

유전알고리즘과 신경회로망을 이용한 플라즈마 식각공정의 모델링과 최적제어입력탐색

論 文

45~1~16

Modeling and Optimal Control Input Tracking Using Neural Network and Genetic Algorithm in Plasma Etching Process

高澤範*·車相燁*·俞正植*·禹廣芳**·文大植***·郭奎煥***·金定坤***·張鎬承***
(Taek-Beom Koh · Sang-Yeob Cha · Jung-Shik Yu · Kwang-Bang Woo · Dae-Sik Mun ·
Kyuh-Wan Guak · Jeong-Gon Kim · Seung-Ho Chang)

Abstract - As integrity of semiconductor device is increased, accurate and efficient modeling and recipe generation of semiconductor fabrication processes are necessary. Among the major semiconductor manufacturing processes, dry etching process using gas plasma and accelerated ion is widely used. The process involves a variety of the chemical and physical effects of gas and accelerated ions. Despite the increased popularity, the complex internal characteristics made efficient modeling difficult. Because of difficulty to determine the control input for the desired output, the recipe generation depends largely on experiences of the experts with several trial and error presently. In this paper, the optimal control of the etching is carried out in the following two phases. First, the optimal neural network models for etching process are developed with genetic algorithm utilizing the input and output data obtained by experiments. In the second phase, search for optimal control inputs is performed by means of using the optimal neural network developed together with genetic algorithm. The results of study indicate that the predictive capabilities of the neural network models are superior to that of the statistical models which have been widely utilized in the semiconductor factory lines. Search for optimal control inputs using genetic algorithm is proved to be efficient by experiments.

Key Words : Plasma etching, Neural network modeling, Genetic algorithm, Recipe generation

1. 서 론

반도체 디바이스의 집적도 증대에 따라 반도체 생산공정은 보다 정밀하고 효율적인 생산기술이 요구되고 있다. 건식식각공정은 주요 반도체 공정의 하나로 현재 플라즈마 가스와 가속시킨 이온을 이용한 식각기술이 폭넓게 사용되고 있다. 가스에 의한 화학작용과 가속시킨 이온에 의한 물리작용으로 식각을 행하는 이 기술은 그 사용이 활발함에도 불구하고 식각시 내부 특성의 복잡함 때문에 정밀하고 효율적 모델링이 어려웠다. 원하는 출력을 얻기 위한 제어입력의 선정도 용이하지 아니하여 생산공정에 있어서 중요한 최적공정운용방식도출(Recipe generation)은 전문가의 경험에 의존하여 많은 시행착오를 거쳐 행해져 왔다.

최근 C.D.Himmel[1]과 E.A.Rietman[2]은 신경회로망을 이용하여 플라즈마 식각공정을 통계기법보다 정확하게 모델링할 수 있음을 보였다. 반도체 생산공정을 신경회로망으로 모델링할

때, 주된 어려움은 신경회로망의 파라미터보다 훨씬 적은 제한된 데이터를 이용하여 우수한 예측성능을 갖는 모델을 개발하는 것이다. 그러나 신경회로망 모델링의 경우 학습 데이터를 과도학습하면, 학습 데이터에 대해서는 정확하게 출력을 예측하지만, 학습하지 않은 데이터에 대한 예측 정확도가 떨어지는 문제점이 있다. Y.L.Huang[3]은 제한된 실험 데이터를 사용하여 플라즈마 식각공정의 신뢰성있는 신경회로망 모델을 구축하고, 이를 위해 은닉층의 뉴런수를 조정하는 방안을 제시했으나, 은닉층의 뉴런수만이 아니고 신경회로망의 구조(은닉층수, 은닉층의 뉴런수)와 학습 파라미터(학습율, 모멘텀 계수, 초기 연결강도의 범위, 학습허용오차, 시그모이드 함수의 기울기)가 상관관계를 가지고 신경회로망의 수렴성능에 영향을 주는데 초기에는 이 요소들의 최적값을 알 수 없기 때문에 최적화된 신경회로망을 구하기가 어렵다. B.H.Kim[4]은 심플렉스 알고리즘[5]에 의해 최적화된 신경회로망을 이용한 플라즈마 식각공정의 모델링을 제시하였다. 하지만, 심플렉스 알고리즘은 초기값에 민감한 영향을 받고, 국부수렴할 가능성이 많으므로 최적화된 신경회로망의 탐색에는 어려움이 따른다.

플라즈마 식각공정의 운영은 온라인 실시간 제어가 연구되고 있으나, 공정출력을 계속하기 위한 안정된 센서의 개발이 진행되고 있는 관계로 실용적으로 사용되지 못하고 있으며, 운전중에 제어입력을 고정하는 운전방식이 활용되고 있다. 운전중 고정된 제어입력을 공정 recipe라고 하며, 설계사양의 변경이나 이상변인으로 인한 공정변동이 발생하기 전까지는 공정 recipe로 공정입력을 고정하여 운전하고 있는데, 장비 setting시 또는

* 正 會 員 : 延世大 大學院 電氣工學科 博士課程

** 正 會 員 : 延世大 工大 電氣工學科 教授 · 工博

*** 正 會 員 : 三星電子(株) 半導體生產技術팀

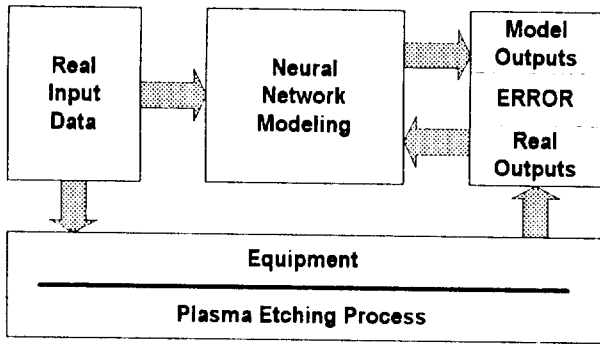
接受日字 : 1995年 3月 30日

1次 修正 : 1995年 5月 12日


2次 修正 : 1995年 9月 22日

3次 修正 : 1995年 11月 7日

4次 修正 : 1995年 11月 13日



(a) 식각공정을 위한 신경회로망 모델링



(b) 식각공정의 최적제어입력 탐색

그림 1 플라즈마 식각공정의 모델링과 최적제어입력 탐색

Fig 1 Modeling and optimal control input tracking of plasma etching process

공정이상으로 인한 장비정비 후에 공정 recipe의 신속정확한 탐색은 생산공정의 품질과 생산성 향상을 위해 필수적이다.

따라서 본 논문에서는 제한된 공정 데이터를 토대로 최적의 신경회로망 모델을 구하고, 공정 recipe의 신속정확한 탐색을 위해 ① 유전 알고리즘과 심플렉스 알고리즘의 효과적인 결합으로 신경회로망의 구조와 학습 파라미터를 동정하여 최적의 신경회로망을 탐색하는 방안과, ② 신경회로망 모델을 토대로 유전 알고리즘을 이용한 최적제어입력의 탐색방안을 제시하고, 식각공정의 최적운영을 위해 두단계로 나누어 연구를 행하였다. 1) 그림 1(a)에서와 같이 실제 공정의 실험을 통하여 얻은 입출력 데이터를 이용하여 유전알고리즘과 심플렉스 알고리즘의 효과적인 결합에 의해 최적화된 식각공정의 신경회로망 모델링을 행하였다. 2) 신경회로망 모델을 토대로 유전알고리즘을 이용하여 최적제어입력을 탐색하였다(그림 1(b)). 신경회로망에 의한 식각공정의 모델링은 현재 반도체 생산라인에서 사용되고 있는 통계적인 방법과의 비교, 그리고 유전알고리즘을 이용한 최적제어입력탐색은 실제 공정의 실험을 통한 효율성과 우수성이 검증된다.

2. 실험 방법

반도체 생산라인에서 사용되는 건식식각장비는 그 종류가 매우 다양하며 장비의 입력요소 또한 매우 복잡하다[6][7]. 본 연구를 위해 선정된 플라즈마 식각장비는 Lam Research사의 Rainbow 4420 단일 웨이퍼 평행판 시스템[8]이며 이는 다른 식각장비와 마찬가지로 복잡한 내부특성때문에 다수의 입력변

표 1 입력요소 및 범위

Table 1 Input parameters and ranges

입력요소(단위)	범위	
	하한값	상한값
Pressure(mT)	200	550
Power(W)	200	400
Gap(cm)	0.7	0.9
SF ₆ (sccm)	20	100
He(sccm)	50	150
Cl ₂ (sccm)	50	150




그림 2 식각률 측정 지점

Fig 2 Measurement points of Etch rate




그림 3 polysilicon의 식각구조

Fig 3 Etch structure of polysilicon

수를 필요로 한다. 따라서 다수의 입력변수들 가운데 식각장비의 모델링을 위한 입력변수의 선정이 필요하다. 표 1은 장비의 특성과 실험에 의해 얻어진 식각에 가장 중요한 6개의 입력변수들로서 범위와 단위를 나타내었다.

출력변수는 식각률, 균일도, 선택도이다. 식각률은 단위 시간당 수직식각률로서 그림 2와 같이 9곳의 점에서 Nanometrics Nanospec AFT 시스템을 사용하여 측정되었다.

polysilicon의 식각률 측정을 위한 증착구조는 그림 3과 같다. 증착두께는 oxide가 1000Å, polysilicon이 2500Å이다.

그림 4는 silicide(WSD)의 식각률 측정을 위한 단면도로서 silicide(WSD)는 4000Å의 두께로 증착되었다. 출력변수로 설정한 식각률은 polysilicon의 평균 수직식각률을 의미하며 선택도




그림 4 silicide(WSi)의 식각구조
Fig 4 Etch structure of silicide(WSi)

와 균일도는 다음 식(1), (2)에서 구해진다.

$$S_{poly} = \frac{R_{silicide}}{R_{poly}} \quad (1)$$

$$U = \frac{R_{max} - R_{min}}{2R_{avg}} \quad (2)$$

여기서 R_{poly} , $R_{silicide}$ 는 polysilicon과 silicide의 평균 수직식각률을 의미하고 R_{max} , R_{min} , R_{avg} 는 9 점에서 측정된 polysilicon의 최대, 최소, 평균 수직식각률이다.

3. 신경회로망을 이용한 식각공정의 모델링

신경회로망은 이미 알려진대로 입출력 변수간의 비선형적 관계를 학습하는 능력을 갖고 있다[9-11]. 이는 식각공정의 모델링에 신경회로망을 적용하는 중요한 요소가 되며, 학습에 의해 복잡한 입출력 관계를 기존의 통계기법보다 정확하게 모델링할 수 있다[1][2].

그림 5는 식각공정의 모델링을 위해 구성된 신경회로망 구조이다. 반도체 공정의 데이터는 경제성 측면이 매우 중요하여 그 갯수가 한정적이므로 보다 효율적인 학습을 위하여 본 연구에서는 6개의 입력을 공통입력단으로 하고 3개의 출력(식각률, 균일도, 선택도)을 각각 독립된 출력단으로 갖는 신경회로망을 구성하였다. 사용된 알고리즘은 FFBP(Feed-Forward Error Back Propagation) 알고리즘으로 입력 데이터에 의해 모델출력이 계산되면 실험출력과의 오차를 구할 수 있다. 식(3)에 의해 출력오차가 계산되며 gradient descent method를 사용하여 출력오차 σ 를 줄이는 방향으로 연결하중의 학습이 행해진다. 식(3)에서 y_i 는 실험출력값, \hat{y}_i 는 계산된 모델출력값이며 n 은 데이터의 갯수이다.

$$\sigma = \frac{1}{n} \sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

출력오차가 사용자가 원하는 값 또는 생산공정에서 허용할 수 있는 오차 이하로 떨어지게 되면 학습이 끝나게 된다.

신경회로망에 의한 모델링의 경우 학습된 데이터에 대해서는 정확한 출력을 예측하지만, 그렇지 않은 데이터에 대해서는 예측의 정확도가 떨어지는 경우가 발생한다. 이러한 단점을 보완




그림 5 신경회로망의 구조
Fig 5 Neural network structure

하기 위하여 본 논문에서는 학습용 데이터와 학습보정용 데이터를 선정하여 학습오차가 불균형적으로 줄

어뜨는 것을 방지하였다. 또한 신경회로망의 구조는 수렴 성능과 밀접한 관계가 있으므로 신경회로망의 최적구조를 위하여 유전알고리즘을 적용한다. 신경회로망의 최적화를 위해서 고려해야 할 요소는 1)신경회로망의 구조(은닉층수와 은닉층의 뉴런 수)와 2)학습 파라미터(연결하중과 문턱치의 학습율, 모멘텀계수와 초기연결하중의 범위, 학습허용오차, 시그모이드 함수의 기울기)이다. 은닉층의 뉴런은 주어진 입출력 관계의 복잡성에 따라 많아져야 하고[13], 은닉층의 뉴런이 너무 적으면 입출력 관계를 정확하게 학습할 수 없는 반면에, 너무 많으면 계산시간이 많이 걸려 학습시간이 길어지고 신경회로망을 과도학습하여 학습하지 않은 데이터에 대해서는 예측능력이 떨어지게 된다[14][15]. 학습율의 값이 크면 연결하중의 변화량이 크게 되기 때문에 학습속도는 빠르게 되지만, 정확한 수렴을 하지 못하고 불안정하게 되는 경우가 발생할 수 있는 반면에, 학습율이 작으면, 연결하중의 변화량이 작아져서 안정되지만 학습속도는 늦어지게 된다[16]. 초기연결하중의 범위가 너무 크면, 일반화 성능이 떨어지고 초기수렴이 발생하게 되지만, 너무 적으면 연결하중을 바람직한 값으로 점진적으로 변화시키는 조정능력을 잃게 된다[17][18]. 그리고, 학습허용오차가 작으면 학습정밀도가 증가되지만 일반화 성능이 떨어지고 학습시간이 길어지는 반면에, 학습허용오차가 크면 학습정밀도는 떨어지지만 학습속도가 증가된다[19]. 시그모이드 함수의 기울기는 연결하중의 변화량과 학습속도에 영향을 준다[20]. 그런데, 은닉층의 수는 신경회로망모델의 성능에 거의 영향을 안준다는 것이 밝혀졌고[4][12], 하나의 은닉층을 갖는 구조로도 충분히 임의의 복잡한 입출력관계를 나타낼 수 있으므로[21] 본 연구에서는 연결하중과 문턱치의 학습률, 모멘텀계수, 초기연결하중의 범위, 학습허용오차, 시그모이드함수의 기울기와 함께 은닉층의 뉴런 수를 최적화한다.

유전알고리즘은 자연도태와 유전적 성질에 기초한 탐색알고리즘으로 최적화하고자 하는 파라미터를 유한길이의 문자열로

코딩하여 여러세대를 지나는 동안 선택, 교배, 돌연변이의 과정을 거쳐 최적해를 찾는 알고리즘이다[22][23]. 미분가능성, 연속성 등의 보조정보를 필요로 하지 않으며 여러개의 문자열을 가지고 탐색하므로 국부극점을 찾을 확률이 적어 기존의 최적화 기법보다 강인한 특성을 갖는다. 신경회로망 모델의 최적화를 위한 유전알고리즘의 적용은 다음과 같은 단계를 거쳐 수행된다.

Step 1. 초기 세대의 생성

최적제어입력의 후보가 되는 문자열의 집단을 랜덤하게 발생시킨다. 여기서 문자열은 그림 6과 같이 이진수로 코딩하여 구성하였으며 집단의 개체수는 허용오차를 고려하여 설정한다.

은닉층 노드수	출력허용오차	초기연결 하중범위	학습률	모멘텀계수	시그모이드 함수 기울기
001	00..11	01..01	10..00	01..11	00..01
3 bits	8 bits	9 bits	10 bits	10 bits	10 bits

그림 6 이진수 코드를 갖는 문자열
Fig 6 Character string with binary codes

Step 2. 각개체의 적합도 계산

집단의 문자열이 갖는 이진값들을 원래의 값으로 디코딩한 뒤, 이러한 파라미터들로 구성된 신경회로망에 의해 학습과 평가를 행한다. 식(4)는 평가지표를 계산하는 식으로 평가지표의 역수(식(5))를 가지고 적합도를 계산한다. 식(4)에서 α_i 는 학습용 데이터의 출력오차이고 α_p 는 학습보정용 데이터의 출력오차이다. K_1, K_2 는 상대적인 중요도를 위한 상수로서 만일 같은 값을 설정 하면 출력오차는 같은 비중을 갖게 된다. 출력오차 σ 는 식(3)에 의해 계산된다.

$$PI = K_1\sigma_i^2 + K_2\sigma_p^2 \quad (4)$$

$$F = \frac{1}{PI} \quad (5)$$

Step 3. 종료조건을 검사

적합도가 목표치 이하이거나 세대수가 지정세대수를 넘어가면 종료한다.

Step 4. 새로운 세대의 생성

1) 새로운 세대수를 (k+1)로 하면, (k+1)세대는 (k)세대의 개체를 재생, 선택을 통한 교배와 돌연변이에 의해 집단을 생성한다. 교배는 그림 7과 같이 (k)세대의 두 개체를 선택하여 행해지며 개체선택은 식(6)의 선택확률을 따른다.

돌연변이는 (k+1)세대의 교배된 염색체에서 그림 8과 같이 임의의 비트가 바뀌는 것으로서 개체내에서의 교배율과 돌연변이율은 초기에 정한 값을 따른다.

$$P_{si} = \frac{F_i}{\sum_{j=1}^R F_j} \quad (6)$$

식(6)에서 R은 집단의 개체수이다.

2) 1)의 단계를 집단의 개체수만큼 수행하여 새로운 세대를 생성하고 완료되면 Step 2로 돌아간다.




그림 7 교배
Fig 7 Crossover




그림 8 돌연변이
Fig 8 Mutation

최종적으로 2진 문자열 코딩을 사용하는 단순 유전알고리즘은 문자열이 갖는 유한성때문에 정밀도에 영향을 주어 최종 수렴치를 보증하지는 못한다. 따라서 본 논문에서는 유전알고리즘의 우수개체 집합을 심플렉스 알고리즘의 초기해로 하여 신경회로망 모델의 구조와 학습파라미터를 동정한다. 심플렉스 알고리즘은 정점 근방에서 뛰어난 탐색기능을 갖지만 선정된 초기해에 민감하고 국부 수렴의 가능성이 있으므로 유전알고리즘과의 병행사용은 매우 효율적이라 할 수 있다.

4. 유전알고리즘을 이용한 최적제어입력 탐색

학습용과 학습보정용 데이터를 사용하여 최적화한 신경회로망 모델은 현재 on-line제어가 이루어지고 있지 못하는 건식식각공정에서 사용자에게 입력에 따른 출력의 대응관계를 정밀하게 보여준다. 그러나 이보다 더 중요한 것은 원하는 출력을 위한 제어입력값의 탐색으로 효율적이고 정밀한 최적입력탐색은 최적공정운용(recipe generation)을 위해 필수적이다. 따라서 본 연구에서는 최적화된 신경회로망 모델과 또하나의 유전알고리즘에 의해 최적제어입력을 탐색한다.

그림 9는 플라즈마 식각공정의 최적제어입력탐색을 위한 흐름도로서 수행단계는 새로운 유전알고리즘의 문자열이 6개의 입력변수(표 1)로 구성되었다는 점과 성능평가지표가 식(7)과 같이 계산된다는 것을 제외하고는 3절에서 사용한 유전알고리즘과 같은 방법으로 수행됨을 알 수 있다.

$$PI = K_1|E/R_r - E/R_c| + K_2|U_r - U_c| + K_3|Sel_r - Sel_c| \quad (7)$$

여기서 K_1, K_2, K_3 는 3가지 출력이 갖는 상대적인 중요도를 나타내는 상수이고, E/R 은 식각률, U 는 균일도, Sel 은 선택도이며, 아래첨자 r은 실제의 출력값을, c는 모델출력값을 나타낸다.

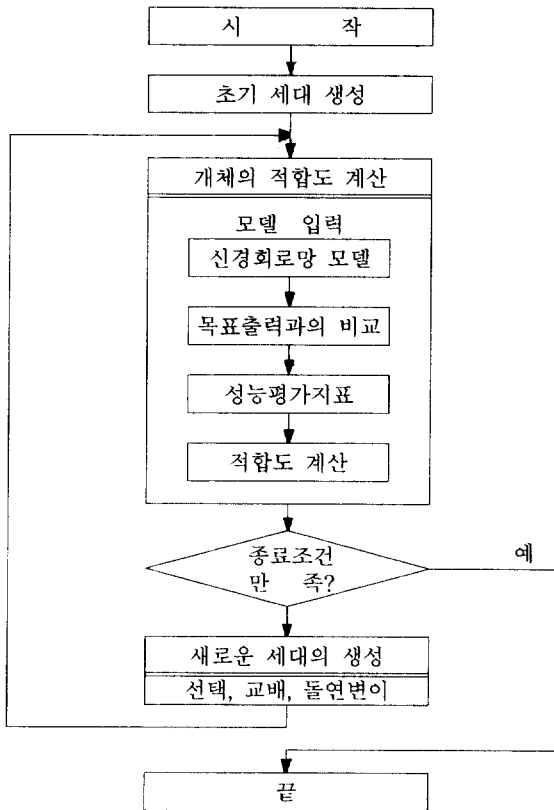


그림 9 최적제어 입력탐색도
Fig 9 Flow chart of optimal control input tracking

5. 실험 결과

5.1 신경회로망 모델링에 대한 결과 고찰

최적한 신경회로망 모델을 위해 식(4)의 성능평가지표가 갖는 K_1 , K_2 는 똑같은 비중을 갖도록 1로 설정하였다. 표 2는 문자열로 코딩하기 위해 설정한 은닉층 뉴런수와 학습 파라미터의 범위이고 표 3은 유전알고리즘에 필요한 파라미터들의 설정값이다.

표 2 최적화를 위한 파라미터들의 범위

파라미터	범위
은닉층의 뉴런수	6-13
학습률	0.01-0.95
모멘텀계수	0.01-0.95
초기연결하중범위	$\pm 0.05 - \pm 2$
학습허용오차	0.001-0.05
시그모이드함수의 기울기	0.01-2

표 3 유전알고리즘을 위한 파라미터설정
Table 3 Parameters for genetic algorithm

파라미터	설정값
진화세대수	500
집단크기	100
총문자열길이	50
교배율	0.7
돌연변이율	0.01

표 4 은닉층의 최적 뉴런수

Table 4 Optimal neuron number of hidden layer

출력단	식각률	균일도	선택도
뉴런수	12	12	8

학습을 위한 데이터는 16개, 학습보정을 위한 데이터로는 15개를 사용하였다. 학습용 데이터는 D.O.E(Design of Experiment) 방법[24]에 의해 1차와 2차 실험을 통해 얻어진 8개씩의 입력력 데이터를 합한 것이며 학습보정용 데이터는 학습보정의 공정을 기하기 위해 표 1의 범위에서 한쪽에 치우치지 않도록 랜덤하게 구하였다. 유전알고리즘에 의해 얻어진 최적한 신경회로망의 은닉뉴런수는 표 4와 같다.




그림 10 평가용 데이터의 결과값 비교 (식각률)

Fig 10 Comparison of outputs of estimation data (etch rate)




그림 11 평가용 데이터의 결과값 비교 (선택도)

Fig 11 Comparison of outputs of estimation data (selectivity)




그림 12 평가용 데이터의 결과값 비교 (균일도)
 Fig 12 Comparison of outputs of estimation data (uniformity)


표 5 평가용 데이터의 출력오차비교
 Table 5 Comparison of output error of estimation data

	식각률	선택도	균일도
기존의 모델식	427.5	0.005	1.03
신경회로망 모델	208	0.02	0.66


통계적 방법의 모델식은 D.O.E에 의한 8개의 1,2차 데이터에서 구할 수 있으며 학습보정용데이터 15개를 대입하여 보다 우수한 예측능력을 갖는다고 판단되는 1차 데이터에 의한 모델식을 사용하였다. 다음에는 새로운 식각을 통하여 표 1의 범위에서 6개의 입출력 데이터를 얻었으며 이 평가용 데이터의 입력을 두 모델에 적용시켜 모델출력을 구하였다.

표 5에서 두 모델출력의 출력오차를 비교하였으며 그림 10, 11, 12는 평가용 데이터(6개)의 출력비교곡선이다. 그림 10, 11, 12에서 X축은 실험번호이고, 평가실험조건은 Gap은 0.8 cm, He 흐름율은 100 sccm, Cl₂ 흐름율은 50 sccm으로 고정시키고, 압력, RF 전력, SF₆ 흐름율은 표 1의 입력범위에서 랜덤하게 선택된 6개의 입력조건으로 정했다. 적은 횟수의 실험으로 가능한한 공정한 평가를 기하기 위하여 주효과가 큰 입력변수 압력, RF 전력, SF₆ 흐름율을 랜덤하게 가변시키고, 나머지 입력력은 고정시켰다. 그리고 그림 10-그림 12의 RSM(Response Surface Method)은 공정응답을 표현하는 매개변수 모델을 효과적으로 생성하기 위해서 D.O.E와 데이터 분석을 결합한 통계기법[24]이며, 현재 반도체 생산라인에서는 이 기법을 생산공정의 모델링과 recipe 생성에 사용하고 있다. 각 공정 출력에 대하여 신경회로망 모델이 통계적 방법과 비교하여 우수한 예측능력을 가짐을 알 수 있다.


각 공정출력에 대한 신경회로망 모델을 이용해서 파악한 플라즈마 식각 특성을 그림 13-그림 18에 나타내었다. 그림 13은 여러변수들에 대한 식각률의 특성을 나타내고 있는데 a)는 RF power와 압력을, b)는 압력과 SF₆를 변화시켰으며 c)와 d)는 압력과 전극의 간격, RF power와 SF₆를 변화시켜 얻은 3차원 곡선이다. 물론 다른 입력값들은 원하는 임의값에 고정시켰으며 이 그림 13을 통하여 RF power와 압력, SF₆ 기체의 흐름이 증가하면, 식각률이 그에 따라 커지는 것을 알 수 있다. 그림 14에 플라즈마 식각공정에서 RF power와 압력, SF₆ 기체의 흐름을 증가시켰을 때 식각률의 변화를 나타내는 실제 실험데이터를 보인다. 그림 13과 그림 14를 비교하면, 신경회로망용




(a) RF power와 압력에 대한 특성



(b) 압력과 SF₆ 흐름율에 대한 특성



(c) 압력과 전극의 간격에 대한 특성




(d) RF power와 SF₆에 대한 특성


그림 13 식각률의 특성곡선도
 Fig. 13 The characteristic graph of etch rate

모델이 실제 공정에서 얻은 실험 데이터의 특성을 정확하게 나타내고 있음을 알 수 있다.

그림 15는 선택도에 대한 특성곡선으로 a)는 RF power와 압력을, b)는 RF power와 SF₆를 변화 시킨 결과이다. 여기서 우




(a) RF power와 식각률 (b) 압력과 식각률




(c) SF₆ 흐름율과 식각률

그림 14 식각률의 추이도

Fig. 14 The trend graph of etch rate




(a) RF power와 압력에 대한 특성




(b) RF power와 SF₆에 대한 특성

그림 15 선택도의 특성곡선도

Fig. 15 The characteristic graph of selectivity




(a) RF power와 선택도 (b) 압력과 선택도




(c) SF₆ 흐름율과 선택도

그림 16 선택도의 추이도

Fig. 16 The trend graph of selectivity



(a) 압력과 SF₆에 대한 특성




(b) RF power와 전극의 간격에 대한 특성

그림 17 균일도의 특성곡선도


Fig. 17 The characteristic graph of uniformity

리는 RF power가 300W 근방에서 높은 선택도를 가짐을 알 수 있다.

그림 16에 RF power와 압력, SF₆ 기체의 흐름을 증가시켰을 때 선택도의 변화를 나타내는, 실제 실험데이터를 보인다. 그림



(a) RF power와 균일도 (b) 압력과 균일도



(c) SF₆ 흐름율과 균일도

그림 18 균일도의 추이도

Fig. 18 The trend graph of uniformity

15와 그림 16을 비교하면, 신경회로망을 모델이 실제 공정의 특성을 잘 나타내고 있음을 알 수 있다. 그림 17은 균일도의 특성을 나타내고 있는데 압력과 SF₆의 흐름율이 높을수록 균일도가 낮으며 전극의 간격이 클수록 균일도가 높아짐을 알 수 있다. 그림 18에 RF power와 압력, SF₆ 기체의 흐름을 증가시켰을 때 균일도의 변화를 나타내는 실제 실험데이터를 보인다. 그림 17과 그림 18을 비교하면, 신경회로망 모델이 실제 공정의 균일도를 잘 나타내고 있음을 알 수 있다.

5.2 최적제어입력 탐색에 대한 결과고찰

유전 알고리즘과 신경회로망에 의해 탐색된 제어입력을 식각 공정에 적용하여 원하는 출력을 얻을 수 있는지 확인하기 위해 두단계로 검토되었다. 우선 임의의 출력값을 설정한 뒤, 최적제어입력탐색 알고리즘에 의해 표 1의 범위에 맞는 입력조건들을 구하였다. 이 입력값을 가지고 식각공정을 행하여 실제의 출력값을 측정한 뒤 설정한 출력값과 비교하였다. 물론 같은 식각 장비에 동일한 조건하에 식각이 행해져도 시간적 차이가 존재하면 오차가 발생하고 신뢰도는 떨어지게 된다. 표 6은 설정오던 출력과 실제의 출력을 비교하기 위한 2개의 데이터를 나타내며, 이는 위에서 언급한대로 시간적 차이를 고려하지 않았다.

본 논문에서는 실제 반도체 생산공정을 고려하여 탐색출력오차의 기준을 목표출력의 ±10%이내로 산정했고, 균일도가 5이하로 되는 것을 제약조건으로 했다. 표 6에서 보는 바와 같이 실험 ②의 균일도를 제외한 탐색출력오차는 10%이내이고, 균일도의 경우에는 실험 ①에서 10%, 실험 ②에서 20%의 탐색출력오차를 보이지만, 5이하의 제약조건은 만족한다. 앞으로 측정지점을 고려한 균일도의 정의와 균일도를 정확하게 예측하기 위한 모델링 기법에 대한 연구가 필요하다.

목표 출력과 탐색하여 얻은 실제출력사이의 오차는 제어입력 변수의 부적절한 선택 및 누락, 신경회로망 모델의 학습오차, 실험기간의 시간적 차이에 의한 공정장비의 자연적인 변화, 측

정오차등에서 발생할 가능성이 높고, 본 연구에서 나머지는 충분히 고려되었지만 시간경과에 따른 공정장비의 자연적인 변화를 고려하지 않아서 오차가 발생했을 가능성이 높다고 하겠다. 그러므로 앞으로 반도체 공정장비의 동특성에 대한 연구가 필요하다.

표 6 목표출력과 실제출력의 비교예

Table 6 Comparison of target outputs and real outputs

	식각률(A/min)	선택율	균 일 도
목표 출력 ①	3500	0.60	2.0
실제 출력 ①	3687.8	0.57	1.8
목표 출력 ②	3500	0.55	3.5
실제 출력 ②	3490	0.53	4.8

6. 결 론

본 논문에서 제한된 공정 데이터를 토대로 최적의 신경회로망 모델을 구하고, 공정 recipe의 신속정확한 탐색을 위해 ① 유전알고리즘과 심플렉스 알고리즘의 효과적인 결합으로 신경회로망의 구조와 학습 파라미터를 동정하여 최적의 신경회로망을 탐색하는 방안과, ② 신경회로망 모델을 토대로 유전 알고리즘을 이용한 최적제어입력의 탐색방안을 제시하고, 제안된 방법을 반도체 생산의 여러 단위공정중에서 플라즈마 식각공정에 적용, 실제 생산장비를 이용한 실험을 통해 제안된 방법의 효용성이 검토되었다. 통계적 방법과 비교 검증한 결과 제안된 방법에 의해 최적화된 신경회로망의 모델은 식각공정이 갖는 비선형적 특성을 잘 학습하고 향상된 예측 능력을 갖추고 있음이 확인되었다. 또한 최적화된 신경회로망 모델을 토대로 유전 알고리즘을 이용한 최적제어입력의 탐색은 시간적 차이가 있음에도 불구하고 원하는 제어입력의 신속한 탐색이 가능하였고, 탐색오차는 생산공정의 허용오차범위 이내로 나타났다.

본 연구에서 제안된 최적의 신경회로망을 이용한 모델링 방법 및 유전 알고리즘을 이용한 최적공정운용의 방법은 나뉜 플라즈마 식각공정에만 국한되지 않고 증착공정(CVD)과 같은 반도체 생산의 다른 단위 공정에도 적용될 수 있다. 따라서 얼마나 정확하게 전체적인 특성을 대표하는 학습 데이터를 얻느냐는 문제와 시간적 차이에 대한 생산공정의 특성변화를 적절하게 고려하는 것이 해결해야 할 과제라 하겠다.

본 연구는 학술진흥재단의 '94년도 공모과제로서 삼성 전자(주) 반도체부문의 지원으로 수행되었다.

참 고 문 헌

[1] Christopher D. Himmel and Gary S. May, "Advantage of plasma Etch Modeling Using Neural Networks over Statistical Techniques". IEEE Trans. Semiconductor Manufacturing. Vol. 6, No. 2, May. 1993.

[2] Edward A. Rietman and Earl R. Lory, "Use of neural networks in modeling semiconductor manufacturing process: an example for plasma etch modeling" IEEE Trans. Semiconductor Manufacturing . Vol. 6, No. 4. Nov 1993.

[3] Y. L. Huang, T. F. Edgar, D. M. Himmelbrau, and I. Trachtenberg, "Constructing a Reliable Neural Network

Model for a Plasma Etching Process Using Limited Experimental Data," IEEE Trans. Semiconductor Manufacturing Vol. 7, No. 3, Aug., 1994

[4] Byunghwan Kim and Gray S. May, "An Optimal Neural Network Process Model for Plasma Etching," IEEE Trans. Semiconductor Manufacturing vol. 7, No. 1, Feb, 1994.

[5] S. S. Rao, Optimization Theory and Applications : John Wiley & sons, 1984.

[6] S. M. SZE, "VLSI Techonology", 2nd edition, 1991.

[7] 이종덕, "집적회로 공정기술", 2nd edition, 1991.

[8] Lam Research, Rainbow 4420 Plasma Etching System Operation and Maintenance Manual.

[9] Philip D. Wasserman, "Advanced Methods in Neural Computing", Van Nostrand Reinhold, 1993.

[10] Dana Z. Anderson, "Neural information processing systems". Denver, American Institute of Physics : 1987.

[11] 中野聲, 飯沼一元, "뉴로 컴퓨터", 대영사, 1991.

[12] S. S. Han, M. Ceiler, S. A. Bidstrup, P. Kohl, 2nd G. May "Modeling the properties of PECVD Silicon Dioxide films Using Optimized Back-Propagatin Neural networks", IEEE Trans. Components, Packaging and Manufacturing Technology, Vol. 17, No. 2, pp. 174-182. June, 1994.

[13] M. Guitierrez, J. Wang, and R. O. Grondin, "Estimating hidden units for two-layer perceptrons," in Proc. IEEE Int. Conf. Artificial Neural Networks, 1989. pp. 120-124.

[14] D. B. Fogel, "An information criterion for optimal neural network selection," IEEE Trans. Neural Networks, Vol. 2, No. 5, pp. 490-497, Sept, 1991.

[15] J. K. Kruschke and J. r. Movellan, "Benifits of gain: Speeded learning and minimal hidden layers in back-propagation networks," IEEE Trans. Syst., Man, Cybern., Vol. 21, No. 1, pp. 273-280, Feb. 1991.

[16] J. P. Cater, "Successfully using peak learning rates of 10 (and greater) in back-propagation networks with the heursitic learning algorithm," in proc. IEEE Int. conf, Artificial Neural Netwroks, Vol. 2, 1987. pp. 645-651.

[17] P. C. Woodland, "Weight limiting, weight quantization & generalization in multi-layer perceptrons," in proc. IEEE Int, Conf. Artificial Neural Networks, 1989, pp. 297-300.

[18] Y. Lee, S. Oh, and M. W. Kim, "The effect of initial weights on premature saturation in back-p0ropagation learning," in Proc, Int Joing Conf. Neural Networks, vol. 1, 1989, pp. 765-769.

[19] S. S. venkatesh, "The science of making EROS:What error tolerance implies for capacity in nermal networks," IEEE Tmas. Knowledge Data Eng., Vol. 4, pp. 135-144, apr. 1992.

[20] 이윤섭, "로봇트 운동을 위한 신경회로망 제어구조의 설계," 박사학위논문, 연세대학교 pp. 25-27, 1990년 12월.

[21] Y. Wada and M. Kawato, "Estimation of generalization capability by compination of new information criterion and cross validation", in Proc. Intm, Joing Conf. Neural Networks, Vol. 2, pp. 1-6, 1991.

[22] D. E. Goldberg, "Genetic Algorithms in search, Optimization and machine Learning", Addison Wesley, 1989.

[23] Z. Michalewicz, Genetic algoritmys+Data Structures= Evolution Programs. New York : springer-Verlag, 1992.

[24] G. E. P. Box, W. B. Hunter and J. S. Hunter, "Statistical for Experiments", Wiley, 1978.

[25] "반도체 산업", 1993년 10월호.

[26] "반도체 산업", 1993년 12월호

저 자 소 개



고택범 (高澤範)

1955년 10월 28일생. 1981년 연세대 공대 전기공학과 졸업. 1983년 동 대학원 전기공학과 졸업(석사). 현재 동 대학원 전기공학과 박사과정 재학중



차상엽 (車相燁)

1967년 2월 13일생. 1991년 연세대 공대 전기공학과 졸업. 1993년 동 대학원 전기공학과 졸업(석사). 현재 동 대학원 전기공학과 박사과정 재학중