

유전자 알고리즘과 레이디얼 베이스 함수망을 이용한 플라즈마 식각공정 모델링

박경영, 김병환*,
세종대학교, 전자공학과

Modeling of plasma etch process using genetic algorithm and radial basis function network

Kyoung-young Park, Byungwhan Kim*
Sejong University, Electronic Engineering

Abstract

플라즈마 공정 모델 개발에 역전파 신경망이 가장 많이 응용되고 있으나, 관여하는 다수의 학습인자로 인해 그 최적화가 매우 어렵다. Radial basis function network (RBFN)은 관여하는 학습인자의 수가 적어 그 최적화가 상대적으로 용이하지만, 두인자의 다양한 조합에 의해 RBFN의 예측성능이 상당히 영향을 받을 수 있다. 본 연구에서는 학습인자 상호간의 작용을 유전자 알고리즘 (genetic algorithm-GA)을 이용하여 최적화하는 기법을 소개한다. 제안하는 알고리즘을 광도파로 제작을 위해 수행한 실리카 식각공정 데이터에 적용하여 평가하였다. 평가에 이용된 식각 응답은, 실리카 식각률, aluminum (Al) 식각률, Al 선택비, 그리고 실리카 프로파일 각도이다. 최적화한 모델은 종래의 모델과 비교하였으며, 그 향상도는 실리카 식각률, Al 식각률, Al 선택비, 그리고 실리카 프로파일 각도에 대해서 각 기 0.8%, 32.4%, 20.3%, 1.3% 등이었다. Al 식각률과 선택비에 대해서 예측성능은 상당히 향상되었다.

Key Words : 플라즈마 식각공정, 예측 모델, 유전자 알고리즘, Radial basis function network

1. 서 론

플라즈마를 모델링하는 기법에는 물리적 모델, 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]. 이 BPNN은 다수의 플라즈마 공정의 모델링에 응용된 바 있다 [2-4]. 그러나 BPNN의 학습에는 다수의 학습인자가 관여하고, 이들 상호간의 복잡성으로 인해 모델의 예측성능을 최적화하기가 매우 어렵다 [2]. BPNN에 비해, radial basis function network [5]는 학습인자의 수가 작아, 그 활용이 기대된다. 학습인자에는 패턴층의 뉴런수, receptive field의 width, 그리고 패턴층과 출력층사이의 초기웨이트의 범위 등이다. 각 변수의 영향을 실험적으로 최적화하여 최근에 식각공정모델을 개

발한 바 있다 [6]. 한편, 각 학습인자를 개별적으로 최적화하는 방식보다 인자상호간의 영향을 동시에 최적화할 때, 예측성능의 증진이 기대된다.

본 연구에서는 유전자 알고리즘 (genetic algorithm-GA) [7]을 이용하여 RBFN 학습인자의 영향을 최적화하는 기법을 개발한다. 이전 연구에서 초기웨이트의 영향이 전술한 다른 두 인자에 비해 상대적으로 미미한 것을 확인하였으며, 이에 본 연구에서는 이를 제외한 나머지 두인자의 영향을 최적화하는 기법을 연구한다. 모델개발에 응용된 실험 데이터는 광도파로 제작을 위한 실리카 박막 재료의 식각공정 데이터이며, 유도결합형 플라즈마를 이용하여 공정을 수행하였다. 데이터는 통계적 실험계획법을 이용하여 체계적으로 수집이 되었으며, 모델링한 식각 응답은 실리카 식각률, aluminum (Al) 식각률, Al 선택비, 그리고 실리카 프로파일 각도 등이다. 최적화한 모델은 일반적인 방식에 의해 개발된 모델과 비교하였다.

2. 실험 데이터

그림 1은 식각공정을 수행한 장비의 유도결합형 플라즈마를 이용한 장비의 개요도이다.




그림 1. 유도 결합형 플라즈마 식각장비의 개요도.

본 식각장비를 이용하여 CF_4/CHF_3 가스플라즈마 하에서 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 [8]이 적용되었으며, 각 실험변수의 최대, 최소값은 표 1에 나타나 있다. 결과적으로 수집된 총 여덟 번의 실험에 중앙점에 해당하는 1회의 실험을 추가하여, 학습데이터를 구성하였다. 모델의 성능 검증을 위해 추가적으로 여섯 번의 실험이 수행되었으며, 따라서 모델에 이용된 데이터의 총 수는 17개이다. 측정된 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 실험변수와 범위.

실험 변수	범위	단위
소스전력	100-800	Watt
바이어스 전력	100-400	Watt
가스비	0.2-5.0	

3. Radial basis function network

그림 2는 RBFN의 개략적인 구조도이다. 그림 2에서와 같이, RBFN은 입력층, 패턴층, 그리고 출력층으로 나누어진다.




그림 2. RBFN의 개요도.

입력데이터는 k-means 알고리즘을 통하여 분류된다. k-means 알고리즘은 n개의 입력값을 임의의 영역으로 분류하는 알고리즘이다. 본 연구에서는 Euclidenen distance를 이용하여 임의의 center 즉 초기 cluster를 결정하고 각 입력값들과의 거리를 계산하여 가장 가까운 cluster에 위치시키는 방식을 이용하였으며, 이는 (1)식으로 표현된다.

$$D = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (1)$$

패턴층의 임의의 뉴런의 출력은 (2)식으로 구해진다.

$$g(x) = e[-(x - \mu_j)^2 / \sigma_j^2] \quad (2)$$

여기서 x 는 입력값, μ_j 은 k-means 알고리즘으로 얻은 새롭게 분류된 영역 (receptive field라 불리는) 지역의 center값이며, σ_j 는 receptive field의 width, $g(x)$ 는 j번째 뉴런의 output이다. 모델 성능은 σ_j 값에 상당한 영향을 받을 수 있으며, 따라서 RBFN 모델최적화를 위한 중요한 학습인자이다. 그리고 패턴층과 출력층 weight은 Least Mean Square Algorithm (LMSA) 즉 에러의 자승이 최소가 되도록 하는 결정방식에 따라 다음과 같이 구해진다.

$$W = ([O]^T [O])^{-1} [O]^T [T] \quad (3)$$

여기서 W 는 weight matrix, O 는 pattern layer output matrix 그리고 T 는 target matrix 이다.

4. 모델링

4.1 GA-RBFN 모델

GA를 이용하여 초기웨이트의 영향을 최적화한다. GA에 관여하는 두 확률변수, 즉 교배확률 (Pc)와 돌연변이 확률 (Pm)은 각 기 0.95와 0.05에 고정하였다. 초기 해 집단을 100으로 설정하였으며, 진화 세대수를 100으로 고정하였다. 초기해 구성의 불규칙성을 고려하여 GA 최적화를 10회에 반복하였으며, 이 중 최적의 모델을 결정하였다. GA 최적화가 적용되는 과정을 설명하기 위하여 AI 식각률을 모델링하는 과정을 설명한다. 초기 해 (chromosome)은 2개의 slot으로 구성이 되었으며, 첫 번째와 두 번째 slot에는 난수 발생기를 이용하여 2-8과 0.5-4.5 사이의 값이 각 할당된다. 진화과정은 100 세대에 이르러 중단이 되게 설정하였다. 각 chromosome의 적합도는 다음과 같은 식으로 계산하였다.

$$F = \frac{1}{RMSE + 1} \quad (4)$$

편의를 위하여 GA를 이용하여 최적화한 RBFN 모델을 GA-RBFN으로 표현한다. 그림 3은 세대에 따른 GA-RBFN 모델의 예측성능과 적합도 값을 도시하고 있다. 예측성능은 일반적인 root mean-square error (RMSE) 공식을 이용하여 계산하였다. 그림 3에서의 각 세대수에서 결정된 RMSE는 해당 세대수에서 발생시킨 100개의 모델 중에서 그 RMSE가 가장 작은 것과 일치한다.

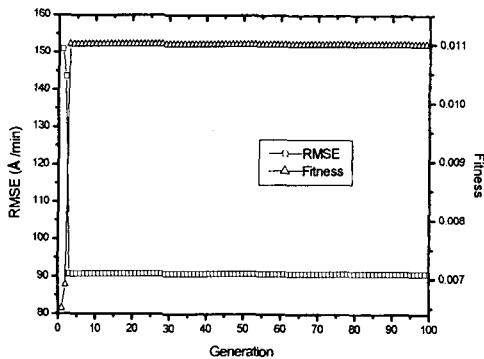


그림 3. 세대수별 GA-RBFN 모델의 RMSE와 F.

그림 3에서와 같이, RMSE는 세대수가 4로 증가할 때, 급격히 감소하고 있으며, 그 이상의 세대수에 대해서는 변화가 없다. 결국, 최적모델은 4 세대수 이상에서 결정되었으며, 해당 RMSE는 90 Å/min 이다. 동일한 방식으로 다른 식각응답에 대해서는 GA-RBFN 개발하였으며, 그 결과가 표 2에 있다.

표 2. 최적화한 GA-RBFN 모델 성능과 최적화한 학습인자.

최적화 값	식각 응답	실리카 식각률	AI 선택비	실리카 프로파일 각도
	학습인자	패턴층 뉴런수	6	2
	Width	1.61	0.64	1.93
RMSE		272	1.56	2.08

4.2 RBFN 모델

비교를 위해 종래의 방식으로 AI 식각률에 대한 RBFN 모델을 개발하였다. 즉 패턴층 뉴런수와 width의 영향을 개별적으로 최적화 하였다. 각 변수의 실험범위는 GA-RBFN에서 적용한 범위와 일치한다. 우선 width를 2.5로 고정하고, 뉴런수를 변화시키면서 RMSE를 계산하였으며, 그 결과가 그림 4에 도시되어 있다. 그림 4에서와 같이, 최적 RMSE는 뉴런수 7에서 결정이 되었으며, 해당 모델의 RMSE는 151 Å/min 이다. 다음에는 RBFN을 결정된 뉴런수에 고정하고, width를 0.5에서 4.5까지 0.5 간격으로 변화시키면서 모델 성능을 평가 하였다. 그 결과가 그림 5에 도시되어 있다.




그림 4. pattern units number에 따른 RMSE 변화




그림 5. width에 따른 RMSE 변화.

그림 5에서와 같이, 최적 RMSE는 width 1.0에서 결정되었으며, 그 RMSE는 134 Å/min이다. 그림 4에서 결정된 모델과 비교하여, RMSE는 약 11% 향상되었다. 또한 이전에 결정된 GA-RBFN 모델과 비교할 때, GA-RBFN 모델이 RMSE를 32% 정도 개선시키고 있음을 알 수 있다. 동일한 방식으로 다른 식각응답에 대해서 RBFN 모델을 개발하였으며, 결정된 모델의 RMSE와 학습인자가 표 3에 나타나 있다. 앞서 개발된 GA-RBFN 모델과 비교해서, GA-RBFN 모델은 실리카 식각률, AI 선택비, 그리고 실리카 프로파일 각도에 대해서 각 기 0.8%, 20.3%, 1.3% 등의 향상률을 보였다. 수치에서와 같이, GA-RBFN 모델은 실리카 식각률과 AI 식각률에 대해서 20%이상의 향상률을 보였으며, 나머지 두 식각응답에 대해서는 그 향상도가 미미하였다. 결국, GA를 이용하여 두 학습인자를 동시에 최적화한 모델은 종래의 모델에 비해 예측성능을 향상시켰음을 본 연구에서 확인할 수 있었다.

표 3. RBFN을 이용한 결과 정리.

실험응답 최적화 값		실리카 식각률	AI 선택비	실리카 프로파일 각도
		학습인자 패턴층 뉴런수	6	7
학습인자 Width	1.5	1.0	3.5	
RMSE		274	1.96	2.11

5. 결론

본 연구에서는 새로운 플라즈마 식각 공정모델을 개발하였다. 즉 유전자 알고리즘을 이용하여 RBFN 학습인자의 영향을 최적화하였으며, 광도파로 제작을 위한 실리카 식각공정 데이터에 적용하여 평가하였다. 고려한 학습인자에는 패턴층 뉴런수와 width이었으며, 식각응답에는 실리카 식각률, AI 식각률, AI 선택비, 그리고 실리카 프로파일 각도 등이다. GA-RBFN모델은 종래의 모델에 비해 우수한 예측성능을 보였다. 상대적으로 개선도가 미미했던 모델의 성능은 width의 다변수 최적화로 극복할 수 있으며, 관련 연구가 진행 중이다.

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] J. Park, I. Sandberg, Neural Computation 3 (1991) 246.
- [6] B. Kim and K. Park, Micro. Eng., 2004. (in press)
- [7] D. E. Goldberg, Genetic Algorithms in Search, Optimization & Machine Learning, Addison Wesley, 1989.
- [8] Montgomery D C. Design and Analysis of Experiments, John Wiley & Sons, Singapore, 1991.