

통계적 모델과 신경회로망 모델의 성능 비교에 관한 연구

한승수, 김인택
명지대학교 전기정보제어공학부

Performance Comparison Between Neural Network Model and Statistical Models

SEUNG-SOO HAN, IN-TAEK KIM

Myongji University, Electrical and Information Control Engineering

Abstract - 시스템의 특성을 이해하고 신뢰성 있는 제어를 위해서는 시스템에 대한 정확한 모델을 필요로 한다. 이러한 목적을 위해서 많은 연구자들에 의한 다양한 방법의 모델링 방법이 계속되어 연구되어지고 있다. 현재 많이 사용하는 모델링 방법 중에는 통계적 기법을 이용하는 것, first principle 방법을 이용하는 것, 지능형 기법을 이용하는 방법 등이 있다. 본 연구에서는 통계적 방법인 fractional factorial 방법을 이용한 모델, Taguchi 방법을 이용한 모델, 그리고 지능형 방법인 신경회로망을 이용한 모델의 3가지 모델을 사용해서 각 모델의 학습오차와 예측오차 등의 특성을 비교하였다. 모델에 사용된 데이터는 비선형 시스템인 플라즈마 화학 증착 장비(Plasma-Enhanced Chemical Vapor Deposition : PECVD)에 의해 증착된 산화막 실험 데이터이다. 각 모델에 대해서 PECVD 데이터를 사용하여 모델을 만들었을 때 각 모델의 학습오차와 학습오차변위, 그리고 예측오차와 예측오차변위를 조사하였다. 세가지 모델 모두 학습오차가 예측오차보다 작았으며, 변위 또한 학습오차변위가 예측오차변위보다 작았다. 본 연구 결과는 일반적으로 신경회로망에 의한 오차가 다른 통계적인 방법에 의한 오차보다 작음을 보여준다.

1. 서 론

프로세스를 개발하는 사람들에게는 프로세스 제어나 고장진단, 성능향상 등을 이루기 위해서 정확하고 효율적인 모델이 필수적이다. 특히 복잡한 비선형 시스템일 경우 정확한 모델을 만드는 것은 매우 어려운 일이다. 이러한 목적을 위해서 많은 연구자들에 의한 다양한 모델링 방법이 연구되어지고 있다. 많은 연구가 통계적 방법을 이용하여 이루어져 왔으나 최근에는 신경회로망이나 퍼지 논리 등을 이용한 지능적 방법이 연구되어 오고 있다. 반도체 공정 등과 같은 복잡한 비선형 공정 모델에 H. Guo, et.al [1]은 통계적인 방법을 사용하여 플라즈마 식각공정을 모델링하였고, 반면에 S. Han, et.al [2]은 신경회로망을 사용하여 PECVD 모델을 만들어서 이를 최적의 공정제어변수를 찾는데 사용하였다. 본 연구에서는 플라즈마 화학 기상 증착 공정을 fractional factorial 방법, Taguchi 방법, 신경회로망 방법을 사용하여 각각 모델링하였으며 각각의 모델의 학습오차와 예측오차를 비교하여 정확도를 비교하였다. Fractional factorial 방법은 factorial·방법에서 실험의 횟수를 줄이면서도 성능을 보전하는 방법이다. 이는 각 파라미터마다 'high'와 'low'의 두 레벨의 값을 이용하여 모델을 만드는데, 시스템이나 프로세스는 main effect와 낮은 차수의 interaction에 의해서 주로 나타나는 사실에 근거를 두고 있다[3]. 1980년에 발표된 Taguchi 방법은 공정이나 제품의 개발에는 시스템 설계, 파라미터 설계, 오차 설계등의 3가지 중요한 스테이지로 나누어서 생각할 수 있다는데 착안한다 [4]. 신경회로망은 인간의 신경 조직을 모방하여 만들었으며, 비선형 데이터에 강한 특성을 갖고 있는 회로망이다. 신

경회로망을 이용하여 모델을 만들기 위해서는 적절한 학습 알고리즘을 사용해야 하는데 가장 많이 사용되는 알고리즘은 feed forward error back propagation algorithm 이다 [5]. 상기 세 가지 방법을 이용하여 각각의 성능을 비교하기 위해서 두 개의 가스 량, 온도, 압력, RF Power 의 5개의 입력 파라미터가 있는 PECVD 시스템을 이용하여 산화막을 증착하였으며, 증착된 산화막의 refractive index, 증착률, 식각률 등 3 가지 특성을 측정하였다. 각 모델의 성능을 비교한 결과, 신경회로망 모델이 fractional factorial 모델보다 학습오차에 있어서는 약 22%, 예측오차에 있어서는 약 43%의 좋은 성능을 나타내었고, Taguchi 모델과의 비교에서는 학습오차는 약 110%, 예측오차는 약 150%의 좋은 성능을 나타내었다.

2. 실험계획법과 모델링

2.1 PECVD 산화막 특성 측정

실리콘 산화막은 Plasma-Therm 700 시리즈를 사용하여 증착하였으며 N₂O, 2% SiH₄를 사용하였고 표 1에서 보인 바와 같이 증착조건을 변화하면서 실험계획법에 의해서 실험하였다.

표 1. Deposition Parameters

Parameter	Range
Substrate Temperature	200 - 400 °C
Pressure	0.25 - 1.8 torr
RF Power	20 - 150 watt
2% SiH ₄ in N ₂ Flow	200 - 400 sccm
N ₂ O Flow	400 - 900 sccm

약 5 μm의 산화막을 4" (100) 방향의 실리콘 웨이퍼 위에 증착 시켰다. 13.56MHz의 RF Power를 사용하였으며 전극간의 간격은 2.29cm이고 전극의 직경은 11 인치이다. 실험계획법에 의해 만들어진 16개의 증착조건과 3개의 center point에서 실험된 데이터는 각 모델의 학습에 사용되었고 이외에도 6개의 다른 조건에서 증착을 실시하여 여기서 얻은 데이터는 예측오차를 측정하는데 사용하였다. 증착후에는 Metricon 2010 prism coupler를 사용하여 산화막의 refractive index와 두께를 측정하였고 이를 이용하여 증착률을 계산하였다.

식각 식각률을 측정하기 위해서 산화막의 일부분에 악스를 입힌 후 49%의 HF:H₂O 용액에 담근다. 이것을 DI용액으로 세척한 후 악스를 제거하고 Dektak 3030 surface profilometer를 이용하여 식각이 안된 부분의 높이를 측정하고 이를 근거로 식각률을 계산하였다.

2.2 통계적 방법에 의한 모델링

2^{k-1} fractional factorial design은 $(k-1)$ 개의 factor를 이용해서 full factorial을 정의하고 마지막 factor는 $(k-1)$ 개 factor의 interaction을 계산하여 정의한다. 본 실험에서는 5개의 공정 제어변수(SiH₄ 가스 양, N₂O 가스 양, 온도, 압력, RF Power)가 있으므로 각각의 가스 량을 A, B라 하고 온도, 압력, RF Power 를 각각 C, D, E라 하면 2^{5-1} fractional factorial design은 다음과 같이 형성된다.

표 2. Fractional Factorial Model

A	B	C	D	E=ABCD
-	-	-	-	+
-	-	-	+	-
-	-	+	-	-
-	-	+	+	+
-	+	-	-	-
-	+	+	-	+
-	+	+	+	+
-	+	+	+	-
+	-	-	-	-
+	-	-	+	+
+	-	+	-	+
+	-	+	+	-
+	+	-	-	+
+	+	-	+	-
+	+	+	-	-
+	+	+	+	+

여기에서 시스템의 변위를 고려하기 위해서 3개의 center point를 추가하여 모델을 만든다.

1980년대에 Genichi Taguchi 교수는 주변 환경 조건에 강하고 각 컴포넌트의 변위가 강인하며 목적값의 주변에서의 변위가 적은 새로운 개념의 실험계획법을 제안하였다. 이를 근거로 하여 기존의 데이터를 이용하여 RS/Discover[6]를 사용하여 Taguchi 모델을 만들었다. 그림1과 그림2는 RS/Discover에 의한 fractional factorial 모델과 Taguchi 모델의 요약을 보여준다.

Summary of MDM: MDM_EROMIEL	1 DESTINATION 2 FACTORS 3 RESPONSES
Controlled factors: SiH ₄ , N ₂ O, TSUBST, PRESSURE, RF_POWER	4 PER_STAT
Responses: RATE, REF_INDEX, ETCH_RATE	5 MODEL
Objective: SCREENING	6 INCLUSIONS
Design Type: FRACTIONAL-FACTORIAL (with centerpoints)	7 CANDIDATES
Model Type: INTERACTIONS	8 DESIGN
MODEL..... 16 terms	9 WORKSHEET
DESIGN..... 17 runs plus 2 replicates	10 SUMMARY
WORKSHEET... 19 total runs (19 completed)	11 NEXT

그림 1. Summary of Fraction Factorial Model

Summary of MDM_TAGUCHI: mcm taguchi method	1 DESTINATION 2 FACTORS 3 RESPONSES
Controlled factors: SiH ₄ , N ₂ O, TSUBST, PRESSURE, RF_POWER	4 PER_STAT
Responses: RATE, REF_INDEX, ETCH RATE	5 MODEL
Perf. Stat.: MEAN_RATE, MEAN_REF_INDEX, MEANETCH RATE	6 INCLUSIONS
Objective: TAGUCHI	7 CANDIDATES
Design Type: FRACTIONAL-FACTORIAL (with centerpoints)	8 DESIGN
Model Type: INTERACTIONS	9 WORKSHEET
MODEL..... 16 terms	10 SUMMARY
DESIGN..... 17 runs plus 2 replicates	11 NEXT
(OUTER... 1 run plus 3 replicates	
WORKSHEET... 19 total runs (19 completed)	

그림 2. Summary of Taguchi Model

2.3 신경회로망에 의한 모델링

신경회로망은 생물체의 신경전달과정을 모방하여 만든 회로망인데 뉴런이라고 하는 연산 소자가 병렬로 여러 개가 연결되어서 하나의 커다란 회로망을 구성하는 것이다. 신경회로망은 복잡한 비선형 시스템을 모델링하는데 많이 사용되고 있으며 각 뉴런들을 연결하는 과정에서 주어진 데이터에 맞는 행동을 하도록 연결강도를 조정하는데 이를 신경회로망의 학습이라 한다. 본 연구에서 사용된 학습 방법은 feed forward error back propagation 방법을 사용했으며, 뉴런에서 사용된 함수는 sigmoidal 함수이다.

Backpropagation은 gradient descent 기법을 사용하는데, 누적된 오차함수 E 를 편미분하여 신경회로망의 weight를 계계적으로 변화시켜 입출력 관계를 학습시킨다. Weight의 변화량을 Δw_{ijk} 라고 했을 때 다음의 식에 의해서 weight 가 변화한다.

$$\Delta w_{ijk}(n+1) = -\eta \frac{\partial E}{\partial w_{ijk}} + \alpha \Delta w_{ijk}(n) \quad (1)$$

여기서 i 는 k 층의 노드를 나타내고 j 는 $(k-1)$ 층의 노드를 나타내며 w_{ijk} 는 두 노드간의 weight를 나타낸다. η 는 학습율이라 하며 보통 0과 1사이의 값을 갖는다. 학습율이 크면 학습 속도는 빨라지지만 오차함수의 최적점 근방에서 수렴하지 않으며, 또한 너무 작게 하면 이러한 문제는 해결할 수 있지만 학습속도가 너무 느리게 된다. 식(1)의 우변의 두 번째 항을 모멘텀항이라 하며 α 값은 0과 1사이의 값을 갖게 된다. 모멘텀항을 추가함으로써 신경회로망을 학습시킬 때 학습공간에서 학습이 진행되는 방향으로의 진행을 도우며 최적점 근방에서의 수렴을 도와준다. 학습율과 모멘텀 이외에도 신경회로망의 성능에 영향을 미치는 것은 학습오차이다. 학습오차가 작으면 주어진 데이터에서는 정확하게 예측하지만 그 이외의 데이터에서는 일반적으로 예측기능이 떨어지게 된다. 신경회로망 모델의 성능에 영향을 미치는 또 다른 변수는 은닉층의 수와 각 층의 뉴런의 수이다. 비선형 시스템의 모델을 위해서는 하나의 은닉층만 있으면 되기 때문에[7] 본 논문에서는 하나의 은닉층을 사용했으며 6개의 뉴런을 은닉층 뉴런으로 사용하였다. 이러한 신경회로망을 구성하여 학습할 때 전술한 학습율, 모멘텀, 학습오차, 은닉층의 뉴런의 수 등을 최적화한 값을 사용해야 모델의 성능의 향상을 볼 수 있다.

그림 3은 feed forward 다층 신경회로망의 모습을 보여주고 있다.

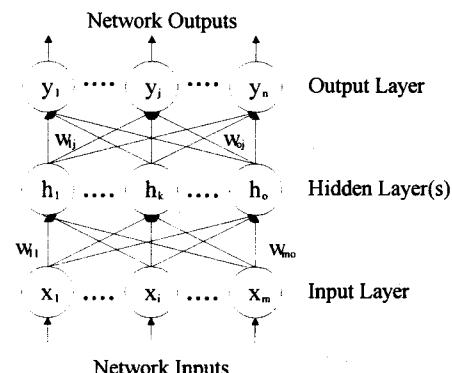


그림 3. Feed Forward Multi-Layered Neural Network

3. 결과 및 토의

각 모델을 만들 때 실험계획법에 의한 19개의 실험 데이터를 사용하여 학습오차를 측정하였으며, 추가로 6번의 실험을 통하여 취득한 데이터를 각 모델의 예측오차를 측정하는데 사용하였다. 실험에서는 산화막의 8가지 특성을 측정하였으나 그 중 refractive index의 실험값의 변화량이 가장 작고, 식각율의 변화량이 가장 크며, 증착율의 변화량이 중간정도이므로 이 세 가지에 대하여 모델을 만들어서 그 성능을 비교하였다. 표 3은 세 가지 특성의 실험 값의 변화량이며, 표 4에는 각 특성에 대한 각각의 모델의 학습오차와 예측오차의 mean square error와 오차의 variance를 나타내었다.

표 3. 측정값의 변화량

특성	변화량
Refractive Index	1.42 - 1.47
Deposition Rate	56 - 506
Wet Etch Rate	330 - 38130

표 4. Summary of MSE and VAR of Each Model

Model		Fractional Factorial		Taguchi		Neural Network	
Error		MSE	VAR	MSE	VAR	MSE	VAR
Etch Rate	학습 오차	1.22 E8	6.78 E6	1.64 E8	9.10 E6	1.17 E6	6.36 E4
	예측 오차	3.13 E8	4.50 E7	1.07 E9	5.29 E7	2.59 E8	3.36 E7
Depo. Rate	학습 오차	1.22 E5	6.26 E3	1.02 E5	5.68 E3	1.06 E4	5.84 E2
	예측 오차	7.97 E4	1.55 E4	8.26 E4	1.45 E4	3.93 E4	7.75 E3
Ref. Index	학습 오차	3.00 E-5	1.67 E-6	1.62 E-4	9.00 E-6	6.70 E-5	3.70 E-6
	예측 오차	5.12 E-4	5.43 E-5	2.54 E-4	2.08 E-5	2.06 E-4	2.79 E-5

표 4에서 보이듯이 신경회로망 모델은 증착율의 예측오차와 refractive index의 학습오차 이외의 다른 모든 경우에 가장 우수한 성능을 보여주고 있다. Taguchi 모델은 실험값의 변화량이 작은 refractive index 모델에서 fractional factorial 모델보다 우수한 성능을 보여주고 있으며, 반면에 실험값의 변화량이 큰 식각율의 경우에 있어서는 fractional factorial 모델이 Taguchi 모델보다 우수한 성능을 보여주고 있다. 측정값의 변화량이 큰 식각율과 증착율에서 학습오차와 예측오차 모두에서 우수한 성능을 보여주고 있다.

4. 결 론

본 연구에서는 통계적 방법에 근거한 fractional factorial 모델, Taguchi 모델과 지능형 모델링 방법중의 하나인 신경회로망 모델을 사용하여 복잡한 비선형 시스템인 폴라즈마 화학 기상 증착법에 의해서 형성된 산화막의 특성에 대한 모델을 만들어서 각 모델의 성능에 대한 고찰을 하였다. 각 모델의 성능을 비교한 결과, 신경회로망 모델이 fractional factorial 모델보다 학습오차에 있어서는 약 22%, 예측오차에 있어서는 약 43%의 좋은 성능을 나타내었고, Taguchi 모델과의 비

교에서는 학습오차는 약 110%, 예측오차는 약 150%의 좋은 성능을 나타내었다.

(참 고 문 헌)

- [1] H. Guo, C. Spanos, and A. Miller, "Real Time Statistical Process Control for Plasma Etching," ISMSS, May, 1991.
- [2] S. Han and G. May, "Using Neural Network Process Models to Perform PECVD Silicon Dioxide Recipe Synthesis via Genetic Algorithms," IEEE Trans. Semi. Manufac., vol. 10, no. 2, pp. 279-287, May, 1997.
- [3] D. Montgomery, *Design and Analysis of Experiments*, 3rd ed., Wiley, 1991.
- [4] G. Taguchi, and Y. Wu, *Introduction to Off-Line Quality Control*, Central Japan Quality Control Association, Nagoya, Japan, 1980.
- [5] R. Lippmann, "An Introduction to Computing with Neural Nets," IEEE Acoustics, Speech and Signal Processing Magazine, vol. 4, no. 2, pp. 4-22, April 1987.
- [6] Bolt Beranek and Newman Inc., *RS/Discover Primer*, 1988.
- [7] B. Irie, and S. Miyake, "Capabilities of Three-Layered Perceptrons," IEEE International Conference on Neural Networks, pp. 641-648, 1988.