

## Atomic Force Microscopy와 신경망을 이용한 플라즈마 진단

## Plasma Diagnosis by Using Atomic Force Microscopy and Neural Network

박민근\*, 김병환\*\*

(Mingun Park, Byungwhan Kim)

**Abstract** - A new diagnosis model was constructed by combining atomic force microscopy (AFM), wavelet, and neural network. Plasma faults were characterized by filtering AFM-measured etch surface roughness with wavelet. The presented technique was evaluated with the data collected during the etching of silicon oxynitride thin film. A total of 17 etch experiments were conducted. Applying wavelet to AFM, surface roughness was detailed into vertical, horizontal, and diagonal components. For each component, neural network recognition models were constructed and evaluated. Comparisons revealed that the vertical component-based model yielded about 30% improvement in the recognition accuracy over others. The presented technique was evaluated with the data collected during the etching of silicon oxynitride thin film. A total of 17 etch experiments were conducted.

**Key Words** : Plasma, Diagnosis, Wavelet, Neural network, Atomic force microscopy

## 1. 서론

플라즈마는 집적회로 제조를 위한 미세 박막의 증착과 식각에 핵심적으로 이용이 되고 있다. 공정의 질 (Quality)을 높이고 장비가동률을 증진하기 위해서는 플라즈마에 대한 엄격한 감시와 진단이 요구된다. 플라즈마는 주로 Optical emission spectroscopy (OES)나 Impedance 센서와 같은 in-situ 진단기구로 수집한 데이터를 감시한다 [1-2]. Ex-situ 진단 방식은 공정후 수집되는 박막표면에 은닉된 정보를 이용하는 진단방식이며, 식각공정 진단에 응용된 바 있다 [3]. 이 경우 신경망이 진단을 위한 Calibration 모델을 개발하는데 이용되었지만, 입력변수가 적어 효과적인 진단을 수행하지 못했다. 진단 효율을 높이기 위해서는 다변수 다량의 입력패턴이 요구된다.

본 연구에서는 신경망, 식각공정후의 박막표면 거칠기 (Roughness), 그리고 웨이브릿을 이용하여 새로운 진단모델을 개발하였다. 박막 거칠기는 Atomic Force Microscopy (AFM)를 이용해 측정하였다. AFM 영상에 이산치 웨이브릿 변환(Discrete wavelet transformation-DWT) [4]을 적용하였으며 변환정보가 신경망의 입력으로 이용되었다. DWT 적용으로 AFM 영상은 세 성분, 즉 수직, 수평, 그리고 대각 성분으로 미세 분화되었으며, 각 성분에 대한 진단 모델을 개발하고 평가하였다. 제안된 기법은 실리콘 옥시나이트라이드 (SiON) 박막의 식각공정에 적용하여 평가하였다

## 2. 실험 데이터

증착된 SiON박막을 그림 1에 도시된 ICP 식각 시스템을 이용하여 식각하였다. 챔버안에서 발생한 플라즈마는 석영유리에 의해 Planar-coupled된 코일과 분리된다. 원통모양의 챔버는 각각 80 cm의 너비와 40 cm의 높이를 가진다. 식각 가스를 공급하기에 앞서 챔버안은 (TUROVAC 3430MC)와 (Edward High Vacuum E2M40)펌프를 이용하여 배기되며, 약  $10^{-6}$  Torr의 기본압력을 유지한다. 공정압력은 throat 밸브를 이용하여 조절하였고, 공정압력 측정을 위해 Baratron Gauge, Pirany Gauge, 그리고 Penning gGauge를 이용하여 조절하였다. 반응 가스의 미세조절을 위해 각각 가스관에 MFC를 장착하여 유량을 조절하였다. 정전이나 기타의 문제로 인한 반응관의 오염을 제거하기 위해 모든 밸브를 공기 잠금 (Air Lock)장치를 사용 안전도를 향상시켰다. 또한 홀더 내부에 냉각수를 공급하여 식각 공정 중 발생하는 온도 상승에 의한 장비의 손상을 최소화하였다.

실험에 사용된 SiON 박막은 PECVD로 증착되었다. Ni 마스크는 박막위에 PR패턴을 형성한 후 마그네트론 스퍼터링을 이용하여 Ni층을 0.15  $\mu\text{m}$  증착시킨 후 acetone으로 PR을 제거하여, Ni 마스크를 형성하였다. 그런 다음에, SiON 박막을  $\text{C}_2\text{F}_6$  플라즈마로 식각하였다. 식각 공정시간은 10분으로 설정하였다. 식각공정후 표면거칠기를 AFM으로 측정하였으며, 샘플 사이즈는  $5\mu\text{m} \times 5\mu\text{m}$ 이었다.

식각공정에 이용된 공정변수는 총 4개이며, 여기에는 소스 전력, 바리어스 전력, 압력, 그리고  $\text{C}_2\text{F}_6$  유량 등이다. 각 공정변수별로 4개의 고장을 발생하였으며, 따라서 총 16개의 플라즈마 고장데이터 수집을 위한 실험을 수행하였다. 각 공정변수의 실험범위는 소스전력 400-1000W, 바이어스 전력

## 저자소개

\* 박민근: 世宗大學 電子工學科 碩士課程

\*\* 김병환: 世宗大學 컴퓨터工學部 副教授 · 工博

30-90W, 압력 6-12 mTorr, 그리고  $C_2F_6$  유량 30-60 sccm 등이다. 한편 공정의 정상상태에 해당하는 각 공정변수의 중간 (즉 소스전력 700W, 바이어스 전력 60W, 압력 9 mTorr,  $C_2F_6$  유량 45 sccm)에 해당하는 실험을 수행하여 모델개발을 위한 학습데이터에 포함시켰다. 단 모델의 인식성능을 테스트하는데 있어서는 정상상태 패턴을 배제한 16개의 고장패턴만 사용하였다.




그림 1. 유도결합형 플라즈마 식각 장비

### 3. 역전파 신경망

AFM 영상 인식기로서 역전파 신경망 (Backpropagation Neural Network-BPNN) [5]을 이용하였다. 은닉층은 1개이며, 학습규칙으로는 (1)과 같이 일반화된 델타규칙을 적용하였다.

$$W_{i,j,k}(m+1) = W_{i,j,k}(m) + \eta \Delta W_{i,j,k}(m) \quad (1)$$

여기서  $W_{i,j,k}$  는 (k-1)층의 j번째 뉴런과 k층의 i번째 뉴런사이의 연결강도 이고,  $\Delta W_{i,j,k}$  는 학습편차를 줄이기 위해 인가되는 웨이트의 변이며, 다음과 같이 정의 된다.

$$\Delta W_{i,j,k} = \frac{\partial E}{\partial W_{i,j,k}} \quad (2)$$

$\eta$  은 학습률을 지칭한다. 학습인자 중, 은닉층의 뉴런수만 2-17범위에서 증가시켰으며, 나머지 학습인자 (학습허용도, 초기웨이트 분포의 크기, 뉴런 활성화 함수경사들은 각 기 0.1,  $\pm 1$ , 그리고 1에 고정하였다. 학습인자들은 [6]에 세세히 설명되어 있다.

### 4. 인식 모델

AFM 영상을 웨이블릿 변환하는 과정을 설명한다. 그림 2 는 소스전력 400W, 바이어스 전력 60W, 압력 9 mTorr, 그리고  $C_2F_6$  유량 45 sccm에서 수집한 AFM 영상이다. AFM 이미지에 DWT를 적용하여 3 종류의 웨이블릿 성분을 얻었으며 변환 인자로 Scale level 1과 타입 1의 다우비치 함수가 사용되었다. Histogram 방법을 사용하여 표면거칠기 윤곽선

을 변환된 approximation 성분으로부터 추출하였다. DWT를 추출된 표면거칠기 윤곽선에 적용하였으며, 그 결과가 그림 3에 도시되어 있다.




그림 2. AFM 영상




그림 3. 추출된 윤곽선에 DWT 적용한 결과

그림 3의 각 수직, 수평, 그리고 대각성분에 대한 웨이블릿 계수들이 그림 4에 도시되어 있다.

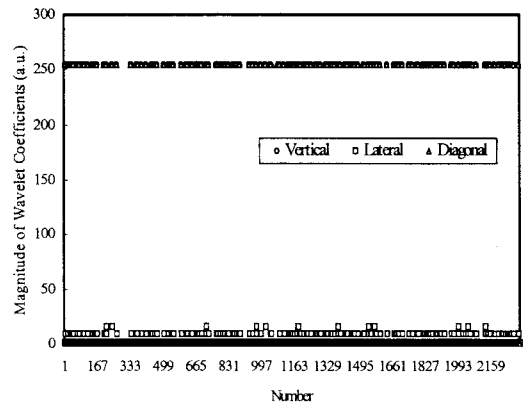


그림 4. 성분별 웨이블릿 계수 패턴

웨이브릿 계수들의 패턴은 플라즈마 조건에 따라 다르며, 따라서 플라즈마 고장상태를 감시하고 진단하기 위한 유용한 징후 (Symptom)로 이용할 수 있다.

## 참 고 문 헌

- [1] Stevenson J.O., Ward, P.P., Smith M. L., Markle R.J., "A Plasma Process Monitor/Control System". Surf. Interf. Anal. vol. 26, pp. 124-133, 1998.
- [2] Bose, F., Patrick R., Baltes H., "Measurement of Discharge Impedance for Dry Etch Process Control," SPIE vol. 2336, pp. 101-110, 1994.
- [3] Kim, B., May, G.S., "Real-Time Diagnosis of Semiconductor Manufacturing Equipment Using a Hybrid Neural Network Expert System," IEEE Trans. Comp. Packag. Manufact. Technol. vol. 20, no. 1, pp. 39-47, 1997.
- [4] Prasad L., Iyengar, S.S., Wavelet Analysis with Applications to Image Processing. CRC Press, 1997
- [5] Rummelhart, D.E., McClelland, J.L., Parallel Distributed Processing. MIT Press, Cambridge, 1986.
- [6] Kim, B., Park S., "An Optimal Neural Network Plasma Model: a Case Study," Chemometr. Intell. Lab. Syst. vol. 56, no. 1, pp. 39-50, 2001.

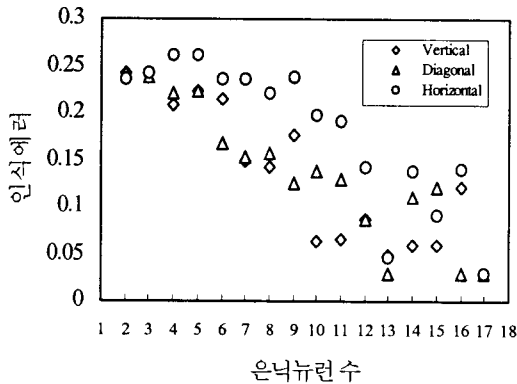


그림 5. 웨이브릿 성분별 진단 모델의 예측성능

DWT-SEM 프로파일의 수직성분은 2304개의 웨이브릿 계수로 구성되었으며, 이는 BPNN의 입력단의 뉴런수와 일치한다. 출력 뉴런수는 총 4개로 구성되며, 각 작은 공정변수의 수와 일치한다. 앞서 준비한 학습데이터를 이용하여 모델링한 후 테스트에러, 즉 인식에러가 그림 5에 도시되어 있다. 인식에러는 Root Mean Square Error (RMSE)로 계산되었다. 그림 5에서와 같이 일반적으로 뉴런수가 증가할 때, 인식에러는 감소하고 있다. 수직 성분 모델의 경우, 은닉뉴런수 17에서 최소 에러 (0.0216)을 보이고 있다. 수평과 대각성분 모델의 경우 은닉뉴런수 17개와 13개에서 최소에러 0.030과 0.029를 보였다. 결국, 수직방향 모델이 가장 작은 인식에러를 보였으며, 수평과 대각성분 모델 대비 그 향상도는 대략 30%였다.

## 4. 결 론

본 연구에서는 플라즈마 진단을 위한 새로운 진단 모델을 개발하였다. 진단 모델은 AFM, 웨이브릿, 그리고 신경망을 결합하여 개발하였다. 웨이브릿은 AFM 영상을 미세하게 세분화하는 데 응용하였다. 진단 성능을 인식에러와 인식률을 기초하여 평가하였으며, 수직성분에 대한 인식 모델이 가장 낮은 인식에러와 높은 인식률을 보였다. 소자제조현장에서 매 웨이퍼 공정시 테스트 패턴에 대한 AFM 영상의 취득이 가능할 때, 본 모델은 플라즈마 공정진단에 효과적으로 사용될 것이다.

## 감사의 글

본 연구는 산업자원부의 System IC 2010 사업과 University IT Research Center 사업의 지원으로 수행되었습니다.