

웨이브릿 시계열 신경망을 이용한 플라즈마 장비 센서 정보 모델링

김유석*, 김병환*, 한정훈**, 서승훈**, 손종원**

*세종대학교 전자공학과, **(주) 주성엔지니어링

초록

본 연구에서는 웨이브릿과 신경망을 결합하여 플라즈마 고장을 감시하기 위한 시계열 모델을 개발하였다. 본 기법은 플라즈마 증착장비에 의해 수집된 18 개의 센서정보에 적용하여 평가하였다. 이산치 웨이브릿 (Discrete Wavelet Transformation)은 장비에서 수집된 센서정보의 전 처리를 위해 이용되었다. 시계열 모델의 성능은 과거와 미래정보의 함수로 평가하였다. 수집된 18 개의 센서정보에 대한 모델성능 비교를 위해 표준화된 성능평가지표가 적용되었다. 평가결과, 본 기법에 의해 개발된 시계열 모델은 대략 4% 정도의 예측에러를 보였다.

1. 서론

플라즈마는 집적회로 제조를 위한 미세 박막의 증착과 식각에 핵심적으로 이용 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 응용된다. 실시간 센서정보 모델링을 위해 시계열(Time-Series) 모델링이 응용되고 있으며, 여기에는 Auto, Cross, Auto/Cross 시계열 모델이 포함된다. 시계열 모델링 기법은 신경망과 결합하여 플라즈마 장비 변수 [3-4] 등을 예측하는데 응용된 바 있다. 최근에 산업용 대형 플라즈마 증착 장비에서 수집된 센서정보에 Auto/Cross 시계열 모델링 기법이 적용된 바 있다 [5]. 한편, 센서정보에 내재해 있는 Noise 를 감소시키고, 동시에 특정 인자를 추출하기 위해 웨이브릿 기법이 응용되고 있으며. 플라즈마 공정과 관련하여 장비 정합망 데이터 [6]와 Scanning Electron Microscope 영상정보에 적용된 바가 있다 [6]. 이들 연구에서는 플라즈마 고장에 대한 민감도를 평가하였으며, 웨이브릿 처리된 정보의 더 높은 고장 민감도를 발표하였다 [7]. 그러나, 아직 웨이브릿 처리된 센서정보를 이용한 시계열 모델의 성능이 보고된 바가 없어 이에 대한 연구가 요구된다.

본 연구에서는 웨이브릿기법과 시계열 신경망 모델을 결합한 센서정보 모델을 개발하였다. 모델성능은 시계열 모델 인자의 함수로 평가하였다. 평가에 이용된 데이터는 이전에 연구 [5]에서 사용한 데이터와 동일하다. 웨이브릿 기법으로, 이산치 웨이브릿 (Discrete Wavelet Transformation-DWT) [8]가 이용되었다. 신경망으로는 역전파 신경망 (Backpropagation Neural Network-BNNN) [9]를 이용하였다.

2. 시계열 모델링

시계열 모델링은 실시간 센서정보를 예측하기 위해 응용되고 있다. 모델링 방식에는 특정센

서의 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 센서 정보이외의 다른 센서정보를 이용해서 특정센서의 미래정보를 예측하기 위한 Cross-Correlated 시계열 (CTS) 모델 등이 있다. 본 연구에서는 첫 번째의 ATS 방식을 이용하여 장비센서정보를 모델링하였으며, 그 구조는 그림 1에 도시되어 있다. 한편 그림 1의 입력정보는 DWT에 의해 변환된 정보가 입력이 되었다. DWT 인자인 scale level과 Daubechies 함수의 값은 1에 고정하였다.

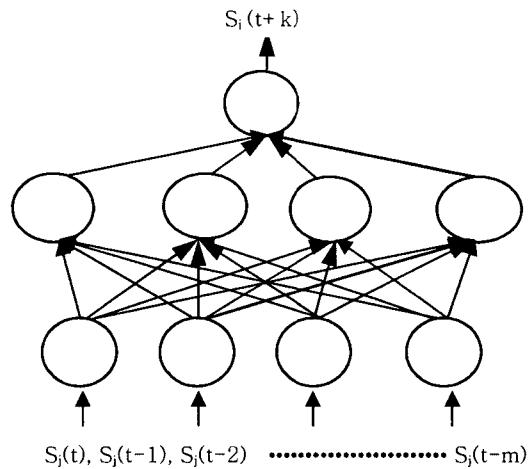


그림 1 Auto-Correlated 시계열 모델 구조

3. 실험결과 및 고찰

편의를 위해 웨이브릿 전처리된 정보를 이용해 개발한 시계열 모델을 WATS 라 표기한다. WATS 모델을 개발할 때, 과거정보의 수(m)와 미래정보의 수(k)의 조합에 따라 모델의 예측성능이 달라지게 된다. 본 연구에서는 각 변수의 값을 1에서 3 까지 변화시켜 총 9 개의 조합에 대해 모델성을 평가하였다. PECVD 장비로부터 총 18 종류의 센서정보를 수집하였으며, 각 센서정보에 대해 9 개의 모델, 즉 162 개의 WATS 모델을 개발하여 평가하였다.

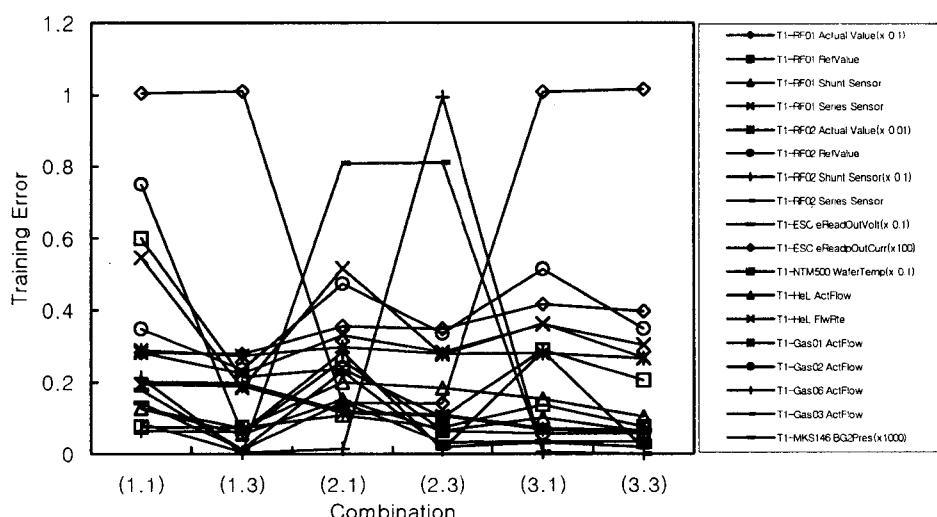


그림 2 WATS의 (m,k) 조합에 따른 학습 성능 변화

WATS 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 괄호에 명시되어 있다. 그림 2에서 그래프의 형태는 주로 지그재그의 형태를 나타내며 $k=3$ 일 때 다른 경우보다 비교적 작은 RMSE 값을 가진다는 것을 알 수 있다. 특히 (1,3)일때 가장 작은 RMSE값을 가진다. 일정한 패턴을 나타내는지 않지만 (2,3)에서 gas 06 센서의 RMSE값이 갑자기 커지는 것을 알 수 있다. 또, RF01Actual Value 센서의 경우 $m=2$ 인 경우를 제외하고 다른 경우에는 RMSE값이 크지만 이와는 반대로 Gas 03 센서의 경우 $m=2$ 인 경우에서만 큰 RMSE 값을 가진다.

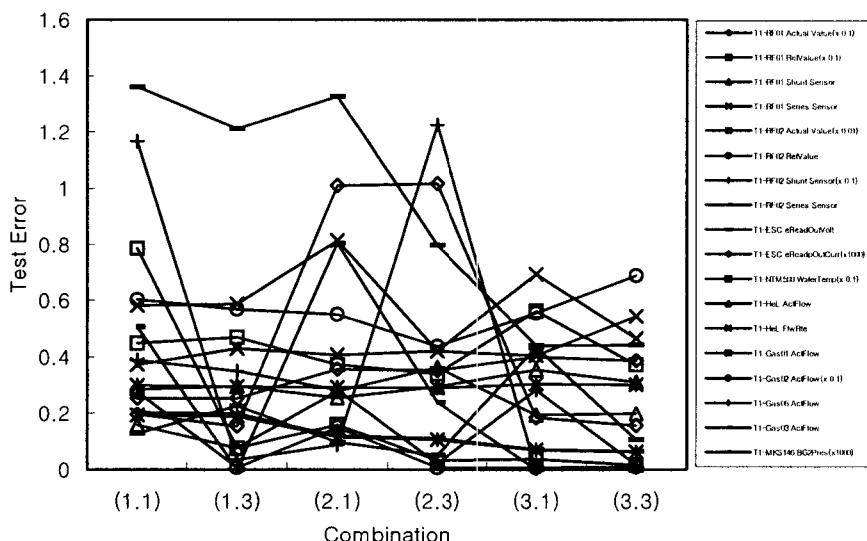


그림 3 WATS의 (m,k) 조합에 따른 예측 성능 변화

그림 3은 WATS모델의 조합에 따른 예측성능을 보이고 있다. 그림 2와 비교해보면 그래프의 형태가 약간 다르다는 것을 알 수 있다. 그래프의 형태는 비슷하지만 전체적으로 변화의 폭이 작다. 지그재그 형태의 그래프는 그림 2와 마찬가지로 $k=3$ 에서 비교적 작은 RMSE 값을 가진다. 그림 2와 비교하면 대체적으로 변화의 폭이 작고 (m,k)가 증가 할수록 RMSE 값이 작아지는 경향이 있다. 그림 2와 마찬가지로 gas 06 센서의 경우 (2,3)에서 RMSE가 갑자기 커진다는 것을 알 수 있다.

표 1은 최적 모델이 결정된 특정 조합, 해당 모델의 예측과 학습에러를 보이고 있다. 표 1에서와 같이 예측에러가 5% 미만인 경우는 4개의 센서에 지나지 않는다. 그렇다고 WATS 모델의 성능이 나쁘다고 단정할 수 없는데, 이는 센서 값들이 상대적으로 매우 다르다는 것에 기인한다. 즉 다른 센서에 비해 절대값이 크게 변하는 정보를 제공하는 센서에 대한 모델의 예측과 학습에러는 상대적으로 클 수 밖에 없다. 이러한 현실적인 문제점을 보완하기 위해 모든 종류의 센서 정보에 적용할 수 있는 메트릭 (Metric)이 요구되며, 본 연구에서는 이를 다음과 같이 정의했다.

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

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 에 표준편차 (SD)가 계산되어 있는데, 이는 센서정보의 변화 정도에 따라 센서들을 분류하기 위해 요구된다. M/SD 를 계산한 결과가 표 2에 나타나 있다. M/SD 값이 0.14를 기준으로 센서정보를 분류할 때, 0.14 이하에 해당하는 센서정보는 16개이며, 이들은 4 % 이하의 예측에러를 보이고 있다. 나머지 두 센서정보는 0.14 이상에 해당하며, 4 %보다 더 큰, 예컨대 'RF01RefValue' 16.22 %, 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. 한편, 이전에 발표한 연구 [5]와 비교해 볼 때, “HeL ActFlow”의 경우 그 % 에러는 2.58 정도였는데, 본 연구에서는 1.57 정도가 되어 시계열 모델의 성능이 크게 향상되었음을 알 수 있다. 다른 17개의 센서정보에 대한 개선도는 미미하였다. 이는 웨이브릿 시계열 모델이 경우에 따라서 보다 우수한 모델을 만드는데 기여할 수 있음을 의미한다.

결국, 특이 센서정보가 아닌 보통의 센서정보를 예측하는데 있어 WATS는 매우 우수한 예측성능을 보이고 있음을 본 연구를 통해 확인할 수 있었다.

표 1 최적 WATS 모델의 학습과 예측에러

센서	OC	예측 에러	학습에러
RF01 Actual Value	(1,3)	1.551562	10.11047
RF01 RefValue	(3,3)	0.167854	0.205131
RF01 Shunt Sensor	(2,1)	0.254485	0.199173
RF01 Series Sensor	(1,1)	0.3726	0.282119
RF02 Actual Value	(3,3)	6.242673	6.242673
RF02 RefValue	(2,3)	0.43856	0.335148
RF02 Shunt Sensor	(3,3)	0.158348	0.16682
RF02Series Sensor	(3,3)	0.065224	0.065224
ESC eReadOutVolt	(3,1)	0.439396	0.333807
ESC ReadpOutCurr	(1,1)	0.000253	0.000283
NTM500 WaferTemp	(2,3)	3.41768	0.739451
HeL ActFlow	(1,3)	0.076098	0.055088
HeL FlwRte	(2,3)	0.420505	0.27676
Gas01 ActFlow	(2,3)	0.290066	0.278894
Gas02 ActFlow	(2,3)	0.06429	0.064814
Gas06 ActFlow	(3,1)	0.000417	0.005781
Gas03 ActFlow	(3,1)	0.000351	0.005764
MKS146 BG2Pres	(2,3)	0.00005	0.000019

표 2 성능지표를 적용하여 계산된 WATS 모델의 예측성능

센서	M	SD	SD/M	RMSE /M (%)
RF01 Actual Value	3511.202	0.020853	5.93908E-06	0.044188
RF01 RefValue	1.0347	0.215081	0.207868	16.22248
RF01 Shunt Sensor	23.08974	0.223567	0.009683	1.102156
RF01 Series Sensor	60.37875	0.473506	0.007842	0.617105
RF02 Actual Value	4494.451	0.000368	8.18E-08	0.138897
RF02 RefValue	17.01924	1.731811	0.101756	2.576848
RF02 Shunt Sensor	40.96363	0.152381	0.00372	0.386557
RF02 Series Sensor	46.95937	2.63E-06	5.59E-08	0.138895
ESC eReadOut Volt	179.0102	0.001535	8.58E-06	0.245459
ESC eReadpOut Curr	0.00645	0.002333	0.361624	3.922425
NTM500 WaferTemp	370.642	4.144717	0.011183	0.922097
HeL ActFlow	4.851236	0.40407	0.083292	1.568631
HeL FlwRte	5.206896	0.727591	0.139736	8.075925
Gas01 ActFlow	299.6104	0.115198	0.000384	0.096814
Gas02 ActFlow	147.3728	0.00021	1.43E-06	0.043624
Gas06 ActFlow	32.30016	0.000328	1.01E-05	0.001291
Gas03 ActFlow	26.30175	3.4E-05	1.29E-06	0.001335
MKS146 BG2Pres	0.010171	7.04E-05	0.006925	0.491575

4. 결론

본 연구에서는 플라즈마 감시와 진단을 위한 WATS 신경망 모델을 개발하였다. 모델 성능은 과거와 미래정보 변수의 조합으로 평가하였다. 산업용 대용량 플라즈마 장비에서 수집한 데이터에 본 모델링 기법을 적용하였으며, 특히 센서 패턴을 제외하고는 예측 에러가 4 % 이하의 우수한 예측모델을 개발할 수 있었다. 특히, 특정 센서에 대해서는 제안한 모델이 상당히 우수한 예측 성능을 보였다. 본 모델링 기법은 반도체 플라즈마 장비 소프트웨어에 구현이 되어 플라즈마 공정의 감시와 진단 효율을 증진하는데 기여할 것이다.

후기

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, 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] 김유석, 김병환, 권기청, 한정훈, 손종원, 플라즈마 증착 장비 센서 정보의 신경망 시계열 모델링, 2006년 정보 및 제어 심포지엄 논문집, 99-101, 2006.
- [6] Kim and W. Choi, Using wavelet filtering for monitoring plasma conditions, *Solid State Technology*, vol. 44, no. 11, pp. 73-81, 2001.
- [7] B. Kim, W. Choi, and M. T. Lim, Wavelet monitoring of plasma etching, *Journal of Vacuum Science and Technology B*, vol. 21, no. 6, 2329-2333, 2003.
- [8] S. G. Mallat, "A theory for multiresolution signal decomposition: The wavelet representation," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 11, no. 7, 1989.
- [9] D. E. Rumelhart and J. L. McClelland: *Parallel Distributed Processing*. MIT Press, Cambridge (1986).