

## 신경망을 이용한 SiN 박막 표면거칠기예의 이온에너지 영향 모델링

김병환<sup>a\*</sup>, 이주공<sup>b</sup>

<sup>a</sup>세종대학교 전자공학과, <sup>b</sup>세종대학교 정보통신공학과

### Neural Network Modeling of Ion Energy Impact on Surface Roughness of SiN Thin Films

Byungwhan Kim<sup>a\*</sup>, Joo Kong Lee<sup>b</sup>

<sup>a</sup>Department of Electronic Engineering, Sejong University, Seoul 143-747, Korea

<sup>b</sup>Department of Information and Communication, Sejong University, Seoul 143-747, Korea

(Received June 16, 2010 ; revised June 28, 2010 ; accepted June 29, 2010)

#### Abstract

Surface roughness of deposited or etched film strongly depends on ion bombardment. Relationships between ion bombardment variables and surface roughness are too complicated to model analytically. To overcome this, an empirical neural network model was constructed and applied to a deposition process of silicon nitride (SiN) films. The films were deposited by using a pulsed plasma enhanced chemical vapor deposition system in SiH<sub>4</sub>-NH<sub>4</sub> plasma. Radio frequency source power and duty ratio were varied in the range of 200-800 W and 40-100%. A total of 20 experiments were conducted. A non-invasive ion energy analyzer was used to collect ion energy distribution. The diagnostic variables examined include high (or) low ion energy and high (or low) ion energy flux. Mean surface roughness was measured by using atomic force microscopy. A neural network model relating the diagnostic variables to the surface roughness was constructed and its prediction performance was optimized by using a genetic algorithm. The optimized model yielded an improved performance of about 58% over statistical regression model. The model revealed very interesting features useful for optimization of surface roughness. This includes a reduction in surface roughness either by an increase in ion energy flux at lower ion energy or by an increase in higher ion energy at lower ion energy flux.

*Keywords:* Surface roughness, Neural network, Model, Silicon nitride, Ion energy

## 1. 서 론

실리콘 나이트라이드(Silicon nitride) 박막은 열적 안정성, 화학적 비활성, 그리고 우수한 유전체 특성을 지녀 메모리나 태양전지 등의 전자소자를 제조하는 데에 활발히 응용되고 있다. SiN은 플라즈마 화학기상 증착(Plasma-enhanced chemical vapor deposition-PECVD)를 이용하여 300°C 이상의 고온에서 SiH<sub>4</sub>-N<sub>2</sub>, SiH<sub>4</sub>-NH<sub>3</sub>, 또는 SiH<sub>4</sub>-NH<sub>3</sub>-N<sub>2</sub> 플라즈마를 이용하여 제조되고 있다<sup>1,2)</sup>. 최근에는 상온(Room temperature)에서 제조된 연구결과가 보고 있

으며, 고온에서 제조된 것과 다른 특이 박막특성을 보였다<sup>3-7)</sup>. 예컨대, 소스전력의 감소에 따라 증착률이 증가되거나<sup>3)</sup>, 바이어스의 감소에 따른 굴절률의 증가<sup>4)</sup> 등이 그 예이다. 한편, SiN 박막특성의 제어를 위해 펄스를 이용한 PECVD가 이용되었으며, duty ratio(DR)의 제어를 통해 박막특성을 향상시킬 수 있었다. 여기에는, DR의 감소에 따른 증착률의 증가<sup>5)</sup>나 표면거칠기의 감소<sup>6)</sup> 등이 포함된다. 진행 중인 상온에서의 SiN 제조에는 이온충돌(Ion bombardment)가 매우 중요한 역할을 수행하고 있으며, 그 영향을 연구하기 위해 이온에너지 분석 시스템(Ion energy analysis system-IEAS, PLASMART)가 응용된 바 있다. 이 기구는 IV probe로 측정한

\*Corresponding author. E-mail : kbwhan@sejong.ac.kr

전기적 데이터를 이용하여 이온에너지 분포를 제공한다. 수집된 이온에너지 분포로부터 이온에너지와 이온에너지 flux에 관한 주요 진단 변수를 추출하며, 이를 이용하여 플라즈마의 감시나 박막증착특성의 영향을 분석할 수 있다. 최근의 실험에서 이온에너지와 박막증착률간의 강한 연관성<sup>5)</sup> 등이 보고된 바가 있다. 박막특성 중, 이온에너지와 flux는 박막표면거칠기에 결정적인 영향을 주고 있다. 이온에너지와 이온에너지 flux는 플라즈마 조건, 즉 소스전력, 압력, 또는 DR의 변화에 따라 다양하게 변화하며, 이에 따라 박막특성도 다양하게 변화하게 된다. DR의 변화에 따른 표면거칠기의 변화가 보고된 바가 있지만, 이온에너지와 표면거칠기간의 모델은 해석적 측면이든 경험적 측면이든 보고된 바가 없어 공정변수에 따른 이온에너지의 표면거칠기기에 영향을 해석하기가 어렵다. 이와 같은 어려움을 극복하는 데에 효과적인 방법은 신경망 모델링 방식을 이용하는 것이다. 신경망은 비선형 시스템의 모델링에 효과적으로 적용되어 왔으며, 특히 플라즈마를 이용한 박막증착과 식각공정의 예측모델링 개발에 활발한 응용이 있었다<sup>8)</sup>. 공정변수(소스전력, 압력 등)와 박막특성(증착률, 식각률 등) 간의 모델링외에, 신경망은 공정 중 수집되는 in-situ 정보와 박막특성간의 모델링, 예컨대 optical emission spectroscopy 데이터와 식각특성간의 모델<sup>9)</sup>, 또는 x-ray photoelectron spectroscopy와 같은 박막표면진단특성과 표면거칠기의 모델링에<sup>10)</sup> 적용된 적이 있다. 그러나 전술한 바와 같이 이온에너지와 증착특성간의 모델은 발표된 바가 없다.

본 연구에서는 신경망을 이용하여 이온에너지와 증착박막의 표면거칠기 특성간의 모델을 개발한다. SiN 증착 실험은 펄스드-PECVD를 이용하여 상온에서 수행되었다. IEAS를 이용하여 이온에너지 정보를 수집하였다. 신경망으로는 일반화된 회귀 신경망(Generalized regression neural network-GRNN)<sup>11)</sup>을 이용하였으며, GRNN 모델의 예측성능은 유전자 알고리즘(Genetic algorithm-GA)<sup>12)</sup>을 이용하여 최적화하였다. 최적화한 모델은 이온에너지의 영향을 고찰하는 데에 활용하였다.

## 2. 실험 데이터

SiN 박막은 그림 1의 펄스드-PECVD 장비를 이용하여 증착하였다. 증착은 SiH<sub>4</sub>-NH<sub>3</sub> 플라즈마에서 RF 소스전력과 DR를 변화시키면서 수행되었다. 소스전력과 DR의 실험범위는 각각 200-800 W와 40-100%였으며, 총 20회의 증착공정이 수행되었다. RF

바이어스 전력은 “0 W”에 고정시켰으며, SiH<sub>4</sub>와 NH<sub>3</sub> 유량은 8과 22 sccm에 고정하였다. 증착된 SiN 박막의 평균 표면거칠기는 atomic force microscopy (AFM)을 이용하여 측정하였다. IEAS를 이용하여 챔버내 플라즈마 이온에너지 진단을 수행하였다. 이 시스템은 여러 플라즈마 조건에서의 이온에너지 데이터를 수집해서 박막특성을 연구하는 데에 이용된 바 있다.<sup>4,5,7)</sup> 에너지 시스템은 이온에너지 분포함수를 수집하며, 수집된 분포함수로부터 여러 이온에너지 변수를 정의한다. 기본적인 이온에너지 변수

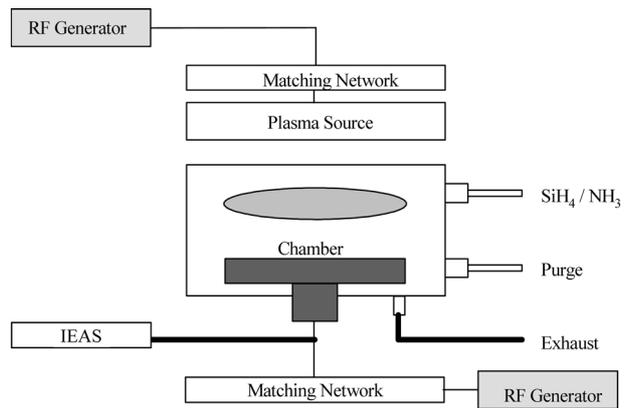


Fig. 1. Schematic of plasma enhanced chemical vapor deposition system.

Table 1. Experimental data of ion energy diagnostics and surface roughness

| E <sub>h</sub> | E <sub>l</sub> | N <sub>h</sub> | N <sub>l</sub> | Surface Roughness |
|----------------|----------------|----------------|----------------|-------------------|
| 28.4293        | 17.6946        | 7.2248         | 7.5229         | 0.479             |
| 37.2985        | 19.3390        | 14.2432        | 7.8218         | 0.582             |
| 40.2304        | 20.1367        | 11.6692        | 7.4353         | 0.751             |
| 42.1224        | 20.7322        | 9.6194         | 7.2270         | 0.544             |
| 43.1628        | 21.0848        | 9.3721         | 7.1732         | 0.421             |
| 30.2450        | 20.7850        | 4.7942         | 8.5991         | 0.395             |
| 38.2476        | 18.8865        | 7.1753         | 6.0147         | 2.34              |
| 35.9783        | 22.0244        | 5.7697         | 9.8907         | 0.219             |
| 35.0842        | 20.7421        | 4.7027         | 5.4163         | 0.311             |
| 34.3634        | 23.8329        | 4.1416         | 8.4943         | 0.692             |
| 30.4750        | 21.3026        | 4.1534         | 8.1723         | 0.129             |
| 30.6118        | 21.0974        | 5.8558         | 9.3271         | 0.405             |
| 28.3191        | 20.5768        | 6.8865         | 12.0729        | 1.014             |
| 27.5386        | 20.9422        | 7.3161         | 12.1904        | 1.655             |
| 27.5753        | 21.8657        | 7.8768         | 13.6277        | 0.54              |
| 25.6118        | 19.2296        | 7.3990         | 11.4564        | 0.518             |
| 35.1308        | 21.7530        | 6.9015         | 11.4560        | 0.495             |
| 32.9559        | 20.9972        | 7.8311         | 17.9422        | 0.433             |
| 30.3320        | 22.2686        | 5.9341         | 9.8569         | 1.652             |
| 28.0616        | 23.0758        | 9.7304         | 7.0676         | 1.693             |

에는 고이온 에너지(High ion energy- $E_h$ ), 저이온 에너지(Low ion energy- $E_l$ ), 고이온 에너지 flux(High ion energy flux- $N_h$ )와 저이온 에너지 flux(Low ion energy flux- $N_l$ )이 포함된다. 전술한 여러 조건에서의 SiN 증착공정 중에 이온에너지 변수를 수집하였으며 관련 데이터는 표 1에 정리되어 있다. 이들 진단 정보는 신경망 모델을 개발할 때 학습패턴의 입력패턴을 구성하며, 모델의 출력패턴은 평균 표면거칠기로 구성되었다.

### 3. 신경망 모델링

#### 3.1 일반화된 회귀 신경망

본 연구에서 이용된 GRNN의 구조가 그림 2에 도시되어 있다. 그림 2에서와 같이 GRNN은 4개의 층, 즉 입력층, 패턴층, 합층, 그리고 출력층으로 구성되어 있다. 입력층의 각 뉴런은 각 공정변수(또는 in-situ 측정 변수)에 해당하며, 패턴층의 뉴런수는 학습패턴의 수와 일치한다. 즉 각 뉴런은 하나의 학습패턴을 의미하며, 그 출력은 입력층에 주어진 임의의 패턴과 저장된 패턴간의 유사성 척도를 의미한다. 각 패턴층 뉴런은 합층의 S-합 뉴런과 D-합 뉴런간에 연결된다. 패턴층 뉴런과 S-합 뉴런간의 웨이트에는 학습패턴의 출력값이 저장되며, 패턴층 뉴런과 D-합 뉴런간의 웨이트에는 동일한 "1"이 할당된다. 임의의 주어진 입력  $x$ 에 대해 출력층 뉴런에서의 예측치는 다음과 같이 계산된다.

$$\hat{y}_i(x) = \frac{\sum_{i=1}^n y_i \exp[-D(x, x_i)]}{\sum_{i=1}^n \exp[-D(x, x_i)]} \quad (1)$$

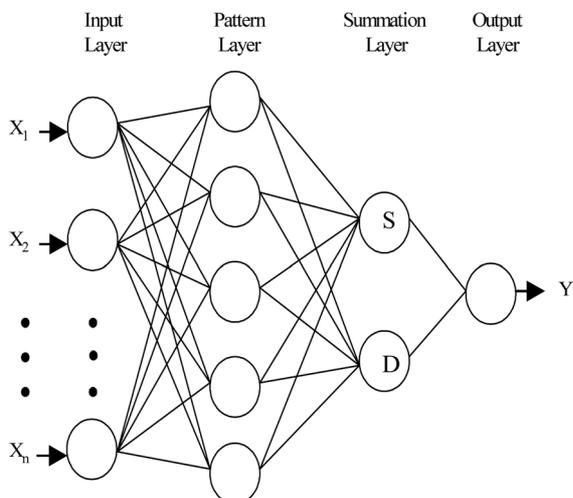


Fig. 2. Structure of generalized regression neural network.

여기서  $n$ 과  $x_i$ 는 학습패턴의 수와 입력층과 출력층 사이에 저장된  $i$ 번째의 학습입력패턴을 의미한다. (1)에서의 gaussian D 함수는 (2)와 같이 정의된다.

$$D(x, x_i) = \sum_{j=1}^p \left( \frac{x_j - x_{ij}}{\zeta} \right)^2 \quad (2)$$

여기서  $p$ 는 입력 벡터를 구성하는 요소의 수이고,  $x_j$ 와  $x_{ij}$ 는  $x$ 와  $x_i$ 의  $j$ th 요소를 의미한다.  $\zeta$ 는 스프레드(spread) 변수라고 지칭하며, GRNN의 학습성능을 결정하는 학습인자이다.  $\zeta$  값은 주로 일정범위, 예컨대 0.1과 1사이의 범위에서 그 값을 증가시키면서 모델성능을 평가하여 최적화된 값을 결정한다. 일반적으로 그림 2의 패턴층의 모든 뉴런의 가우시안 함수의  $\zeta$ 를 동일한 값에서 최적화하였으나, 최근 이를 다변수화하고 최적화하는 기법을 개발하여 모델성능이 개선된 바가 있다<sup>8)</sup>. 본 연구에서는 이 기법을 적용하여 최적화된  $\zeta$ 를 결정한다.

#### 3.2 최적화된 모델

준비한 학습데이터를 이용하여 GRNN 모델을 개발한다. 먼저 spread의 0.1과 1사이의 범위에서 0.1 간격으로 증가시키면서 모델을 개발하였다. 모델의 예측성능은 GA를 이용하여 최적화하였다. GA는 다양한 플라즈마 공정 데이터에 대한 예측 모델을 개발하는 데에 효과적으로 적용된 바 있다<sup>8)</sup>. GA 최적화에 관여하는 인자에는 초기해의 수, 세대 수, 교배와 돌연변이 확률, 그리고 적합수 함수 등이 있다. 첫 두 인자는 동일한 100에 고정하였다. 교배와 돌연변이 확률은 각각 0.95와 0.05에 고정하였다. 각 해의 적합도를 평가하는 적합도 함수는 다음과 같이 정의하였다.

$$\text{적합도 함수} = 1/(1 + \text{RMSE}) \quad (3)$$

여기서 RMSE는 root mean square error를 지칭하며, 학습데이터에 대해 계산된 양이다. 다음 세대는 roulette wheel selection<sup>11)</sup> 방법을 사용하여 발생시켰다.

신경망 모델개발을 위한 spread의 범위는 0.1-1.0이었다. 각 spread에서 최적화한 모델을 개발하였으며, spread의 변화에 따른 모델 성능이 그림 3에 나타나 있다. 그림 3의 각 에러는 RMSE를 의미한다. 그림 3에서와 같이 spread의 감소에 따라 모델의 인식성능이 감소하고 있음을 알 수 있다. 0.1에서 RMSE가 가장 작았지만, 너무 과대하게 학습(over-training)되는 것을 피하기 위해 0.2에서의 모델을 선택하였으며, 모델에러는 0.09 정도였다. 결정된 모델의 실제치와 예측치간의 성능 비교가 그림 4에

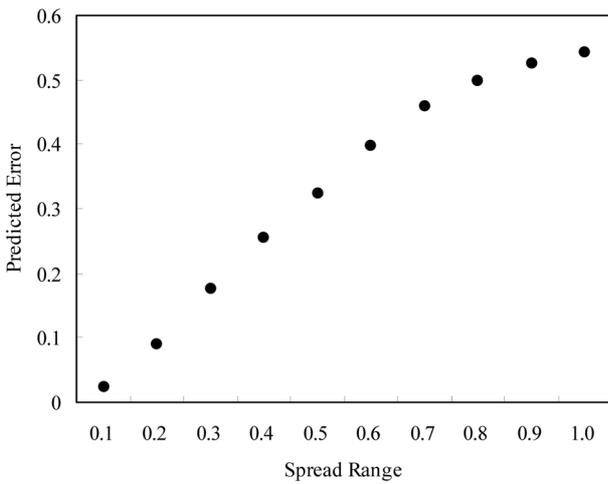


Fig. 3. Prediction performance of GRNN model as a function of spread range.

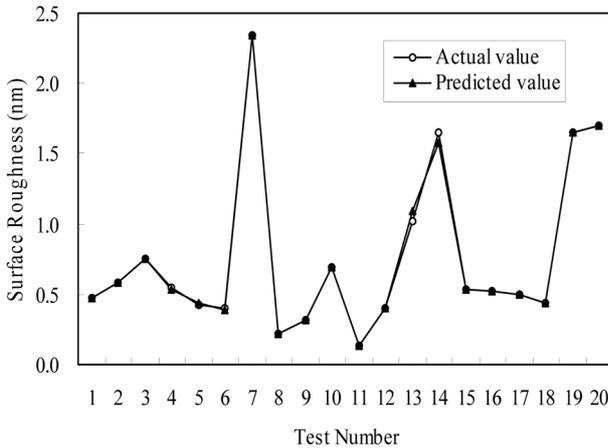


Fig. 4. Comparison of model predictions and actual measurements.

나타나 있다. 그림 4에서와 같이 개발된 모델은 실제치를 매우 정확하게 인식하고 있음을 알 수 있다. 최적화된 GRNN 모델의 성능비교를 위해 통계적 회귀모델을 개발하였다. 완전 2차형의 통계모델은 식 (4)에서와 같이 상수항, 단일(single) 항, 제곱(square) 항, 그리고 교호(interaction)항으로 구성되었다.

$$\begin{aligned}
 &A + a * E_h + bE_i + cN_h + d * N_i + e * E_h * E_i + f * E_h * N_h \\
 &+ g * E_h * N_i + h * E_i * N_h + i * E_i * N_i + j * N_h * N_i \\
 &+ k * E_h^2 + l * E_i^2 + m * N_h^2 + n * N_i^2 \quad (4)
 \end{aligned}$$

식 (4)에서 A와 소문자로 표기된 항은 실험데이터를 이용하여 추정되는 regressor 변수들이다. 신경망 모델개발에 이용된 데이터를 적용하여 통계모델을 개발한 결과 모델의 예측성능은 0.219였다. 앞서의 신경망 모델은 이 통계 모델에 비해 59% 정도의 개선된 인식성능을 보이고 있다.

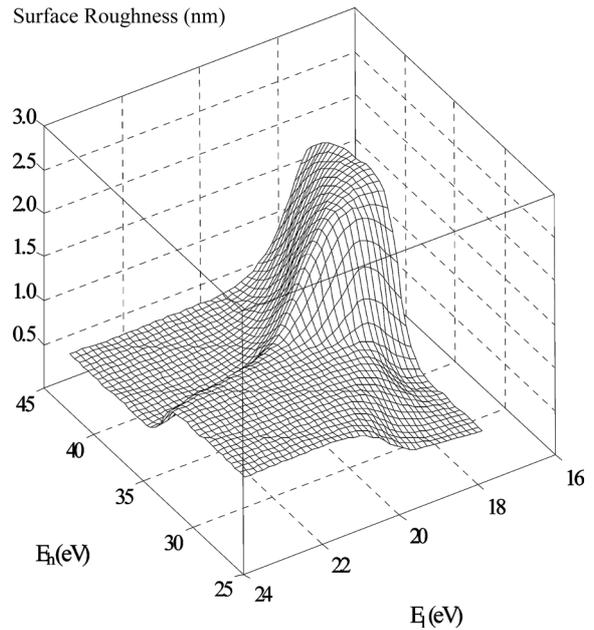


Fig. 5. Effect of  $E_h$  and  $E_i$  on surface roughness.

### 3.3 모델 해석

이온에너지 영향을 해석하기 위해 최적화된 모델로부터 다양한 3D 그림을 얻었다. 그림 5는  $E_h$ 와  $E_i$ 의 표면거칠기에의 영향을 보이고 있다. 그림 5에서와 같이  $E_i$ 이 높은 조건에서의  $E_h$ 의 증가는 표면거칠기를 약간 감소시킨다. 이는 이온에너지의 증가가 보다 부드러운 박막표면을 제조하는 데에 효과적임을 보여준다. 그러나,  $E_i$ 이 낮은 경우  $E_h$ 의 영향은 상당히 증가하게 되며,  $E_h$ 의 증가에 따라 표면거칠기가 급격하게 증가하고 있음을 보인다. 이는 과도한 이온충돌로 인해 야기되는 것으로 이해할 수 있는 일반적인 현상이다. 이를 역으로 해석하면  $E_i$ 이 높은 조건에서  $E_h$ 를 감소시킬 경우 표면거칠기를 더 줄일 수 있다는 것을 암시하며, 이는 표면거칠기의 최적화에 중요한 단서를 제공한다. 한편, 그림 5에서와 같이  $E_h$ 가 낮은 조건에서의  $E_i$ 을 감소시키는 영향은 전술한  $E_i$ 이 높은 조건에서의  $E_h$ 를 증가시키는 영향과 비슷하다. 높은  $E_h$ 에서의  $E_i$ 의 감소는 단지  $E_i$ 이 매우 높은 범위에서 급격히 표면거칠기를 증대시키고 있다. 그림 5에서 보다 작은 표면거칠기는 낮은  $E_i$ 과 낮은  $E_h$ 에서 얻었으며, 보다 낮은  $E_i$ 에서의  $E_h$ 의 감소로 표면거칠기를 더 작게 할 수 있을 것으로 기대된다. 이는  $E_h$ 와  $E_i$ 이 함께 표면거칠를 결정하는 데에 관여하는 것을 의미하며, 또한 그림 5으로부터  $E_i$ 에 비해  $E_h$ 가 표면거칠기에 더 증대한 영향을 미치고 있음을 알 수 있다.

그림 6은  $N_h$ 와  $E_h$ 의 표면거칠기에의 영향을 보이

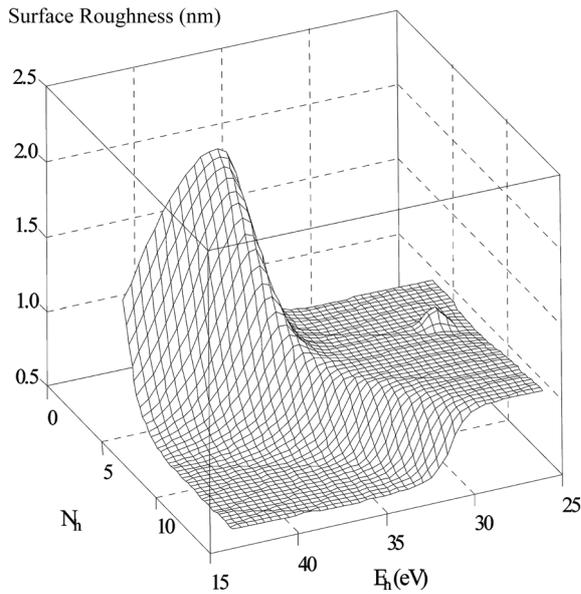


Fig. 6. Effect of  $E_h$  and  $N_h$  on surface roughness.

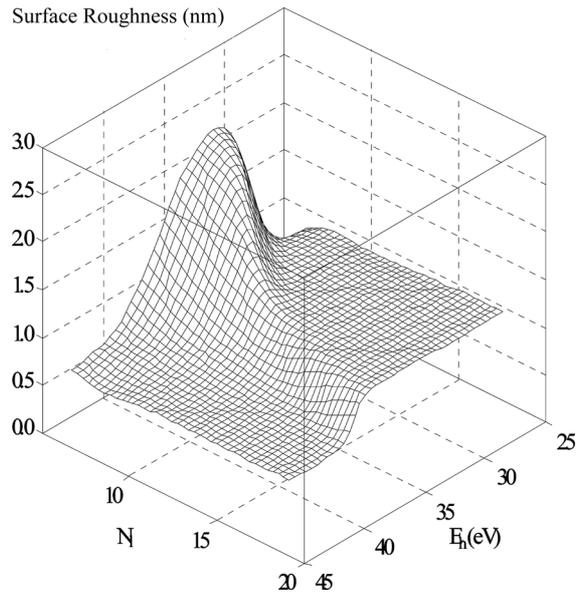


Fig. 7. Effect of  $N_h$  and  $E_h$  on surface roughness.

고 있다. 그림 6에서와 같이  $N_h$ 의 영향은  $E_h$ 가 높은 조건에서는 매우 미미함을 알 수 있다. 그러나  $E_h$ 가 낮은 조건에서는  $N_h$ 를 증가할 때 표면거칠기가 감소하게 된다. 이는 보다 낮은  $E_h$ 에서  $N_h$ 를 증가시킬 때 보다 작은 표면거칠기를 얻을 수 있음을 암시한다. 보다 낮은  $E_h$ 는 웨이퍼에 인가하는 radio frequency 바이어스 전력을 감소시켜 플라즈마 쉬스 전압을 줄여 용이하게 얻을 수 있다. 한편, 그림 6에서와 같이 높은  $N_h$ 에서의  $E_h$ 의 증가는 표면거칠기를 약간 증가시키고 있다. 이는 높은  $N_h$ 와 높은  $N_h$ 로 야기될 수 있는 과대한 이온충돌에 의해 야기된 것으로 이해할 수 있다. 그러나 낮은  $N_h$ 에서의  $E_h$ 의 증가는 표면거칠기를 초기에 급격하게 증가시키고 있으나 높은  $E_h$ 의 범위에서는 그 반대로 표면거칠기를 감소시키고 있다. 이로부터  $E_h$ 의 분포를 유추할 수 있는데, 즉  $E_h$ 가 작은 범위에서는  $E_h$ 가 국부적으로 이온들에게 전달되지만,  $E_h$ 가 충분히 클 경우 보다 균일하게 이온들에게 전달되어 보다 균일한 표면거칠기를 얻을 수 있다.

그림 7은  $N_h$ 와  $E_h$ 의 표면거칠기에의 영향을 나타내고 있다. 그림 7에서와 같이  $N_h$ 에 상관없이  $E_h$ 의 증가에 따라 표면거칠기는 감소한다. 이는  $E_h$ 이  $N_h$ 의 영향을 받지 않고 표면거칠기에 영향을 주고 있음을 의미한다. 한편,  $N_h$ 의 증가에 따라 표면거칠기는 감소하며, 이는 거의 모든  $E_h$ 에서 나타나고 있다. 결국,  $N_h$ 와  $E_h$ 은 서로 독립적으로 영향을 미치고 있음을 알 수 있다.

그림 8은  $E_h$ 과  $N_h$ 의 영향을 나타내고 있다. 그림 8에서와 같이  $N_h$ 이 낮은 조건에서  $E_h$ 의 감소는, 구

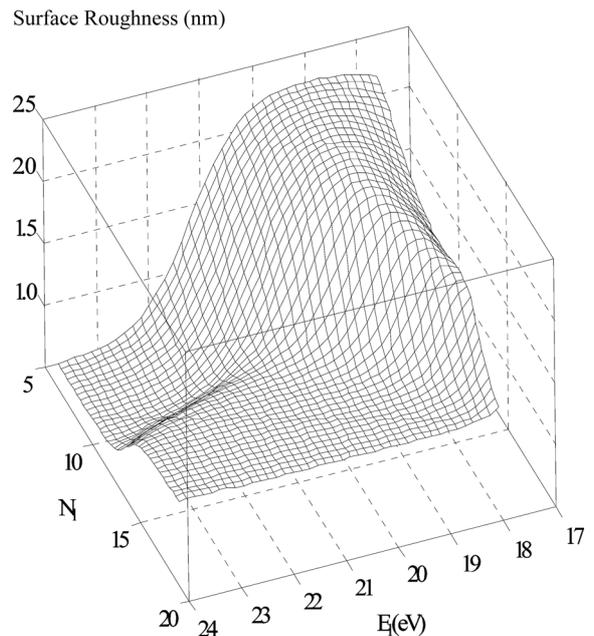


Fig. 8. Effect of  $E_h$  and  $N_h$  on surface roughness.

체적으로  $E_h$ 이 높은 영역에서의  $E_h$ 의 감소는 표면거칠기를 급격하게 감소시키고 있다. 이는 그림 6에서의  $N_h$ 에서의  $E_h$ 가 높은 범위에서의  $E_h$ 의 변화와 일치한다. 이로부터, 이온에너지 flux가 낮은 조건에서 이온에너지가 높은 범위에서의 이온에너지의 증가는 표면거칠기를 공통적으로 감소시키고 있음을 알 수 있다. 이는 표면거칠기를 제어하는데 매우 유용하게 활용할 수 있는 진단 정보라고 할 수 있다. 한편, 그림 8에서와 같이  $N_h$ 의 영향은  $E_h$ 에 따라서 상당히 다르다.  $E_h$ 이 높은 조건에서  $N_h$ 를 감소시킬 때 표면거칠기가 약간 감소하고 있다. 그러

나, 이와 반대로  $E_i$ 이 낮은 조건에서의  $N_h$ 의 감소는 표면거칠기를 급격하게 증대시키고 있으며, 이는 이온충돌의 급격한 감소에 기인하는 것으로 해석할 수 있다. 이와 비슷한 현상이 그림 6의  $E_h$ 가 낮은 조건에서의  $N_h$ 의 감소에 따라 발생한다. 이로부터 이온에너지가 낮은 조건에서 이온에너지 flux의 증가는 표면거칠기를 공통적으로 크게 증대시키고 있음을 알 수가 있다.

#### 4. 결 과

본 연구에서 이온에너지와 박막표면거칠기간의 관계를 예측할 수 있는 신경망 모델을 개발하였다. SiN 박막을 pulsed-PECVD 시스템을 이용하여 증착하였으며, 표면거칠기는 atomic force microscopy를 이용하여 측정하였다. 이온 충돌과 밀접하게 연관되어 있는 진단변수를 추출하고 이들과 표면거칠기간의 관계를 신경망을 이용하여 모델링하였다. 모델의 예측성능을 유전자 알고리즘을 이용하여 최적화하였으며, 최적화한 모델로부터 다양한 3D 그림을 그려 진단변수의 영향을 해석하였다. 모델로부터 유용한 이온에너지 영향을 이해할 수 있었으며, 여기에는 높은  $E_i$ 에서의  $E_h$ 의 감소 또는 낮은  $E_h$ 에서의  $N_h$ 의 증가에 따른 표면거칠기의 감소가 포함된다.

#### 후 기

본 연구는 세종대 교내 연구비에 의해 지원받았습니다.

#### 참고문헌

1. P. Temple-Boyer, L. Jalabert, L. Masarotto, J. L. Alay, J. R. Morante, J. Vac. Sci. Technol. A, 18 (2000) 2389.
2. M. Orfert, K. Richter, Surf. Coat. Technol., 116 (1999) 622.
3. B. Kim, S. Kim, Met. Mater.-Int., 14 (2008) 637.
4. S. Kim, B. Kim, Met. Mater.-Int., 15 (2009) 881.
5. B. Kim, S. Kim, Thin Solid Films, 517 (2009) 4090.
6. B. Kim, S. Kim, Y. H. Seo, S. J. Kim, S. C. Jung, D. Kim, J. Nanosci, Nanotechnol., 8 (2008) 5363.
7. H. Lee, B. Kim, S. Kwon. Curr. Appl. Phys., 10 (2010) 971.
8. B. Kim, M. Kwon, S. Kwon, Microelectron. Eng., 86 (2009) 63.
9. B. Kim, M. Kwon, Appl. Spectrosc., 62 (2008) 73.
10. B. Kim, M. Park, Appl. Spectrosc., 60 (2006) 1192.
11. D. F. Specht, IEEE Trans. Neural Network, 2 (1991) 568.
12. Goldberg, Genetic Algorithms in Search, Optimization & Machine learning, Addison Wesley, Reading, MA 1989.