
Neural Networks을 이용한 Reactive Ion Etching 공정의

실시간 오류분류 및 검출에 관한 연구

유경한, 이송재, 소대화, 홍상진*

명지대학교 전자공학과

Real-time Fault Detection and Classification of Reactive Ion Etching Using Neural Networks

Kyung-Han Ryu, Song-Jae Lee, Dea-Wha Soh and Sang-Jeen Hong*

Department of Electronic Engineering

Myongji University, 38-2 Nam-dong, Youngin city, Gyeonggi-do 449-728, Korea

*E-Mail: samhong@mju.ac.kr

abstract

차세대 반도체 공정을 위한 많은 노력 중 Reactive Ion Etching(RIE)에 대한 연구의 중요성은 계속되고 있으며, 현재 제조공정 라인에서는 공정상의 오류를 줄이는 노력에 주목 하고 있다. 본 논문에서는 이러한 점을 고려하여 반도체 제조 장비에서 발생하는 실시간 데이터에 대해 신경망을 이용하여 각 장비파라미터의 허용범위를 검출하고, 제안된 방법의 성능평가를 위하여, 생산라인에서 수집된 데이터를 활용하였다. 기존의 통계적 공정제어(SPC) 제서 지시되는 방법이 아닌 신경망 모델을 통하여 random variability를 고려한 control limit을 제시한다.

keywords

fault detection and classification, neural network

I. 서론

반도체 제조 공정 장비의 상태가 시간에 따라 변화하는 동적 상황 하에서 장비 condition을 감지하고, 장비의 상태를 확인 하는 것은 원하는 깊이만큼 정확하게 Etching을 하기 위해서 매우 중요하다.

본 논문에서는 여러 개의 반도체 제조 공정중 RIE(Reactive Ion Etching)의 생산성을 향상시키기 위한 실시간 감시시스템을 지능화 하는 방법에 관하여 기술한다. 반도체 생산 장비의 실시간 감시 시스템의 대표적인 접근 방법에는 실시간 계측에 의한 방법[1,2] 예측 모델에 의한 방법[3], 그리고 패턴인식에 의한 방법[4]이 있다. 첫 번째 방법은 생산 장치가 웨이퍼를 가공하는 처리와 가공된 정도를 화학 또는 광학적으로 측정하는 작업을 병행하는 방법이다. 이 방법은 모든 생산 장치에 대하여 측정 장치를 병합해야 하므로 생산 원가를 증가시키는 단점을 가지고 있다. 두 번째 방법은 처리를 위한 인자들과 계측 값 사이의 관계를 함수로 표현한 다음, 입력되는 인자값으로부터 계측 값을 예측 하는 방법이다. 이 방법은 두 인자들 사이의 관계를 정의 하는

함수를 정확하게 표현하는 것이 어렵다는 것이 문제점이다. 세 번째 방법은 사전에 수집된 계측 값과 이때의 상태자료들을 신경망과 같은 패턴인식 모델에 학습 시킨 후, 입력된 자료와 학습된 상태자료를 비교하여 가장 유사한 상태자료가 가지는 계측값을 출력하는 방법이다. 본 논문에서는 RIE의 출력자료를 조합하여 학습시키고, 정상여부를 판단하는 지능형 실시간 감시 시스템을 제안 한다.

학습은 SOM(Self Organizing Maps) 모델을 사용한 군집화을 선행 한 후, 정상인 모델을 도출하기 위해서 BP(Back Propagation) 모델을 사용하였다. 이렇게 얻어진 정상 모델 10개를 가지고 정상의 범위를 도출 하여 오류검출을 하고자 한다.

II. 알고리즘

II- 1. SOM(Self Organizing Maps)

SOM은 그림 1에서 보는 바와 같이 2개의 층으로 이루어져 있다.

첫 번째 층은 입력 층이고, 두 번째 층은 경쟁 층인데 2차원의 격자로 되어 있다.

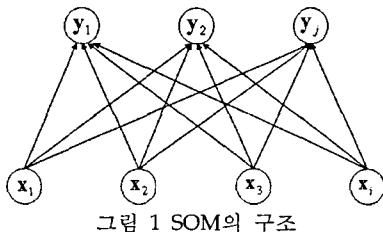


그림 1 SOM의 구조

모든 연결들은 첫 번째 층에서 두 번째 층의 방향으로 되어 있으며 두 번째 층은 완전 연결되어 있다. 각각의 뉴런들은 연결 강도 벡터와 입력벡터가 얼마나 가까운가를 계산한다. 각 뉴런들은 서로 경쟁하는데 거리가 가까운 뉴런이 선택되고 출력된다. 알고리즘은 다음과 같은 단계를 거친다.

- [학습단계1] 연결 강도를 초기화 한다. N개의 입력으로부터 M개의 출력 뉴런 사이의 연결 강도를 작은 값의 임의수로 초기화 한다. 초기의 이웃반경은 모든 뉴런이 포함될 수 있도록 충분히 크게 잡았다가 점차로 줄어든다.
- [학습단계2] 새로운 입력 벡터를 제시 한다.
- [학습단계3] 입력벡터와 모든 뉴런들 간의 거리를 계산 한다. 입력과 출력 뉴런 j 사이의 거리 d_j 는 식1과 같이 계산 한다.

$$d_j = \sum_{i=0}^{N-1} (X_i(t) - w_{ij}(t))^2 \quad (1)$$

여기서 $X_i(t)$ 는 시각 t 에서의 I번째 입력벡터이고 $w_{ij}(t)$ 는 시각 t 에서의 I번째 입력벡터와 j 번 째 출력 뉴런 사이의 연결 강도이다.

- [학습단계4] 최소 거리에 있는 출력 뉴런을 선택 한다. 최소거리 d_j 인 출력 뉴런 j^* 를 선택 한다.
- [학습단계5] 뉴런 j^* 와 그 이웃들의 연결강도를 재조정 한다. 뉴런 j^* 와 그 이웃 반경내의 뉴런들의 연결강도를 식2에 의해 재조정 한다.

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(x_i(t) - w_{ij}(t)) \quad (2)$$

여기에서 j 는 j^* 의 이웃 반경내의 뉴런이고 i 는 0에서 N-1까지의 정수값이다. α 는 0과 1사이의 값을 가지는 이득항 인데 시간이 경과함에 따라 점차 작아진다.

- [학습단계6] 단계2로 돌아가서 각 단계를 반복 한다. 본 논문에서 SOM은 RIE 장비에서 나오는 실시간 data를 효율적으로 처리하기 위해서 군집화를 하는데 사용되었다.

II- 2. BP (Back propagation)

백프로퍼게이션 학습 알고리즘은 기울기를 따

라가는(gradient descent)방법인데, 기본적인 구조는 다음과 같다.

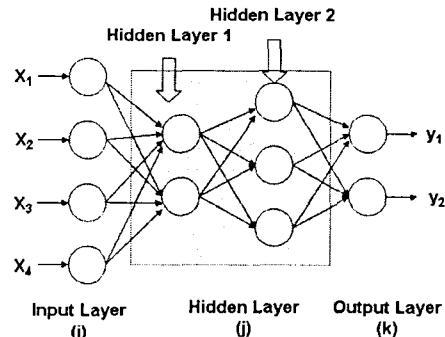


그림3 BP (Back propagation)의 구조

입력 층의 각 유닛에 입력 데이터를 제시 하면 이 신호는 각 유닛에서 변환되어 중간층에 전달되고 최종적으로 출력 층으로 나오게 된다. 이 출력 값과 원하는 출력 값을 비교하여 그 차이를 감소시키는 방향으로 연결강도를 조정 하고, 상위층에서 역전파하여, 하위 층에서는 이를 근거로 다시 자기 층의 연결 강도를 조정해 나간다.[5] 입력 층에 주어진 입력패턴이 출력 층에 전파되면서 변한 출력을 목표패턴과 비교한다. 출력된 패턴이 목표패턴과 일치 하는 경우에는 학습이 일어나지 않는다. 그렇지 않은 경우 학습을 계속하게 된다. 학습과정은 그림 4와 같다.

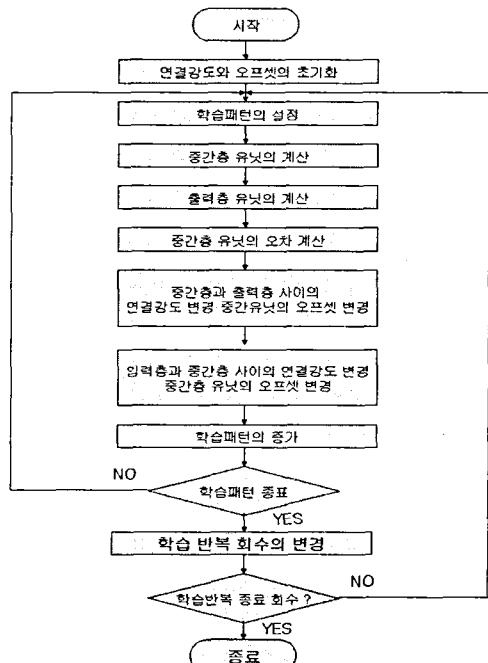


그림4 BP 알고리즘의 학습과정

본 논문에서 BP는 정상이라고 판단되는 입력 data를 학습하여 정상 패턴을 도출 하는 목적으로 사용되었다.

3. Experiment

III- 1. Data 습득

Data는 RIE에 사용되는 59개의 인자 중에서 PCA (Principal Component Analysis)에 의해서 11개의 유효한 인자를 선별하여 1/10 초마다 시계열로 샘플링 하여 2260개 단위로 처리 하였다.[6]

III- 2. 실험

실험의 과정은 그림5 와 같다.

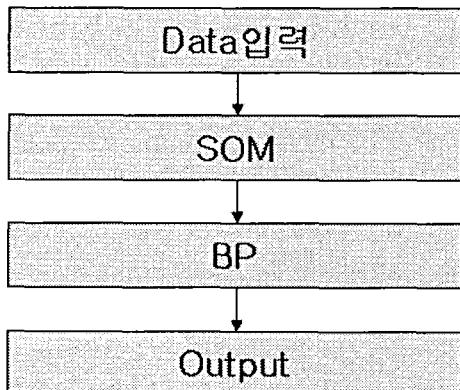


그림 5 시스템 개요도

실험은 PCA에 의해서 얻어진 유효한 인자들에서 얻어진 시계열 data 중에서 원하는 만큼 정확하게 식각하도록 하는 10개의 정상 인자값들을 입력 data로 SOM을 사용하여 군집하고, BP 학습을 통해서 10 개의 정상 패턴을 구하였다. 이렇게 구해진 정상 패턴들 중에서 최대값과 최소값을 사용하여 정상의 허용 범위를 도출 하였다. Test를 위해 Applied Materials etcher로부터 얻어진 실제 data를 사용 하여 평가 하였다. 결과는 다음과 같다.

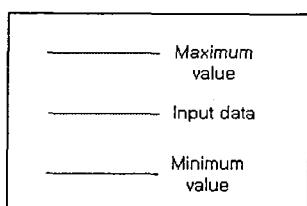


그림6 범례

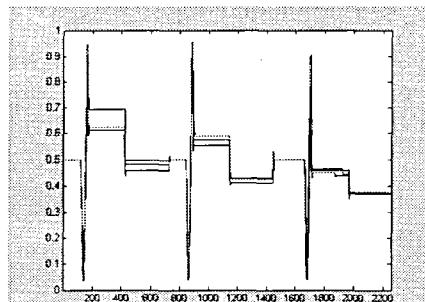


그림7 Source RF match(1~2256) 전체그림

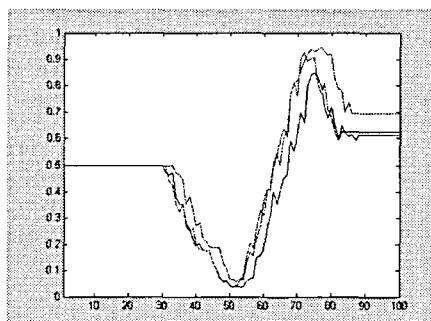


그림8 Source RF match(90~230) 부분그림

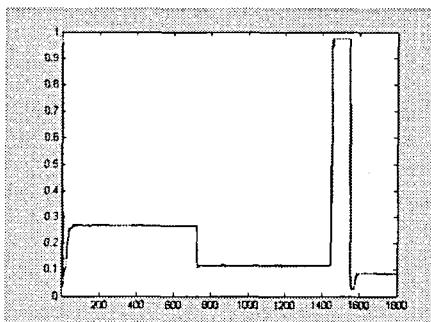


그림9 Throttle valve(1~2256) 전체그림

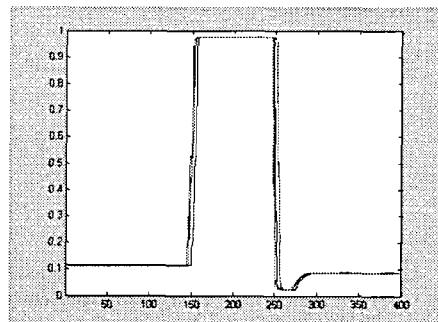


그림10 Throttle valve(1300~1700) 부분그림

그림6은 Source RF match의 전체구간에서의 결과 그림이고, 그림7은 그림6에서 변화가 심한 900~230구간을 부분적으로 확대한 그림이다. 같은 방법으로 그림8은 Throttle valve의 전체구간에서의 그림이고, 그림9는 1300~1700구간의 확대 그림이다.

IV 결론

10개의 정상인 모델 중, 최고값과 최소값을 구하여 그 값의 범위를 정상의 범위결정 하였다. 이렇게 결정한 정상의 범위를 가지고 실제 RIE 공정의 data를 Test 한 결과 정상과 오류를 판단 할 수 있었다. 실험을 통해서 NN(Neural Network)을 이용하여 통계적 공정 방법과 같은 정상 허용범위를 도출 할 수 있다는 사실을 확인 하였다.

향후연구의 방향은 그래프가 급격하게 변화하는 구간은 조금 더 정상 허용범위를 넓게 해서 공정시에 false alarm줄이고, 변화가 없이 평평한 구간은 허용범위의 폭을 줄여서 조금 더 정확한 품질의 RIE를 할 수 있는 시스템을 개발 하는 것이다.

References

- [1] Sylvie Bosch-charenay, Jiazhan Xu, John Haigis, Peter A. Resenthal, Peter Solomon, and James M. Bustillo, "Real-time etch-depth measurements of MEMS devices," *Journal of Microelectromechanical systems*, Vol.110, No.2, pp.111~117, April, 2002.
- [2] T. J. Knight, D. W. Greve, X. Cheng and B. H. Krogh, "Real-time multivariable control of PECVD silicon nitride film properties," *IEEE Transaction on Semiconductor Manufacture*, Vol.10, No.1, pp.137-145, February, 1997.
- [3] T.L Vincent, P.P. Khargonekar and F. L. Terry, Jr., "An extended Kalman filtering-based method of processing reflectometry data for fast In-Situ Rate Measurements," *IEEE Transaction on Semiconductor Manufacture*, Vol.10, No.1, pp.137-145, February, 1997.
- [4] P. J. O'Sullivan, J. Martinez, J. Durham and S. Felker, "Using UPM for real-time multivariate modeling of semiconductor manufacturing equipment," *SEMATECH APC/AEC Workshop VII*, New Orleans, Louisiana, pp.5~8, November, 1995.
- [5] 김 대수, "신경망 이론과 응용(I)," *하이테크정보*, 1993.
- [6] Chein-I Chang, Qian Du, "Interference and Noise-Adjusted Principal Components Analysis" *IEEE Transactions on geoscience and remote sensing*, VOL. 37, NO. 5, SEPTEMBER 1999.