

## 시계열 신경망을 이용한 식각종말점 진단

김민재, 박민근, 우봉주\*, 김병환  
 세종대학교, 전자공학과

### Diagnosis of Etch Endpoint Using Time-Series Neural Network

MinJae Kim, Min Geun Park, Benjamin Woo\*, Byungwhan Kim  
 Sejong University, (\*) Semi Sysco


**Abstract** - 자기 연관 시계열 신경망을 이용하여 식각종말점 패턴-기반 플라즈마 상태를 진단하는 방법을 제안한다. 식각종말점 패턴은 Oxide 박막의 식각공정 중 Optical Emission Spectroscopy를 이용하여 수집하였으며, 역전과 신경망을 이용하여 진단 모델을 개발하였다. 진단 모델은 단일 신경망과 모듈러 신경망을 이용하여 개발하였으며, 비교평가결과 모듈러 신경망이 더 우수한 성능을 보였다.

이용하여 대략 41초 정도까지 0.2초 간격으로 수집되었다. 첫 웨이퍼 식각공정 중에 N(409.3)에 대해 수집된 OES 패턴이 그림 2에 도시되어 있다.

#### 1. 서 론

플라즈마 공정은 메모리 소자를 비롯한 각종 전자소자의 제작을 위한 다양한 종류 (금속체, 유전체 등)의 미세 박막을 식각(Etching)하는데 핵심적으로 응용되고 있다. 식각공정 중에 원하는 두께까지 식각이 되었을 때, 그 순간을 식각 종말점 (Etching Endpoint-EEP)이라 정의하고 있다. EEP에서 식각은 반드시 종료되어야 하며, 종료되지 않고 그대로 진행될 경우, 이미 형성된 패턴의 프로파일의 변형을 가져올 수 있을 뿐 아니라, 하부 박막에의 과도한 이온 충돌과 플라즈마 방사 데미지로 인해 후속 증착공정에서의 균일도의 확보를 어렵게 하고, 나아가서 제조된 소자의 질 (Quality)을 저하시키게 된다. EEP 검출을 위해 가장 많이 응용되는 플라즈마 진단기구는 Optical emission spectroscopy (OES) [1]이다. 한편, 특정 공정중에 수집되는 OES 패턴들은 상호 유사성을 가지고 있으며, 따라서 이를 이용하여 플라즈마 상태를 진단하는 것이 기대된다.

본 연구에서는 OES 패턴과 시계열 신경망 (Time-Series Neural Network-TSNN)을 이용하여 플라즈마를 진단하는 방법을 제안한다. EEP 패턴은 Oxide 식각공정중에 수집하였다. 두 종류의 진단 모델 (단일과 모듈러)을 개발하였으며, 진단 성능을 학습인자의 함수로 비교평가하였다.




<그림 2> N(409.3)의 Peak 패턴

#### 2.2 신경망 진단 모델

각 웨이퍼 공정에서 N(409.3)만을 진단하는 것으로 가정한다. 이 경우, 나머지 40개 라디칼 패턴 (각 웨이퍼 공정에서의 8개의 라디칼 패턴)은 테스트 패턴을 구성하게 된다. 패턴 유사성을 확인하기 위해 전체 5개의 웨이퍼공정에서 수집한 N(409.3)을 비교해 본 결과 크게 두 종류의 class로 구분할 수 있었다. 진단을 위해 각 class에서 하나의 패턴을 결정하였으며, 이들은 각각 #1과 #5의 웨이퍼 공정에 해당된다.

진단 모델은 역전과 신경망 (Back propagation neural network-BPNN)을 이용한 Auto-Correlated Time-Series 방식을 채택하였으며, 이러한 방식은 반도체 장비 센서정보에 대한 진단 모델을 개발하는 데에 활용된 바 있다 [2]. 시계열 모델링을 위해 요구되는 과거정보와 미래정보의 양은 동일하게 “1”로 설정하였다. 3 종류의 진단 모델 (즉 #1, #2, 그리고 #1/#2 모델)을 개발하여 그 진단 성능을 평가하였다. 여기에서 #1/#2 모델은 #1과 #2 모델을 동시에 이용한, 예컨대 모듈러 형식의 진단 모델이다. 모듈러진단모델은 이전에 정합망 데이터에 적용된 바 있다 [3]. 진단을 위해 요구되는 정상조건 다음과 같은 방법으로 정의했다. #1 모델을 이용할 경우 #5를 제외한 #2-#4 웨이퍼 공정에 해당하는 나머지 세 데이터를 테스트 데이터로 활용해 정상조건을 정의했다. 모델 성능에 영향을 미치는 학습인자에는 학습허용도를 이용하였으며, 그 값을 0.1, 0.01, 0.001, 그리고 0.0001로 변화시켰다. 나머지 학습인자인 은닉층 뉴런 수는 5개, 초기 웨이트의 범위는 [-1, +1], 그리고 활성화함수의 경사는 1에 고정하였다. #1과 #5 모델에 대한 학습허용도에 따른 TSNN의 예측성능은 표 1에 나타나 있다. 예측 성능은 Root Mean Square Error (RMSE)로 계산하였다. 개발된 각 모델에 대해서 전문한 방식으로 결정된 정상조건은 표 2에 나타나 있다. 표 2에서 “N”은 정상 (Norma)을 의미한다.



<그림 1> 식각 패턴의 구조

#### 2. 본 론

##### 2.1 OES 데이터 수집

OES 패턴은 나이트라이드위에 7000 Å의 옥사이드가 증착된 구조이며, 그림 1에 그 구조가 도시되어 있다. 총 5개의 웨이퍼 공정에 대해 OES 패턴이 수집되었으며, 각 웨이퍼 공정에서 총 9개의 라디칼 Peak에 대한 실시간 데이터가 수집되었다. 여기에는 N(409.3), N(410.99), N(493.50), N2(601.36), N2(645.48), N2(575.52), CN(304.20), CN(358.60), CN(388.30) 등이 포함된다. ()안의 수치들은 해당 라디칼이 존재하는 파장이며, 단위는 “nm”이다. 본 데이터는 (주)세미시스코가 개발한 EEP 검출시스템을

**<표 1> 학습허용도에 따른 모델 예측성능**


학습허용도	#1 모델	#5 모델
0.1	0.598	0.598
0.01	0.175	0.175
0.001	0.052	0.034
0.0001	0.052	0.021

**<표 2> 학습허용도에 따른 모델 특이 정상조건**

학습허용도	#1 모델	#5 모델
0.1	29.65<N<95.47	9.76<N<72.19
0.01	19.93<N<82.21	3.70<N<58.67
0.001	13.92<N<71.35	2.83<N<54.78
0.0001	9.86<N<59.82	2.46<N<51.02

**<표 3> #1 모델의 진단 성능**

웨이퍼 번호	Validation Error	Status	모델 판정	진단
#1	13.31	F	F	O
#2	620.05	F	T	X
#3	99.76	F	F	O
#4	124.47	F	F	O
#5	143.05	F	F	O



**<그림 3> 모델의 진단 성능**

**2.3 진단 성능 평가**

개발된 모델을 표 2의 정상조건을 기준으로 평가하였다. 표 3에는 테스트 패턴중의 하나인 N(410.99)에 대한 진단 성능이 나타나 있다. 표 3에서 "T"와 "F"는 각기 정상상태와 비정상상태를 의미한다. 표 3의 마지막 행에 모델의 정상조건 (표 2)과 비교한 진단결과가 나타나 있다. 이 예의 경우 #2웨이퍼 공정에 대해서 진단 오류가 하나 발생하였음을 알 수 있다. 이와 동일한 방식으로 나머지 35개의 테스트 패턴에 대해 진단 성능을 평가하였으며 그 결과가 그림 3에 도시되어 있다. 진단성능은 잘못 진단된 테스트 패턴의 수로 계산하였다. 그림 3에서와 같이 #5 모델이 학습허용도 0.1과 0.001에서 더 나은 성능을 보이고 있으며, 0.1에서 최적의 진단성능을 보였다. 이는 대략 22.5%의 진단오류에 해당한다.

**<표 4> 모듈러 (#1과 #2)모델에 대한 진단 성능**

웨이퍼 번호	#1 모델	#5 모델	진단 I	진단 II
#1	F	F	F	F
#2	T	F	T	F
#3	F	F	F	F
#4	F	F	F	F
#5	F	F	F	F

다음에는 #1과 #2 모델을 함께 이용해 진단 성능을 평가하였

다. 비정상패턴을 테스트할 경우, 각 모델의 판정결과에 "T"가 나타날 수 있다. 이 경우, 본 연구에서와 같이 2개의 모델만을 이용할 때, 최종 진단하기가 어렵다. 따라서 진단 기준을 설정하기 위해 두 가지 경우, 즉 "T"가 하나 포함되어 있으면 "T"로 진단하는 경우와 "F"로 진단하는 경우를 비교 평가하였다. 전자와 후자를 각 각 진단 I과 II로 정의하였다. 그 한 예가 표 4에 나타나 있다. 표 4는 N(493.50) 패턴에 대한 결과를 정리한 것이다. 표 4에서와 같이 진단 기준에 따라 최종 진단 성능이 달라지게 되며, 테스트 패턴이 "F"인 경우를 고려하면 진단오류가 "0"인 진단 II가 더 나은 진단방식임을 알 수 있다. 전체 테스트 패턴에 대한 두 방식의 진단 성능은 그림 4에 도시되어 있다. 그림 4에서와 같이 진단 II가 진단 I에 비해 더 나은 성능을 보이고 있으며, 전술한 경험적 지식에 비추어 진단 II가 비정상패턴의 감지에 더 효과적임을 알 수 있다. 특히 학습허용도 0.0001에서 최소의 진단오류 (8개)를 얻었으며, 이는 앞서의 단일 모델을 이용한 진단 성능보다 더 우수하다.

**3. 결 론**

본 연구에서는 시식각종말점패턴-응용 플라즈마를 진단하는 시계열 신경망 모델을 개발하였다. 모델의 진단 성능은 학습허용도의 함수로 평가하였다. 총 3종류의 모델을 개발하였으며, 이 중 모듈러 신경망이 가장 우수한 진단 성능을 보였다.

**감사의 글**

본 연구는 정보통신부가 지원하는 2006년도 2차 IT 산업경쟁력 강화사업으로 지원되었습니다.

**[참 고 문 헌]**

[1] H. E. Litvak, J. Vac. Sci. Technol. B 14, 516 (1996).  
 [2] 김유석, 김병환, 권기청, 한정훈, 손종원, 2006년 정보 및 제어 심포지엄 논문집, 99 (2006).  
 [3] B. Kim, S.. Kim, Microelectron. Eng. 82, 44(2005).