

# 반도체 공정 실시간 자동 진단 시스템

권오범 한혜정<sup>0</sup> 김계영

숭실대학교 컴퓨터학과

(xanado, hyej113<sup>0</sup>)@vision.ssu.ac.kr, gykim@computing.ssu.ac.kr

## A Real-Time Automatic Diagnosis System for Semiconductor Process

O-bum Kwon, Hye-jeong Han<sup>0</sup>, Gye-young Kim

Dept. of Computing, Soongsil University

### 요약

일반적으로 사용되는 반도체 공정에 대한 진단 기법은 한 공정을 진행하기 전에 테스트 공정을 수행하여 공정의 결과를 예측하는 방법이다. 본 논문에서 제안하는 실시간 자동 진단 시스템은 기존 방법의 문제점인 자원의 낭비를 막고, 실시간으로 진단함으로써 시간의 낭비를 막는 진단 시스템을 제안한다. 실시간 자동 진단 시스템은 크게 시스템 초기화 단계, 학습 단계 그리고 예측 단계로 나누어진다. 초기화 단계는 진단할 공정에 대한 사전 입력값을 받아 시스템을 초기화하는 과정으로 공정장비 파라미터별 중요도 자동 설정 과정과 초기화 클러스터링으로 이루어진다. 학습 단계는 실시간으로 저장된 공정장치별 데이터와 계측기로부터 획득된 데이터를 이용하여 최적의 유사 클래스를 결정하는 단계와 결정된 유사 클래스를 이용하여 가중치를 학습하는 단계로 나누어진다. 예측 단계는 공정 진행 중 획득된 실시간 데이터를 학습 단계에서 결정된 파라미터별 가중치를 사용하여 공정에 대한 진단을 한다. 본 시스템에서 사용하는 클러스터링 알고리즘은 DTW(Dynamic Time Warping)를 이용하여 파라미터 데이터에 대한 특징을 추출하고 LBG(Linde, Buzo and Gray) 알고리즘을 사용하여 데이터를 군집화 한다.

### 1. 서론

최근 반도체 제조회사들은 인수 및 합병으로 인해 반도체 제조에 대한 관심이 증폭되고 있다. 국내 반도체 제조회사가 이러한 상황 속에서 살아남을 수 있는 이유는 반도체 제조과정에서 발생하는 오류를 최소화하여 반도체 제조비용을 최소화했기 때문이다. 이러한 비용 최소화에 대한 문제를 해결하기 위해서 사용되는 방법 중 하나가 반도체 제조 공정 진단 시스템이다. 반도체 제조 공정 진단 시스템이란 반도체 제조 공정의 성공 여부를 판단하는 시스템이다. 현재 가장 많이 사용되고 있는 공정 진단 방법은 실제 공정을 수행하기 전후에 테스트 공정을 수행한 후 계측기를 사용하여 공정이 올바르게 진행되었는지를 판단하여 실제 공정의 진행 여부를 결정하는 것이다. 이러한 방법은 반복적인 테스트 공정으로 발생하는 자원의 낭비와 계측과정을 통해 해당 시간만큼 생산시간이 증가하는 생산성 낭비를 초래한다. 또한 하나의 대표 웨이퍼를 통해 전체를 평가하므로 그 신뢰성에 문제가 있으며, 고가의 검사 장비 도입과 그에 따른 인력 및 생산라인 내 공간 증가, 전체적인 비용증가의 문제를 초래 한다. 그리고 공정진행 후 테스트 공정의 결과가 올바르지 않다고 판단될 경우 원인 파악이 불가능하며, 공정 진행의 단계별 특성 반영이 전혀 이루어지지 않는다. 본 논문에서는 이와 같은 문제점을 보완하고 공정 장치별로 발생되는 파라미터 정보를 실시간으로 감시하여 진단을 내리는 공정 장비 실시간 자동 진단 시스템을 다음과 같이 제안하고자 한다. 첫째, 공정장비로부터 획득되는 데이터를 실시간으로 감시하여 그 결과를 예측하는 기법을 제안한다. 둘째, 공정 장비의 각 파라미터별 가중치를 달리하여 장비별 특성을 반영한 진단 기법을 제안한다.

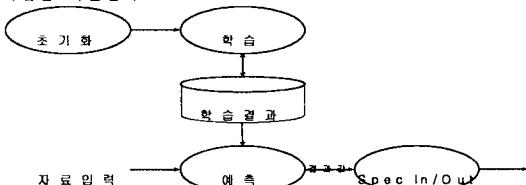


그림 1 전체 시스템 구조도

그림 1은 본 논문에서 제안하는 반도체 제조 공정 자동 진단 시스템에 대한 전체 구조도이다. 초기화 단계는 진단할 공정에 대한 사전 입력값을 받아 공정 종류에 맞는 시스템으로 초기화하는 과정으로 공정장비 파라미터별 중요도 자동설정 과정 그리고 초기화 클러스터링으로 이루어진다. 초기화 클러스터링은 DTW를 이용한 특징추출과 LBG 알고리즘을 사용한 파라미터별 클러스터링으로 구성된다. 학습 단계는 실시간으로 공정 진단을 하기 위하여 테스트 공정으로부터 획득된 데이터와 계측기로부터 획득된 결과 데이터를 사용하여 예측에 사용될 가중치를 학습하는 단계로써, 가중치 학습을 위한 최적의 유사 클래스를 결정하는 단계와 결정된 유사 클래스를 이용하여 가중치를 학습하는 단계로 나누어진다. 예측 단계는 공정 진행 중 획득된 실시간 공정 데이터를 학습 단계에서 결정된 파라미터별 가중치를 사용하여 실시간으로 공정에 대한 진단을 한다.

### 2. 시스템 초기화

본 시스템의 초기화는 진단할 공정에 대한 초기화 값(Initial Data)을 입력받는 공정 종류에 맞는 학습 및 예측을 할 수 있는 시스템으로 초기화하는 입력단계와 공정장비 파라미터별 중요도를 자동으로 설정하는 단계, 초기화 클러스터링을 하는 단계 그리고 초기 데이터를 저장하는 단계로 이루어진다.

시스템 초기화 단계에서 입력되는 초기화 값은 공정 종류(Recipe No.), 유효 단계 정보(Valid Step Info.), 파라미터 정보(Parameter Info.)로 이루어져 있는데, 공정 종류란 반도체 제조 공정중 구체적으로 어떤 공정인지를 나타내는 숫자 값이다. 유효 단계란 공정의 진행 단계 중 실제 공정 결과에 영향을 미치는 유효한 단계를 말한다.

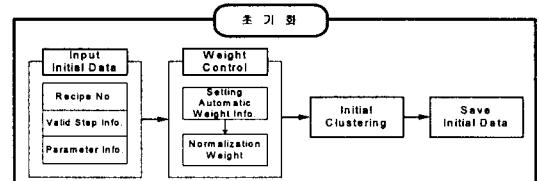


그림 2 시스템 초기화 단계

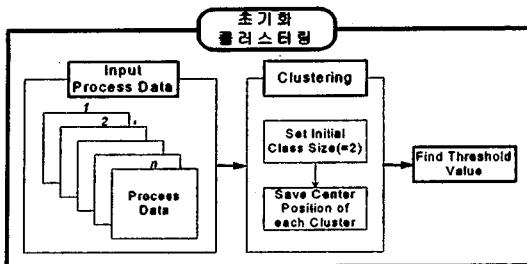


그림 3 초기화 클러스터링 구조도

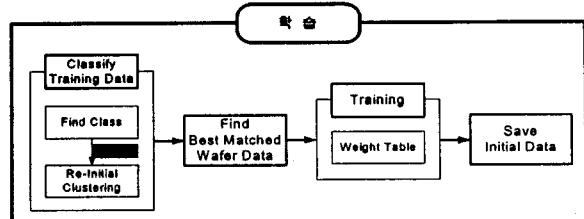


그림 4 학습단계

| 학습패턴 # | Parameter 1의 Class # | Parameter 2의 Class # | ... | 결과값  |
|--------|----------------------|----------------------|-----|------|
| 1      | 2                    | 3                    | ... | 9.07 |
| 2      | 3                    | 4                    | ... | 9.14 |
| 3      | 2                    | 2                    | ... | 9.18 |

표 1 학습패턴

그림 4은 이러한 학습 과정을 나타내고 있다. 학습 단계는 유사한 표본들끼리의 군집화를 목적으로 하는데, 그 결과는 각 파라미터 내 클래스별 군집 중심값을 가지며 표 1과 같은 패턴을 저장하게 된다. 그림 4에서 보듯이 훈련 데이터를 클러스터링 하는 과정은 클래스를 결정하는 부분과 재초기화 클러스터링을 수행하는 부분으로 나뉘어진다. 클래스를 결정하는 방법은 계측 데이터 클러스터링 알고리즘과 동일한 방법을 사용하지만 파라미터마다 클러스터링 과정을 수행하는 중에 각 군집의 임계값을 벗어나는 위치에 새로운 파라미터 데이터의 위치가 결정될 경우, 재초기화 과정(추가된 파라미터 데이터를 포함한 데이터에 대해 초기화 클러스터링 과정을 다시 수행하는 과정)을 수행하게 된다. 훈련데이터가 입력되면 학습된 데이터 중에서 가장 유사한 데이터를 찾아내서 가중치를 학습하는 과정을 거치게 되는데, 이때 반도체 공정 장비의 파라미터 개수가 대단히 많기 때문에 웨이퍼 데이터 클래스는 수많은 종류를 가질 수 있으며 더욱 복잡하게 이루어진다. 이와 같이 학습을 수행하기 위해서 항상 같은 클래스를 가지는 훈련데이터가 존재할 확률이 대단히 낮기 때문에 훈련 데이터와 훈련 데이터간의 최적의 유사성을 가지는 훈련 데이터를 결정하는 알고리즘이 요구된다. 최적의 유사 클래스를 결정하는 방법은 본 시스템이 클러스터링을 하기 위한 특징벡터를 찾아내는데 사용하는 알고리즘이 DTW이기 때문에 두 패턴간의 유사도 정보를 알 수 있으므로 웨이퍼 데이터와의 유사도가 가장 높은 데이터로 결정한다.  $i$ 번째 파라미터 데이터에서의 유사도를  $P_i(i)$ 라고 하고,  $i$ 번째 파라미터의 가중치를  $w(i)$ 라고 했을 때, 웨이퍼 데이터와의 유사도( $W_s$ )는 식 (1)과 같이 표현할 수 있다.

$$W_s = \sum_{i=1}^n (P_i(i) \times w(i)) \quad (1)$$

최초 학습 단계에서 사용되는 가중치는 사전 가중치 값을 사용하여 정규화한 값을 사용한다. 가중치 학습은 정규화된 가중치를 구할 때와 같은 방법으로 구한 정규화된 가중치 차이값을 가중치에다가 더하거나 빼주는 방법을 사용한 가중치 리스트를 만드는 단계와 이것이의 반복적인 학습으로 이루어진다. 가중치 분류 레벨을  $n$ 이라 하면 총 가중치 리스트는  $2n+1$ 개가 생성될 것이다. 훈련 데이터 학습 단계에서는 생성된 가중치 리스트들을 사용하여 4장에서 설명한 예측 결과값 계산 방법과 같은 방법으로 훈련 데이터에 대한 예측 결과값을 계산한다. 계산된 결과값은 훈련 데이터에 있는 실측 결과값과 비교하여 가장 차이가 적은 가중치 리스트를 선택하는데 이를 대학습단계마다 반복적으로 수행하며 시스템 초기화 단계에서 가중치 학습 횟수를 미리 정하여 준다.

### 4. 실시간 예측

본 시스템의 예측 단계는 반복적인 학습 단계의 수행결과를 근거

로 반도체 공정 진단의 결과값을 예측하는 단계로 예측 데이터를 분류하는 단계, 훈련 데이터 중에서 가장 유사한 웨이퍼 데이터를 찾는 단계, 공정 진단의 근거가 되는 공정 결과값을 예측하는 단계로 이루어진다. 예측 과정은 반도체 생산성의 향상을 위하여 실시간으로 수행되며, 그림 5는 이러한 실시간 예측 과정을 나타내고 있다. 훈련 데이터의 군집화 과정과는 달리 예측 데이터에 대한 군집화 과정은 예측 파라미터 데이터의 특징 벡터값의 위치가 학습 파라미터 데이터 군집 중에 속하지 않더라도 그 클래스를 결정해야만 한다. 그래서 입력된 데이터와 각 파라미터별로 기준 데이터와 DTW를 수행하여 특징 벡터값을 결정한 다음 각 군집의 중심과 거리가 가장 가까운 군집의 클래스를 예측 파라미터 데이터의 클래스로 결정하게 된다. 파라미터별로 클러스터링 과정을 수행한 후, 예측 웨이퍼 데이터의 클래스도 다른 웨이퍼 데이터의 클러스터링 과정과 마찬가지로 파라미터 데이터의 클래스 코드 시리즈로 클래스 정보를 가진다.

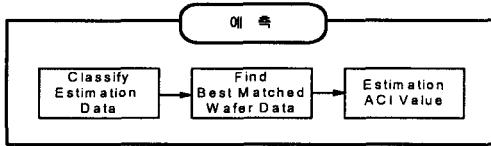


그림 5 예측 단계

예측 과정에서는 학습된 가중치 정보를 사용한다. 예측 데이터와 가장 유사한 클래스를 가지는 훈련 데이터를 검색하는 방법은 3절과 마찬가지의 방법으로 찾는다. 반도체 공정 중 예정공정은 진단 근거로 ACI(After Clean Inspection) 값이 사용되는데, 이처럼 공정마다 진단의 근거가 되는 결과값이 존재한다. 계측기로부터 측정된 훈련 데이터의 결과값을  $R_e$ 라 하면 예측한 결과값  $R_p$ 는 식 (2)로 표현할 수 있다.

$$R_p = \sum_{i=0}^n (P_i \times D(i) \times w(i)) \quad (2)$$

이 때,  $D(i)$ 는  $i$ 번째 파라미터의 훈련 파라미터 데이터 패턴과 예측 파라미터 데이터 패턴을 DTW 알고리즘을 수행하여 획득된 두 패턴의 차이값의 정도를 의미한다.  $w(i)$ 는 4.3절에서 설명한 선택된 가중치 리스트에서  $i$ 번째 파라미터의 가중치이다. 예를 들어 참조 패턴보다 입력 패턴이 두 배를 경우  $D(i)$ 는 2.0의 값을 가지며 같은 경우 1.0의 값을 가진다. 그리고 두 배 작을 경우  $D(i)$ 는 -2.0의 값을 가진다.

## 5. 실험 및 결과

실험은 팬티엄 III 1.2GHz 칩이 장착된 PC에서 수행하였다. 운영체제로는 MS Windows XP Professional을 메모리는 512MB를 사용하였다. MS Visual C++ 6.0을 사용하였다.

실험 데이터는 예정 공정 장비로부터 파라미터 데이터를 획득하였고, 계측기로부터 ACI 데이터를 획득하였다. 샘플링 간격은 1초로 하였으며, 입력 데이터는 파라미터 데이터와 ACI 데이터로 구성되어 있으며, 예측 데이터는 파라미터 데이터를 사용하였다. 예측 결과인 출력 값은 예정 공정의 결과값인 ACI값으로 하였으며, 실제 실시간 실험을 할 수 있는 관계로 실험 데이터의 형태는 MDB 파일 형태로 하였다. 학습 방법은 오프라인 형태로 적용되었으며, 학습에 대한 사용자의 선택적 권한을 고려하였다. 기본적으로 본 시스템에는 파라미터의 개수는 제약이 없으며, 이번 실험에서는 훈련 데이터의 형태는 총 15단계의 훈련 데이터 군을 사용하였고, 17개의 파라미터를 사용하였고 파라미터별로 유효 단계 정보를 사용하였다. 평가에 사용된 예측 데이터가 실제 계측기로부터 측정된 ACI 값이 없다는 가정 하에 파라미터 데이터만을 사용하여 학습량의 증가에 따른 예측 ACI 값과 실제 ACI 값의 차이가 어떻게 변화하는지를 평가 방법으로 사용하였다. 실험에 사용된 예측 데이터는 총 7개이며, 실험은 주요 파라미터만을 사용한 경우, 가중치 정보의 변경을 통한 평가, 주요 단계만을 사용한 경우에 대하여 평가하였다.

그림 6은 7개의 테스트 공정 데이터를 실험 데이터로 사용한 경우 3개의 테스트 공정에 대하여 학습횟수가 증가함에 따라 예측 ACI 값과 차이값이 어떻게 변화하는지를 보여준다. 그림 6에서 보듯이 학습 초기에는 학습량이 부족하여 유사패턴을 찾는데 실패한 경우를 나타내는데, 학습량이 어느 정도 증가하면 그림과 같은 큰 오차를 나타내지는 않음을 알 수 있다.

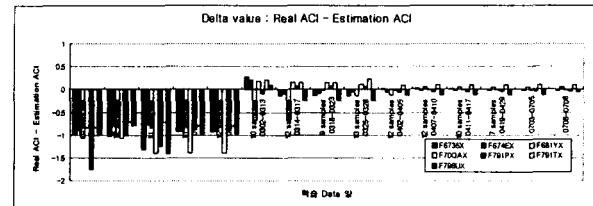


그림 6 실측 ACI값과 예측 ACI값의 차

## 6. 결 론

본 논문에서는 반도체 공정 실시간 자동 진단 시스템을 제안하였다. 시스템은 모두 세 개의 단계로 이루어져 있는데, 시스템 초기화 단계, 학습 단계, 예측 단계로 나누어진다.

시스템 초기화 단계에서는 진단할 공정에 대한 사전 입력값을 받아 시스템을 초기화하는데, 사전 입력값 중에서 시스템의 전체 결과에 큰 영향을 미칠 수 있는 유효 단계와 가중치 정보가 적절해야 함을 알 수 있었다. 학습 단계에서는 실시간으로 저장된 공정 장치별 데이터와 계측기로부터 획득된 데이터를 이용하여 가중치를 학습하는 단계인데, 학습량이 많을수록 좀더 정확한 결과값을 예측한다는 것은 본 시스템에 사용한 클러스터링 알고리즘이 여러 개의 클래스로 이루어진 클래스 시리즈의 유사패턴을 찾아내는데 적당함을 알 수 있었다. 반도체 예정 공정 자동 진단 시스템으로 실험해 본 결과는 학습량의 증가에 따라 보다 정확한 결과값을 예측하고 있음을 알 수 있었으며 사용자의 임의적인 가중치 변경은 학습과 예측에 대한 오류를 가질 수 있음을 보여주었다. 그리고 경험적으로 획득 가능한 공정 장비의 파라미터별 주요 단계 정보도 중요하게 선택되어야 할 수 있었다.

향후 연구 과제로는 진단결과 오류가 있음을 나타내는 데이터에 대한 실험을 통한 연구와 여러 개의 결과 값을 가지는 공정에 대한 확장에 관한 연구가 필요하다.

## 참 고 문 헌

- [1] D. Rafiei and A. Mendelzon, "Similarity-based queries for time series data", SIGMOD Record (ACM Special Interest Group on Management of Data), 26(2), pp.13-25, May 1997.
- [2] C. Faloutsos, M. Ranganathan, and Y. Manolopoulos, "Fast subsequence matching in time-series databases", In Proc. of the ACM SIGMOD Conference on Management of Data, May 1994.
- [3] Guoqing Chen, Qiang Wei, Hong Zhang, "Discovering similar time-series patterns with fuzzy clustering and DTW method", IFSA World Congress and 20th NAFIPS International Conference, Vol. 4, pp.2160-2164, 2001.
- [4] K.J. McLaughlin, T.F. Edgar, I. Trachtenberg, "Real-time monitoring and control in plasma etching", IEEE Control Systems Magazine, Vol. 11, Issue 3, pp.3-10, April 1991.
- [5] Earl Gose, Richard Johnsonbaugh, Steve Jost, Pattern Recognition and Image Analysis, Prentice Hall, 1996.
- [6] Richard O. Duda, Peter E. Hart, David G. Stork, Pattern Classification, Wiley-Interscience, 2001.
- [7] Michael C. Fairhurst, Computer Vision For Robotic Systems An Introduction, Prentice Hall, 1988.
- [8] 김상운, 패턴인식 입문, 홍릉과학출판사, 1997.