

신경망을 이용한 실리콘 나이트라이드 박막의 전하밀도 모델링 Charge Density Modeling of Silicon Nitride Thin Films Using Neural Network

권상희¹, 김병환^{1*}

(1) 세종대학교, 전자공학과
(1*) 세종대학교, 전자공학과

초 록 : 플라즈마 응용화학기상법을 이용하여 Silicon Nitride (SiN) 박막을 증착하였다. PECVD 공정은 Box Wilson 실험계획표를 이용하여 수행하였다. SiN박막의 전하밀도를 신경망과 유전자 알고리즘을 이용하여 모델링하였다. 개발된 모델을 이용하여 전하밀도에의 N₂와 NH₃의 영향을 다양한 온도에서 고찰하였다. N₂ (or NH₃)의 증가에 따라 전하밀도는 증가하였으며, 이는 전하밀도의 [N-H]에의 강하게 의존하고 있음을 보인다. 전하밀도는 고온에서의 NH₃의 증가, 또는 높은 NH₃ 유량에서의 온도의 증가에 따라 급격 증가하였다. 굴절률 모델과 비교할 때, 이 같은 현상이 [N-H]의 증가에 기인하는 것으로 해석되었다.

데이터가 포함되지 않은 먼 중심에 해당하는 12번의 실험데이터로 평가하였다. 실험에 이용된 실험변수와 실험범위는 표 1에 나타나 있다. 4 inch, (100) 방향의 p-t pe Silicon 웨이퍼 위에 증착되었으며, 증착 중에 SiH₄ 가스는 2% N₂ 가스로 희석되었다. 전하밀도는 C-V 측정기술을 이용하여 측정하였다.

1. 서 론

태양전지의 Passivation 막에 이용되는 Silicon nitride (SiN) 박막은 Plasma Enhanced Chemical Vapor Deposition (PECVD) s stem을 사용하여 증착되어 왔다[1-2] PECVD를 사용한 SiN 박막 증착에는, Radio frequenc (RF) 전력 또는 압력과 같은 다 수의 공정변수가 관여하고 있다. 공정변수에 따라 박막특성은 달라지며, 공정메커니즘의 해석과 공정 최적화를 위해 컴퓨터 시뮬레이션 모델의 개발이 요구된다. 하지만, 플라즈마와 공정변수간의 복잡한 반응으로 플라즈마 예측모델을 개발하는 것은 매우 어렵다. 이러한 복잡성을 피하기 위해서, 신경망과 통계적 실험계획법을 결합해서 예측모델을 개발하려는 시도가 있었으며, PECVD-SiN 박막 특성 모델링에 적용되었다 [3-4]. 박막특성 중 높은 전하밀도는 태양전지의 표면 Passivation의 개선에 요구된다. 본 연구에서 SiN박막의 전하밀도 모델을 Generalized Regression Neural Network (GRNN) [5]과 Genetic Algorithm (GA) [6]를 이용하여 개발하였다. GA는 GRNN 모델의 예측수행을 최적화하기 위해 사용하였다. SiN의 PECVD 공정은 통계적인 실험설계를 사용하여 수행되었다. 최적화한 모델을 이용하여 기판 온도에 따른 N₂ 유량과 NH₃유량에 따른 전하밀도의 특성을 해석하였다.

2. 본 론

2.1 실험적인 세부사항

SiN 박막은 13.56 MHz에서 동작하는 Plasma-Therm 700 series batch reactor를 사용하여 증착하였다. 장비 개요도가 그림 1에 도시되어 있다. 전극사이의 거리는 2.29 cm 이고 직경은 11 inches이었다. PECVD 공정은 먼 중심 Box Wilson 실험계획법 [7]을 이용하여 수행되었다. 이 실험계획법은 2⁶⁻¹ 부분인자 실험계획법과 중심점에 해당하는 실험, 그리고 12 개의 먼중심에 해당하는 실험으로 구성되었으며, 총 45번의 실험이 수행되었다. 첫 두 종류의 실험을 통해 33번의 실험이 수행되었고, 수집된 데이터는 신경망 모델을 학습하는데 이용되었다. 학습된 GRNN의 예측성능은 학습




그림 1. PECVD 시스템의 개요도

표 1. 공정변수와 범위

Parameters	Range	Unit
Substrate Temperature	200-400	°C
Pressure	0.6-1.2	Torr
RF Power	20-40	W
NH ₃ Flow	1-1.4	sccm
SiH ₄ Flow	180-260	sccm
N ₂ Flow	0-1000	sccm

2.2 신경망 모델 개발

전하밀도 특성에의 공정변수의 영향을 고찰하기 위해 신경망 모델을 개발하였다. 구체적인 모델 개발과정은 이전 연구 [8]에 상세 기술되어 있다. 예측 모델은 GRNN과 GA를 이용하여 개발되었으며, 개발된 모델의 예측성능은 0.72 (×10¹²/cm²)이었다. 특 , GA는 패턴층 뉴런의 다변수화된 학습인자의 영향을 효과적으로 최적화시켰으며, 그 결과 매우 우수한 예측모델을 개발할 수 있었다.

개발된 모델을 이용하여 공정변수, 즉 N₂와 NH₃의 영향을 다양한 온도 환경에서 살펴본다. 그림 2는 N₂와 온도의 영향을 도시하고 있다. 다른 4개의 공정변수는 표 1의 실험 구간에서의 중간 값에 설정하였다. 그림 2에서 N₂ 유량 0 sccm에서 온도를 증가시킬 때, 비교적 높은 온도구간에서 온도의 증가에 따라 전하밀도가 증가하는 것을 알 수 있다. 온도증가에 따라 박막내의 H 농도가 감소하는 것이 보고된 바 있으며 [9], 따라서 향상된 전하밀도는 [H]의 감소와 밀접한 관련이 있어 보인다. N₂ 1000 sccm에서도 온도의 영향

이 유사함을 알 수 있다. 한편, 그림 2에서와 같이, N₂의 증가에 따라 전하밀도는 크게 증가하고 있다. N₂의 증가에 따라 [N-H]가 증가하며, 따라서 향상된 전하밀도는 [N-H]의 증가와 매우 밀접한 관계가 있음을 알 수 있다. 그러나, N₂의 증가에 따라 굴절률은 크게 감소하였으며 [10], 이는 박막특성 최적화를 위해 전하밀도와 굴절률사이의 trade-off가 필요함을 시사한다.

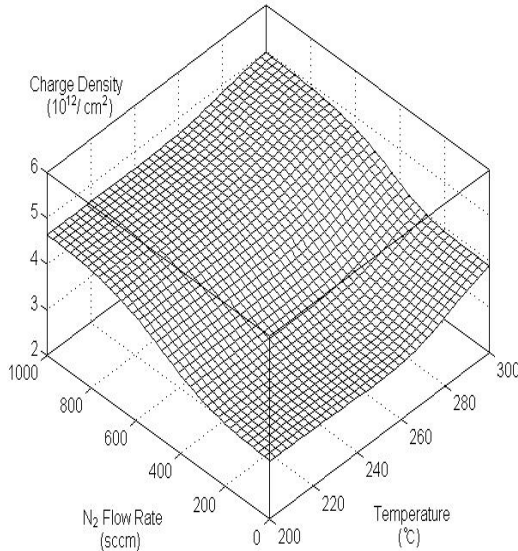


그림 1. 전하밀도에의 온도와 N₂유량의 영향

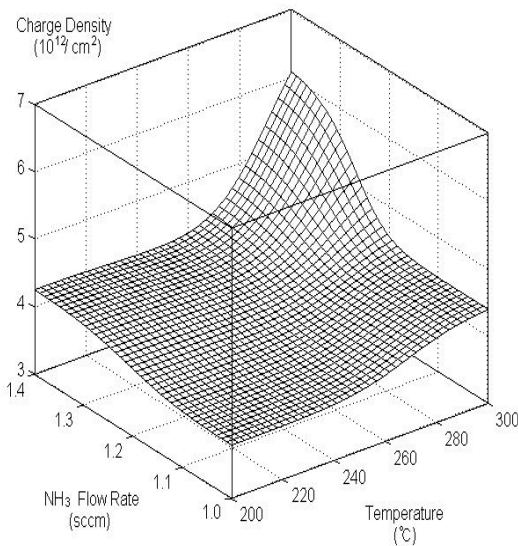


그림 3. 전하밀도에의 온도와 NH₃ 유량의 영향

그림 3은 전하밀도를 온도와 NH₃ 유량의 함수로 도시한 것이다. 그림 3에서, NH₃ 1.0 sccm에서 온도를 증가시킬 때 전하밀도가 증가하고 있다. 이는 그림 2의 경향과 일치한다. NH₃ 1.4 sccm에서 250 °C 이상에서의 온도의 증가에 따라 전하밀도는 급격하게 증가하고 있다. 관련 메커니즘의 해석을 위해 이전에 보고한 굴절률 모델 [10]의 경향과 비교하였다. 이 모델에서는 굴절률이 온도의 증가에 따라 증가하다가 높은 온도에서는 감소하고 있음을 보였다. 이는 높은 온

도에서 [N-H]의 증가가 있었음을 의미하며, 결국 그림 3의 급격히 증가된 전하밀도는 [N-H]의 증가에 기인한다고 해석할 수 있다. 전하밀도의 [N-H]에의 강한 의존성은 앞에서의 그림 2에서의 N₂ 영향에서 이해한 바 있다. 한편, 250 °C이하에서의 온도증가에 따른 [Si-H]의 증가는 전하밀도에 영향을 주지 않고 있음을 알 수 있으며, 이는 전하밀도가 [Si-H]의 변화에 영향을 미치지 않게 받고 있음을 의미한다.

그림 3에서와 같이, 200 °C에서 NH₃ 유량이 증가함에 따라 전하밀도가 증가하고 있다. 이는 예상되는 [N-H]의 증가에 기인하는 것으로 해석할 수 있다. 이는 굴절률 모델에서의 NH₃의 증가에 따른 굴절률의 감소에서 확인할 수 있다. 한편, 300 °C에서의 NH₃ 유량의 증가에 따라, 전하밀도는 급격히 증가하고 있다. 관련 메커니즘의 해석을 위해 굴절률 모델 [10]과 비교하였다. 굴절률 모델은 동일 온도에서의 NH₃ 유량의 증가에 따라 감소하였으며, 특 고유량의 NH₃에서의 감소는 더 현저하였다. 이는 [N-H]의 급격한 증가에 기인하는 것으로 해석할 수 있다. 그림 3에서 최대 전하밀도는 고온과 높은 NH₃ 유량에서 얻을 수 있음을 알 수 있다.

3. 결 론

본 연구에서는 PECVD를 이용해 증착된 SiN 박막의 전하밀도를 신경망을 이용하여 모델링하였다. GA-GRNN의 최적화된 모델로 온도에 따른 N₂와 NH₃ 유량의 영향을 고찰하였다. 이전에 보고된 굴절률 모델은 전하밀도와 [N-H]와의 상관성을 해석하는 데에 활용하였다. 비교 결과, 전하밀도는 [N-H]의 증가에 따라 증가하였으며, 특 급격한 전하밀도의 증가는 [N-H]가 상대적으로 [Si-H]보다 큰 것에 기인하는 것으로 해석되었다. 또한 전하밀도는 [Si-H] 변화에 미미하게 반응하는 한편, [N-H]의 변화에는 매우 민감하게 반응하는 것으로 확인되었다.

감 사 의 글

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

참 고 문 헌

- [1] P. Temple-Boer, L. Jalabert, L. Masarotto, J. L. Ala, and J. R. Morante, J. Vac. Sci. Technol. A 18 (2000) 2389.
- [2] H. Gleskoya, S. Wagner, V. Gasparik, and P. Koyac, Appl. Surf. Sci. 175, 12 (2001).
- [3] B. Kim and W. S. Hong, IEEE Trans. Plasma Sci. 32, 84 (2004).
- [4] B. Kim, K. Park, D. Lee, Plasma Sour. Sci. Technol. 14, 83 (2005).
- [5] D. F. Specht, IEEE Trans. Neural Network 2 (1991) 568.
- [6] D. E. Goldberg, Genetic Algorithms in Search, Optimization & Machine Learning, Addison Wesley, Reading, MA, 1989.
- [7] D. C. Montgomery, Design and Analysis of Experiments, John Wiley & Sons, Singapore, 1991.
- [8]
- [9] B. F. Hanalogiu and E. S. Adil, J. Vac. Sci. Technol. A 16, 2794 (1998).
- [10] B. Kim, D. W. Kim, and S. S. Han, Vacuum 72, 385 (2004).