

유전자 알고리즘-응용 역전파 신경망 웨이트 최적화 기법을 이용한 플라즈마 식각 공정 모델링

배중기, 김병환*

(*) 세종대 학교, 전자공학과

(02) 3408-3729 (연구실), (02) 3408-3329 (fax), (e-mail) kbwhan@sejong.ac.kr

Modeling of plasma etch process using genetic algorithm optimization of neural network initial weights

Junggi Bae, Byungwhan Kim*

(*) Sejong University, Electronic Engineering

Abstract

플라즈마 식각공정은 소자제조를 위한 미세 패턴링 제작에 이용되고 있다. 공정 메커니즘의 정성적 해석, 최적화, 그리고 제어를 위해서는 컴퓨터 예측모델의 개발이 요구된다. 역전파 신경망 (backpropagation neural network-BPNN) 모델을 개발하는 데에는 다수의 학습인자가 관여하고 있으며, 가장 그 최적화가 어려운 학습인자는 초기웨이트이다. 모델개발시, 초기웨이트는 random 값으로 설정이 되며, 이로 인해 초기웨이트의 최적화가 어렵다. 본 연구에서는 유전자 알고리즘 (genetic algorithm-GA)을 이용하여 BPNN의 초기웨이트를 최적화하였으며, 이를 식각공정 모델링에 적용하여 평가하였다. 실리카 식각공정 데이터는 2^3 인자 실험계획법을 이용하여 수집하였으며, GA에 관여하는 두 확률인자의 영향을 4^2 인자 실험계획법을 이용하여 최적화 하였다. 종래의 모델에 비해, 최적화된 모델은 실리카 식각률, Al 식각률, Al 선택비, 그리고 프로파일 응답에 대해서 각 기 24%, 13%, 16%, 그리고 17%의 향상률을 보였다. 이는 제안된 최적화 기법이 플라즈마 모델의 예측성능을 증진하는데 효과적으로 응용될 수 있음을 의미한다.

Key Words : 플라즈마, 식각공정, backpropagation neural network, genetic algorithm

1. 서 론

플라즈마 식각공정은 소자제조를 위한 미세 패턴링 제작에 이용되고 있다. 플라즈마 공정에는 다수의 공정변수 (소스전력, 압력, 가스 등)가 관여하고 있으며, 이들 변수의 조합에 따라 플라즈마 특성이 크게 변화하게 된다. 공정변수의 개별적 조정을 통해 공정을 최적화하는 데에는 한계가 있으며, 예상되는 과대한 비용과 시간을 줄이기 위해서는 컴퓨터 예측모델이 필요하다. 공정최적화 외에, 개발되는 컴퓨터 모델은 실험으로 확인되지 않은 다양한 플라즈마 조건에서의 식각 메커니즘의 정성적인 해석과 공정제어에 응용할 수 있다.

플라즈마를 모델링하는 기법에는 물리적, 해석적 모델, 통계적인 회귀모델, 그리고 신경망을 이용한 기법 등이 있다. 신경망은 다수의 플라즈마 공정 모델링에 적용된 바 있으며, 회귀 모델에 비해 우수한 예측성능을 보였다. 신경망 중에서, 그 응용이 가장 활발한 구조는 역전파 신경망 (backpropagation neural network-BPNN) 이다 [1]. BPNN은 다수의 플라즈마 공정의 모델링에 응용이 된 바 있다 [2-4]. BPNN모델을 개발하는 데에는 다수의 학습인자가 관여하고 있으며, 가장 그 최적화가 어려운 학습인자는 초기웨이트이다. 모델개발시, 초기웨이트는 random 값으로 설정이

되며, 이로 인해 초기웨이트의 최적화가 어렵다.

본 연구에서는 유전자 알고리즘 (genetic algorithm-GA) [5]을 이용하여 BPNN의 초기웨이트를 최적화하며, 이를 식각공정데이터에 적용하여 예측모델을 개발한다. 실험 데이터는 광도파로 제작을 위한 실리카 재료의 식각공정 데이터이며, 유도결합형 플라즈마를 이용하여 공정을 수행하였다. 데이터는 2^3 인자 실험계획법 [6]을 이용하여 체계적으로 수집이 되었으며, 모델이 이용된 식각 응답은 실리카 식각률, aluminum (Al) 식각률, Al 선택비, 그리고 실리카 프로파일 각도 등이다. 한편, GA에 관여하는 최적화인자인 두 확률변수, 즉 교배와 돌연변이 확률,는 최적화에 영향을 줄 수 있으며, 따라서 그 최적화된 값을 찾기 위하여 4^2 인자 실험계획법이 적용되었다. 최적화한 모델은 일반적인 방식에 의해 개발된 모델과 비교하였다.

2. 실험

2.1 실험 데이터

그림 1은 식각공정을 수행한 장비의 유도결합형 플라즈마를 이용한 장비의 개요도이다. 본 식각장비를 이용하여 CF_4/CHF_3 가스플라즈마하에서 실리카 박막을 식각하였다. 공정에 이용된 공정변수는 총 4종류이며, 여기에는 소스전력 바이어스 전력, 그리고 두 종류의 가스(CHF_3 와 CF_4)이다. 2^{4-1} 부분인자 실험계획법 [6]이 적용되었으며, 각 실험 변수의 최대, 최소값은 표 1에 나타나 있다. 결과적으로 수집된 총 여덟 번의 실험에 중앙점에 해

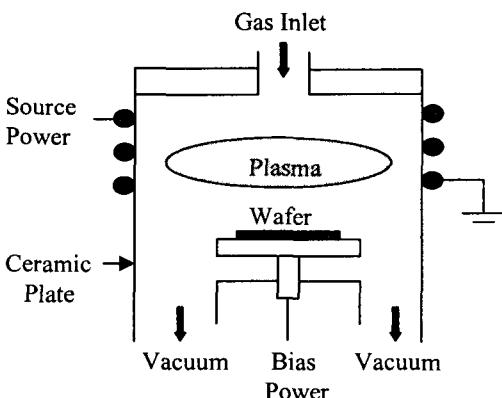


그림 1. 유도결합형 플라즈마 식각 장비.

당하는 1회의 실험을 추가하여, 학습데이터를 구성하였다. 모델의 성능 검증을 위해 추가적으로 여섯 번의 실험이 수행되었으며, 따라서 모델에 이용된 데이터의 총 수는 17개이다. 측정한 식각응답은 실리카 식각률, aluminum (Al) 식각률, Al 선택비, 그리고 실리카 프로파일 각도 등이며, SEM(scanning electron microscopy)를 이용하여 측정하였다.

표 1. 통계적 실험계획을 위한 실험번수와 범위.

실험 번수	범위	단위
소스전력	100~800	Watt
바이어스 전력	100~400	Watt
가스비	0.2~5.0	

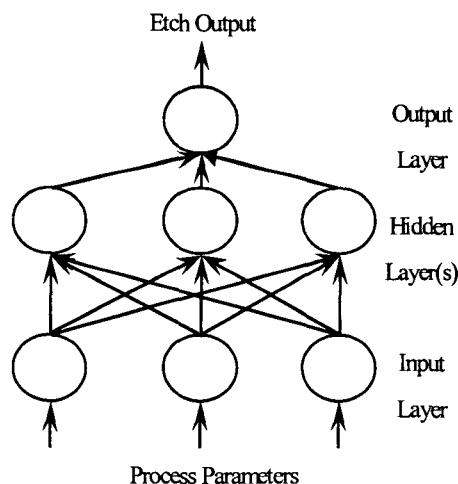


그림 2. BPNN의 개요도.

2.2 역전파 신경망

그림 2의 BPNN 구조는 플라즈마 공정데이터 해석에 가장 많이 적용되고 있는 구조이다. BPNN은 주로 은닉층이 하나인 3개의 층으로 구성되며, 학습은 일반화된 델타 규칙 [1]을 이용하여 진행되고, 이는 다음과 같이 표현된다.

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

여기서 $W_{i,j,k}$ 는 $(k-1)$ 층의 j 번째 뉴런과 k 층의 i 번째 뉴런사이의 연결강도이고, $\Delta W_{i,j,k}$ 는 학습편차

를 줄이기 위해 인가되는 웨이트의 변이이며, 다음과 같이 정의 된다.

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

η 과 m 은 학습률과 반복회수를 각 기 지칭한다.

3. 결과 및 고찰

3.1 GA-BPNN 모델

GA를 이용하여 초기웨이트의 영향을 최적화한다. 다른 학습인자인, 학습허용도, 은닉뉴런의 수, 활성화함수 경사 값은 각기, 0.1, 3, 그리고 1.0에 고정하였다. GA에 관여하는 두 확률변수, 즉 교배 확률 (P_c)와 돌연변이 확률 (P_m)은 GA 최적화 성능에 영향을 줄 수 있으며, 따라서 이들 상호간의 영향을 최적화하기 위하여 4²실험계획법이 적용되었다. 두 변수의 실험범위는 표 2에 나타나 있다. GA 최적화가 적용되는 과정을 설명하기 위하여 실리카 식각률을 모델링하는 과정을 설명한다. 초기 해 집단을 100으로 설정하였으며, 진화 세대수를 100으로 고정하였다. 초기 해 (chromosome)은 총 12개의 slot으로 구성이 되었으며, 각 slot에는 난수발생기를 이용하여 +1과 -1사이에서 발생한 값이 할당이 된다. 각 chromosome의 적합도는 다음과 같은 식으로 판정하였다.

$$F=1/(1+RMSE) \quad (4)$$

진화과정은 100 세대수에 이르러 중단이 되게 설정하였다. 본 예에서, P_c 는 0.80으로 고정하였으며, P_m 을 표 2에서와 같이 0.05에서 0.20까지 0.05씩 증가하면서 모델을 개발하였다. 편의를 위하여 GA를 이용하여 최적화한 BPNN 모델을 GA-BPNN으로 표현한다. 3은 P_c 와 P_m 의 여러 조합에서 결정된 최적화된 GA-BPNN 모델의 예측성능을 나타내고 있다. 예측성능은 일반적인 root mean-square error (RMSE) 공식을 이용하여 계산하였다. 표 3에서와 같이 P_c 와 P_m 의 조합에 따라 예측성능이 상당히 변화하였으며, $P_c=0.95$, $P_m=0.15$ 에서 가장 우수한 모델을 개발하였으며, 해당 모델의 RMSE는 202 Å/min 이었다. 동일한 방식으로 다른 식각

응답에 대해서도 모델을 개발하였으며, 최적화한 모델의 성능이 표 4에 나타나 있다.

표 2. GA 최적화를 위한 확률변수와 범위

확률 변수	범위	증분
P_c	0.80~0.95	0.05
P_m	0.05~0.20	0.05

표 3. 실리카 식각률의 최적화된

GA-BPNN 모델 성능		
P_c	P_m	예측 에러 (Å/min)
0.80	0.15	256
0.85	0.05	274
0.90	0.20	261
0.95	0.15	202

표 4. 최적화된 GA-BPNN 식각 모델의 성능

식각 특성	P_c	P_m	예측 에러
실리카 식각률	0.95	0.15	202
AI 식각률	0.80	0.20	374
AI 선택비	0.95	0.10	1.58
실리카 프로파일	0.90	0.15	2.05

3.2 BPNN 모델

비교를 위해 종래의 방식으로 BPNN 모델을 개발하였다. 비교를 공정하게 하기 위하여 주어진 초기웨이트 범위 [+1, -1]에서 총 100개의 모델을 연속적으로 개발하였으며, 이중 RMSE가 가장 작은 모델을 비교 모델로 결정하였다. 다른 학습인자는 이전의 GA-BPNN 모델을 개발할 때 설정한 값들과 동일하다. 결정된 모델의 RMSE가 각 식각응답별로 표 5에 나타나 있다. 표 5의 BPNN 모델에 대한 표 4의 GA-BPNN모델의 예측성능을 퍼센트 향상도로 환산하여 그림 4에 도시하였다. 그림 4에서와 같이 모든 식각 응답에 대해서 GA-BPNN은 향상된 예측정확도를 보이고 있으며, 그 향상도는 실리카 식각률 모델에서 크게 증가하였다.

4. 결 론

본 연구에서는 새로운 플라즈마 식각 공정모델을 개발하였다. 즉 유전자 알고리즘을 이용하여 BPNN의 초기웨이트의 영향을 최적화하였으며, 광도파로 제작을 위한 실리카 식각공정 데이터에 적용하여 평가하였다. GA 최적화에 관여하는 두 확

률변수의 영향도 통계적 실험계획법을 적용하여 최적화하였다. 최적화한 GA-BPNN모델을 종래의 방식으로 개발한 모델과 예측성능을 비교하였으며, 총 4개의 식각응답에 대해서 예측성능을 상당히 증진시켰다. 제안된 방식의 가장 큰 장점은 초기웨이트의 불규칙성에 관계없이 우수한 예측모델을 개발할 수 있다는 데 있다.

참고 문헌

- [1] Rummelhart D E, McClelland J L. Parallel Distributed Processing, Cambridge, M.I.T. Press, 1986.
- [2] B. Kim and S. Park, Chemom. Intell. Lab. Syst., 56, 39 (2001).
- [3] B. Kim, S. M. Kong, and B. T. Lee, J. Vac. Sci. Technol. A, 20, 146 (2002).
- [4] B. Kim and K. Kwon, J. Appl. Phys., 93, 76 (2003).
- [5] D. E. Goldbeg, Genetic Algorithms in Search, Optimization & Machine Learning, Addison Wesley, 1989.
- [6] Montgomery D C. Design and Analysis of Experiments, John Wiley & Sons, Singapore, 1991.