신경망을 이용한 펄스드 이온에너지의 SiN 표면 거칠기에의 영향 모델링

Modeling of pulsed ion energy imapct on SiN surface roughness using a neural network

이화준[a], 김병환[a*],
[a*]세종대학교 전자공학과(E-mail:kbwhan@sejong.ac.kr)

초 록 : 본 연구에서는 이온에너지와 박막 표면 거칠기와의 관계를 신경망을 이용하여 모델링하였다. Pulsed 플라즈마 증착장비를 이용하여 상온에서 실리콘 나이트라이드 (SiN)을 증착하였다. 바이어스 전력과 duty ratio는 각각 40~100W와 30~90%로 변화하였다. 이온에너지 정보는 비침투식 이온에너지 분석시스템을 이용하여 수집하였다. 신경망의 성능은 유전자알고리즘을 이용하여 최적화시켰다. 최적화한 모델은 이온에너지의 영향을 고찰하였다. 모델로부터 고 이온에너지는 저 이온에너지가 높은 조건에서 증가시킬 때에 표면 거칠기를 보다 작게 한다는 것을 알 수 있었다.

1.서론

Silicon nitride 박막은 우수한 유전체 특성, 열적 안정성, 그리고 화학적 불활성 등의 특징이 있으며, 각 종 전자소자의 제작에 응용되고 있다. 플라즈마 화학기상 증착법 (Plasma Enhanced Chemical Vapor Deposition-PECVD)은 SiN 박막의 증착에 많이 이용된다. 최근 PECVD 또는 펄스 형 PECVD를 이용하여 저온에서의 SiN 박막제조 연구가 진행되고 있다 [1-3]. 이들 연구는 낮은 소스전력에서의 높은 증착률 [1]과 작은 duty ratio에서의 높은 증착률 [2] 또는 작은 표면거칠기 [3]등을 보고하고 있다. 저온 SiN 증착공정에서 이온에너지는 박막표면에서의 reaction을 촉진시키며, 여기에는 이온충돌, 이온 incorporation, bond breaking 등이 포함된다. 이온 에너지의 영향은 이온에너지 분석 시스템 (PLASMART^{TM})을 이용하여 고찰된 바가 있다 [1, 2]. 그러나 이온에너지의 박막특성에의 영향을 예측하고 모델링하는 것은 플라즈마와 박막특성간의 복잡성으로 인해 매우 어렵다. 이에 따라, 이들 간의 해석적 또는 경험적 모델이 개발된 바가 없었다.

본 연구에서는 Generalized regression neural network (GRNN) [4]를 이용하여 SiN박막의 표면 거칠기와 이온에너지와의 관계를 모델링 하였다. 이온에너지 분포는 전술한 이온에너지 분석시스템을 이용하여 수집하였다. 또한 GRNN의 성능을 최적화 하기위해 Genetic algorithm (GA) [5]를 이용하였다. 개발된 모델을 이용하여 SiN 박막 표면 거칠기에 대한 이온에너지의 영향을 고찰한다.

2.실험데이터

본 연구에서는 이온에너지의 영향을 고찰하였다. 펄스드-PECVD를 이용하여 SiN 박막을 p-type의 (100) 실리콘 웨이퍼 위에 증착하였다. 웨이퍼의 두께는 525±25㎛이고, 저항은 1~30Ω•cm이다. 소스전력은 500W로 고정하였으며, 바이어스 전력과 duty ratio는 각 각 40-100W, 30-90%의 범위에서 변화시키며 증착하였다. SiH_4, NH_3 그리고 N_2 가스는 각 각 8, 22 그리고 10sccm에 고정하였다. 증착 중에 비침투식 이온에너지 시스템을 이용하여 이온에너지인 E_h, E_l와 이온에너지 flux인 N_h N_l를 측정하였다. 여기서 “h"와 ”l"은 각 각 “high"와 ”low"를 의미한다. 이온에너지 변수는 이전의 연구에서 자세히 설명한 바 있다 [1].

3.결론

GRNN의 구조는 그림 1.에 도시 되어 있다. 그림 1.에서와 같이, GRNN은 총 4개의 층, 즉 입력층, 패턴층, 합층 그리고 출력 층으로 구성된다. 합층은 모델링 하고자 하는 각 출력변수에 대해, 2개의 S 와 D 뉴런으로 구성된다. 출력층 에서의 예측치는 (1)식으로 구해진다.

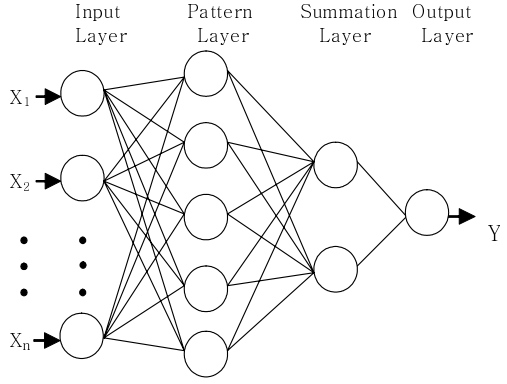

Fig 1. Structure of GRNN

여기서 P는 각 입력패턴을 구성하는 전체 독립변수의 수를 지칭한다. x_j와 x_{ij}는 x_j와 x_{ij}의 j번째의 요소를 의미한다. 그리고 변수 ζ는 spread라 불리며, GRNN의 성능을 결정하는 유일한 학습인자이다. 일반적으로 spread는 실험적으로 일정한 범위 내에서 결정하며, 결정된 spread를 그림 1.의 패턴층을 구성하는 모든 가우시안 함수가 가지게 된다.

$$\hat{y_i}(x)=\frac{\sum_{i=1}^{n} y_i exp\,[-D(x,x_i)]}{\sum_{i=1}^{n} exp\,[-D(x,x_i)]} \quad (1) \qquad D(x,x_i)=(\frac{x_j-x_{ij}}{\zeta})^2 \quad (2)$$

GRNN 예측성능은 spread 값을 0.2에서 1.2까지 0.1간격으로 증가시키면서 평가하였다. 모델의 예측성능은 Root Mean-Squared Error (RMSE)으로 계산하였다. 각 spread에서의 모델의 RMSE가 가장 작은 spread 0.2에서 실제치와 예측치를 비교 분석 한 것을 그림 2.에 도시되어 있다.

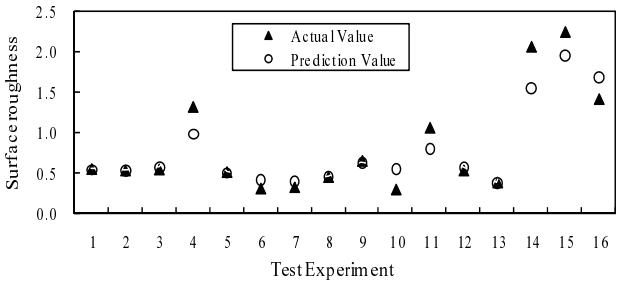

Fig 2. Actual and predicted value of surface roughness

개발된 모델로부터 3D 그림을 그려 이온에너지의 영향을 고찰하였다. 그림 3은 E_h와 E_l의 영향을 도시하고 있다. 그림 3.에서와 같이 E_h가 증가할 때 변곡점이 생기며, 이는 높은 E_l에서 더 작아진다. 이는 높은 E_l에서 E_h를 증가할 때 보다 작은 표면 거칠기를 얻을 수 있음을 의미한다. 그림 4.에서 모든 E_l에 대해서 N_h를 감소시킬 때, 표면 거칠기가 작아지고 있음을 보이고 있다.

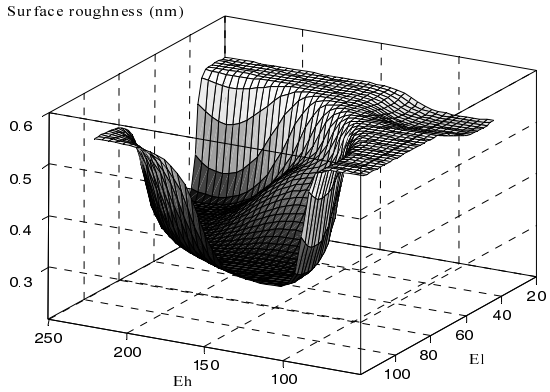

Fig 3. Effect of E_h and E_l on surface roughness.

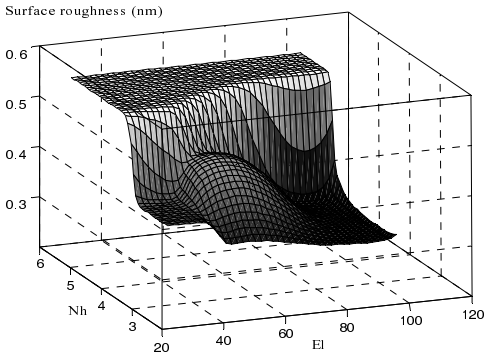

Fig 4. Effect of E_l and N_h on surface roughness.

감사의 글

이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국과학재단의 지원을 받아 수행된 기초연구사업임 (2009-0087476).

참고문헌

1. B. Kim and S. Kim, Room-temperature high radio-frequency power effectson silicon nitride films deposited by using a plasma-enhanced chemical vapor deposition, Met. Mater.-Int. 14, 637 (2008).
2. B. Kim, S. Kim, Radio frequency source power effect on silicon nitride films deposited by using a room temperature pulsed-PECVD, Thin Solid Films, 517, 4090 (2009).
3. B. Kim, S. Kim, Y. S대, S. J. Kim, S. C. Jung, and D. Kim, Surface morphology of SiN film deposited by pulsed PECVD at room temperature, J. Nanosci. Nanotechnol. 8, 5363 (2008).
4. D. F. Specht, “A general regression neural network" IEEE Trans. Neural Network 2 (1991) 568.
5. D. E. Goldberg, Genetic Algorithms in Search, Optimization & Machine Learning, Addison Wesley, Reading, MA, 1989.