
Neural Networks을 이용한 Reactive Ion Etching 공정의 실시간 오류 검출에 관한 연구

유경한 · 이송재 · 소대화 · 홍상진*

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*

요 약

본 논문은 정수장에서 사용하는 응집제의 종류를 결정하기 위한 시스템 개발에 관한 내용이다. 정수장은 여러 단위 처리장으로 구성되며, 불순물을 제거하기 위하여 혼화지에서 응집제를 주입하여 침전을 시킨다. 현재까지 응집제 결정을 위해 Jar-test를 이용하는데, 이 방법은 사람의 주관적인 판단에 의존하므로 실험 오차가 발생할 수 있다. 특히 정수장의 자동화를 위한 시스템 개발에서 가장 큰 걸림돌로 작용하고 있다. 본 논문은 이러한 문제점을 해결하기 위하여 로드맵에 기초한 데이터마이닝 기법을 이용하여 응집제를 선택할 수 있는 제어기를 개발하였다. 제어 규칙은 클러스터링 기법으로 도출하였는데, 군집의 초기 값과 개수는 통계적 지수 값을 사용하여 결정하였다.

ABSTRACT

In coagulant control of water treatment plants, rule extraction, one of datamining categories, was performed for coagulant control of a water treatment plant. Clustering methods were applied to extract control rules from data. These control rules can be used for fully automation of water treatment plants instead of operator's knowledge for plant control. To perform fuzzy clustering, there are some coefficients to be determined and these kinds of studies have been performed over decades such as clustering indices. In this study, statistical indices were taken to calculate the number of clusters. Simultaneously, seed points were found out based on hierarchical clustering. These statistical approaches give information about features of clusters, so it can reduce computing cost and increase accuracy of clustering. The proposed algorithm can play an important role in datamining and knowledge discovery.

키워드

Coagulant control, rule extraction, datamining, rule-based control

I . 서 론

반도체 회로의 집적도와 밀도가 급격히 증가함으로써 생산성 향상을 위한 반도체 공정이 부각 되고 있다. 일반적으로, 실시간으로 반도체 제조 공정 장비의 상태를 감지하여 확인하는 것은 원하는 깊이만큼 정확하

게 Etching을 하기 위해서 매우 중요하다. 기존 오프라인 공정에서 SPC (statistical process control)을 사용하여 장비 상태를 감지하고 있으나, SPC를 실시간으로 구현 경우 공정단계마다 다른 control limit를 사용해야하는 복잡성을 보이고 있다[1].

본 논문에서는 여러 가지 반도체 제조 공정 중 RIE(Reactive Ion Etching)의 생산성을 향상시키기 위한 실시간 감지 시스템을 지능화하는 하는 방법을 기술한다. 반도체 생산 장비의 실시간 감지 시스템의 대표적인 접근 방법에는 실시간 계측에 의한 방법[2,3], 예측 모델에 의한 방법[4], 그리고 패턴인식에 의한[5,6] 방법이 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 인자 값으로부터 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 계측 값을 출력하는 방법이다. 본 논문에서는 RIE의 출력자료를 조합하여 학습시키고, 정상여부를 판단하는 지능형 실시간 감지 시스템을 제안 한다.

기존의 BP(Back-Progation)을 사용한 실험은 그림 1과 같이 하위층과 상위층의 차이가 크기 때문에, 상위층의 값을 제대로 표현하지 못하고 있다. 이 문제점을 보완하기 위해 무감독 학습 SOM(Self Organizing Maps)과 감독학습 BP (Back Propagation)학습을 결합한 방법을 제안한다. SOM 사용하여 군집화를 한 후, 이를 바탕으로 정상인 모델을 도출하기 위해서 BP로 학습한다. 이렇게 얻어진 정상 모델 10개를 가지고 정상의 범위를 도출하여 RIE공정에 사용되는 parameter들의 오류검출을 하고자 한다.

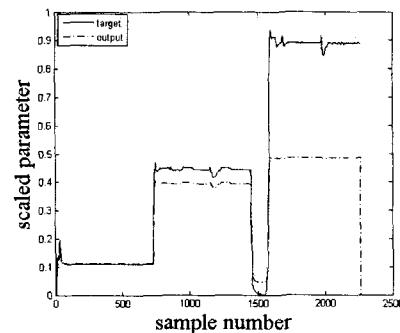


그림 1. BP만을 사용한 시계열 예측
Figure 1. Prediction of time series data using BP

II. 알고리즘

2.1. SOM(Self Organizing Maps)

Kohonen에 의한 개발한 SOM(self-organizing map)은 위상 개념을 지닌 지도의 형태를 표현하여 데이터를 압축하거나, 군집하는데 많이 사용되고 있다. SOM은 무감독 학습을 하며, 그림 2와 같이 입력층과 출력층 2개가 격자 형태로 연결된 구조이다.

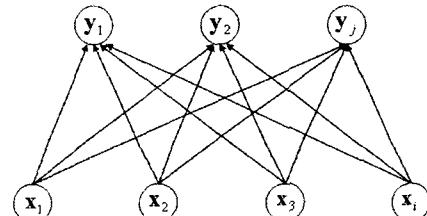


그림 2. SOM의 구조
Figure 2. Structure of SOM

모든 연결들은 첫 번째 층에서 두 번째 층의 방향으로 되어 있으며, 두 번째 층의 완전 연결되어 있다. 각각의 뉴런들의 연결 강도 벡터와 입력벡터가 얼마나 가까운가를 일반적인 신경망과 마찬가지로 입력노드와 입력과 출력간의 연결강도를 나타내는 가중치를 이용하여 계산한다. 각 뉴런들은 서로 경쟁해서 거리가 가까운 뉴런이 선택되고 출력된다(Winner-take- All). 수식은 다음과 같다.

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

여기서 $X_i(t)$ 는 시각 t 에서의 i 번째 입력벡터이고 $w_{ij}(t)$ 는 시각 t 에서의 I 번째 입력벡터와 j 번째 출력 뉴런 사이의 연결 강도이다. 여기서 최소 거리가 있는 출력 뉴런을 선택하여 가중치를 아래 식과 같이 업데이트를 한다.

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

여기서, α 는 0과 1사이의 값을 가지는 이득 값으로 가중치의 변화율을 조정하고, 시간이 경과함에 따라 점차 작아진다.

본 논문에서 SOM은 RIE 장비에서 나오는 실시간 data를 효율적으로 처리하기 위해서 비슷한 층끼리 군집화를 하는데 사용되었다.

2.2. BP (Back propagation)

백프로퍼게이션 학습 알고리즘은 기울기를 따라가는(gradient descent)방법인데, 기본적인 구조는 다음과 같다.

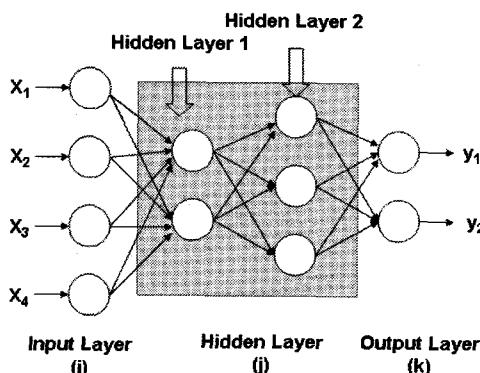


그림 3. BP (Back propagation)의 구조
Figure 3. Structure of BP

입력 층의 각 유닛에 입력 데이터를 제시 하면 이 신호는 각 유닛에서 변환되어 은닉층 (hidden layer)에 전달되고 최종적으로 출력층 (output layer)으로 전달된다.

$$z_j = f\left(v_{0j} + \sum_{i=1}^n x_i v_{ij}\right) \quad (3)$$

$$y_k = f\left(w_{0k} + \sum_{j=1}^p z_j w_{jk}\right) \quad (4)$$

z_j 와 y_k 는 은닉층과 출력층에서 활성함수 $f(x)$ 에 의해 계산되어 출력되는 값이다. v_{ij} 는 입력층과 은닉층의 연결강도이고, w_{jk} 는 은닉층과 출력층사이의 연결 강도를 의미한다.

이렇게 계산된 출력 값(y_k)과 원하는 출력 값(t_k)을 비교하여 그 차이를 감소시키는 방향으로 연결강도를 조정 하고, 상위층에서 하위층으로 역전파하여, 하위 층에서는 이를 근거로 다시 자기 층의 연결 강도를 재조정해 나간다[7]. 입력 층에 주어진 입력패턴이 출력 층에 전파되면서 변화된 출력을 목표패턴과 비교하는 과정을 수행한다. 수식은 아래와 같다.

$$\delta_k = (t_k - y_k)y_k(1 - y_k) \quad (5)$$

$$\Delta w_{jk} = \alpha z_j \delta_k \quad (6)$$

$$\delta_j = \left(\sum_{k=1}^m \delta_k w_{jk} \right) z_j(1 - z_j) \quad (7)$$

$$\Delta v_{ij} = \alpha x_i \delta_j \quad (8)$$

식(5),(6)은 은닉층과 출력층 사이의 연결강도 조절하는 식이며, 식(7),(8)은 입력층과 출력층 사이의 연결 강도를 조절하는 식이다.

정상모델을 통해서 parameter의 정상허용범위를 얻기 위해 사용되어진 BP의 전체 학습과정은 그림 4와 같다.

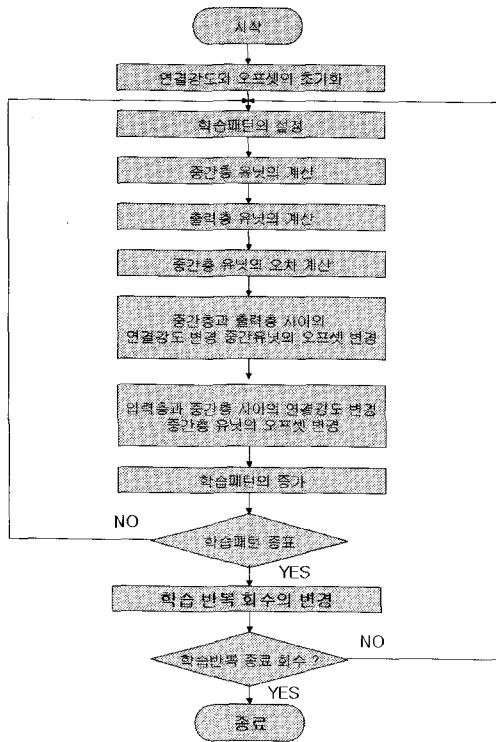


그림 4. BP 알고리즘의 학습과정
Figure 4. Training flowchart of BP algorithm

III. Experiment

3.1. Data 습득

Data는 RIE에 사용되는 59개의 인자 중에서 PCA(Principal Component Analysis)에 의해서 11개의 유효한 인자를 선별하여 1/10 초마다 시계열로 샘플링하여 2260개단위로 처리하였다 [8].

3.2. 실험

실험의 과정은 그림5와 같이 입력 data를 PCA를 통해서 전처리 과정을 거치고 SOM과 BP를 통해서 결과를 얻었다.

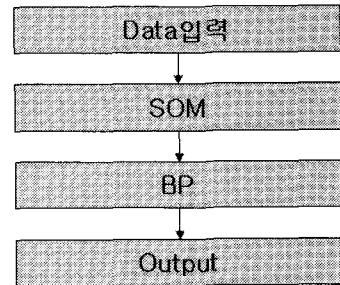


그림 5. 시스템 개요도
Figure 5. flowchart of suggested system

실험은 PCA에 얹어진 각 인자에 대해 10개의 정상 패턴들을 입력 data로 SOM에 사용하여 군집하였다. 군집된 데이터를 3-9-1구조 BP 학습을 통해서 10 개의 정상 패턴에 대해 학습을 통한 출력모델의 최대값과 최소값을 통해서 RIE공정에서의 control limit를 도출하였다.

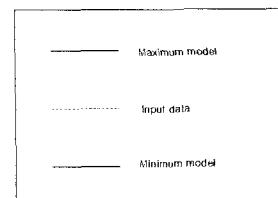


그림 6. 범례
Figure 6. Index to figures 7~10

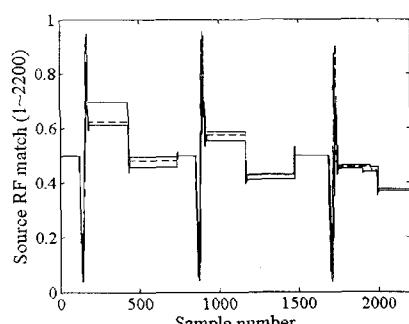


그림 7. Source RF match(1~2200) 전체그림
Figure 7. Source RF match whole section

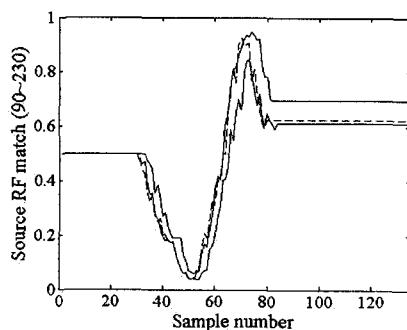


그림 8. Source RF match(90~230) 부분그림
Figure 8. Source RF match part(90~230)

도출된 control limit을 가지고 성능 Test를 위해 Applied Materials etcher로부터 얻어진 실제 data를 사용하여 평가 하였다.

결과는 그림 7~10과 같다.

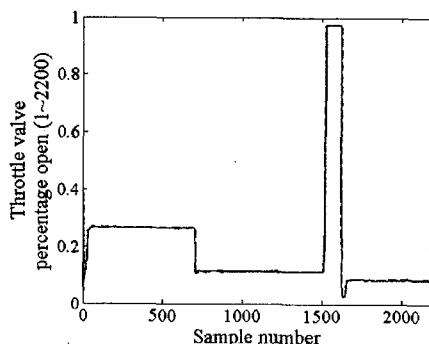


그림 9. Throttle valve(1~2256) 전체그림
Figure 9. Throttle valve whole section

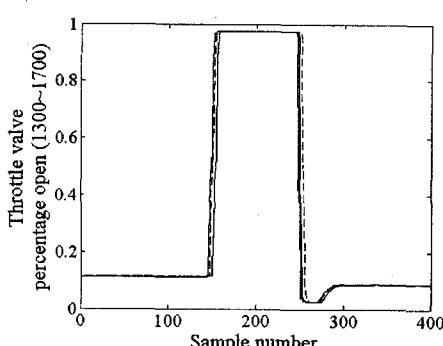


그림 10. Throttle valve(1300~1700) 부분그림
Figure 10. Throttle valve part(1300~1700)

그림7은 Source RF match의 전체구간에서의 결과 그림이고, 그림8은 그림7에서 변화가 심한 900~230구간을 부분적으로 확대한 그림이다. 같은 방법으로 그림9는 Throttle valve의 전체구간에서의 그림이고, 그림10은 1300~1700구간의 확대 그림이다.

IV. 결 론

10개의 모델 중, 최대값과 최소값을 나타내는 모델들을 구하여서 그 값의 범위를 control limit으로 결정하였다. 이렇게 결정된 정상의 범위를 가지고 실제 RIE공정의 data를 Test 한 결과 정상과 오류를 판단할 수 있었다. 실험을 통해서 NN(Neural Network)을 이용하여 통계적 공정 방법과 같은 정상 허용범위를 도출할 수 있다는 사실을 확인 하였다. 수행결과 통계적 공정 제어에서 사용하는 control limit 보다 범위가 좁아서 더욱 세밀하고, 정확도를 요하는 RIE공정에 적합함을 확인 할 수 있었다. 그러나 전체 110개의 모델 중에서, 정상의 범위가 좁아서 정상을 오류로 판단하는 false alarm을 3곳에서 발견 할 수 있었다.

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] Michael D. Baker, Christopher, Himmel, and Gary S. May "Time Series Modeling of Reactive Ion Etching Using Neural Network," *IEEE Transactions on Semiconductor Manufacturing*, Vol.8, No.1, pp.62~71, Feb 199 [5].
- [2] 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.
- [3] 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.
- [4] 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.
- [5] 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.
- [6] Sang Jeen Hong and Gary S. May, "Neural Network-Based Real-Time Malfunction Diagnosis of Reactive Ion Etching Using In Situ Metrology Data," *IEEE Transactions on semiconductor manufacturing*, VOL. 17, NO.3, AUGUST 2004.
- [7] 김 대수, "신경망 이론과 응용(I)," 하이테크정보, 1993.
- [8] Chein-I Chang and Qian Du, "Interference and Noise-Adjusted Principal Components Analysis," *IEEE Transactions on geoscience and remote sensing*, VOL. 37, NO. 5, SEPTEMBER 1999.

저자소개



소대화 (Dea-Wha, Soh)

한국 과학기술단체총연합회 이사
중국 동북대학교 겸직 교수
명지대학교 반도체 기술 센터장
명지대학교 전자공학과 교수

※ 관심분야 : 반도체 재료 및 소자



홍상진 (Sang Jeen, Hong)

명지대학교 전기전자공학부 졸업
Georgia Institute of Technology, MS
Georgia Institute of Technology,
Ph.D
명지대학교 전자공학과 조교수

※ 관심분야 : 반도체 공정, APC, 인공지능



유경한 (Kyung-Han, Ryu)

명지대학교 전자공학과 졸업
(공학사)
명지대학교 전자공학과 대학원
석사과정

※ 관심분야 : 반도체 공정, SPC, APC



이송재 (Song-Jae, Lee)

명지대학교 전기정보제어공학과
졸업(공학사)
명지대학교 전기정보제어공학과
대학원 석사과정

※ 관심분야 : 신경망, 반도체공정, 신호처리분야