

신경망과 전문가 시스템을 결합한 플라즈마 장비 센서정보 융합

박민근*, 김병환*, 손종원**, 한정훈**, 서승훈**

*세종대학교, **주성엔지니어링

초록

본 연구에서는 플라즈마 상태를 조기에 예측하는 기법을 개발하였다. 본 기법은 신경망 시계열 모델, CUSUM 제어 차트, 그리고 Dempster Schaffer 전문가 시스템을 결합하여 개발하였다. 시계열 모델은 과거와 미래정보의 조합을 통해 그 예측성능을 최적화하였다. 본 기법은 소자제조업체에서 가동중인 PECVD 장비에서 수집된 센서정보에 적용하여 평가하였으며, 플라즈마의 정상과 고장 상태를 조기에 정확히 예측할 수 있었다. 소자제조업체에서 본 기법을 적용할 때, 장비 생산성과 소자수율의 증진에 기여할 수 있다.

1. 서론

플라즈마 공정은 반도체 소자제조를 위한 박막의 증착과 패터닝 (Patterning)에 핵심적으로 이용되고 있다. 플라즈마는 공정변수 (소스전력, 압력 등)에 매우 민감하게 반응을 한다. 챔버내로 전달되는 공정변수에 이상 (Anomaly)이 발생할 경우 플라즈마 상태가 달라지며, 이에 따라 챔버 (Chamber) 내에 발생하는 플라즈마 밀도, 전자온도, 플라즈마 전위, 그리고 라디칼 농도가 변화하게 되고, 이는 공정특성 (예컨대, 식각률, 균일도, 증착 두께, 박막 균일도)의 변화를 초래하게 된다. 플라즈마 특성의 변화는 제조되는 공정의 질 (Quality)을 저하시키며, 이는 소자수율의 저하로 이어져 소자제조업체에 막대한 손실을 초래하게 된다. 나아가서, 플라즈마 이상이 적시에 탐지가 안 될 경우, 장비의 가동이 중단되는 상황도 초래될 수 있으며, 이는 소자생산성을 줄이는 주요 이유가 되고 있다. 따라서, 소자생산성과 수율의 확보를 위해서는 플라즈마 공정을 엄격히 감시하는 기법이 요구되고 있다.

Sandia Lab 의 연구진은 Optical emission spectroscopy (OES)-기반 플라즈마 감시시스템을 개발한 바 있다 [1]. 즉 OES 를 이용해 수집되는 특정 라디칼의 Peak 을 추적하여 플라즈마 상태를 감시하였다. Texas (Austin)대학 연구진 [2], LSI Logic [3], Arisona 대학 연구진 [4] 등은 RF 임피던스 센서를 이용한 감시 기술을 보고한 바 있다. 즉 챔버 안 임피던스를 저항과 리액턴스 성분으로 분해하여 공정변수에 따른 민감도를 플라즈마 감시에 응용하였다. OES 나 RF 임피던스 센서를 설치하지 않고 장비 부품인 RF 정합망 (Match network) 감시에 기초한 진단방식이 보고된 바 있다 [5]. 본 감시기술에서는 Signal Flow Diagram 을 설계하여 챔버 임피던스 정합에 관여하는 두 임피던스와 상 (Phase) 모터의 전기적 위치를 감시하였으며, 기존의 OES 와 RF 센서방식과는 달리 장비부품을 직접 플라즈마 감시에

응용하였다는 점에서 구분된다. 조지아 공대 연구진은 장비외부 변수 (RF 전력, 압력 등)의 실시간 정보를 CUSUM 제어차트 [6]에 연계하여 플라즈마 감시를 시도한 바 있다 [7].

본 연구에서는 시계열 신경망, CUSUM 제어차트, 그리고 Dempster Schafer (DS) 전문가 시스템을 결합한 플라즈마 장비 초기 감시 기술을 개발하였다. 본 기술은, 현재 소자 제조업체에서 가동중인 PECVD 장비에서 수집된 센서정보에 적용하여 평가하였다.

2. 실험 방법

PECVD 공정 순서는 총 9 개의 공정으로 구성되어 있으며, 본 연구에서 적용한 공정단계는 5 번째의 “PRE” 단계였다. PRE 단계는 총 18 개의 센서정보로 구성되어 있으며, 각 센서정보는 총 13 샘플된 데이터로 구성되어 있다. 본 연구에서는 이 중, 두 센서정보, 즉 Gas06 ActFlow 과 HeL ActFlow에 대한 센서정보에 대한 분석 결과만을 보고한다.

3. 실험결과 및 고찰

시계열 모델로 Auto-correlated 시계열 방식이 채택되었으며, 관련 신경망 구조는 그림 1 에 도시되어 있다.

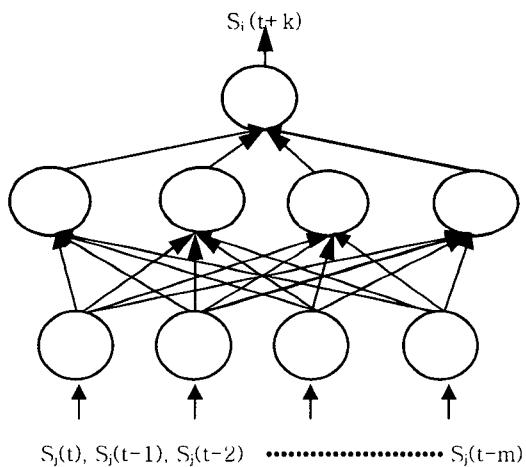


그림 1. Auto-correlated 시계열 모델링 구조

시계열 모델링과 평가를 위해 동일 단계에 대한 정상상태와 고장상태에 대한 센서정보를 수집하였다. 우선 정상상태의 센서정보를 이용하여 시계열 신경망 모델링을 개발하였으며, 개발에 이용된 신경망 종류는 역전파 신경망 (Backpropagation neural network)이었다. 신경망 학습에는 다수의 학습인자가 관여하고 있으며 [8]. 본 모델개발에서는 은닉층의 뉴런수를 2 에 고정하였으며, 학습허용도, 초기웨이트의 범위, 활성화 함수의 경사, 그리고 학습률은 각기 0.1, ±1, 1, 그리고 0.01 에 고정하였다. 학습인자 외에, 시계열 모델에 이용되는 과거 센서정보의 양 (m)과 미래의 예측하는 시점 (k)이 시계열 모델성능에 상당한 영향을 미칠 수 있다. 이에 따라 각 센서별로 총 9 가지의 시계열 모델을 개발하였으며, 이 중 가장 좋은 성능을 가진 모델을 결정하였다. 예로 Gas06 ActFlow에 대한 (m, k) 조합에 따른 모델성능은 표 1에 나타나

있다. 표 1에서와 같이 (2, 1)에서 가장 작은 예측에러를 구하였으며, 이 모델을 동일 센서정보 감시에 응용하였다.

표 1. Gas06 ActFlow에 대한 (m, k)

조합에 따른 모델성능

(m, k)	학습에러	테스트 에러	Val 에러
(1, 1)	0.064161	0.301424	0.22293
(1, 2)	0.012034	0.071015	0.052197
(1, 3)	4.394192	4.178113	4.233757
(2, 1)	0.01205	0.057591	0.042136
(2, 2)	4.411232	4.581482	4.286912
(2, 3)	4.411232	4.581482	4.524232
(3, 1)	4.234901	4.724031	4.589653
(3, 2)	4.234901	4.724031	4.459037
(3, 3)	5.016716	6.208457	5.999981

표 2. HeL ActFlow에 대한 (m, k)

조합에 따른 모델성능

(m, k)	학습에러	테스트 에러	Val 에러
(1, 1)	0.06871	0.101632	2.962467
(1, 2)	0.070253	0.184558	3.329033
(1, 3)	0.076826	0.224898	3.496568
(2, 1)	0.070238	0.136478	3.207224
(2, 2)	0.076808	0.181741	3.371952
(2, 3)	0.062279	0.172128	3.671992
(3, 1)	0.07663	0.115711	3.460256
(3, 2)	0.062269	0.097291	3.716421
(3, 3)	0.056639	0.168589	3.931704

이와 동일한 방식으로 다른 센서인 HeL ActFlow에 대한 시계열 모델링을 수행하였으며, (3, 2)에서 가장 우수한 시계열 모델을 개발하였다. 개발된 모델의 실시간 조기 감시 성능을 고장상태의 센서정보를 이용하여 평가하였다. 이를 위해 고장센서정보를 이용하여 Validation 데이터를 구성하였으며, 이를 모델에 인가하였다. Validation 데이터는 총 9개의 데이터로 구성되었다. 우선 앞서 결정된 Gas06 ActFlow 센서정보에 대한 시계열 모델에 Validation 데이터를 인가하였을 때의 에러는 0.042136였으며, 이는 모델 테스트 데이터에 대한 에러와 비슷함을 알 수 있다. 이는 모델에 인가한 센서정보가 정상 상태의 플라즈마에서 수집 되었음을 의미한다. Validation 데이터에 대한 예측치와 실제치가 그림 1에 도시되어 있다.

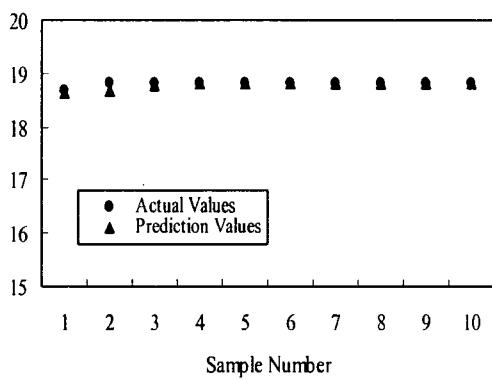


그림 2. Validation 데이터에 대한 시계열의 모델의 예측치와 실제치

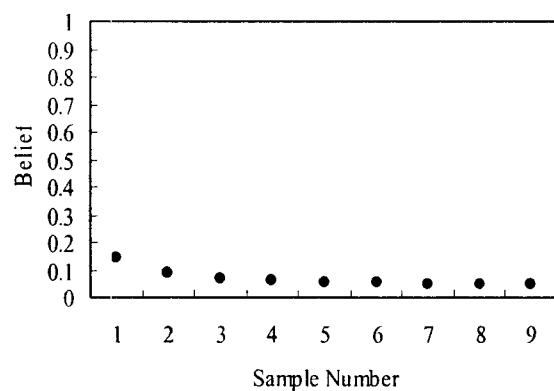


그림 3. DS 전문가 시스템을 이용하여 융합된 CUSUM Beliefs

모델로부터의 예측치는 CUSUM 제어차트에 전달되어 각 샘플링 시간마다 고장 Belief가 계산이 된다. 이 때, CUSUM 제어차트의 적용에 필요한 해당 센서의 목표치와 평균치는 각각 18.8032와 18.57691였으며, 설계변수인 d 와 θ 는 각각 3과 0.2에 고정하였다. DS 전문가 시스템을

이용하여 매 샘플링 순간에서 Update된 Belief 값은 그림2에 도시되어 있다. 그림2에서와 같이 Belief 값은 거의 0 근처에서 변하고 있으며, 이는 플라즈마 상태가 정상임을 조기 예측하고 있음을 의미한다. 결국, 시계열 모델이 정상의 플라즈마 상태를 조기에 효과적으로 예측하고 있음을 알 수 있다.

동일한 방식으로 앞서 개발된 HeL ActFlow 시계열 모델에 Validation 데이터를 인가하였을 하였을 때의 에러는 3.71642 였으며, 이는 모델개발시의 테스트에 려 0.097291 보다 약 37 배정도 더 큰 수치임을 알 수 있으며, 따라서 플라즈마 상태의 고장을 예측할 수 있다. 확인을 위해 모델 예측치와 실제치가 그림 3에 도시되어 있으며, 실제치 패턴은 플라즈마 고장을 분명하게 보이고 있다. 하지만, 모델 예측치 변화는 미미하여, 예측치 패턴으로는 고장상태의 유무를 확인하기가 어려워 보인다. 예측치에 CUSUM 제어차트와 DS 전문가 시스템을 순차적으로 적용하면서, Update 한 Belief 값들은 그림 4에 도시되어 있다. 이 때 이용된 CUSUM 제어차트 변수는 이전에 설정한 값과 동일하게 하였다.

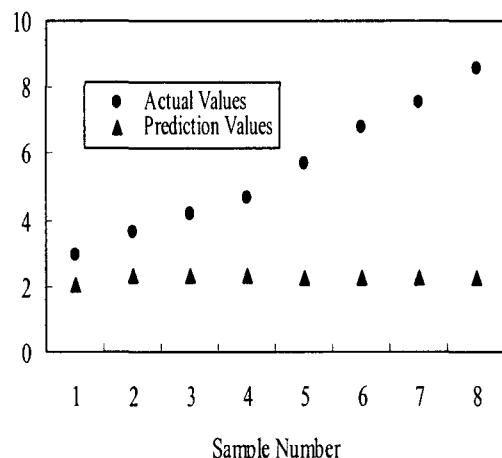


그림 4. Validation 데이터에 대한 시계열의 모델의 예측치와 실제치

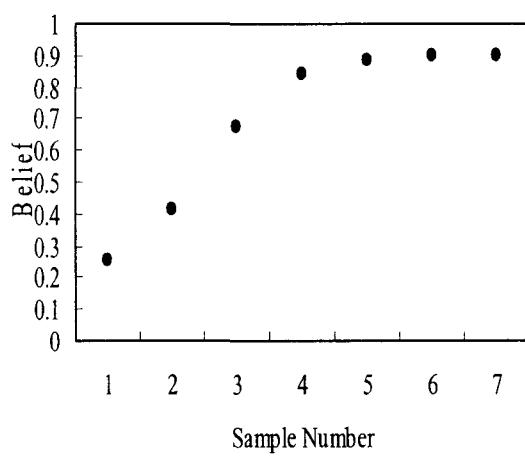


그림 5. DS 전문가 시스템을 이용하여 융합된 CUSUM Beliefs

그림 4에서와 같이 Belief 값은 시간이 증가하면서 증가하고 있으며, 따라서 고장이 전개되고 있는 과정을 분명하고 조기에 예측하고 있다. 이상의 사례보고에서와 같이, 본 연구에서 제안하는 시계열모델, CUSUM 제어차트, 그리고 DS 전문가 시스템을 결합한 감시 기법은 플라즈마 상태를 사전에 예측하는데 매우 효과적임을 확인할 수 있다.

4. 결론

본 연구에서는 플라즈마 상태를 조기에 예측하는 기법을 시계열모델, CUSUM 제어 차트, 그리고 전문가 시스템을 결합하여 개발하였다. PECVD 장비에서 수집한 센서정보에 적용하여 그 감시 성능을 평가하였으며, 정상이나 고장상태의 플라즈마에 대하여 정확하게 그 상태를 조기에 예측하고 있음을 확인할 수 있었다. 본 기법을 소자제조업체에 적용할 때, 공정의 Quality의 변화를 조기에 예측할 수 있어 장비 생산성과 수율확보에 기여할 수 있으리라 기대된다.

감사의 글

본 연구는 산업자원부가 지원하는 System IC 2010 (시스템직접반도체 기반기술개발) 사업과 ITRC의 지원에 의해 수행되었습니다.

참고문헌

- [1] J. O. Stevenson, P. P. Ward, M. L. Smith, R. J. Markle, A plasma process monitor/control system, Surface and Interface Analysis, vol. 26, 124 (1998).
- [2] S. Bushman, T. F. Edgar, I. Trachtenberg, Radio frequency diagnostics for plasma etch systems, SPIE vol. 2336, 1994.
- [3] F. Bose, R. Patrick, H. Baltes, Measurement of discharge impedance for dry etch process control, SPIE vol. 2336, 101 (1994).
- [4] F. Bose, R. Patrick, H. P. Baltes, Electrical characterization of a processing plasma chamber, J. Vac. Sci. Technol. A, vol. 15, no. 6, 2930 (1997).
- [5] B. Kim, C. J. Lee, Monitoring plasma impedance match characteristics in a multipole inductively coupled plasma for process control, J. Vac. Sci. Technol. A, vol. 18, no. 1, 58 (2000).
- [6] D. C. Montgomery, Introduction to Statistical Quality Control, John Wiley & Sons, Singapore, 1985.
- [7] B. Kim, G. S. May, Real-time diagnosis of semiconductor manufacturing equipment using a hybrid neural network expert system," IEEE Trans. Comp. Package. Manufact. Technol. C, vol. 20, no. 1, 39 (1997).
- [8] B. Kim and S. Park, "An optimal neural network plasma model: a case study," Chemometrics and Intelligent Laboratory Systems, vol. 56 (1),(39) 2001.