

OES 정보와 신경망을 이용한 플라즈마 식각률 비균일도의 모델링

권민지, 김병환*

세종대, 전자공학과

(Modeling of Plasma Etch Non-Uniformity by Using OES Information and Neural Network)

Minji Kwon, Byungwhan Kim*

Sejong Univ. Electronic Engineering

Abstract - 소자 수율을 향상시키기 위해서는 웨이퍼 전체에 걸쳐 플라즈마 공정특성이 균일하게 분포되어야 한다. 본 연구에서는 Actinometric 광반사분광기 (Optical Emission Spectroscopy) 정보를 이용하여 식각률 비균일도에 대한 모델을 개발하였다. 제안된 기법은 Oxide 식각공정에서 수집한 데이터에 적용하였으며, 체계적인 모델링을 위해 공정데이터는 통계적 실험계획법을 적용하여 수집되었다. 신경망의 예측성능은 유전자 알고리즘을 이용해서 증진시켰다. OES의 차수를 줄이기 위해 주인자 분석을 세 종류의 분산 (100, 99, 98%)에 대해서 적용하였다. 개발된 모델은 발표된 이전의 모델에 비해 17% 증진된 예측성능을 보였다.

1. 서 론

반도체 플라즈마 공정은 미세 박막의 중착과 패턴닝에 핵심적으로 응용이 되고 있다. 플라즈마 공정의 최적화와 실시간 감시, 그리고 제어를 위해서는 공정 예측모델이 요구된다. 플라즈마의 복잡한 물리화학적 특성을 모델링하기 위해 신경망, 특히 역전파 신경망 (Backpropagation neural network-BPNN)이 많이 응용되고 있다. BPNN은 공정변수 또는 플라즈마 진단을 위한 In-situ 테이터와 박막특성의 예측에 응용되었다 [1-2]. 대표적인 In-situ 테이터에는 광방사분광기 (Optical Emission Spectroscopy-OES) 정보가 있으며, 수집된 정보전체[2] 또는 주인자분석 (Principal Component Analysis-PCA)을 이용해 차수가 감소된 OES 데이터[3]가 활용된 적이 있다. 한편, BPNN의 학습에는 다수의 학습인자가 관여하고 있으며 [4], 따라서 이들의 영향을 최적화할 때, 예측성능이 보다 증진된 BPNN 모델을 개발할 수 있다. OES 정보의 모델링과 관련하여 BPNN의 학습인자를 최적화한 모델이 개발된 적이 없다.

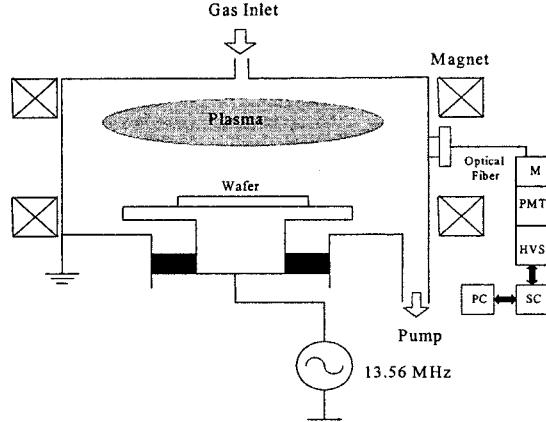
본 연구에서는 OES 정보와 BPNN, 그리고 PCA를 이용하여 박막 특성 예측모델을 개발한다. 다수 학습인자의 영향은 유전자 알고리즘 (Genetic Algorithm-GA)을 이용하여 최적화하였다. OES 정보는 Oxide 박막의 플라즈마 식각공정중에 수집하였다. 식각공정은 통계적 실험계획법에 따라 진행되었다. 개발된 식각률 모델은 기 개발된 모델과 그 성능을 비교평가하였다.

2. 본 론

2.1 실험적인 세부사항

실험에 이용된 MERIE 장비의 개요도가 그림 1에 도시되어 있다. 하부전극은 13.56 MHz에서 동작하는 RF 전력이 연결되어 있다. 하부전극과 평행한 자력선은 챔버외부에 설치되어 있는 Electromagnetic 코일에 DC 전류를 전달하여 발생한다.

테스트 패턴은 Boron이 도핑된, (100)방향의 Si 기판위에 형성하였으며, 보다 구체적인 내용은 참고문헌 [6]에 세세히 기술되어 있다. 식각공정은 전술한 MERIE 장비를 이용하여 CHF₃/CF₄ 플라즈마에서 수행하였다. 체계적인 모델링을 위해 2⁴⁻¹ 부분인자 실험계획법 [5]이 적용되었으며, 실험계획법에 이용된 공정변수와 범위는 표 1에 있다. 수집된 데이터 공정변수 중심점에 해당하는 실험과 함께 BPNN의 학습에 이용되었다. 학습된 모델의 예측성능은 다른 8개의 실험 데이터를 이용하여 평가하였다. 식각공정 중에 발생하는 라디칼 강도는 Optical Emission Spectroscopy (OES)를 이용하여 측정하였다. 파장 범위는 200-800 nm이었다. 각 OES Spectra는 총 2001개의 라디칼 변수 정보를 포함하고 있으며, 이를 신경망 입력패턴으로 이용하기에는 너무 변수가 많다. 변수를 줄이기 위해 PCA를 적용하였으며, 데이터 분산 (Variance)은 100, 99, 그리고 98%로 설정하였다. 그 결과, 100, 99, 그리고 98%에 대해 16, 8, 그리고 5개로 변수의 차수가 감소하였다.



〈그림 1〉 MERIE 장비의 개요도

〈표 1〉 실험변수와 범위

Parameters	Range	Unit
CHF ₃ 유량	20-80	sccm
CF ₄ 유량	10-40	sccm
RF 전력	300-800	W
압력	50-200	Torr

2.2 신경망 모델링

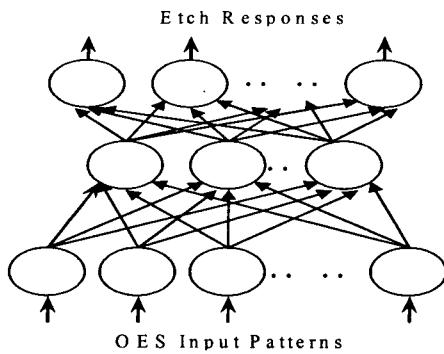
BPNN의 구조는 그림 2에 도시되어 있다. 그림 2에서와 같이 은닉층은 하나이며, 학습 규칙으로는 일반화된 멜타 규칙을 적용하였으며, 뉴런간 웨이트 조정은 (1)과 (2)에 의해 이루어졌다.

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

여기서 $W_{i,j,k}$ 는 ($k-1$) 층의 j 번째 뉴런과 k 층의 i 번째 뉴런사이의 연결강도이고 $\Delta W_{i,j,k}$ 는 학습편차를 줄이기 위해 인가되는 연결강도의 변화이며 다음과 같이 정의 된다.

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

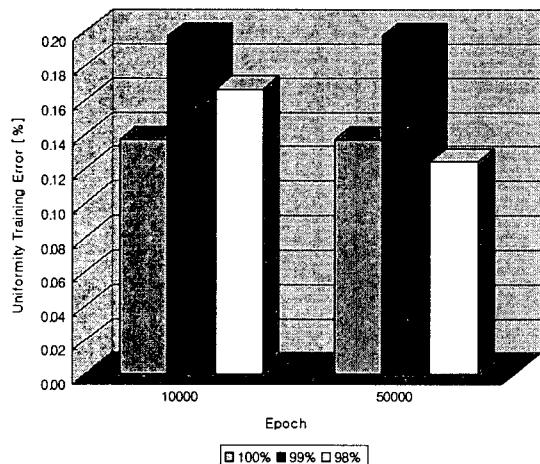
BPNN의 학습에는 다수의 학습인자가 관여하고 있으며 [], 이들은 모델의 학습과 예측성능에 상당한 영향을 미친다. 학습인자에는 학습허용도 (TT), 은닉층 뉴런수 (NHN), 초기웨이트의 크기 (MIW D), 그리고 은닉층 뉴런의 단극성 시그모이드 함수의 경사 (GBSF), 출력층 뉴런의 선형함수의 경사 (GLF) 등이 있다. 플라즈마 방전모델에의 이들의 영향이 이전 연구에 세세히 설명되어 있다 []. 경우에 따라서는 주어진 TT에서 학습이 종료되지 않을 수도 있으며, 과대한 학습이 진행되는 것을 방지하기 위해 다른 학습종료 기준으로 Epoch를 프로그램 상에 각 기 10,000과 50,000으로 설정하여 평가하였다.



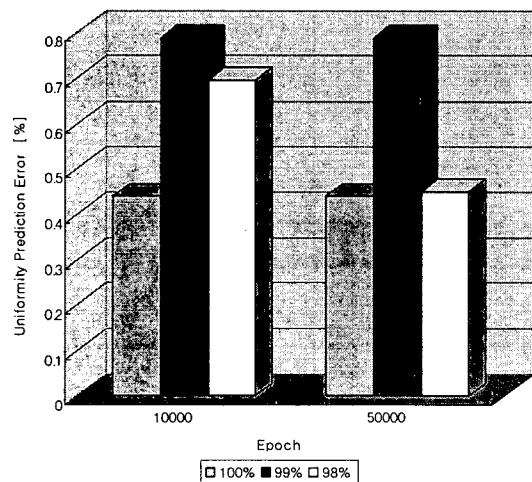
〈그림 2〉 BPNN의 개요도

〈표 1〉 유전자 알고리즘 최적화를 위한 인자와 범위

Parameters	Range
TT	0.04-0.12
NHN	2-9
MIWD	$\pm 0.4 \pm 1.2$
GBSF	0.4-2.0
GLF	0.4-2.0



〈그림 3〉 Epoch에 따른 GA-BPNN 모델의 학습성능



〈그림 4〉 Epoch에 따른 GA-BPNN 모델의 예측성능

2.3 GA-BPNN 모델

BPNN의 학습인자를 최적화하기 위해 GA를 적용하였다. 각 학습인자의 범위는 표 2에 나타나 있다. GA에 관여하는 초기 해의 규모는 100으로 설정하였으며, 교배와 돌연변이 확률은 각각 0.95와 0.05였다. 초기해의 적합도를 평가하기 위한 적합도 함수는 식 (3)로 정의되었다.

$$F = 1/(1+RMSE) \quad (3)$$

여기서 RMSE는 학습에러를 의미한다. 세대 수는 100으로 설정하였으며, 따라서 유전자 동작은 세대수 100에서 종료된다. 전체 세대에서 발생한 모델 중 가장 작은 예측 에러를 보이는 모델을 결정하였다.

그림 3은 GA-BPNN 모델의 학습성능을 epoch의 함수로 도시하고 있다. 그림 3에서와 같이, Epoch 10,000일 경우, 100%의 분산에서 학습에러가 최소가 되었으며, 그 값은 0.137%이다. Epoch 50,000일 경우에는 최소 학습에러는 98% 분산에서 발생하였으며, 그 값은 0.124%이다. 이는 Epoch 10,000에서 구해진 최소에러에 비해 대략 9%정도 학습성능이 증진된 수치이다. 그림 4는 GA-BPNN 모델의 예측성능을 보이고 있다. 그림 4에서와 같이 Epoch 10,000일 경우 예측에러는 100%의 분산에서 최소가 되었으며, 그 값은 0.439%이다. 그림 3과 비교하여 최소의 예측에러가 최소의 학습에러에서 얻어졌음을 확인할 수 있다. Epoch 50,000에서도 동일한 100%의 분산에서 최소에러 0.439%를 얻었다. 이는 Epoch 10,000에서 얻어진 최소 예측에러와 동일하며, 따라서 학습과 예측에러 측면에서 Epoch 50,000과 100%의 분산에서 구한 모델이 최적의 모델로 결정되었다. 한편, 최근의 연구보고에서 100%의 분산에서 은닉층 뉴런수의 함수로 모델이 개발 [2]된 바 있으며, 당시의 모델에 레 (0.53%)에 비해 본 연구에서 개발된 모델의 에러는 17% 증진된 예측성능을 보이고 있다. 이는 BPNN의 학습인자 최적화의 중요성을 의미한다.

3. 결 론

본 연구에서는 OES 정보와 신경망을 이용하여 공정제어 모델을 개발하였다. OES 차수는 PCA를 이용해 줄였으며, 3 종류의 분산에 대해 모델을 개발하고 비교하였다. 과거의 모델에 비해 우수한 예측 성능을 개발할 수 있었으며, 개발된 모델은 플라즈마 공정의 Run-To-Run 제어와 감시에 활용할 수 있다.

감 사 의 글

본 논문은 산업자원부가 지원하는 국가 반도체연구개발사업인 “시스템집적반도체기반기술개발사업(시스템IC2010)”을 통해 개발된 결과임을 밝힙니다.

[참 고 문 헌]

- B. Kim and W. S. Hong, "Use of neural network to characterize a low pressure temperature effect on refractive property of silicon nitride film deposited by PECVD," IEEE Trans. Plasma Sci. 32, 84 (2004).
- B. Kim, J. Bae, and W. S. Hong, "Plasma control using neural network and optical emission spectroscopy," J. Vac. Sci. Technol. A 23, 355 (2005).
- S. J. Hong, G. S. May, and D. C. Park, "Neural network modeling of reactive ion etching using optical emission spectroscopy data," IEEE Trans. Semicond. Manufact. 16, 598 (2003).
- B. Kim and S. Park, "An optimal neural network plasma model: a case study," Chemomemtr. Intell. Lab. Syst. 56, 39 (2001).
- D. C. Montgomery, Design and Analysis of Experiments, John Wiley & Sons, Singapore, 1991.
- B. Kim, K. H. Kwon, and Sung Ku Kwon, Jong Moon Park, Seong Wook Yoo, Kun Sik Park, and Bo Woo Kim, Modeling oxide etching in a magnetically enhanced reactive ion plasma using neural networks, J. Vac. Sci. Technol. B, vol. 20, no. 5, 2113, 2002.