

웨이블렛과 신경망을 이용한 플라즈마-유도 X-Ray Photoelectron Spectroscopy 고장 패턴의 인식

Recognition of Plasma-Induced X-Ray Photoelectron Spectroscopy Fault Pattern Using Wavelet and Neural Network

김수연*, 김병환**
Sooyoun Kim, Byungwhan Kim

Abstract - To improve device yield and throughput, faults in plasma processing equipment should be quickly and accurately diagnosed. Despite many useful information of ex-situ sensor measurements, their applications to recognize plasma faultshave not been investigated. In this study, a new technique to identify fault causes by recognizing X-ray photoelectron spectroscopy (XPS) using neural network and continuous wavelet transformation (CWT). The presented technique was evaluated with the plasma etch data. A total of 17 experiments were conducted for model construction. Model performance was investigated from the perspectives of training error, testing error, and recognition accuracy with respect to various thresholds. CWT-based BPNN models demonstrated a higher prediction accuracy of about 26%. Their advantages over pure XPS-based models were conspicuous in all three measures at small networks.

Key Words : Plasma Fault, X-ray Photoelectron Spectroscopy, Wavelet, Neural Network

1. 서론

플라즈마는 집적회로 제조를 위한 미세 박막의 증착과 식각에 핵심적으로 이용이 되고 있다. 공정의 질 (Quality)을 높이고 장비 가동률을 증진하기 위해서는 플라즈마에 대한 엄격한 감시와 진단이 요구된다. 플라즈마는 주로 Optical Emission Spectroscopy (OES) [1]나 Impedance 센서[2]와 같은 In-situ 진단 기구로 수집한 데이터를 감시한다. 한편, 플라즈마 공정 후에 수집되는 박막 표면상의 정보를 플라즈마 상태를 감시하고 진단하는 중요 정보가 은닉되어 있으며, 따라서 이를 이용한 감시/진단 기술의 개발이 요구된다. 관련 연구로, 식각 후 Scanning Electron Microscope로 수집된 패턴의 측면 프로파일 정보가 플라즈마 감시에 응용된 바 있다 [3]. 한편, X-ray 광전자 분광기 (XPS)는 공정 후 표면상의 화학적 상태 변이를 분석하는데 이용되며, 공정 조건에 따라 화학적 상태 변이는 매우 미세하고 복잡하게 변화한다. 따라서 XPS 패턴의 변화는 플라즈마 감시와 진단에 활용할 수 있지만, 아직 관련 연구가 보고된 바가 없다.

본 연구에서는 플라즈마 고장 진단을 위한 새로운 모델을 개발하였다. 본 모델은 XPS, 웨이브릿, 그리고 신경망을 결합하여 개발하였다. XPS 패턴 인식기로서 역전파 신경망 (Backpropagation Neural Network-BPNN) [4]을 이용하였다. 평가에 이용된 데이터는 실리콘 카바이드 (Silicon Carbide-SiC) 박막의 식각 공정에서 수집되었다.

2. 실험

그림 1은 식각 공정에 이용된 플라즈마 식각 장비를 도시하고 있다. 원통형 챔버의 반지름은 80 mm이고 높이는 40 mm이다. 식각 가스를 공급하기에 앞서 챔버 안은 두 펌프, 즉 Turbo (TUROVAC 3430MC)와 Rotary (Edward High Vacuum E2M40) 펌프를 이용하여 배기되며, 약 10^{-6} Torr의 기본압력을 유지한다. 가스 유입은 질량 유입 제어기 (Mass flow controller)로 정확히 조절되며, Baratron Gauge로 측정되는 압력은 Throttle 밸브로 제어 된다.




그림 1. 유도결합형 플라즈마 식각 장비

저자소개

- * 김수연 : 世宗大學 電子工學科 學士課程
- ** 김병환 : 世宗大學 컴퓨터工學部 副教授 · 工博

3. 결과 및 고찰

실험 패턴은 <0001> 방향성의 n-type, 2인치, 4H-SiC 웨이퍼로 제조하였다. 웨이퍼의 열전도성은 4.9 W/cm·K 이었다. Cr negative mask를 이용하여 Photo Resist (PR)를 형성하였다. Magnetron sputtering을 이용하여 패턴된 PR 위에 Ni 박막을 0.18 um 만큼 증착시킨 후, Acetone으로 PR를 제거하여, Ni Mask 층을 형성하였다. 그런 다음에, SiC 박막은 NF/CH₄ 플라즈마로 식각되었다. 식각 공정 시간은 5분으로 설정하였다. 실험 변수는 4개였으며, 여기에는 소스 전력, 바이어스 전력, 압력, 그리고 가스비였다. 플라즈마의 정상 상태에 해당하는 기준 조건은 소스 전력 800 W, 바이어스 전력 100 W, 압력 9 mTorr, 그리고 가스비는 0.6에 설정하였다. 기준 조건에서 각 공정 변수를 변화시키며 플라즈마 고장을 발생시켰다. 각 공정 변수별로 4개씩 고장을 발생시켰으며, 따라서 총 17개의 패턴 (1개의 정상 패턴과 16개의 고장 패턴)을 준비하였다. 식각 공정 후 박막 표면의 화학적 상태는 XPS (EscaLab 250)로 측정하였으며, Kinetic Energy의 범위는 686.1-1486.6 eV이었으며 0.1 eV 간격으로 수집하였다.




그림 2. 소스 전력의 변화에 따른 XPS 패턴 변화

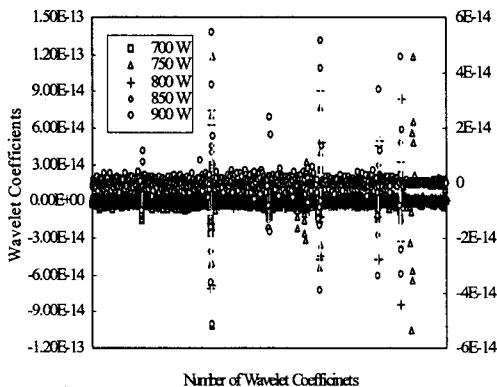


그림 3. 소스 전력의 변화에 따른 XPS의 웨이블릿 변환 데이터 패턴 변화

3.1 XPS 데이터의 CWT

그림 2는 소스 전력을 700에서 900 W까지 50 W씩 증가시키면서 수집한 XPS 패턴을 보이고 있다. 그림에서와 같이 각 소스 전력에 따라 패턴 모습이 다르며, 이는 플라즈마 진단에 매우 유용한 특징이다. 그림 2의 XPS 데이터에 연속적 웨이블릿 변환 (Continuous Wavelet Transformation-CWT)를 적용한 후의 결과가 그림 3에 도시되어 있다.

표 1. XPS 패턴으로 구성된 BPNN 진단기의 인식정확도

은닉층 뉴런수	Testing Error
3	0.367
4	0.264
5	0.269
6	0.193
7	0.039
8	0.038
9	0.038

표 2. CWT-XPS 패턴으로 구성된 BPNN 진단기의 인식정확도

은닉층 뉴런수	Testing Error
3	0.249
4	0.169
5	0.079
6	0.039
7	0.028
8	0.037
9	0.039

3.2 XPS 고장 패턴의 진단

진단기를 구성하기 위해 BPNN을 17개의 XPS (또는 CWT-XPS) 패턴으로 학습시킨 후, 구성된 진단기의 진단 성능을 기준 조건을 제외한 16개의 XPS 패턴으로 테스트하였다. 진단기의 입력은 801개의 XPS 요소로 구성되었으며, 출력단은 4개의 뉴런으로 구성되었다. 출력단의 각 뉴런은 플라즈마 고장의 원인이 되는 각 공정 변수에 해당한다. 진단기의 성능은 은닉층 뉴런수를 3에서 9까지 변화시키며 인식정확도와 진단정확도 측면에서 평가하였다. 다른 학습 인자인 학습 오차 한계, 초기 웨이트 분포의 크기, 활성화 함수의 경사는 각기 0.1, ±1.0, 그리고 1.0에 고정하였다. 학습인자에 대해서는 이전의 연구 [5]에 상세히 기술되어 있다. 인식정확도는 Root Mean Squared-Error (RMSE)로 계산하였다. 표 1과 2에 XPS와 CWT-XPS 패턴으로 개발된 진단기의 인식정확도가 은닉층 뉴런수의 함수로 정리되어 있다. 표 1에서와 같이 뉴런수의 증가에 따라 RMSE가 줄어들다가 뉴런수가 7이상인 경우에는 더 이상 줄어들지 않고 있다. 가장 작은 RMSE는 은닉층 뉴런수가 7,8,9에서 결정되었으며, 0.038 정도였다. CWT-XPS 패턴을 이용하여 개발한 BPNN 진단기

의 인식정확도가 표 2에 정리되어 있다. 표 1과 비교할 때 뉴런수가 3-6의 범위에서 훨씬 작은 RMSE를 보이고 있다. 가장 작은 RMSE는 뉴런수 7에서 결정되었으며, 해당 RMSE는 0.028이다. 이는 표 1에서 결정된 가장 작은 RMSE와 비교할 때, 대략 24%정도 감소된 수치이며, 이로써 CWT-XPS가 보다 정확한 진단기를 구성하는데 효과적임을 알 수 있었다.

한편 진단정확도는 다음과 같이 임계점 (Threshold)의 함수로 평가하였다.

$$|MP - FS| < \text{threshold} \quad (1)$$

여기에서 MP는 진단기로부터의 예측치이며, FS는 고장 심각도 (Fault Severity)를 의미한다. 기준 플라즈마 조건에 해당하는 변수에 대한 FS는 0이며, 이 조건에서 증가 또는 감소하는 것에 비례하여 FS 더 커지거나 감소하게 된다. FS는 [+1, -1]범위에서 변화하게 했다. 임계점은 0.1에서 0.5까지 변화시키며, 각 임계점에서 고장 원인이 확인된 XPS 패턴 수를 계산하였다. 그리고 모든 임계점에서 확인된 고장 원인 총수를 계산하였으며, 이를 진단기의 진단정확도의 비교를 위해 이용하였다. 앞서 결정된 가장 작은 RMSE를 가진 두 모델에 대해 (1)을 적용하여 계산된 모든 임계점에 대한 전체 진단 정확도가 그림 4에 도시되어 있다.




그림 4. 은닉층 뉴런수에 따른 전체 진단정확도

그림 4에서와 같이 은닉층 뉴런수 3-6범위에서 CWT-XPS 모델이 XPS 모델에 비해 보다 높은 진단정확도를 보이고 있다. 뉴런수가 7-9에서는 두 모델의 진단정확도는 비슷했다. 결국, CWT-XPS는 은닉층 뉴런수가 적을 때 보다 우수한 진단기를 개발하는데 유용함을 확인할 수가 있었다.

4. 결론

본 연구에서는 플라즈마 고장을 진단하기 위한 진단기를 XPS, 웨이브릿, 그리고 신경망을 결합하여 개발하였다. XPS와 CWT-XPS 패턴을 이용하여 두 종류의 모델을 개발하였으며, 모델 성능은 인식정확도와 진단정확도 측면에서 은닉층 뉴런수의 함수로 평가하였다. CWT-XPS 모델은 XPS 모델

에 비해 보다 작은 인식정확도를 보였으며, 동시에 보다 작은 뉴런수에서 월등한 진단 성능을 보였다. 이는 CWT-XPS가 보다 정확한 진단기를 구성하는데 효과적임을 의미한다.

감사의 글

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

참고 문헌

- [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] Kim, B., Lee, C., "Monitoring Plasma Impedance Match Characteristics in a Multipole Inductively Coupled Plasma for Process Control." J. Vac. Sci. Technol. A, vol. 18, no. 1, pp. 58-62, 2000.
- [3] Kim, B, Choi, W., Lim M.T., "Wavelet monitoring of plasma etching," J. Vac. Sci. Technol. B, vol. 21, no. 6, pp. 2329-2333, 2003.
- [4] Rummelhart, D.E., McClelland, J.L.: Parallel Distributed Processing. M.I.T. Press, Cambridge, 1986.
- [5] 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.