

레이디얼 베이스 함수망과 유전자 알고리즘을 이용한 플라즈마 전자밀도 모델링

김수연, 김병환
 세종대학교, 전자공학과

Modeling of Electron Density Non-Uniformity by Using Radial Basis Function Network and Genetic Algorithm


Su Yeon Gim, Byungwhan Kim
 Sejong University, Electronic Engineering

Abstract - Radial Basis Function Network (RBFN)을 이용하여 플라즈마 전자밀도를 모델링하였다. RBFN의 예측성능은 학습인자의 함수로 최적화하였다. 체계적인 모델링을 위해 통계적인 실험계획법이 적용되었으며, 실험은 반구형 유도 결합형 플라즈마 장비를 이용하여 수행이 되었다. 전자밀도 측정에는 Langmuir probe가 이용되었다. 최적화된 GA-RBFN모델을 일반 RBFN모델과 비교하였으며, 11%정도 모델의 예측성능을 향상시켰다.

1. 서 론

플라즈마 특성은 공정 또는 장비변수에 비선형적으로 변화한다. 플라즈마 특성은 해석적인 물리적 모델, 경험적 통계적 회귀모델 또는 신경망 모델개발을 통해 해석되고 있다. 통계적 회귀모델에 비해 신경망 모델은 우수한 예측성능을 보이고 있어, 플라즈마 공정의 모델링과 특성화에 많이 응용되고 있다 [1-3].

본 연구에서는 반구형 유도 결합형 플라즈마 (Hemispherical Inductively Coupled Plasma-HICP)의 전자밀도(Ne)의 특성을 예측하기 위한 모델을 Radial Basis Function Network (RBFN)[4]와 유전자 알고리즘 (Genetic algorithm-GA) [5]을 이용하여 개발하였다. GA-RBFN 모델은 종래의 RBFN 모델과 그 성능을 비교하였다.



<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 (Heden사)를 이용해 측정하였다. 그림 1에서와 같이 전자밀도는 세 곳, 즉 중앙과 중앙에서 3과 4 inch 떨어진 지점에서 측정을 하였다.

실험 데이터는 통계적 실험계획법 (Face-Centered Box Wilson Design) [6]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	700-900	W
압력	5-10	mTorr
척 위치	-30-90	mm
Cl ₂ 유량	60-120	sccm



<그림 2> RBFN의 구조도

2.2 RBFN 모델링

2.2.1 RBFN

RBFN의 구조는 그림 2에 도시되어 있다. 그림 2에서와 같이, RBFN은 입력층, 패턴층, 그리고 출력층으로 나누어진다. 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 입력 값, μ_j 은 k-means 알고리즘으로 얻은 새롭게 분류된 영역 (receptive field라 불리는) 지역의 center값이며, σ_j 는 receptive field의 width, $g(x)$ 는 j번째 뉴런의 output이다. 모델 성능은 σ_j 값에 상당한 영향을 받을 수 있으며, 따라서 RBFN 모델최적화를 위한 중요한 학습인자이다. 그리고 패턴층과 출력층의 weight는 (2)식에 의해 일반적으로 결정된다.


$$\Delta w_i = \alpha (t_i - y_{ip}) x_i \quad (2)$$

여기서 t_i 는 target 값, y_{ip} 는 출력 층에서 나오는 예측모델 값, 그리고 x_i 는 패턴층에서 나와 출력층으로 들어가는 입력 값이다.


2.2.2 RBFN 최적화

RBFN 모델의 예측성능은 그 학습인자인 패턴층 Unit수와 Width의 함수로 평가하였다. 우선 Width를 2.5에 고정하고 패턴층 뉴런수를 2에서 8까지 증가시키면서 모델 예측성능을 Root Mean-Square Error로 계산하였다. 그 결과가 그림 3에 도시되어 있다. 그림 3에서와 같이 Unit

수에 따라 예측성능이 달라지고 있음을 알 수 있으며, Unit수가 8에서 가장 작은 예측에러 1.282(1010/cm³)를 얻었다. 다음에 Unit 수를 8에 고정하고 Width를 0.5에서 4.5까지 0.5 간격으로 증가시키면 모델성능을 평가하였다. 그 결과가 그림 4에 도시되어 있다. 그림 4에서와 같이 Width가 4.5에서 최소의 예측에러 0.943(1010/cm³)를 얻었다.



〈그림 3〉 패턴층 Unit수에 따른 RBFN 모델의 예측성능



〈그림 4〉 Width에 따른 RBFN 모델의 예측성능


2.2.3 GA RBFN

GA 최적화에서, 초기 해의 수는 100, 교배와 돌연변이 확률은 0.95와 0.05에 각기 고정하였다. 실수 encoding 방식을 적용하여 각 초기 해를 표현하였고 해의 적합도는 다음의 수식(3)을 이용하여 평가하였다.


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

여기서 *RMSE*는 학습에러를 의미한다. 다음 세대 (Generation)의 해는 Elitist Roulette Wheel 선택 [5] 방식을 이용하여 발생시켰다. GA 진화는 100 세대에서 종료되는 것으로 하여 모델을 개발하였다.

RBFN의 학습인자인 (1)의 width를 다변화하였으며, 그 최적화된 값을 GA를 이용하여 결정하였다. 다변수화된 Width의 수는 패턴층 Unit과 일치한다. 주어진 Unit수에 대해 다변수화된 Width의 초기값은 난수 발생기를 이용하여 발생하였다. 본 연구에서는 Unit 수를 2에서 8로 증가시키면서 GA-RBFN 모델을 개발하였다. 학습이 종료된 후 테스트 데이터에 대한 RMSE가 가장 작은 모델을 결정하였으며, 그 결과가 그림 5에 도시되어 있다. 그림 5에서와 같이, Unit 수 6에서 얻은 최소의 예측에러는 0.839(1010/cm³)였다. 최적화된 모델의 예측치를 실제치와 비교한 결과가 그림 6에 도시되어 있다. 모델 예측치가 실제치에 매우 근접하므로 모델의 우수한 예측성능을 보이고 있다. 한편, 일반 RBFN 모델과 비교할 때, GA-RBFN 모델이 약 11% 정도 예측성능이 우수함을 알 수 있다.



〈그림 5〉 패턴층 Unit수에 따른 GA RBFN 모델의 예측성능



〈그림 6〉 전자밀도 GA RBFN 모델의 성능 평가

3. 결 론

본 연구에서는 RBFN과 GA-RBFN을 이용하여 플라즈마의 전자밀도에 대한 예측모델을 개발하였다. 체계적인 모델링을 위해 통계적인 실험 계획법이 적용되었다. 모델 예측성능은 학습인자를 변화시켜 최적화시켰으며, 최적화된 GA-RBFN 모델은 일반 RBFN 모델에 비해 11%정도 예측성능을 향상시켰다. 개발된 모델은 전자밀도의 정성적 해석에 활용할 계획이다.

감 사 의 글

이 논문은 중소기업기술혁신개발사업(전략과제)의 지원으로 수행되었습니다.

[참 고 문 헌]

- [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] B. Kim and S. Park, *IEEE Trans. Plasma Sci.* 30, 698 (2002).
- [4] J. Park, I. Sandberg, *Neural Computation* 3 (1991) 246.
- [5] D. E. Goldberg, *Genetic Algorithms in Search, Optimization & Machine Learning*, Addison Wesley, Reading, MA, 1989.
- [6] D. C. Montgomery, *Design and Analysis of Experiments*, John Wiley & Sons, Singapore, 1991.