

# 플라즈마 장비 센서정보의 Auto/Cross-Correlated 시계열 모델링

## Auto/Cross-Correlated Time Series Modeling of Plasma Equipment Sensor Information

김기태\*, 김병환\*\*

(Kitae Kim, Byungwhan Kim)

**Abstract** - Auto-Cross Correlated time series (ACTS) model was constructed by using the backpropagation neural network. The performance of ACTS model was evaluated with sensor information collected from a large volume, industrial plasma-enhanced chemical vapor deposition system. A total of 18 sensor information were collected. The effect of inclusion of past and future information were examined. For all but three sensor information with a large data variance demonstrated a prediction error less than 3%. By integrating ACTS model into equipment software, process quality can be more stringently monitored while improving device throughput.

**Key Words** : Time Series Model; Backpropagation Neural Network; Plasma Equipment; Sensor

### 1. 서론

플라즈마는 집적회로 제조를 위한 미세 박막의 증착과 식각에 핵심적으로 이용이 되고 있다. 공정의 질 (Quality)을 높이고 장비가동률을 증진하기 위해서는 플라즈마에 대한 엄격한 감시와 진단이 요구된다. 플라즈마는 주로 Optical Emission Spectroscopy (OES) [1] 나 Impedance 센서 [2]와 같은 In-situ 진단기구로 수집한 데이터를 감시한다. 한편, 플라즈마 장비는 다수의 고가 부품들로 구성되며, 각 부품에서는 부품의 상태를 알리는 센서정보가 산출된다. 센서정보는 플라즈마 감시와 진단을 위해 중요한 자료임에도 불구하고, 실제 제조현장에서 가동되는 플라즈마 장비에서는 이들 센서정보를 처리하는 컴퓨팅 기구 내지 기능이 구비되어 있지 않다. 플라즈마 감시를 위해서는 각 센서정보를 모델링하는 기법이 요구되며, 이러한 모델들은 센서자체의 상태 확인, 실시간 고장 탐지, 센서정보의 미래 상태 예측, 그리고 고장원인의 진단에 핵심적으로 활용된다. 실시간 센서정보 모델링을 위해 시계열 (Time-Series) 모델링이 적용되고 있으며, 여기에는 Auto, Cross, Auto/Cross 시계열 모델이 포함된다. 시계열 모델링 기법은 신경망과 결합하여 플라즈마 장비 변수 [3-4] 등을 예측하는데 응용된 바 있다. 하지만, 시계열 모델링 방식은 학교나 연구소 수준의 장비에 적용되었을 뿐, 소자제조현장에서 가동 중인 대형 플라즈마장비에서 수집된 센서정보에 적용된 사례는 보고된 바가 없다. 또한 시계열 모델링시 입력할 과거정보의 양과 예측할 미래 시간의 양은 시계열 모델의 성능에 영향을 미치며, 따라서 이들의 영향을 고찰하여, 최적의 양들을 설정할 필요가 있다. 그러나 이에 대한 체계적인 분석결과는 보고된 바가 없

다.

본 연구에서는 산업용 플라즈마 장비에서 수집한 장비센서정보에 대한 Auto/Cross-Correlated 신경망 모델을 개발하였다. 센서정보는 소자제조업체에서 가동 중인 플라즈마화학 기상 증착장비 (Plasma Enhanced Chemical Vapor Deposition System-PECVD)로부터 수집하였다. 신경망으로는 역전파 신경망 (Backpropagation Neural Network-BNNN) [5]를 이용하였다.

### 2. 시계열 모델링

시계열 모델링은 실시간 센서정보를 예측하기 위해 응용되고 있다. 모델링 방식에는 특정센서의 현재와 과거정보를 이용해서 특정 센서자신의 미래정보를 예측하기 위한 Auto-Correlated 시계열 (ATS) 모델과 특정센서의 현재와 과거정보 외에 다른 센서의 현재정보를 이용해서 특정 센서의 미래정보를 예측하기 위한 Auto-Cross-Correlated 시계열 (ACTS) 모델, 특정 센서정보이외의 다른 센서정보를 이용해서 특정센서의 미래정보를 예측하기 위한 Cross-Correlated 시계열 (CTS) 모델 등이 있다.

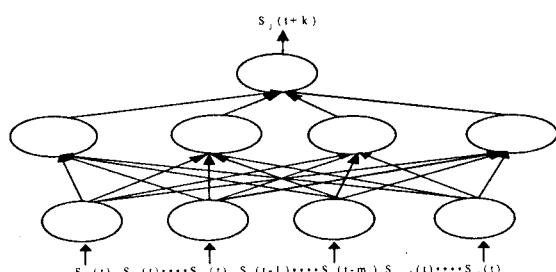


그림 1. Auto-Cross Correlated 시계열 모델 구조

### 저자 소개

\* 김기태 : 世宗大學校 電子工學科 學士課程

\*\* 김병환 : 世宗大學校 컴퓨터工學部 副教授

본 연구에서는 두 번째의 ACTS 방식을 이용하여 장비센서 정보를 모델링하였으며, 그 구조는 그림 1에 도시되어 있다.

### 3. 결과

ACTS 모델을 개발할 때, 과거정보의 수 ( $m$ )와 미래정보의 수 ( $k$ )의 조합에 따라 모델의 예측성능이 달라지게 된다. 본 연구에서는 각 변수의 값을 1에서 3까지 변화시켜 총 9개의 조합에 대해 모델성능을 평가하였다. PECVD 장비로부터 총 18 종류의 센서정보를 수집하였으며, 각 센서정보에 대해 9개의 모델, 즉 162개의 ACTS 모델을 개발하여 평가하였다.

ACTS 모델개발을 위해 각 센서정보는 ( $m,k$ )의 조합에 따른 학습과 테스트 데이터로 나누어 모델의 예측성능을 평가하였다. 우선 각 센서정보의 각 조합에 따른 모델의 학습에러가 그림 2에 도시되어 있다. 모델에러는 Root Mean Squared Error (RMSE)로 계산되었다. 편의를 위해, RMSE는 스케일된 값을 도시하였으며, 스케일 크기는 그림 2의 각 센서정보의 팔호에 명시되어 있다. 그림 2에서와 같이 대부분의 센서정보에 대해 학습에러는 ( $m,k$ )의 조합에 상관없이 일정한 값을 보이고 있다. 두 번째 센서인 "RF01 RefValue"는 다른 센서에 비해 상당히 큰 학습에러의 변화를 보이고 있는데, 이는 센서정보 자체가 시간에 따라 크게 변하는 것에 기인한다.

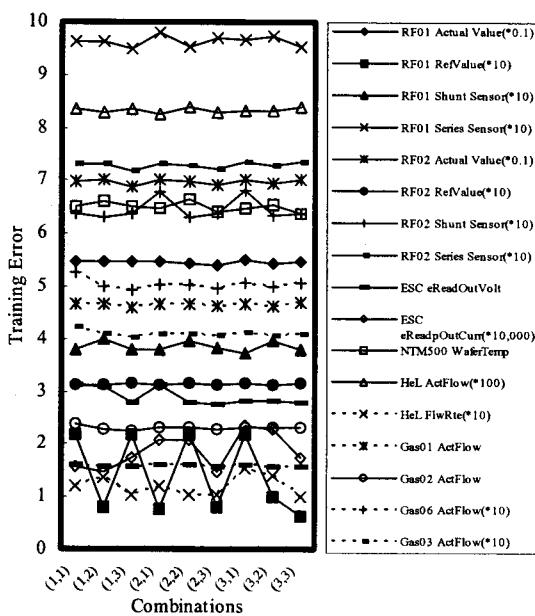


그림 2. ACTS의 ( $m,k$ ) 조합에 따른 학습 성능 변화

그림 3은 ACTS모델의 조합에 따른 예측성능을 보이고 있다. 그림 3에서와 같이 특정 조합에서 ACTS 모델의 RMSE는 가장 작은 값을 가지며, 이 모델을 해당 센서에 대한 최적 모델이라고 할 수 있다. 각 센서에 대해 결정된 최적 모델이 표 1에 정리되어 있다. 표 1은 최적 모델이 결정

된 특정 조합, 해당 모델의 예측과 학습에러를 보이고 있다.

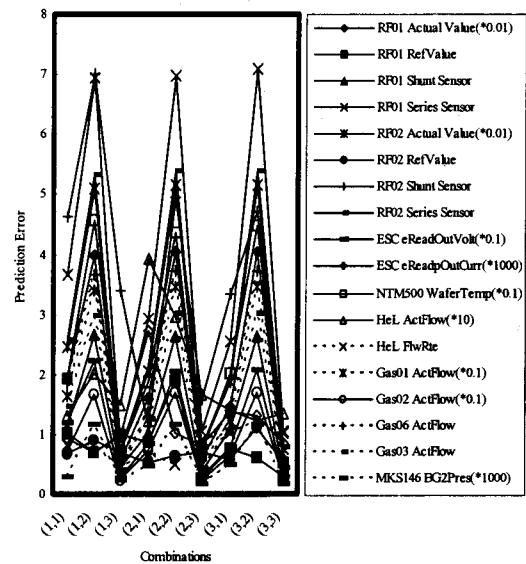


그림 3. ACTS의 ( $m,k$ ) 조합에 따른 예측성능 변화

표 1. 최적 ACTS 모델의 학습과 예측에러

센서	OC	TR-RMSE	TE-RMSE
RF01 Actual Value	(1,3)	55.26586	54.62249
RF01 RefValue	(2,3)	0.253664	0.079033
RF01 Shunt Sensor	(2,3)	0.376065	0.381611
RF01 Series Sensor	(1,3)	0.898798	0.948043
RF02 Actual Value	(1,3)	70.65456	68.75667
RF02 RefValue	(3,3)	0.527036	0.315096
RF02 Shunt Sensor	(3,3)	0.808694	0.637327
RF02 Series Sensor	(1,3)	0.73822	0.71839
ESC eReadOut Volt	(1,3)	2.70715	2.779985
ESC eReadpOutCurr	(1,2)	0.000701	0.000147
NTM500 WaferTemp	(3,3)	5.211113	6.370174
HeL ActFlow for ESC	(2,3)	0.123846	0.083187
HeL FlwRte	(1,3)	0.432232	0.103775
Gas01 ActFlow	(1,3)	4.790637	4.581509
Gas02 ActFlow	(1,3)	2.350589	2.253821
Gas06 ActFlow	(1,3)	0.504903	0.493546
Gas03 ActFlow	(1,3)	0.411389	0.401907
MKS146 BG2Pres(*1000)	(3,3)	0.000167	0.000159

표 1에서 알 수 있듯이 예측에러가 5% 미만인 모델은 총 18개 중 9개에 해당한다. 이는 5%를 벗어난 센서들의 정보값이 상대적으로 매우 큰 값을 가지는 것에 기인한다. 따라서 센서정보의 값에 상관없이 모델의 예측성능을 평가하는 기준이 요구되며, 다음과 같은 평가지표를 제시한다.

$$\text{평가지표 (PI)} = M / \text{RMSE} * 100 \% \quad (1)$$

여기서  $M$ 은 테스트 데이터의 출력에 대한 평균치이며, RMSE는 표 1에서의 최적 모델에 대한 예측에러이다. 각 센서의 테스트 데이터에 대해 본 평가지표를 적용하여 계산된 결과가 표 2에 나타나 있다. 표 2에는  $M$ 외에 표준편차

(SD)가 계산되어 있는데, 이는 센서정보의 변화 정도에 따라 센서들을 분류하기 위해 요구된다. M/SD를 계산한 결과가 표 2에 나타나 있으며, 이 값이 0.13을 기준으로 센서정보를 분류할 때, 0.13 이하에 해당하는 센서정보는 15개이며, 이들은 3% 이하의 예측에러를 보이고 있다. 나머지 3 센서정보는 0.13 이상에 해당하며, 3%보다 더 큰, 예컨대 'RF01RefValue' 23.58%, 예측에러를 보이고 있다. 이는 예측이 어려운 정보가 이들 센서정보에 포함된 것에 기인하며, 불필요한 경고(Alarm)를 줄이기 위해서는 이들 센서정보에 대한 모델링은 피해야 할 것으로 사료된다. 결국, 특이 센서정보가 아닌 보통의 센서정보를 예측하는데 있어 ACTS는 매우 우수한 예측성능을 보이고 있음을 본 연구를 통해 확인할 수 있었다.

표 2. 성능지표를 적용하여 계산된 ACTS 모델의 예측성능

	M	SD	SD/M	PI(%)
RF01 Actual Value	3511.657	1.488039	0.000443	1.573796
RF01 RefValue	1.070707	0.384722	0.296686	23.58003
RF01 Shunt Sensor	23.09091	0.288943	0.012545	1.628628
RF01 Series Sensor	60.33333	0.534522	0.009371	1.489475
RF02 Actual Value	4498.34	9.92E-05	0	1.570681
RF02 RefValue	17.05102	1.772484	0.102213	3.094011
RF02 Shunt Sensor	40.94898	0.221171	0.005873	1.975344
RF02 Series Sensor	47	0	0	1.570681
ESC eRead Out Volt	178.9495	0.437379	0.002185	1.51263
ESC eRead pOutCur r	0.00648	0.00232	0.349002	10.78462
NTM500 Wafer Temp	370.7205	4.932047	0.016716	1.403721
He ActFlow for ESC	4.875402	0.357437	0.075695	2.544692
HeL FlowRte	5.149345	0.716026	0.141419	8.362227
Gas01 ActFlow	299.6395	0.289951	0.000969	1.598869
Gas02 ActFlow	147.3709	0.065121	0.000632	1.594907
Gas06 ActFlow	32.2999	1.39E-06	3.85E-08	1.563172
Gas03 ActFlow	26.3014	1.33E-06	4.89E-08	1.564134
MKS146 BG2Pres	0.010165	4.76E-05	0.004851	1.642941

#### 4. 결론

본 연구에서는 플라즈마 감시와 진단을 위한 ACTS 신경망 모델을 개발하였다. 모델성능은 과거와 미래정보 변수의 조합으로 평가하였다. 산업용 대용량 플라즈마 장비에서 수집한 데이터에 본 모델링기법을 적용하였으며, 특히 센서패턴을 제외하고는 예측에러가 3% 이하의 우수한 예측모델을 개발할 수 있었다. 본 모델링 기법은 반도체 플라즈마 장비 소프트웨어에 구현이 되어 플라즈마 공정의 감시와 진단효율을 증진하는데 기여할 것이다.

#### 감사의 글

본 연구는 산업자원부가 주관하는 System IC 2010 사업에 의해 지원되었습니다.

#### 참 고 문 헌

- [1] J. O. Stevenson, P. P. Ward, M. L. Smith, and R. J. Markle: A Plasma Process Monitor/Control System. Surf. Interf. Anal. Vol. 26 (1998) 124-133
- [2] F. Bose, R. Patrick, and H. Baltes: Measurement of Discharge Impedance for Dry Etch Process Control. SPIE 2336 (1994) 101-110.
- [3] B. Kim, G. S. May, Real-time diagnosis of semiconductor manufacturing equipment using a hybrid neural network expert system, IEEE Trans. Compo. Packag. Manufact. Technol., 20, 1, (1997) 39-47.
- [4] M.D. Baker, G. S. May, Time-series modeling of reactive ion etching using neural networks, IEEE Trans. Semicond. Manufact., 8, 1, 62-71, 1995.
- [5] D. E. Rumelhart and J. L. McClelland: Parallel Distributed Processing. MIT Press, Cambridge (1986).