

반구형 유도결합플라즈마 장비의 전자온도 신경망 모델 Neural Network Model of Electron Temperature for Hemispherical Inductively Coupled Plasma Equipment

김수연¹, 김우석¹, 김병환^{1*}
(1) 세종대학교, 전자공학과

초 록 : 신경망을 이용하여 반구형 유도결합형 플라즈마 장비에 대한 전자온도의 예측모델을 개발하였다. 신경망으로는 Radial Basis Function Network을 이용하였고, 신경망의 예측성능은 유전자 알고리즘을 이용하여 최적화하였다. 체계적인 모델링을 위해 2⁴ 전 인자 (Full Factorial) 실험계획법을 이용하여 Cl₂ 플라즈마에서의 데이터를 수집하였다. 최적화된 전자온도 모델의 예측성능은 0.143 eV이었다. 개발된 모델을 이용하여 공정변수에 따른 예측온도의 영향을 고찰하였다. 소스전력과 압력의 변화에 따른 전자온도의 변화는 작았다. 그러나 Cl₂ 유량과 특히 척위치의 증가에 따른 전자온도의 증가는 현저하였으며, 이는 고이온밀도의 형성에 기인하는 것으로 해석되었다.

1. 서 론

플라즈마는 소자제조를 위한 증착과 식각공정에 핵심적으로 응용되고 있다. 공정 또는 장비변수에 따라 플라즈마 특성은 복잡하게 변화한다. 플라즈마 특성은 해석적인 물리적 모델, 경험적 통계적 회귀모델 또는 신경망 모델개발을 통해 해석되고 있다. 통계적 회귀모델에 비해 신경망 모델은 우수한 예측성능을 보고 있어, 플라즈마 공정의 모델링과 특성화에 많이 응용이 되고 있다 [1-2].

본 연구에서는 반구형 유도결합형 플라즈마 (Hemispherical Inductively Coupled Plasma-HICP) 특성을 예측하기 모델을 Radial Basis Function Network (RBFN)[3] 을 이용하여 개발하였다. RBFN의 예측성능은 유전자 알고리즘 (Genetic Algorithm-GA) [4]을 이용하여 최적화하였다. 최적화된 모델을 이용하여 공정변수에 따른 전자온도의 변화를 고찰하였다. 데이터의 체계적인 수집을 위해 통계적 실험계획법이 응용되었다.




그림 1. HICP의 개요도

2. 본 론

2.1 실험데이터 수집

실험에 이용된 HICP 장비의 개요도가 그림 1에 나타나 있다. 그림 1에서와 같이 반구형의 챔버에 반경 0.25 inch의 코일이 4 mm 간격으로 10회 감겨 있다. 13.56 MHz의 Radio frequency (RF) 전력이 L-type 정합망을 통해 전달된다. 플라즈마 전자특성은 Langmuir probe (Heden 사)를 이용해 측정하였다. 그림 1에서와 같이 전자온도는 세 위치, 즉 중앙, 중앙에서 3과 4 inch 떨어진 곳에서 측정을 하였으며, 그 평균치를 모델개발하는데에 이용하였다. 실험 데이터는 통계적 실험계획법 (Face-Centered Box Wilson Design) [5]을 이용하여 수집하였다. 2⁴ 전 인자 실험계획법에 이용된 공정변수와 실험범위는 표 1에 나타나 있다. 실험계획법의 적용으로 수집된 16회의 실험데이터와 표 1의 각 공정변수의 중간 값에서 수집된 1회의 데이터를 이용해 RBFN 모델을 개발하였다. 한편, 모델 성능을 평가하기 위해 8회의 추가 실험을 수행하였다. 결국 모델개발을 위해 총 25회의 실험이 수행되었다.

표 1. 공정변수와 실험범위

공정변수	실험범위	단위
소스전력	70-900	W
압력	5-10	mTorr
척 위치	-30-90	mm
Cl ₂ 유량	60-120	scm




그림 2. RBFN의 구조도.

2.2 RBFN

RBFN의 구조는 그림 2에 도시되어 있다. 그림 2에서와 같이, RBFN은 입력층, 패턴층, 그리고 출력층으로 나뉘어진다. 입력데이터는 k-means 알고리즘을 통하여 분류된다. 패턴층의 임의의 뉴런의 출력은 (1)식으로 구해진다.

$$g(x) = e^{-(x - \mu_j)^2 / \sigma_j^2} \quad (1)$$

여기서 x 는 입력값, μ_j 은 k-means 알고리즘으로 얻은 새

롭게 분류된 영역 (receptive field라 불리는) 지역의 center 값이며, σ_j 는 receptive field의 width, $g(x)$ 는 j번째 뉴런의 output이다. 모델 성능은 σ_j 값에 상당한 영향을 받을 수 있으며, 따라서 RBFN 모델 최적화를 위한 중요한 학습 인자이다. 그리고 패턴층과 출력층 weight은 (2)식에 의해 일반적으로 결정된다.

$$\Delta w_i = \alpha (t_i - y_p) x_i \quad (2)$$

여기서 t_i 는 target 값, y_p 는 출력층에서 나오는 예측모델 값, 그리고 x_i 는 패턴층에서 나와 출력층으로 들어가는 입력값이다.

2.2 GA 최적화

RBFN의 모델링에 관여하는 학습인자에는 패턴층의 뉴런수와 식 (1)의 width 변수이다. 본 연구에서는 패턴층 뉴런수를 8에 고정하였으며, 또한 width를 다 변수화한 후 GA를 이용하여 그 최적화된 값을 구하였다. GA 최적화에서, 초기 해의 수는 100, 교배와 돌연변이 확률은 0.95와 0.05에 각 기 고정하였다. 실수 encoding 방식을 적용하여 각 초기 해를 표현하였고 해의 적합도는 다음의 수식을 이용하여 평가하였다.

$$F = 1/(1+RMSE) \quad (3)$$

여기서 RMSE는 학습에러를 의미한다. 다음 세대 (Generation)의 해는 Elitist Roulette Wheel 선택 [4] 방식을 이용하여 발생시켰다. GA 진화는 100 세대에서 종료되는 것으로 하여 모델을 개발하였다. GA 최적화를 통해 개발된 전자온도 모델의 예측 에러는 0.143 eV이었다.




그림 3. 압력과 소스전력에 따른 전자온도 모델

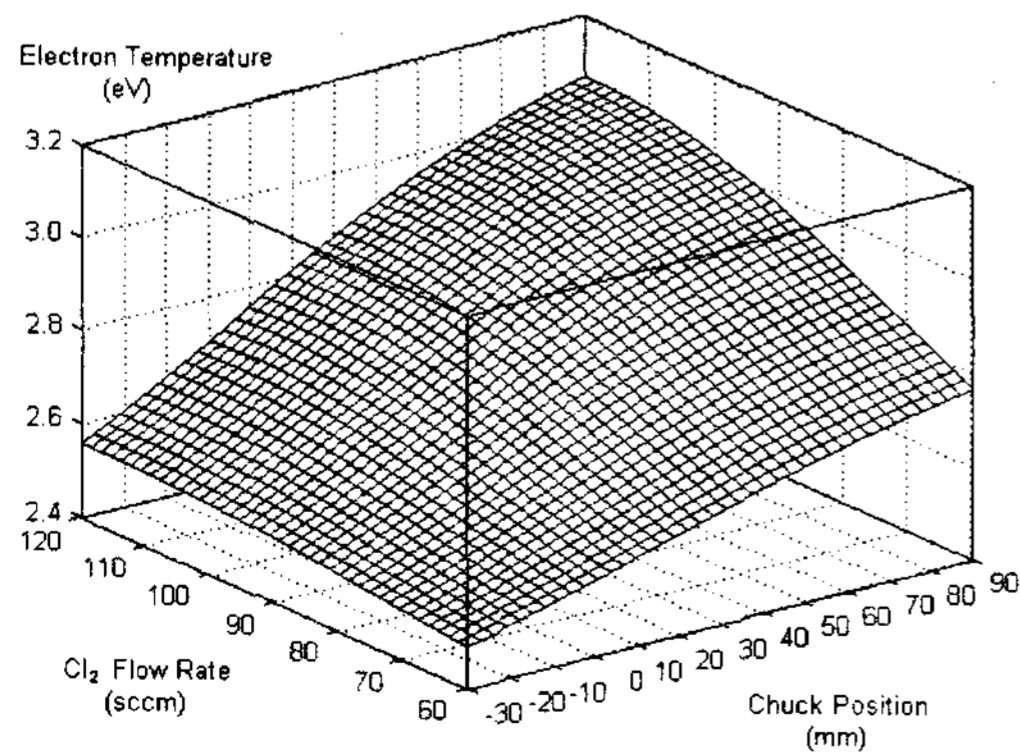


그림 4. 척위치와 Cl₂ 유량에 따른 전자온도 모델

2.3 전자온도 해석

최적화된 모델을 이용하여 공정변수의 함수로 3D 그림

을 그려 공정변수의 영향을 고찰한다. 그림 3은 압력과 소스전력의 함수로 전자온도를 도시하고 있다. 다른 두 변수는 표 1의 중간 값에 고정하였다. 그림 3에서와 같이 소스전력의 증가는 전자온도를 약간 증가시키고 있다. 이는 증가된 이온화에서 비롯된 이온농도의 증가 [6]에 기인하는 것으로 해석할 수 있다. 이전의 연구에서는 이를 증가된 가스 가열에 의한 중성자수 증가에 기인한다고 추측한 바 있다 [7]. 한편 그림 3에서와 같이 압력의 증가에 따른 전자온도의 변화는 매우 작다. 종래의 연구보고와 비교하면 이는 매우 흥미로운 특징이다. 즉, 이전의 다수의 플라즈마 소스들은 압력의 증가에 따라 전자온도의 감소를 보고한 바 있다 [7-8]. 그림 3에서 종래의 보고와 유사한 전자온도의 변화는 고전력하에 고압력 범위 내에서의 압력의 증가에서 찾아볼 수 있다. 압력의 증가에 따른 전자온도의 감소는 향상된 충돌률에 기인하는 것으로 일반적으로 해석하고 있다.

그림 4는 척위치와 Cl₂ 유량에 따른 전자온도의 변화를 보이고 있다. 다른 두 변수는 표 1의 중간 값에 고정하였다. 그림 4에서와 같이 척위치의 증가에 따라 전자온도는 증가하고 있으며, 이는 전술한 바와 같이 소스로의 척이 접근함에 따라 이온 밀도가 높아지기 때문이다. 한편 전자온도는 Cl₂ 유량이 높은 영역에서 더 현저히 증가하고 있는데, 이는 이 영역에서 발생하는 이온밀도가 Cl₂ 유량이 작은 영역에 비해 높기 때문일 것이라고 추측된다. 즉, 소스로 근접함에 따라 형성되는 고온의 전자밀도는 가스 분해율을 촉진시켜, 원자작 Cl₂의 밀도를 증가시키는 것으로 해석된다. 그림 4에서와 같이 Cl₂ 유량의 증가에 따라 전자온도는 증가하고 있다. 특히 플라즈마 소스에 척이 근접할수록, Cl₂ 유량증가에 따른 전자온도의 증가는 더 큰데, 이는 전술한 전자온도와 이온밀도의 관계로 해석할 수 있다.

3. 결 론

본 연구에서는 HICP 플라즈마의 전자온도를 예측하는 모델을 신경망과 유전자 알고리즘을 이용하여 개발하였다. 최적화된 신경망 모델로부터 구한 3D 그림을 이용하여 공정변수의 영향을 고찰하였다. 척위치가 전자온도에 상당한 영향을 미치고 있으며, 이온밀도가 높은 영역에서의 Cl₂ 유량의 영향은 현저하였다. 소스전력과 압력의 영향은 미미하였다.

감사의 글

이 논문은 중소기업기술혁신개발사업(전략과제)의 지원으로 수행되었습니다.

참고 문헌

- [1] B. Kim, J. Bae, and B. T. Lee, Microelectron. Eng. 83, 513 (2006).
- [2] B. Kim, B. T. Lee, J. Appl. Phys. 98, 034912 (2005).
- [3] J. Park, I. Sandberg, Neural Computation 3 (1991) 246.
- [4] D. E. Goldberg, Genetic Algorithms in Search, Optimization & Machine Learning, Addison Wesley, Reading, MA, 1989.
- [5] D. C. Montgomery, Design and Analysis of Experiments, John Wiley & Sons, Singapore, 1991.
- [6] C. R. Eddy, Jr., D. Leonhardt, D. R. Douglass, B. D. Thoms, V. A. Shamamian, and J. E. Butler, J. Vac. Sci. Technol. A, 17, 38 (1999).
- [7] M. V. Malyshev and V. M. Donnelly, J. Appl. Phys. 87, 1642 (2000).
- [8] M. V. Malyshev and V. M. Donnelly, J. Appl. Phys. 84, 1222 (1998).
- [9] R. A. Stewart, P. Vitello, and D. B. Graves, J. Vac. Sci. Technol. B 12, 478 (1994).