

플라즈마 화학기상법을 이용하여 증착된 박막 전하 농도의 신경망 모델링

Neural Network Modeling of Charge Concentration of Thin Films Deposited by Plasma-enhanced Chemical Vapor Deposition

김우석*, 김병환**
Wooserk Kim, Byungwhan Kim

Abstract - A prediction model of charge concentration of silicon nitride (SiN) thin films was constructed by using neural network and genetic algorithm. SiN films were deposited by plasma enhanced chemical vapor deposition and the deposition process was characterized by means of 2^{6-1} fractional factorial experiment. Effect of five training factors on the model prediction performance was optimized by using genetic algorithm. This was examined as a function of the learning rate. The root mean squared error of optimized model was 0.975, which is much smaller than statistical regression model by about 45%. The constructed model can facilitate a qualitative analysis of parameter effects on the charge concentration.

Key Words :Modeling, Neural Network, Plasma-enhanced Chemical Vapor Deposition System, Charge Concentration

1. 서론

플라즈마 화학기상법 (Plasma-enhanced Chemical Vapor Deposition)은 소자제조를 위한 미세 박막의 증착에 핵심적으로 응용이 되고 있다. 제조되는 박막의 질 (Quality)을 높이고 동시에 최적화에 소요되는 시간을 줄이기 위해서는 박막 특성을 예측할 수 있는 컴퓨터 모델이 요구된다. 증착된 박막특성은 플라즈마 조건에 따라서 복잡하게 변화하고 공정조건에 따른 그 메커니즘도 제대로 이해가 안 되고 있어 해석적으로 모델링하기가 어렵다. 이 같은 어려움을 극복하기 위해 신경망 (Neural Network)이 플라즈마 공정에 효과적으로 응용이 되고 있으며, 최근 증착률과 굴절률의 모델링에 응용된 바 있다 [1-3]. 이외의 중요한 특성으로는 박막내부의 전하 농도 (Charge Concentration)이며, 박막의 굴절률 또는 Stress에 영향을 미치고 있어 공정조건에 따른 메커니즘의 해석을 위한 신경망 모델의 개발이 요구된다. 이전의 연구에서 역전파 (Backpropagation) 신경망 (BPNN) [4]을 이용한 저장전하의 모델[5]이 개발된 바 있으나, 제한된 수의 학습인자를 최적화했다는 한계가 있었다. 최근 활성화함수의 경사가 모델성능에 상당한 영향을 미친다는 보고가 있었으며, 따라서 종래의 학습인자에 이들 학습인자를 포함하여 최적화할 때, 더 성능이 향상된 모델개발을 기대할 수 있다.

본 연구에서는 BPNN의 학습에 관여하는 학습인자를 동시에 제어하여 모델예측성을 개선하는 기법을 소개한다. 학습인자의 제어에는 유전자 알고리즘 (Genetic

Algorithm-GA) [5]이 이용되었다. 본 기법은 PECVD를 이용한 실리콘 나이트라이드 (Silicon Nitride-SiN) 박막 제조공정에 적용하였으며, 체계적인 모델링을 위해 통계적 실험계획법을 이용하여 데이터가 수집이 되었다. 최적화된 BPNN 모델성능은 통계적인 모델과 비교하였다.

2. 실험 데이터

(100) 방향의 p-type Si 웨이퍼 위에 0.05 um 두께의 SiN 박막을 PECVD를 이용하여 증착하였다. 전하 농도는 C-V 측정을 이용하여 계산하였다. 체계적인 모델링을 위해 증착공정은 면중심 부분인자 (2^{6-1}) 실험계획법 [6]을 이용하여 진행이 되었다. 여기에 중심점에 해당하는 실험이 추가된 총 33개의 데이터가 학습데이터로 이용되었다. 모델 예측성을 테스트하기 위해 면 중심에 해당하는 12개의 실험이 이용되었다. 실험계획법에 이용된 공정변수와 실험범위는 표 1에 나타나 있다.

표 1. 실험계획법에 이용된 공정변수와 범위

공정 변수	실험 범위	단위
기판 온도	200-400	°C
압력	0.6-1.2	Torr
RF 전력	20-40	W
NH ₃ 가스	1-1.4	sccm
SiH ₄ 가스	180-260	sccm
N ₂ 가스	0-1000	sccm

저자소개

* 김우석 : 世宗大學 電子工學科 碩士課程

** 김병환 : 世宗大學 컴퓨터工學部 副教授 · 工博

3. 결과 및 고찰

3.1 역전파 신경망

BPNN은 플라즈마 공정데이터 해석에 가장 많이 응용되고 있는 구조이다. BPNN은 주로 은닉층이 하나인 3개의 층으로 구성되며, 학습은 일반화된 델타 규칙을 이용하여 진행이 되고, 이를 지배하는 규칙은 다음과 같이 표현된다.

$$W_{i,j,k}(m+1) = W_{i,j,k}(m) + n \Delta W_{i,j,k}(m) \quad (2)$$

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

$$\Delta W_{i,j,k} = \frac{\partial E}{\partial W_{i,j,k}} \quad (3)$$

는 학습률을 지칭한다. BPNN의 학습에는 많은 학습인자가 관여하고 있으며 [7], 여기에는 학습허용도 (Training Tolerance-TT), 은닉층 뉴런수 (Number of Hidden Neurons-NHN), 초기웨이트 분포의 크기 (Magnitude of Initial Wight Distribution-MIWD), 은닉층 뉴런의 활성화 함수 (바이올라 시그모이드 함수)의 경사 (g_b), 그리고 출력층 뉴런의 활성화 함수 (선형 함수)의 경사 (g_1)등이 포함된다. 이를 인자들은 모델 성능에 큰 영향을 미치지만, 이를 상호간의 영향을 해석적으로 최적화하는 것은 매우 어렵다. 이전에, 학습인자의 모델 학습과 예측에러에 대한 모델을 개발하고, 이에 기초하여 학습인자를 최적화한 연구보고가 있었다 [9]. 이 경우 학습인자 영향 모델을 개발하는데에 따른 에러가 수반되어 최적화 효율이 저하될 수 있으며, 따라서 모델없이 학습인자를 최적화하는 기법이 요구된다. 본 연구에서는 이를 GA를 이용하여 해결하였다.

표 1 실험계획에 이용된 공정변수와 범위

Training factors	Ranges
TT	0.06-0.15
NHN	4-12
IWD	0.6-1.2
g_b	0.6-1.5
g_1	0.6-1.5

3.2 모델 성능

GA를 적용하는데 필요한 각 학습인자의 실험범위가 표 2에 나타나 있다. 편의를 위해 GA를 이용한 BPNN 모델을 GA-BPNN이라 칭한다. GA를 적용하는데 있어 초기 세대수는 100개, 각 해는 6개의 slot으로 구성되었으며, 각 slot에는 난수발생기에 의해 표 1의 각 변수의 주어진 범위에서 발생한 값이 할당이 된다. 그리고 각 해의 평가함수는 다음과 같이 주어졌다.

$$\text{평가함수} = 1/(1+\text{RMSE}) \quad (4)$$

여기서 RMSE (Root Mean Squared Error)는 테스트 데이터

에 대한 에러를 지칭한다.

표 2 학습률에 따른 최적모델과 학습인자

학습률	0.001	0.002	0.003	0.004	0.005
TT	0.115	0.073	0.073	0.115	0.629
NHN	9	6	12.62	6	7
IWD	1.004	1.121	1.388	0.921	0.941
g_b	2.048	0.779	2.676	0.758	1.137
g_1	1.690	0.835	1.186	0.853	0.953
RMSE	1.177	1.126	1.168	1.142	0.975

그림 1은 학습률 (Learnig Rate)가 0.001일 때 GA-BPNN의 세대수(Generation number)에 따른 RMSE와 Fitness를 도시하고 있다. 그림 1에서 결정된 가장 작은 RMSE는 1.177이었다. 다음에는 학습률을 0.001에서 0.005까지 증가시키면서 GA-BPNN 모델을 개발하여 성능을 평가하였으며 그 결과가 표 2에 나타나 있다. 표 2에는 각 학습률에서 결정된 모델의 예측에러와 학습인자가 나타나 있다. 표 2에서와 같이 학습률의 증가에 따라 RMSE가 감소하고 있으며, 0.005에서 최소 RMSE 0.975를 얻었다. 한편, 0.005보다 큰 학습률에 대해서는 예측에러의 변화가 없거나 더 증가되었다.

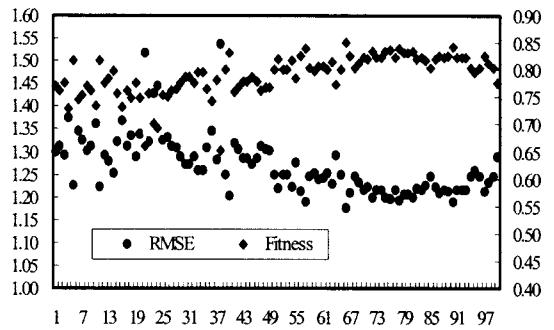


그림 1. GA-BPNN의 예측에러와 적합도

비교를 위해 통계적인 회귀 모델을 개발하였다. 회귀모델의 일반적인 형태는 다음과 같이 표현된다.

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i=1}^k \sum_{j \neq i} \beta_{ij} x_i x_j \quad (5)$$

(5)에서 y 는 전하농도이며, β_i 와 β_{ij} 는 추정해야 할 회귀계수이다. x_i 는 공정변수에 해당하는 Regressor 변수이다. 총 4종류의 회귀모델이 개발되었으며, 이를 유형 1, 2, 3, 4로 표현하였다. 유형 1은 (5)에서 상수와 첫 항으로 구성된 모델이며, 유형 2는 (5)에 있는 모든 항을 다 포함한 모델이다. 유형 3과 4는 (5)에서 4번째 항인 Interaction 항과 3번쨰인 자승항이 배제되어 구성된 모델을 지칭한다. 개발된 모델에 대한 예측 에러는 표 3에 나타나 있다. 표 3에서와 같이 최적 모델은 유형 4로 결정이 되었으며, 그 RSME는 1.79였다. 이전에 결정된 신경망 모델과 비교하면, 신경망 모델이 45%정도 개선된 예측성능을 보이고 있다. 이로써 GA 최적화 기법이 우수한 예측모델을 개발하는데 매우 효과적임을 확인할 수 있었다.

표 3 통계 모델의 예측에러

유형	학습에러	예측 에러
1	1.4087	1.9424
2	0.7564	23.9913
3	0.7595	1.9424
4	1.4070	1.7913

4. 결론

본 연구에서는 PECVD를 이용하여 증착한 SiN 박막 내부의 전하농도를 예측하기 위한 신경망 모델을 이용하여 개발하였다. 유전자 알고리즘을 BPNN 학습인자 상호간의 영향을 최적화하기 위해 응용되었다. 모델성능은 학습률의 함수로 평가하였으며, 통계적인 회귀 모델에 비해 45%정도 개선된 예측모델을 개발할 수 있었다. 개발된 모델은 공정의 정성적인 분석과 최적화에의 활용이 기대된다.

감사의 글

본 연구는 산업자원부의 System IC 2010 사업과 University IT Research Center 사업의 지원으로 수행 되었습니다.

참 고 문 헌

- [1] Kim, B., Kim, S., Hong, W.S., "Use of neural network to control of a refractive index of SiN film deposited by plasma enhanced chemical vapor deposition," *Plasma Chemistry and Plasma Processing*, vol. 24, no. 1, pp. 29-40, 2004.
- [2] Kim, B., Park, K., Lee, D., "Use of neural network to model a deposition rate of PECVD-silicon nitride films, *Plasma Source Science and Technology*," vol. 14, pp. 83-88, 2005.
- [3] Kim, B., Hong, W.S., "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.*, vol. 32, no. 1, pp. 84-89, 2004.
- [4] Rummelhart D.E., McClelland J.L, *Parallel Distributed Processing*. MIT Press, Cambridge, 1986.
- [5] Goldberg, D.E. *Genetic Algorithms in Search, Optimization & Machine Learning*. Addison Wesley, Reading MA, 1989.
- [6] Montgomery, D.C., *Design and Analysis of Experiments*. John Wiley & Sons, Singapore, 1991.
- [7] Kim, B., Park S., "An Optimal Neural Network Plasma Model: a Case Study," *Chemometr. Intell. Lab. Syst.* vol. 56, no. 1, pp. 39-50, 2001.