

광방사분광기와 신경망을 이용한 플라즈마 식각공정 모델링

권민지, 김병환
 세종대학교, 전자공학과

Modeling of Plasma Etching by Using Neural Network and Optical Emission Spectroscopy

Minji Kwon, Byungwhan Kim
 Sejong University

Abstract - 본 연구에서는 반도체 플라즈마 공정감시와 제어에 응용될 수 있는 모델을 제안한다. 본 모델은 광방사분광기(OES)정보와 신경망을 이용해서 개발하였으며, OES의 차수를 줄이기 위해 주인자 분석을 세 종류의 분산(100, 99, 98%)에 대해서 적용하였다. 모델의 예측성능은 유전자 알고리즘을 이용하여 최적화하였다. 제안하는 모델링 방식은 MERIE를 이용한 Oxide 식각공정에 적용하였으며, 개발된 모델은 발표된 이전의 모델에 비해 증진된 예측성능을 보였다.

1. 서 론

반도체 플라즈마 공정은 미세 박막의 증착과 패터닝에 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 데이터와 박막특성 예측에 응용되었다 [1-2]. 대표적인 In-situ 데이터에는 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.

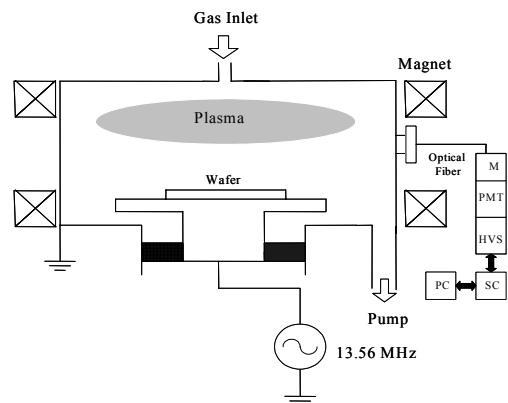
본 연구에서는 OES 정보와 BPNN, 그리고 PCA를 이용하여 박막특성 예측모델을 개발한다. 다수 학습인자의 영향은 유전자 알고리즘(Genetic Algorithm-GA)를 이용하여 최적화하였다. OES 정보는 Oxide 박막의 플라즈마 식각공정 중에 수집하였다. 식각공정은 통계적 실험계획법에 따라 진행되었다. 개발된 식각률 모델은 기 개발된 모델과 그 성능을 비교평가 하였다.

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 []에 상세히 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 함께BPNN의 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 사용하기에는 너무 변수가 많다. 변수를 줄이기 위해 PCA를 적용하였으며, 데이터 분산(Variance)는100, 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	sccnm
CF ₄ 유량	10-40	sccm
RF 전력	300-800	W
압력	50-200	Torr

2.2 신경망 모델링

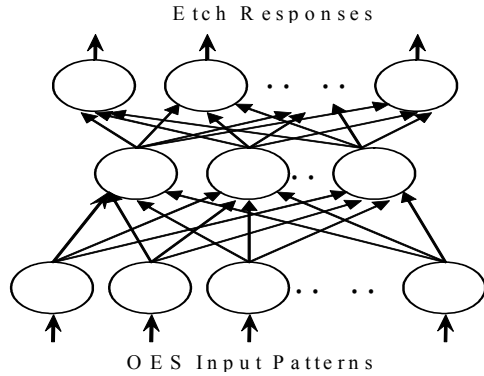
BPNN의 구조는 그림 2에 도시되어 있다. 그림 2에서와 같이 은닉층은 하나이며, 학습 규칙으로는 일반화된 델타 규칙을 적용하였으며, 뉴런간 웨이트 조정은 (1)과 (2)에 의해 이루어졌다.

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


여기서 W_{i,j,k}는 (k-1)층의 j 번째 뉴런과 k층의 i 번째 뉴런사이의 연결강도 이고 ΔW_{i,j,k}는 학습편차를 줄이기 위해 인가되는 연결강도의 변이이며 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(MIWD), 그리고 은닉층 뉴런의 단극성 시그모이드 함수의 경사(GBSF), 출력층 뉴런의 선형함수의 경사(GLF)등이 있다. 플라즈마 방전모델에의 이들의 영향이 이전 연구에 상세히 설명되어 있다 []. 경우에 따라서는 주어진 TT에서 학습이 종료되지 않을 수도 있으며, 과도한 학습이 진행되는 것을 방지하기 위해 다른 학습종료 기준으로 Epoch를 프로그램 상에 각 기 10,000과 50,000으로 설정하여 평가하였다.



〈그림 2〉 BPNN의 개요도



〈그림 4〉 과거 모델과의 예측성능 비교

〈표 1〉 유전자 알고리즘 최적화를 위한 인자와 범위

Parameters	Range
TT	0.04-0.12
NHN	5-10
MIWD	±0.4-±1.2
GBSF	0.4-2.0
GLF	0.4-2.0

3. 결 론


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

감사의 글

본 연구는 서울시 산학연 협력사업의 지원으로 수행되었음(과제번호 10583).

[참고 문헌]

- [1] 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).
- [2] 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).
- [3] 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).
- [4] B. Kim and S. Park, "An optimal neural network plasma model: a case study," Chemomemtr. Intell. Lab. Syst. 56, 39 (2001).
- [5] D. C. Montgomery, Design and Analysis of Experiments, John Wiley & Sons, Singapore, 1991.



〈그림 3〉 Epoch에 따른 PCA-BPNN 모델의 예측성능

2.3 GA-BPNN 모델

BPNN의 학습인자를 최적화하기 위해 GA를 응용하였다. 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. 각 SR에서 결정된 GA-GRNN 모델의 예측성능은 그림 3에 도시되어 있다. 그림 3에서와 같이, Epoch에 따라 최적 모델의 유형이 틀리다. Epoch가 10,000일 경우 98%의 분산에서 최적 모델이 구해졌으며, 그 값은 301 Å/min이다. 한편, Epoch가 50,000일 경우에는 99%의 분산에서 최적 모델이 구해졌으며, 그 값은 249 Å/min이다. 전술한 모델에 비해 17.3% 정도 개선된 예측성능을 보이고 있다. 한편, 개발된 모델을 최근 발표한 모델 [2]과 비교하였다. 최근 발표한 모델은 3 종류이며, 여기에는 종래의 방식, 즉 4개의 공정변수를 입력으로 이용하는 모델(CONV), 전체 OES 데이터를 이용한 모델(FULL OES), 그리고 PCA를 적용한 모델(PCA-OES)이 포함된다. 세 번째 모델의 경우 분산은 100%로 설정하였다. 이들 모델의 예측성능은 NHN의 함수로 최적화하였다. 본 연구에서 개발된 모델들의 이들 모델들에 대한 예측성능 측면에서의 상대적이 개선도가 그림 4에 도시되어 있다. 그림 4에서와 같이 모든 유형에 대해서 예측성능이 개선되었으며, 특히 PCA-OES 모델에 비해서는 50% 이상 예측성능을 증진시켰다. 이는 제안하는 기법이 보다 우수한 예측성능을 가지는 모델개발에 효과적임을 보여준다.