief limit (UBL)"로 명명하였다. 임의의 run으로부터 예측된 값이 이 영역(LBL-UBL) 내에 놓여 있을 때 그것은 정상

run에 존재할 확률이 높다. 정상과 비정상 공정사이 에 분명한 경계선을 오류검출 어플리케이션에서 제공해 주는 것이 이상적이다. 결점이 있는 공정에 대해 오류의 유무를 판단해주기 위해 또 다른 경계선을 도입하여 이 실험에 사용되었다.

Lower plausibility limit (LPL) 과 upper plausibility limit (UPL)이 LBL 과 UBL의 선형 스케일링에 의해 정의 되었다. 이 실험에서 많은 스케일링이 시도 되었고 100% 스케일링은 오류 판단기준을 만들기 위한 최적의 경계선을 주었다. 이 실험에서 사용된 baseline run 데이터는 RIE공정의 Run 비용 때문에 한정적이기 때문에 LPL 과 UPL을 수동적으로 결정할 수밖에 없었다. 그러나 산업체로부터 좀 더 반도체 제조 데이터를 이용할 수 있었다면, 모델로부터 plausible limit을 파악할 수 있었다. 그렇다면 belief limit 와 plausible limit사이의 영역은 좀 더 좁아질 것 이라 생각한다.

5. 결과 및 결론

실험을 위해 10개의 실험 RUN 들은 baseline 의 정상run과 비슷하게 조정하였고 몇몇은 고의적으로 오류가 나도록 조정하여 오류발견을 실험 하였다. 실험절차는 그림 1에서 묘사되었던 것처럼 실시간 방식으로 수행되었다. 그리고 이 실험에 대한 평가는 표 2에서 볼 수 있는 것처럼 run-to-run으로 수행되었다. 단계에서 그 다음단계로 넘어가는 시점에서 급변하는 영역이 있다.

더욱이 이런 영역은 공정제어부분에서 무시할

표 2 오류발견 결과
Table 2. Fault detection results

	STEP_1	STEP_2	STEP_3	STEP_4	STEP_5	STEP_6	STEP_7	STEP_8	STEP_9	STEP_10	STEP_11
TT_01	○	○	○	○	○	○	○	○	○	○	○
TT_02	○	●	●	●	○	○	●	○	○	○	○
TT_03	○	●	●	●	○	○	○	○	○	○	○
TT_04	○	○	○	○	○	○	○	○	○	○	○
TT_05	○	○	○	○	○	○	○	○	○	○	○
TT_06	○	○	●	○	●	●	○	○	●	●	●
TT_07	○	○	○	○	○	○	○	○	○	○	○
TT_08	○	●	●	○	●	●	○	○	●	●	●
TT_09	○	○	○	○	○	○	○	○	○	○	○
TT_10	○	○	○	○	●	○	○	○	●	○	○

수 있는 부분이거나 아주 중요한 요소 중에 하나이다. 그것을 초기단계에 지적함으로써 SVM모델에서 경계선들은 특히 급변하는 영역에 대해 중요한 역할을 한다. 그림1에서 묘사된 것처럼 급변하는 부분을 무시하지 않고 오류알람을 나타내주는 것을 볼 수 있다. Belief limit들을 근거로 압력에서의 오류검출은 일반적으로 잘 수행한다. 그러나 많은 이벤트들이 belief limit구간에서 근소한 차이로 오류발견이 일어난다. 근소한 차이의 값들도 belief limit 구간을 벗어난 것은 사실이므로 오류임을 알려준다. 그러나 실제로 오류로 판정할 만큼 중요한 것은 아니다. 이것은 판단근거를 만드는 문제이다. 이 실험의 영역을 조금 넘었을지 모른다. 이 실험에서 판단근거를 위해 만든 기준은 LPL 과 UPL을 전 절에서 언급되었던 것처럼 사용되었다. plausible limit들이 너무 넓은 경우에는 알람을 놓치는 경우가 증가할지도 모른다. 그리고 너무 좁히면 오류알람의 확률이 증가한다.

이론적으로 적절하게 결정된 plausible limit들은 정상 run을 증가시킬 수 있고 오류알람의 기회를 감소시킨다. 적절한 plausible limit들을 결정하는 것은 많은 실험 데이터로 이를 수 있다. 그리고 그것에 다양한 환경에 대한 weight factor는 공정 엔지니어들에게 남긴다.

표2은 control limit에 모델 기반으로 모델 run-to-run 오류검출 결과를 단계별로 보여준다. 오류가 없는 run들은 ○(정상)으로 표시 그리고 오류가 있는 run들은 ●(오류)으로 표시한다. 정상run에 가깝게 조정된 TT_01, TT_07, TT_09에서는 오류가 발견되지 않았다. 이것은 조정된 0%의 오류발견을 한다는 것을 알 수 있다. TT_04, TT_05 run ±1% mass flow controller (MFC) 변환 이동은 비정상 동작이었지만 오류발견을 하지 못했다. 두 개의 run에서 오류발견의 요소의 부족으로 missed alarm들로 해석 될 수 있다. SVM에서 작은 MFC 변환이동을 발견하려면 생략된 변

수들로만 학습해야한다. 그러나 다른 RF prove 변화에 관련된 오류는 성공적으로 발견되었다. 향후 연구에는 오류발견과 다변량 모델링에 이용되는 변수들을 세밀하게 분류하여 오류발견 능력을 개선시킬 수 있을 것이다.

7. 참고문헌

- [1] S. Hong, G. May and D. Park, "Neural Network Modeling of Reactive Ion Etch Using Optical Emission Spectroscopy Data," *IEEE Trans. Semi. Manufac.* Vol. 16, No. 4, pp. 1-11 2003.
- [2] D. Montgomery, *Introduction to statistical Quality Control*, New York, NY: Wiley, 1991.
- [3] H. Guo, C. Spanos, and A. Miller, "Real time statistical process control for plasma etching," in *Proc. Semiconductor Manufacturing Science Symposium*, 1991, pp. 113-118.
- [4] G. Barna, "APC in the Semiconductor Industry; History and Near Term Prognosis," in *Proc. IEEE/SEMI Adv. Semi. Manufac. Conf.*, pp. 364-369. 1996.
- [5] B. Goodlin, D. Boning and H. Sawin, "Simultaneous Fault Detection and Classification for Semiconductor Manufacturing Tools," in *Proc. Int. Symposium on Plasma Processing XIV*, 2002
- [6] S. Lachman-Shalem, N. Haimovitch, E. Shauly, and D. Lewin, "MBPCA Application for Fault Detection in NMOS Farbrication," *IEEE Trans. Semi. Manufac.*, Vol. 15, No. 5, pp. 60-69, 2002.