

적응 훈련 신경망을 이용한 플라즈마 식각 공정 수율 향상을 위한 공정 분석 및 예측 시스템 개발

최문규*, 김훈모**

Development of Process Analysis and Prediction System to Improve Yield in Plasma Etching Process Using Adaptively Trained Neural Network

Mun Kyu Choi*, Hun Mo Kim**

ABSTRACT

As the IC(Integrated Circuit) has been densified and complicated, it is required to thorough process control to improve yield. Experts, for this purpose, focused on the process analysis automation, which is came from the strict data management in semiconductor manufacturing.

In this paper, we presents the process analysis system that can analyze causes, for a output after processes. Also, the plasma etching process that highly affects yield among semiconductor process is modeled to predict a output before the process. To approach this problem, we use adaptively trained neural networks that exhibit superior accuracy over statistical techniques. And in comparison with methods in other paper, a method that history of trend for input data is considered is shown to offer advantage in both learning and prediction capability. This research regards CD(Critical Dimension) that is considerable in high integrated circuit as output variable of the prediction model.

Key Words : Semiconductor(반도체), Plasma Etching Process(플라즈마 식각 공정), Process Analysis System(공정 분석 시스템), Adaptively Trained Neural Network(적응 훈련 신경망)

1. 서론

현재 세계 반도체 회사들은 치열한 경쟁 속에서 자회사의 우위를 선점하기 위해 다른 어떤 회사보다 먼저 고집적 회로 기술을 개발함과 동시에 생산 자동화 시스템의 지속적인 개선을 통한 최고 품질, 최저 원가 및 적시 출하 달성을 목표로 하고 있다.

반도체는 하나의 완성된 제품으로 나오기 위해서는 사진, 식각, 확산, 에피택셜, 산화, 이온주입,

금속증착 그리고 화학기상증착과 같은 단위 공정들이 반복하여 400 ~ 500여 공정을 거쳐야 한다^{1,4)}. 따라서 현장에서는 이와 같은 선행 공정들에 영향을 받는 수많은 공정들을 적절히 관리함으로써 생산성을 향상시키고자 한다. 그러나 반도체 회로가 점점 미세해지고 복잡해짐에 따라 현재의 관리 수준 즉, 생산라인에서 집계되는 각종 1차 가공을 통한 통계 결과만이 시스템으로 처리되는 수준보다

* 성균관대학교 기계공학과 대학원

** 성균관대학교 기계공학부

좀더 임격한 공정 관리를 요구하게 되었다. 이에 따라 다른 어떤 제조 공정보다 복잡한 반도체 제조 공정을 잘 파악하고 예측할 수 있는 또한 전문가 수준의 정확하고 빠른 판단을 할 수 있는 예측·분석 시스템이 대두되었다. 이에 본 논문에서는 전 공정을 대상으로 공정 후 결과에 대한 신속한 원인 분석이 가능한 분석 시스템을 구축한다. 그런 후 이 시스템을 기반으로 반도체 공정 모델에서 기존의 통계적 모델^[1,2]을 통한 공정 제어보다 우수한 성능을 보이고 있는^[5,7,8] 적응 훈련 신경망을 이용하여 식각 공정을 모델링한다. 이때, 앞서 연구된 논문들은 신경망의 출력으로 식각률 그리고 선택도와 같은 웨이퍼에서의 화학적 효과에 대해 고려하였는데, 본 논문에서는 64M 이상의 고집적도 회로 패턴 식각에서 중요한 요소로 작용하고 있는 CD(Critical Dimension)을 출력 변수로 한다. 또한, 모델링하는데 있어 기존의 모델링 방법에 비해 훨씬 뛰어난 특성을 보이는, 모델의 입력측에 주요 변수의 데이터 이력이 반영될 수 있는 방법을 사용하였다^[6].

2. 식각 공정

식각 공정은 주로 사진 공정에서 마스크로부터 웨이퍼 표면 위의 감광막으로 패턴이 옮겨지고 난 다음에 이루어진다. 그래서 사진·식각으로 묶어 설명되는 경우가 많다. 사진 공정에서 감광액이 없는 부분이 식각의 대상이 된다. 식각의 방법은 크게 부식성 가스를 사용하는 건식과 화공약품을 쓰는 습식이 있다. 과거 집적도가 낮을 때는 습식이 주류였으나 집적도 향상과 함께 대부분의 식각은 건식이 주로 사용되고 있다. 건식, 습식 모두 그 개념상 차이는 없다. 감광액은 그대로 보존되거나 영향을 적게 주면서 감광액이 없는 부분의 아래에 있는 산화막이나 다결정 실리콘 또는 금속층을 깎아 버리는 것이다. 식각이 끝나면, 웨이퍼 위에 남아 있는 감광액은 쓸모가 없으므로 황산 같은 용액으로 제거한다.

반도체 제조 현장에서 수많은 공정들이 크게 두 가지 작업으로 분류되는데 첫째는 실제 반도체 제품을 생산하기 위해 각 공정의 설비를 통한 생산 공정이 행해지고, 둘째는 이러한 생산 공정 후 불량량의 유무를 체크하기 위한 계측 공정이 이루어진다. 식각 공정의 경우 공정이 잘 진행되었는지를

평가하기 위해 식각률, 균일성, 선택도 그리고 비등방성 등과 같은 웨이퍼의 화학적 특성이 조사된다. 그러나 본 논문에서는 고집적도 회로 패턴 식각에서 점점 중요한 요소로 작용하고 있는 임계치수(CD : Critical Dimension)를 고려하도록 한다. CD는 Fig. 1과 같이 polysilicon 패턴간 간격을 말하는 것으로 반도체 디바이스 설계시에 그 허용값과 허용오차가 정해지는 공정 출력 변수로서 식각층의 용도에 따라 허용간격은 달라진다.




Fig. 1 CD measurement

3. 공정 분석 시스템

공정 중에 오류가 발생할 경우 현재의 생산 설비 파라미터를 조율하거나 생산 자체를 중지시키는 일을 하게 되는데, 이때 그 오류의 원인이 된 생산 설비를 찾고 그 설비의 특정 파라미터를 밝혀 내는 과정이 현재 공정 엔지니어들에 의해 수동적으로 행해지고 있다. 따라서, 현장에서는 숙련된 엔지니어가 행하고 있는 공정의 불량 발생 원인 분석을 시스템화함으로써 누구나 쉽고 빠르게 그 상황에 대처할 수 있도록 노력하고 있다.

3.1 시스템 구성

공정 분석 시스템을 적용하기 위한 반도체 현장의 전체 시스템 개요는 Fig. 2와 같다. 여기에서 기존 시스템을 살펴보면 크게 두 부분으로 나뉘어져 있는데, 반도체 현장으로부터 올라오는 데이터 중 필요한 부분을 실시간으로 받아 들여 공정 감시가 이루어지도록 하는 부분과 현장의 모든 데이터를 보관하여 언제라도 필요할 때에 검색할 수 있도록 데이터베이스화시키는 부분으로 구성되어 있다. 이

때, 요구되는 공정 분석 시스템은 실시간으로 발생하는 알람성 데이터에 대한 분석과 엔지니어의 필요에 의한 조회용 데이터에 대한 분석을 위해 두 부분으로부터 정보를 모두 받아들인다. 현장의 알람 정보 혹은 클라이언트 프로그램을 통한 엔지니어의 조회 정보를 바탕으로 EDB(Engineering Data Base)의 raw data와 전문 엔지니어에 의해 작성된 기준 정보 테이블의 정보를 조합한 후, 결과 분석 알고리즘을 이용하여 알람 혹은 조회 데이터에 대한 분석 결과를 제시한다.

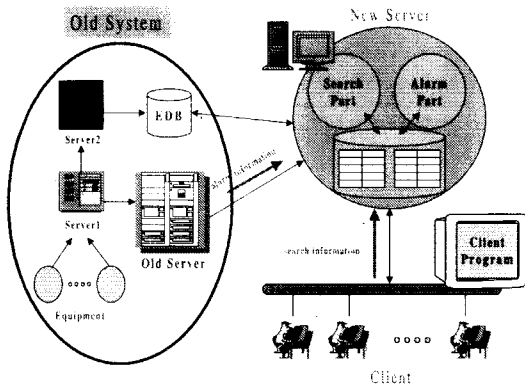


Fig. 2 System configuration

3.2 기준 정보 테이블

반도체 공정의 경우 한 공정에서 불량 발생하면, 그와 관련된 생산설비의 어떤 파라미터가 문제인지 뿐만 아니라, 그 보다 더 앞선 몇몇 공정의 파라미터들까지 분석하게 된다. 예를 들어, ADI(After Develop Inspection)-CD 공정의 파라미터 값들이 기준값을 벗어나지 않았으나, 그 다음 계측 공정인 ACI(After etching Inspection)-CD 공정의 파라미터 값이 기준값을 벗어날 경우, 바로 앞 생산 공정인 식각 공정의 설비 파라미터만을 조사하는 것이 아니라 한 공정 더 앞선 사진 공정의 설비 파라미터들까지 분석하게 된다. 이는 사진 공정 파라미터들의 미세한 변화가 그 공정 자체에는 아무런 문제를 주지 않으나, 그 다음 생산 공정인 식각 공정에서는 중대한 잘못의 원인이 될 수 있기 때문이다. 따라서, 불량 발생 공정에 대한 원인을 분석하기 위해 Table 1에서 보는 바와 같이 각 공정에서 중요한 파라미터들을 선정한 후 그들에 대한 특성값들을

공정 순서대로 정리한 테이블 즉, 기준 정보 테이블을 작성하였다. 이 테이블에서 불량발생공정은 웨이퍼의 불량 발생 공정으로, 분석의 대상이 되는 기준 공정이고, TRACE 공정은 이 기준 공정보다 앞선 공정들로 웨이퍼가 기준 공정 전까지 거처온 일정 공정 수의 생산 공정과 계측 공정을 나타낸다. ITEM은 각 공정에서 현장 엔지니어들이 특히 중요하게 생각하는 파라미터들로 이상현상이 발생했을 경우 제일 먼저 이들을 분석하게 된다. 또, WEIGHT는 이들 각 ITEM중에서도 그 공정에서 차지하는 중요도가 서로 틀린데 이러한 특징을 나타내는 것이다.

Table 1 Basic information table

불량발생 공정	TRACE 공정	ITEM	Max.	Target	Min.	WEIGHT
T0075	T0075	CD1	0.58	0.52	0.47	1
		CD3	0.56	0.51	0.46	1
	T0060	RET-ID				1
		EXP-T	+10	0	-10	2
		FOCUS	+0.2	0	-0.2	3
		TTLFC	+0.15	0	-0.15	4
	T0050	THK	1,677.50	1,525.00	1,372.50	1
T0110	T0110	CD1	0.56	0.51	0.45	1
		T0085	B	1,085.70	987.00	888.30
		C	9.90	9.00	8.10	2
		D	458.70	417.00	375.30	3
		E	1,092.30	993.00	893.70	4
		F	7.70	7.00	6.30	5
		G	273.90	249.00	224.10	6

3.3 공정 분석

현재 공정에서의 불량 발생이 어떤 요인에 의한 것인지를 파악하고, 제어하기 위해서는 앞서 살펴본 기준 정보 테이블을 바탕으로 아래와 같은 기준에 따라 분석하게 된다.

- ① 현재 공정에서 각 ITEM의 중요도
- ② 실제 ITEM값이 기준값을 벗어난 정도
- ③ TRACE 공정이 불량 발생 공정으로부터 떨어져있는 정도

위의 기준을 바탕으로 불량발생의 원인이 된 생산 공정 ITEM들을 다음과 같은 식에 기초해서 그 점검 우선 순위가 결정된다.

1) 동일 TRACE공정에서 점검 우선 순위

$$\text{점검 우선 순위} = \text{중요도} * \frac{|\text{실제ITEM값} - \text{Target}|}{|\text{Target} - \text{Min.}|}$$

이식은 동일한 level에서 즉, 같은 TRACE공정 안에서 우선 순위 결정에 관한 것이다. 이 식에서 |실제 ITEM값 - Target|에서 |Target - Min.|을 나눈것은 각각 단위가 틀린 ITEM들에 대해서 서로 비교할 수 있도록 한 일종의 정규화 과정이다. 특히 |Target - Min.|으로 나눔으로써 실제 ITEM값이 기준에서 몇 배 벗어났는가를 알 수 있다. 그리고, 이 정규화된 값에 엔지니어들이 정한 중요도를 다음과 같이 변환하여 곱해준다.

- 1 순위 - 10, 2 순위 - 9, ... , 10 순위 - 1

이때, 엔지니어들이 생각하기에 좀 더 중요한 값은 그 값을 크게 줄 수 있도록 한다.

2) 최종 점검 우선 순위

$$\text{최종 점검 우선 순위} = \text{점검 우선 순위} * \text{level 가중치}$$

여기서, level이란 불량발생 계측 공정에서 떨어진 정도를 의미하는데, 1 level 공정은 바로 이전 공정을 의미하고, 2 level 공정은 2단계 전 공정을 의미한다. 각각의 level 가중치는 다음과 같다.

- 1 level-1, 2 level-0.9, ... , 10 level-0.1

따라서, 위의 1, 2과정을 특정 불량발생공정에 대한 각 ITEM들에 대해 모두 계산한 후, 가장 큰 순서대로 즉, 가장 먼저 조치를 취해야할 순서대로 엔지니어에게 제시해준다.

4. 식각 공정 예측

앞서 제시된 공정 분석 시스템은 기존의 수동적인 방법에 비해 훨씬 빨리 알람 상황에 대처할 수 있게 해준다. 그러나, 이 역시 웨이퍼가 공정을 진행한 후 그에 대한 결과가 분석되기 때문에 어느 정도의 웨이퍼 손실은 감수해야 된다. 만일, 어떤 웨이퍼의 계측 공정 결과가 기준 한계선을 벗어났다면 즉, 불량이 발생하였다면, 이 특정 웨이퍼의 불량이 밝혀지기까지 뒤이어 진행된 모든 웨이퍼를 버려야 할지도 모른다. 따라서, 이러한 손실을 줄일 수 있는 공정제어를 달성하기 위해서는 반도체 공정을 모델링하여 미리 결과를 예측할 수 있는 시스템을 구축해야 된다.

4.1 식각 공정 모델 예측

기존의 반도체 공정 모델링에 대한 연구가 주로 식각 공정을 대상으로 하여 이루어져 왔는데, 이것은 반도체 단위 공정들 중에서도 특히 식각 공정이 제조 수율에 상당한 영향을 미치기 때문으로, 실제 한 예로 사진 공정의 경우 불량이 발생하면 웨이퍼 위의 감광액을 제거하고 처음부터 다시 진행하면 되지만, 식각 공정에서는 바로 웨이퍼 손실로 이어진다. 기존 식각 공정 모델은 실험실에서 각 식각 장비에 대한 설정 입력값을 부여하고, 그에 따른 식각이 얼마나 잘 되었는가에 관심을 두고 이루어졌으나, 본 논문에서는 실제 반도체 공정에서 진행된 데이터를 바탕으로 현장 엔지니어들이 특히 중요하게 생각하는 계측값에 대해 예측이 가능하도록 한다. 국내 모 반도체 회사의 SRAM 공정 중 플라즈마 식각 공정에 관련된 데이터를 제공받아 모델링을 수행한다. 여기서, 모델링을 위한 입력변수 즉, 식각 장비의 입력 파라미터로 온도, RF-Power, 압력, 식각 가스등이 있을 수 있으나, 데이터를 제공해주는 회사의 보안 유지 관계로 생산 현장에서 사용하는 용어(B, C, D, ...) 그대로 사용한다. 그리고, 모델링의 출력 변수로는 CD를 선택한다.

4.2 신경망을 이용한 예측 모델링

본 논문에서는 기존 연구를 통해 전통적인 통계적 방법에 비해 그 우수성이 입증된 적응 훈련 인공신경망^[9,10,11]을 이용하여 모델링을 수행하도록 한다. 여기서, 실제 공정에 가까운 모델을 구축하기

위해 데이터의 변동 추세를 고려한 방법을 제시하고, 이전 모델과의 비교를 통해 그 우수성을 입증하도록 한다.

4.2.1 CROSS 모델

반도체 공정의 모델링에 관한 기존 논문들은 입력들의 상호 연관 관계에 의해 출력을 예측할 수 있는 모델을 제시하였다. 이는 식각 공정이 이루어 지는데 있어, 결과에 가장 큰 영향을 미치는 원인으로 식각 장비의 여러 입력 요소 중 중요한 변수들을 선택하고, 그들 개개의 영향과 그들 서로간의 교차 효과를 고려한 것이다. 본 논문에서는 이렇게 구축된 모델을 'CROSS 모델'이라 한다. 이러한 모델을 구축하기 위해 현장에서 수집된 식각 공정 데이터 중 이상이 없는 37쌍의 시계열 입·출력 데이터를 선택하여, 앞선 30쌍의 데이터는 모델링을 위해 사용하고, 나머지 7쌍의 데이터를 가지고 구축된 모델의 예측 능력을 살펴보고자 한다. 식각 공정 모델의 주요 입력변수는 엔지니어가 가장 중요하게 여기는 B, C, D, E, F, G, H로 정하고, 출력변수는 CD로 한다. 데이터를 학습시키기 위해 신경망 기법 중 오류 역전파 학습 알고리즘에 모멘텀과 적응 학습률 방법을 첨가함으로써, 학습 시간을 줄이면서 최적의 모델이 탐색되도록 하였다. 이때, 모멘텀을 위한 모멘텀 상수는 0.9로 하였으며, 적응 학습률을 위한 에러율 1.05, 학습 증가율 1.04 그리고, 학습 감소율을 0.7로 하였다^[12]. 이를 통해 탐색된 최적의 모델은 입력층(7), 은닉층(12), 출력층(1)으로 구성되며, 30,000번의 iteration 후 최종 SSE(Sum Square Error)는 0.09이고, 그에 따른 비선




Fig. 3 Learning result of adaptively trained neural network CROSS model

형 근사는 Fig. 3과 같다. Fig. 4는 이렇게 구축된 신경망 모델에 대한 예측 능력을 나타내고 있다.

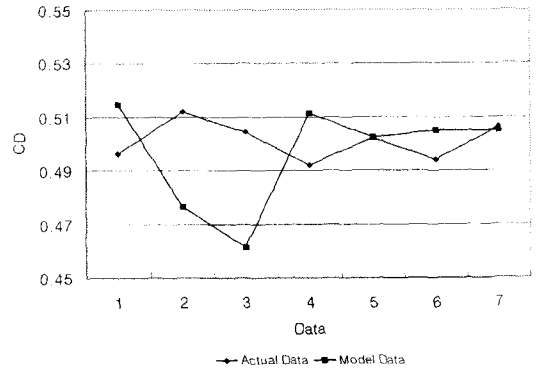


Fig. 4 Prediction result of adaptively trained neural network CROSS model

4.2.2 CROSS + AUTO 모델

앞서 살펴보았듯이 입력변수간의 연관관계만으로 복잡한 식각 공정을 표현하는에는 한계가 있으므로, 본 논문에서는 입력변수의 상호 연관관계 뿐 아니라 식각 공정이 진행됨에 따라 반응실의 내부 혹은 외부의 환경 변화에 따른 입력변수의 변동 추세가 공정 모델에 반영되도록 하는 방법을 제시한다. 이때, 이를 'CROSS + AUTO 모델'이라 한다. 즉, 시간에 따른 입력 데이터의 변동이 심한 주요 입력변수에 대해, 현재의 입·출력 데이터 시점을 t 라고 하고, 한 단계 이전의 데이터 시점을 $t - T$, 두 단계 이전의 시점을 $t - 2T$ 라고 한다면, 변수의 변동 추세가 모델에 포함될 수 있도록 5 시점의 데이터를 모델의 입력으로 제시한다. 따라서, 엔지니어가 선정된 주요 입력변수 중 데이터의 변동이 심한 D, E, F 변수에 대해 $D(t)$, $D(t-T)$, $D(t-2T)$, $D(t-3T)$, $D(t-4T)$, $E(t)$, $E(t-T)$, $E(t-2T)$, $E(t-3T)$, $E(t-4T)$, $F(t)$, $F(t-T)$, $F(t-2T)$, $F(t-3T)$, $F(t-4T)$ 데이터가 모델의 입력에 추가 되도록 한다. 이에 따라 식각 공정 모델을 위한 총 입력변수는 $B(t)$, $C(t)$, $G(t)$, $H(t)$ 를 포함하여 19개 된다. 출력변수는 $CD(t)$ 로 하고, 모델 형성을 위해 26쌍의 입·출력 데이터와 예측 성능을 평가하기 위한 7쌍의 데이터를 사용하였다. 신경망 모델은 Fig. 5와 같이 입력층(19), 은닉층(24), 출력층(1)으로 구성하였고, 이를 통해 30,000번의

iteration 후 SSE가 0.00012521이 되었다. 이렇게 수행된 인공신경망의 비선형 근사는 Fig. 6과 같고, 7쌍의 시계열 데이터에 대한 예측 능력은 Fig. 7에서 살펴 볼 수 있다. Fig. 8에서 두 모델에 대한 예측 능력을 비교하고 있다. 이와 같은 결과의 정리 즉, Table 2를 통해 CROSS + AUTO 모델의 학습 능력과 예측 능력에 대한 우수성을 입증할 수 있는데, 여기서 절대 에러의 평균이 기준 한계값의 범위보다 훨씬 작은 것을 볼 수 있다. 따라서, 본 논문에서는 실제 식각 공정을 모델링하는데 있어, 주요 입력 변수의 상호 연관 효과와 시간에 따른 데이터의 변동 추세를 모두 고려함으로써 보다 우수한 모델을 구현하였다.




Fig. 5 Adaptively trained neural network CROSS + AUTO architecture

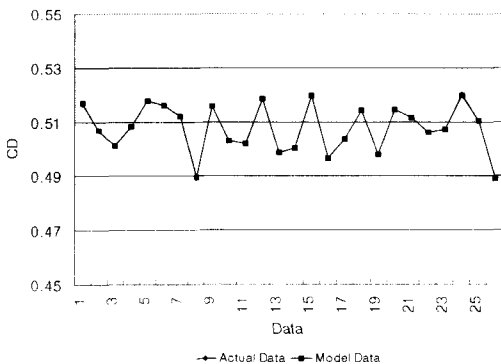


Fig. 6 Learning result of adaptively trained neural network CROSS + AUTO model




Fig. 7 Prediction result of adaptively trained neural network CROSS + AUTO model




Fig. 8 Comparison of prediction result's absolute error

Table 2 Comparison of the two models

	CROSS	CROSS + AUTO
Architecture	7-12-1	19-24-1
Iteration Number	30,000	30,000
Learning SSE	0.09	0.0001251
Prediction SSE	0.826825	0.597128
Range of Control Limit	0.0265	0.0265
Mean of Absolute Error	0.01843	0.007494

5. 적용 사례

5.1 공정 분석 시스템

개발된 시스템이 실제 현장에 적용된 예가 다음과 같다. 시스템의 초기화면을 통해 정보를 입력받거나 혹은 불량률이 발생할 경우 그에 대한 이전 공정들의 각 파라미터들에 대한 영향 정도를 조사한다. 이에 대한 결과 화면이 Fig. 9와 같다. 이 결과에서 T1990.01 공정의 THK 파라미터에 가장 크게 영향을 미친 요인이 바로 이전 생산 공정인 T1983.01에서의 DE_N2FLOW112 파라미터로 나타났다. Fig. 10과 같이 입력 정보 혹은 알람 정보와 관련된 raw data들에 대한 차트를 보여줌으로써 엔지니어들이 좀더 쉽게 분석할 수 있도록 도와준다.

5.2 시각 공정 예측

모델을 통해 예측된 ACI-CD값이 만일 기준 한계선을 벗어날 경우, 시스템이 어떤 분석 결과를 제시할지 다음의 예를 통해 살펴본다. 먼저, 이를 위해 주요 입력변수의 값으로 Table 3과 같은 범위로 300쌍의 랜덤 데이터를 생성한다. 이때, 선정된 입력 변수값을 인공신경망에 의해 구축된 CROSS + AUTO 모델의 입력으로 제시하여 Fig. 11과 같은 예측된 ACI-CD 값을 얻는다. 여기서, 예측된 2개의 결과(사각형 표시)가 기준 하한선(LCL : Low Control Limit)을 벗어남으로써 신속한 공정 제어가 요구되어짐을 알 수 있다.




Fig. 10 Chart screen of process analysis system

Table 3 Random input range

	Max.	Min.
B	996	976
C	6.2	5.8
D	417	413
E	995	985
F	5.3	4.8
G	250	245
H	9.5	8.5

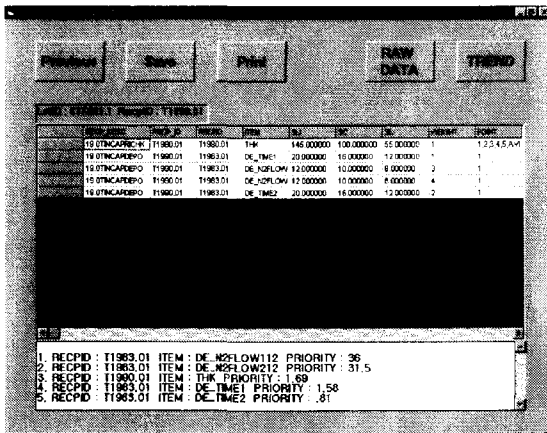


Fig. 9 Analysis result screen of process analysis system




Fig. 11 Prediction result by random input

6. 결론

반도체 제조 현장에서 불량 발생률을 줄이기 위하여, 본 논문에서는 전 공정을 대상으로 공정 분석 시스템을 개발하였다. 또한, 인공신경망을 이용하여 플라즈마 식각 공정을 모델링하는데 있어, 기존의 모델과 새로운 모델을 비교·분석하여 보았다.

1) 공정 분석 시스템을 개발함으로써, 불량 발생에 대한 기존의 수동적 원인 분석을 자동화하여 긴급 상황에 대한 신속한 대처가 이루어질 수 있도록 하였다.

2) 인공신경망을 이용하여 식각 공정을 모델링함으로써 불량이 알려지기까지 몇 시간이 걸리던 문제를 미리 예측하도록 함으로써, 많은 양의 웨이퍼 손실을 감소시킬 수 있었다.

3) 공정 모델링에서, 주요 입력 변수들의 상호 연관 관계와 입력 변수들의 시간에 따른 변동 추세를 고려함으로써 학습 능력 면에서나 예측 능력 면에서 월등히 우수한 모델을 구축하였다.

향후 연구 과제는 다음과 같다.

1) 본 연구에서는 인공신경망을 이용한 모델링을 플라즈마 식각 공정에 국한하였으나, 공정 분석 시스템과의 유연한 연동을 위하여 다른 공정으로의 확대 적용에 대한 연구가 필요하다.

2) 모델을 통해 예측된 이탈 결과에 대한 원인이 분석될 수 있는 알고리즘이 구현되어야 하겠다.

3) 각 생산 설비의 이력 정보 및 각종 환경 변수들에 대한 정보를 공정 분석 시스템과 식각 공정 모델에 연동시킴으로써 불량 발생 원인에 대한 보다 정확하고 자세한 분석이 제시되어야 하겠다.

참고문헌

- Paul E. Riley and David A. Hanson, "Study of Etch Rate Characteristics of SF₆/He Plasmas by Response-Surface Methodology: Effects of Interelectrode Spacing," IEEE Trans. Semiconductor Manufact., Vol. 2, No. 4, Nov. 1989.
- Gary S. May, Jiahua Huang and Costas J. Spanos, "Statistical Experimental Design in Plasma Etch Modeling," IEEE Trans. Semiconductor Manufact., Vol. 4, No. 2, May. 1991.
- 전자 자료사 편집부, "반도체(공정 및 측정)," 전자 자료사, 1996.
- 정항근, 최진영, 한길희, "집적회로 설계를 위한 반도체 소자 및 공정," 홍릉출판사, 1997.
- Edward A. Rietman and Earl R. Lory, "Use of Neural Networks in Modeling Semiconductor Manufacturing Process: An Example for Plasma Etch Modelig," IEEE Trans. Semiconductor Manufact., Vol. 6, No. 4, Nov. 1993.
- Michael D. Baker, Christopher D. Himmel, and Gary S. May, "Time Series Modeling of Reactive Ion Etching Using Neural Networks," IEEE Trans. Semiconductor Manufact., Vol. 8, No. 1, Feb. 1995.
- Fariborz Nadi, Alice M. Agogino, and David A. Hodges, "Use of Influence Diagrams and Neural Networks in Modeling Semiconductor Manufacturing Process," IEEE Trans. Semiconductor Manufact., Vol. 4, No. 1, Feb. 1991.
- Christopher D. Himmel and Gary S. May, "Advantages of Plasma Etch Modeling Using Neural Networks Over Statistical Techniques," IEEE Trans. Semiconductor Manufact., Vol. 6, No. 2, May 1993.
- LiMin Fu, "Neural Networks In Computer Intelligence," McGrawHill, 1994.
- Nikola K. Kasabov, "Foundations of Neural Networks, Fuzzy System, and Knowledge Engineering," A Bradford Book, 1996.
- Robert Hecht-Nielsen, "Neurocomputing," Addison Wesley, 1991.
- Matlab. Neural Network Toolbox. Math. Works.