
Support Vector Machine을 이용한 Reactive Ion Etching의 Run-to-Run 오류검출 및 분석

박영국* · 홍상진** · 한승수*

Run-to-Run Fault Detection of Reactive Ion Etching Using Support Vector Machine

Young-Kook Park* · Sang Jeen Hong** · Seung-Soo Han*

본 연구는 과학기술부/한국과학재단 우수연구센터육성사업의 지원으로 수행되었음
(차세대전력기술연구센터)

요 약

현재 고밀도 반도체제작 환경에서는 반작용적인 이온 식각 과정(reactive ion etching)에서의 생산성을 극대화하기 위해서 비정상적인 공정장비를 발견하는 것이 매우 중요하다. 생산과정에서 오류발견의 중요성을 설명하기 위해 Support Vector Machine (SVM)은 실시간으로 공정오류에 대한 판단을 위해 사용되었다. 반작용적인 이온 식각 도구 데이터는 59개 변수들로 구성된 반도체 공정장비로부터 얻는다. 각각의 변수들은 초당 10개의 데이터로 구성되어있다. 식각 런의 11개의 파라미터에 대한 모델을 만들기 위해 baseline 런으로부터 얻은 데이터로 SVM 모델을 구성하고 정상 런데이터와 비정상 런데이터로 SVM 모델을 검증한다. 통계적 공정제어에서 흔히 이용되는 관리한계를 도입하여 정상데이터가 내재하고 있는 램덤변화율이 반영된 SVM 모델 기반의 관리한계를 수립하고, 그 관리한계를 바탕으로 오류발견을 실행한다. SVM을 이용함으로써 RIE의 오류발견은 run to run 기반에 정상 런데이터는 0% 오류율이 증명되었다.

ABSTRACT

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. The reactive ion etching (RIE) tool data acquired from a production line consist of 59 variables, and each of them consists of 10 data points per second. Principal component analysis (PCA) is first performed to accommodate for real-time data processing by reducing the dimensionality of the data. 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

I. 서 론

과거 반도체 제조의 주된 화제는 다양한 산업분야의 발전을 위해 좀 더 작고 뛰어난 성능을 가진 초고밀도 집회로의 개발에 집중되어 있었다. 하지만 지금은 집회로의 제조비용을 줄이는 것에 시선을 돌리고 있다. 제조비용의 절감은 기기 연산 메커니즘과 원자재비용, 좀 더 개선된 공정장비 그리고 숙련된 기술 인력으로 달성될 수 있다. 제조비용을 줄이기 위한 또 한 가지 방법은 품질에 영향을 줄 수 있는 불완전한 공정요소들을 최소화하는 것이다. 이러한 이유 때문에 반도체 제조과정에서 제품의 품질을 보증하기 위해서는 백 개 이상의 연속적인 공정단계를 성공적으로 수행해야 한다. 그렇기 때문에 공정과정에서 오류검출은 다른 어떤 산업 현장보다 중요하게 요구된다. 오류 검출은 단지 장비의 중단시간 뿐만 아니라 잘못된 공정을 줄이기 위해서 필요하다.

디지털기기들의 소형화가 요구하기 때문에, 반도체가 공 장비와 공정과정은 점차 정교해지고 있으며 그 핵심은 집적도가 높은 반도체를 제조하기 때문에 공정오류를 최소화해서 제조비용을 줄이는 것이다. 공정과정에서 오류가 생기는 것은 장비상태에 따라 발생되기도 한다. 비록 공정장비에서 일정한 양의 랜덤변수는 피할 수 없을 지라도, 불량요인이 되는 동작의 변화가 크게 일어날 때 발생한다.

장비가 허용할 수 있는 수준을 넘어선 변화를 신뢰할 수 없을 때, 웨이퍼 품질은 급격히 떨어진다. 오류발견은 장비상태를 나타내 주는 것 중에 하나이다. 그러므로 오류가 발생한 시점에서의 오류검출은 제조비용을 줄이기 위한 큰 이점을 준다[1].

반작용적인 이온 식각(reactive ion etching)은 진공실(vacuum chamber)안에 물리적 이온 충격과 화학반응이 결합된 플라즈마 식각 기술이다. 플라즈마 공정의 복잡성 때문에 진보된 공정 제어(advanced process control)의 준비로서 오류 검출 및 분류(fault detection and classification)는 차세대 반도체 공정에서 도전과제로 남아있다. 이번 연구에서 SVMs는 다양한 공정 파라미터들의 시계열 모델링을 위한 도구로서 사용되었다. 그리고 만들어진 모델은 반도체 제조공정의 오류 검출 및 분류를 위해 이용되었다. SVM은 분류와 회귀(classification and regression)판단에 뛰어난 일반화 수행을 보여준다. 또한 SVM은 다른 분야에도 적용된다.

예를 들면 플라스틱 사출성형 제조과정에서도 오류 검출 도구로 사용할 수도 있다. 이 논문은 다음과 같이 구성 되어있다. 2절은 데이터 습득과 차원을 줄이기 위한 전처리 과정. 3절은 SVM 모델링에 대한 간략하게 설명하였다. 모델을 통한 오류검출과 FDC의 결과들은 각각 4절 5절에 설명하였다. 마지막 6절에는 결론을 설명하였다.

II. 진보된 공정 제어를 위한 오류발견

최근에 반도체 제조회사는 잘못된 공정을 피함으로서 그들의 생산비용 절감을 위해 노력을 하고 있다. 공정과정에서 잘못된 웨이퍼가 다음 단계로 경고 없이 지나간다면 특정 지점에서 재작업을 위한 준비시간과 비용을 필요로 하고, 공정 마지막 지점에서 결합이 있는 장비들을 점검해야 할 것이다.

펜티엄4 프로세서 가공을 예로 들면 600개 이상의 단위공정에서 마이크로프로세서를 만들기 위해서는 결합 없는 공정과정이 연속적으로 이루어져야 한다. 만일 어느 곳이라도 잘못된 공정이 일어난다면 정상적인 프로세서를 생산하기 힘들다. 이것은 반도체 생산에서 결합 있는 부분을 발견하는 것이 중요하다는 것을 설명해준다. 전통적으로 통계적 공정관리(statistical process control)기술은 통계적으로 수립된 관리한계(control limit)를 이용하여 반복적인 공정에서의 오류 발견을 설명해준다[2]. 그것은 허용 가능한 공정데이터의 변화범위를 한정한다.

특정동작을 끝마치자마자 공정처리에서 계량데이터를 가져오게 되고 이 데이터는 공정처리를 어떻게 할 것인지를 판단하기 위해 사용된다. 계량데이터가 관리한계 내에 있을 때 그것은 SPC에 통제된 것으로 생각한다. 그러나 공정관리를 넘어선 계량데이터는 SPC의 통제를 벗어났다고 생각한다. 이것은 공정과정 중에 잘못된 부분이 있다는 것을 알려준다[3]. 더욱이 공정과정 중에 장비의 오동작으로 변화추이(drift)가 발생할 때 SPC는 상대적으로 간단한 관리도로 찾을 수 있다. 그리고 변화추이의 발견은 정상 동작을 위한 변하기 쉬운 원인을 제거하기 위한 조사의 시작점이다. 그러나 SPC는 공정단계가 끝날 때까지 그런 변화추이를 발견이 어렵다는 문제가 있다. 이러한 문제 때문에 플라즈마 식각을 위한 실시간 통계적 공정관리가 제안되었다[4]. SPC에서 몇몇의 고유의 제한을 완화하기 위해 APC 기술이 고안되었다. APC는 모델

기반인 공정 제어와 FDC를 포함한다[5]. FDC는 플라즈마 식각에서 도구데이터와 [6] 원래의 계량데이터를 [7] 이용한다. 그리고 주성분분석(principal component analysis)은 주로 데이터의 차원을 줄이기 위해 사용되었다. 모델을 기반으로한 PCA는 nMOS 제작에서도 FDC가 적용 될 수 있다[8].

2.1 데이터 습득

실험 런(Run)들은 10개의 baseline 런들로 구성되어있고, 10개의 테스트 런은 3개의 정상런과 7개의 비정상 런들이 있다. 비정상 런들은 정상상태의 진공실(chamber) 환경을 인위적으로 수정하여 나온 결과 상태를 기록한 것이다. 제안된 오류 검출 및 분류법을 설명하기 위해서 59 개의 시스템 변수들로부터 데이터들이 DPS-II etcher로부터 10Hz로 동시에 수집된다. 각각의 런은 초기 안정화단계와 dechuck 단계를 포함한 11개의 다른 스텝으로 구성된다. 그리고 SVM 모델을 만든 baseline과 정상 런들의 목록뿐만 아니라 이번 연구에서 사용된 비정상 런들의 설명은 표1에서 설명한다.

표 1. 10개의 baseline 중에 3개의 정상런과 7개의 비정상 런을 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

2.2 주성분 분석

이번 연구에서 우선 도전 과제는 수집된 데이터와 etch 처리과정 상태 사이의 관계를 수립하기위해 방대한 양의 도구데이터에 대해 설명 한다. 이 관계를 완화하기위해 PCA는 데이터들의 차원을 줄이기 위한 도구로서 사용되었다. PCA는 통계적 기술이 잘 수립되어있다. 이전에도 통계적 기술을 이 목적을 위해 사용되었다[1][9]. 벡터 x

를 고려하면 랜덤변수 p로 구성되어 있다. \sum 가 x의 공분산 매트릭스이라 하자. 그러면 $k = 1, 2, \dots, r$ 에 대해서 k^{th} 는 principal component (PC)는 $t_k = u_k^T x$ 로 주어진다. 여기서 u_k 는 k^{th} 에서 가장 큰 고유치에 응답하는 \sum 의 고유벡터이다.

그리고 T는 전치수행을 표현한다. PCA를 통해 차원을 줄이는 것은 새로운 좌표에 배치하여 데이터를 변환시킴으로서 달성된다. (예를 들면, 선택된 고유벡터들) 그 벡터는 서로 관련성은 없고 처음부터 원래의 데이터집합에서 대부분의 변수표현을 유지하는 것처럼 배열된다. 일반적으로 고유값은 가장 큰 것에서 가장 작은 것으로 배열된다. 그러면 처음 몇 개의 PC들은 원래의 벡터 x에서 대부분의 변수를 설명할 것이다. 그림1은 단순하게 된 그림으로 된 PCA의 삽화를 보여준다. 데이터 위치에 어떤 변수들은 수동으로 생략되었다. 왜냐하면 그 데이터들은 기술적으로 만들었거나 중요한 변수들을 보지 못했기 때문이다. 고려할만한 20개의 런(run)들로부터 데이터는 11개의 단계로 나뉘어졌다. PCA는 각 단계에서 수행되었다 그리고 중요한 요소들과 관련된 처음 5개의 고유벡터들은 중요한 변수들을 확인하기위해 조사되었다. 결국 선택된 변수들은 SVM 모델링과 오류발견을 위해 사용된다.




그림 1. 차원 감소를 나타내는 PCA의 개략도
Fig. 1 Schematic of PCA presenting dimensional reduction

III. Support Vector Machine

SVM은 회귀(regression)문제를 평가하기위해 사용될 때 3개의 특징들을 가지고 있다. 첫째, SVM은 선형분류기들의 학습을 위한 알고리즘이다. 둘째, SVM은 최대마진의 개념으로부터 시작되었다. 셋째, SVM은 커널들을 사용함으로써 비선형 SVM으로 확장될 수 있다. 예로서

$$S = (x_1, y_1), (x_2, y_2), \dots, (x_l, y_l), y_m = g(x_m)$$

이 주워졌다. 여기서 각각의 입력 벡터 $x_i \in R^d$ 는 $y_m \in \{-1, +1\}$ 에 의해 분류된 집단에 속해있다. 두 집단들이 선형적으로 분류되어 있다면 초평면(hyperplane)은

$$y(w \cdot x_i + b) > 0, \quad i = 1, \dots, l \quad (1)$$

을 만족한다. (1)은 결정함수 (2)의 평가를 통해 분류기로서 사용되었다.

$$f(x_i) = \text{sign}((w \cdot x_i) + b) \quad (2)$$

여기서 w 는 초평면에 수직벡터이다.

그리고 $b / \|w\|$ 는 초평면에서 원점까지의 수직선의 거리. SVM은 분류된 초평면들 사이에 마진이 최대화된 초평면을 찾는다. 최대 마진은 초평면에서부터 가장 근접한 학습데이터 점까지 수직선의 거리로 정의될 수 있다. 마진의 최대값은 발견되지 않은 데이터의 오분류의 위험을 최소화 하게 해준다[10]. 파라미터 w 와 b 는 초평면에 만족하는 근접한 데이터 점으로 크기 조정되었다.

$$|(w \cdot x_i + b)| = 1 \quad (3)$$

그러면 마진은 $1 / \|w\|$ 로서 주워진다. 그리고 최대값은 $\|w\|^2$ 을 최소화하는 것과 같다. 최대 마진을 갖는 초평면의 w 와 b 파라미터는 2차 방정식 프로그래밍으로 해결함으로써 구할 수 있다.

$$\min_{w, b} \frac{1}{2} \|w\|^2 \quad (4)$$

subject to

$$y_i(w \cdot x_i + b) \geq 1, \quad i = 1, \dots, l$$

비선형 문제를 다루기 위해 비선형 매핑함수 Φ 는 고차원 특징을 가진 공간 F 안에 입력 공간을 사상하는데 사용된다. 여기서 그룹들 사이에 선형분리가 수행된다. 데이터는 비선형 사상함수 Φ 를 사용함으로써 고차원 특징을 가진 공간 F 에 사상된다. 그리고 원점으로부터 분류된 최대 마진 초평면은 다음의 문제를 해결함으로써 알 수 있다:

$$\min_{w, \xi \in R^l, \rho} \frac{1}{2} \|w\|^2 + \frac{1}{\nu l} \sum_{i=1}^l \xi_i - \rho \quad (5)$$

subject to $w \cdot \Phi(x_i) \geq \rho - \xi_i$
 $\xi_i \geq 0$

여기서 w 는 가중치 벡터이며, 오프셋(offset) ρ 에 따라 F 에 초평면을 정의한다. l 은 학습하고자 하는 데이터의 수이다. ν 는 사용자정의 파라미터, ξ 는 입력 벡터 x 와 관련된 슬랙(slack)변수이다. 여기서는 학습을 하는 동안 오분류된 변수들을 허용하게 되면 더 큰 마진이 생길 수 있고 데이터의 오분류 위험을 줄일 수 있기 때문에 슬랙변수들에 대해 소개한다.

파라미터 $\nu \in (0, 1)$ 는 오분류된 예제들과 분류기의 일반화의 능력사이에서 교환 제어한다. ν 를 작게 하면 할수록 어떤 목적을 가진 함수에서 오분류된 슬랙변수의 비율을 작게 한다. 또한 ν 가 바깥쪽에 묶여있으면 더 크게 그리고 다수의 서포트벡터에 모여있으면 더 낮게 하는 것을 볼 수 있다[11]. 라그랑제 곱셈기를 사용함으로써 첫번째의 문제는 이중문제에서 변환되는 것이다. 그것을 해결하기 위해 (6)식을 사용하면 좀더 편리하다.

$$\min_{\alpha} \frac{1}{2} \sum_{ij} \alpha_i \alpha_j K(x_i, x_j) \quad (6)$$

subject to $0 \leq \alpha_i \leq \frac{1}{\nu l},$
 $\sum \alpha_i = 1$

여기서 a 는 라그랑제 곱셈기이고 K 는 커널함수이다. (7)로서 정의된.

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (7)$$

이로서 최적화문제는 커널함수에 달려있기 때문에 사상함수 Φ 는 명쾌하게 사용되지 않는다.




그림 2. 샘플 압력 파라미터
 Fig. 2 Sample figure process parameter(Pressure)

IV. 실험

이 논문에서 SVM은 수 많은 데이터를 학습할 때 생기는 문제를 최소화하기 위해 사용되었다. SVM은 경험적 위험 최소화(empirical risk minimization) 원칙을 구현한 신경망보다 더 높은 일반화를 수행한다 [12]. 이러한 접근법은 반도체 공정분야 경우에 유용할지도 모른다. 왜냐하면 파라미터 값의 변화에 대한 응답의 폭이 크기 때문이다. 그러나 SVM의 단점은 학습데이터들이 많고 2차 3차 함수에 따라 학습시간이 증가한다는 것이다. 이 경우에 랜덤변수가 섞여있을 것이고 통계적인 방법보다 월등한 능력을 보여주지만 신경망과는 비슷한 성능을 보여준다. Baseline 안에는 장비의 정상조건 상태에서 원하는 공정 조건을 만들었다. 그러나 10개의 baseline 런에서 습득된 데이터는 꼭 같지는 않다. 그 이유는 baseline 공정 또는 장비가 예상치 못한 변화가 생길지도 모르기 때문이다. 모든 baseline 런들의 평균값을 계산한 것은 특정 baseline 런들을 선택된 것보다 랜덤변화를 줄여 SVM 학습에 이용하기 위해서이다. baseline으로부터 각 파라미터의 평균 데이터가 최상의 표현임을 가정하면, 각 공정 파라미터에

대한 SVM 모델이 수립된다. 그러나 가정을 한 이유는 모든 정상 런들을 포함하는 모델을 이끌어내기 위한 것이지만 그것은 랜덤변화를 모두 포함한다고 말하기는 어렵다. 압력(pressure)의 파라미터를 위한 SVM 모델이 생성된 후에 압력에 응답하는 baseline 런들은 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 런으로부터 예측된 값이 이 영역(LBL-UBL) 내에 놓여 있을 때 그것은 정상 run에 존재할 확률이 높다. 반면에 임의의 런이 이 영역을 넘어섰지만 정상 런일 것 같은 곳에 있다면 어떤 판단근거에 의하여 오류가 있음 직하다는 것을 부분적인 표시는 LBL-UBL 영역에서 얼마나 벗어나 있는지




그림 3 파라미터 결과 UBL(Upper belief limit), LBL(Lower belief limit), UPL(Upper plausible limit), LPL(Lower plausible limit)
 Fig. 3 Result of parameter UBL(Upper belief limit), LBL(Lower belief limit), UPL(Upper plausible limit), LPL(Lower plausible limit)

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	○	○	○	○	●	○	○	○	●	○	○

에 달려있다. 정상과 비정상 공정사이에 분명한 경계선을 오류검출 어플리케이션에서 제공해 주는 것이 가장 이상적이다.

결합이 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 정의되었다. 이 실험에서 많은 스케일링이 시도되었고 100% 스케일링은 오류 판단기준을 만들기 위한 최적의 경계선을 주었다. 이 실험에서 사용된 baseline 런 데이터는 RIE공정의 런 비용 때문에 한정적이기 때문에 LPL 과 UPL을 수동적으로 결정할 수밖에 없었다. 그러나 산업체로부터 좀더 반도체 제조 데이터를 이용할 수 있었다면, 모델로부터 plausible limit을 파악할 수 있었다. 그렇다면 belief limit 와 plausible limit사이의 영역은 좀더 좁아질 것이라 생각한다. 그 모델링 과정과 압력에서 수립된 경계선들은 그림2에 제공되었다. 나머지 파라미터들은 모델링되었고 각 모델의 belief 와 plausibility limit들은 똑같은 방법으로 결정되었다. 이 기준을 사용함으로써 오류검출의 결과들은 다음 절에 설명하였다.

V. 결과 및 성능평가

일단 SVM 모델과 각각의 파라미터에 대한 두 개의 경계선이 생성되었다. 실험을 위해 10개의 실험 RUN 들은 baseline의 정상런과 비슷하게 조정하였고 몇몇은 고의적으로 오류가 나도록 조정하여 오류발견을 실험하였다. 실험절차는 그림 3에서 묘사되었던 것처럼 실시간 방식으

로 수행되었다. 그리고 이 실험에 대한 결과는 표2에서 볼 수 있는 것처럼 run-to-run으로 수행되었다. 단계에서 그 다음단계로 넘어가는 시점에서 급변하는 영역이 있다. 더욱이 이런 영역은 공정제어부분에서 무시할 수 있는 부분이고 또한 아주 중요한 요소 중에 하나이다. 그것을 초기 단계에 지적함으로써 SVM모델에서 관리한계들은 특히 급변하는 영역에 대해 중요한 역할을 한다. 그림3에서 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 알 수 있다. 그러나 실제로 오류로 판정할 만큼 중요한 것은 아니다. 이것은 판단 근거에 대한 문제이다. 이 실험의 영역을 조금 넘었는지 모르지만, 이 실험에서 판단근거를 위해 만든 기준은 LPL 과 UPL을 전 절에서 언급되었던 것처럼 사용되었다. plausible limit들이 너무 넓은 경우에는 오류를 놓치는 경우가 증가할지도 모른다. 그리고 너무 좁으면 오류의 확률이 증가한다. 이론에서 적당하게 결정된 plausible limit 들은 정상 런을 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. 표2는 관리한계(control limit)에 모델 기반으로 run-to-run에서 오류검출 결과를 단계별로 보여준다. 오류가 없는 런들은 ○(정상)으로 표시 그리고 오류가 있는 런들은 ●(오류)으로 표시한다. 정상런에 가깝게 조정된 TT_01, TT_07, TT_09 에서는 오류가 발견되지 않았다. 이것은 조

정한 0개의 오류발견을 한다는 것을 알 수 있다. TT_04, TT_05 런 $\pm 1\%$ mass flow controller (MFC) 변환 이동은 비 정상 동작이었지만 오류발견을 하지 못했다. 두 개의 런에서 오류발견의 요소의 부족으로 결함을 정상으로 판단한 것으로 해석 될 수 있다. SVM에서 작은 MFC 변환이동을 발견하려면 주성분 분석에서 생략된 변수들로만 학습을 해야한다. 그러나 다른 RF prove 변화에 관련된 오류는 성공적으로 발견되었다.

VI. 결 론

고집적 반도체제작 환경에서 생산성을 생각해보면 비 정상적인 공정과정을 실시간으로 찾아 내는 것은 수율을 높이기 위해 중요하다. 이 논문에서 SVM은 반작용적인 이온 식각에서 run-to-run 오류발견을 위한 도구로서 제안되었다. SVM의 효율적인 오류검출 능력을 증명하기 위해 진보된 공정제어부분에 분류와 회귀기능을 도입하였다. 생산라인으로부터 요구된 RIE 도구 데이터는 59개 변수들로 구성되어있다. 그리고 각각의 변수들은 초당 10개의 데이터를 수집하였다. 주성분 분석(principal component analysis)은 이 데이터의 차원을 줄이기 위해 실시간으로 사용되었다. 주성분 분석에서는 11개의 시스템 파라미터를 선택하여 모델을 구성하여 실험하였다.

반작용적인 이온 식각도구는 데이터에 적용된 LPL과 UPL 구간에 안에서 수행된다. 그 결과로 0%의 오류발견이 되었으나, TT_04 과 TT_05 런 (missed alarm)은 오류는 발견할 수 없었다. 이 두 개의 런들은 단순히 오류를 만들기 위한 요소가 부족했기 때문이다. 향후 연구에는 오류발견과 다변량 모델링에 이용되는 변수들을 세밀하게 분류하여 오류발견 능력을 개선시킬 수 있을 것이다.

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] S Hong, J. Park and S. Han, "Incipient Fault Detection of Reaction Ion Etching Process" *Trans. EEM*, Vol. 6, No. 6, pp. 262-271, 2005.
- [4] 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.
- [5] G. Barna, "APC in the Semiconductor Industry; History and Near Term Prognosis," in *Proc. IEEE/SEMI Adv. Semi. Manufac. Conf.*, pp. 364-369. 1996.
- [6] B. Goodlin, D. Boning and H. Sawin, "Simultaneous Fault Detection and Classification for Semiconductor Manufacturing Tools," in *Proc. Int. Symposium on Plasma Processing XIV*, pp. 415, 2002
- [7] H. Yue, S. Qin, R. Markle, C. Nauert, and M. Gatto, "Fault Detection of Plasma Etchers Using Optical Emission Spectra," *IEEE Trans. Semi. Manufac.*, Vol. 13, No. 3, pp. 374-385 2000.
- [8] 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.
- [9] Jolliffe, *Principal Component Analysis*, New York, NY: Springer-Verlag, 1986.
- [10] V. N. Vapnik, *The Nature of Statistical Learning Theory*, New York: Springer-Verlag, 1999.
- [11] B. Scholkopf, J. Platt, J. Shawe-Taylor, A. Smola and R. Williamson, "Estimating the support of a high-dimensional distribution" *Neural Computation*, Vol. 13, pp. 1443-1471, 2001.
- [12] L. J. Cao, E. Francis and H. Tay, "Support vector machine with adaptive parameters in financial time series forecasting," *IEEE Trans. Neural Networks*, Vol. 14., No. 6, pp. 1506-1518, 2003.

저자소개



박 영 국 (Young-Kook Park)

명지대학교 전기공학 학사
명지대학교 정보공학 석사과정
차세대전력기술연구센터 연구원

※관심분야: 반도체 공정, APC, 인공지능, SoC



홍 상 진 (Sang Jeen Hong)

명지대학교 전기전자공학부 학사
Georgia institute of Technology, MS
Georgia institute of Technology, PhD

일본 동북대학교 외국인 특별연구원

명지대학교 전자공학과 조교수

※관심분야: 반도체 공정, APC, 인공지능



한 승 수 (Seung Soo Han)

연세대학교 전기공학과 학사
연세대학교 전기공학과 석사
Georgia institute of Technology, PhD

명지대학교 정보공학과 부교수(현재)

차세대전력기술연구센터 연구원

※관심분야: 반도체 공정, APC, 인공지능, SoC