

다중 시계열 패턴인식을 이용한 반도체 생산장치의 지능형 감시시스템

이 중재[†]·권 오범^{††}·김 계영^{†††}

요약

본 논문에서는 다중 시계열 패턴인식 사용하여 생산장치의 상태자료부터 공정결과를 예측하여 정상 또는 비정상을 판정하는 지능형 감시시스템에 관하여 기술한다. 제안하는 감시시스템은 초기화, 학습 그리고 인식의 세 단계로 구성된다. 초기화 단계에서는 감시대상의 생산장치가 가지는 인자들 각각의 가중치와 각 인자들이 가지는 시계열 자료 중에서 학습과 인식에 유효한 단계를 설정한다. 학습단계에서는 LBG 알고리즘을 사용하여 이 생산장치에 의하여 생성되고 수집된 패턴들을 군집화 한다. 각 패턴은 시계열 형태의 자료와 처리 완료 후 계측기에 의하여 측정된 ACI로 구성된다. 인식단계에서는 DTW를 사용하여 실시간으로 입력된 패턴과 군집화된 패턴들 사이의 대응을 수행하여 가장 잘 정합되는 패턴을 찾는다. 그 다음은 이 패턴이 가지는 ACI, 차 그리고 가중치들의 조합으로 예측된 ACI 값을 산출한다. 최종적으로 예측된 ACI가 정상으로 수용할 수 있는 값 범위에 있는지 여부를 결정한다. 제안하는 시스템의 성능평가를 위하여 식각장치로부터 획득된 자료를 대상으로 실험하였다. 실험결과에서는 학습횟수가 증가함에 따라 예측 ACI값과 실제 ACI값 사이의 오차가 현저히 감소함을 볼 수 있다.

An Intelligent Monitoring System of Semiconductor Processing Equipment using Multiple Time-Series Pattern Recognition

JoongJae Lee[†]·OBum Kwon^{††}·Gye-Young Kim^{†††}

ABSTRACT

This paper describes an intelligent real-time monitoring system of a semiconductor processing equipment, which determines normal or not for a wafer in processing, using multiple time-series pattern recognition. The proposed system consists of three phases, initialization, learning and real-time prediction. The initialization phase sets the weights and the effective steps for all parameters of a monitoring equipment. The learning phase clusters time series patterns, which are produced and gathered for processing wafers by the equipment, using LBG algorithm. Each pattern has an ACI which is measured by a tester at the end of a process. The real-time prediction phase corresponds a time series entered by real-time with the clustered patterns using Dynamic Time Warping, and finds the best matched pattern. Then it calculates a predicted ACI from a combination of the ACI, the difference and the weights. Finally, it determines Spec in or out for the wafer. The proposed system is tested on the data acquired from etching device. The results show that the error between the estimated ACI and the actual measurement ACI is remarkably reduced according to the number of learning increases.

키워드 : 반도체(Semiconductor), 생산장치(Processing Equipment), 감시시스템(Monitoring System), 패턴인식(Pattern Recognition), DTW(Dynamic Time Warping), LBG(Linde-Buzo-Gray), 군집화(Clustering)

1. 서론

20세기의 최고의 발명은 반도체 칩(chip)이라 할 수 있는데, 처음 발명된 이후 발전에 발전에 거듭하여 최근에는 컴퓨터 뿐만 아니라 가전제품을 포함하여 거의 모든 제품에 반도체 소자가 사용되고 있다. 다양하고 많은 수요에 부응하고자 반도체를 생산하는 수많은 회사가 있다. 최근에는

기억장치 부분의 공급이 수요를 초과하면 원가절감을 통한 경제적인 경쟁력을 향상하기 위하여 전력하고 있다. 중공업이나 기계 등의 다른 산업 보다 반도체 산업은 생산성 즉, 동일한 시간에 더 많은 수의 웨이퍼를 더 높은 수율로 생산하는 것이 곧 경쟁력이다. 본 논문에서는 반도체 산업의 생산성을 향상하기 위한 실시간 감시시스템을 지능화하는 방법에 관하여 기술한다.

주 기억장치 또는 중앙처리장치 등과 같이 목적하는 기능의 역할을 수행할 수 있는 칩들로 구성된 웨이퍼(wafer)는 수십의 공정(process)과 각 공정마다 정확성 검사를 통하여

* 본 연구는 숭실대학교 교내연구비 지원으로 이루어졌다.

† 준희원 : 숭실대학교 대학원 컴퓨터학과

†† 준희원 : (주) 임프 연구원

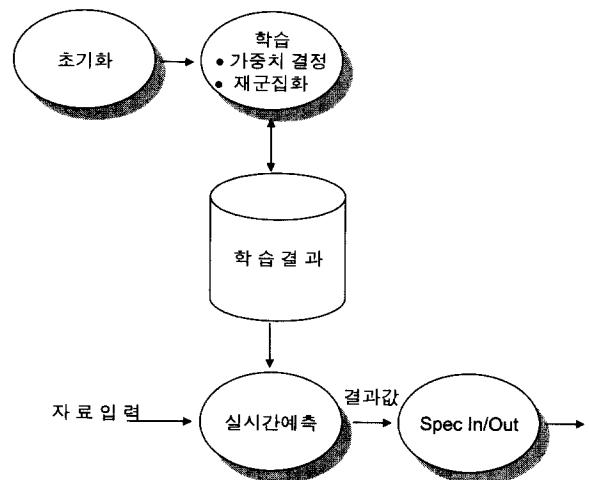
††† 종신회원 : 숭실대학교 컴퓨터학부 교수

논문접수 : 2003년 10월 24일, 심사완료 : 2004년 3월 2일

생산된다. 효율적인 관리를 위하여 공정 하나를 수행할 때, 통상적으로 50개의 웨이퍼로 구성된 레시피(recipe) 단위로 처리한다. 하나의 레시피에 대하여 공정을 수행하는 일반적인 방법은 다음과 같다. 실제공정을 수행하기 전에, 레시피 중에서 하나의 웨이퍼를 임의로 선택하여 시험 공정을 수행한 후, 계측기를 사용하여 처리의 정확성을 측정한다. 측정된 정확도가 만족하지 않는 경우는 공정장치의 인자값들을 재조정 후 다시 처리하지만, 만족하는 경우는 나머지 웨이퍼들 모두에 대하여 현재 상태로 처리를 계속 수행한다 다음, 임의로 선택된 하나의 웨이퍼에 대한 정확도를 계측기를 사용하여 측정한다. 이때, 측정된 정확도가 만족하는 경우는 다음 공정단계로 넘어가지만, 만족하지 않을 경우는 모든 웨이퍼를 폐기처분한 후, 처음부터 다시 수행한다. 이 방법은 계측기를 사용하여 정확성을 검사하는 동안에는 생산장치가 처리를 중단하므로 낮은 생산성과 하나의 표본 웨이퍼를 통해 전체를 평가하므로 낮은 신뢰성 그리고 고가의 검사 장비 도입과 그에 따른 인력 및 공간의 필요로 인하여 높은 생산비용을 요구되는 단점이 있다. 또한, 모든 공정을 완료한 후에 수행하는 최종 검사 단계에서 오류가 발견되는 경우, 원인 파악이 어려운 치명적인 문제가 있다. 이와 같은 문제와 단점을 해결하기 위하여 고안된 방법 중에서 하나는 생산장치의 실시간 감시시스템이다[1].

반도체 생산장치의 실시간 감시시스템의 대표적인 접근 방법에는 실시간 계측에 의한 방법[2,3], 예측 모델에 의한 방법[4], 그리고 패턴인식에 의한 방법[5,6]이 있다. 첫 번째 방법은 생산장치가 웨이퍼를 가공하는 처리와 가공된 정도를 화학 또는 광학적으로 측정하는 작업을 병행하는 방법이다. 이 방법은 모든 생산장치에 대하여 측정장치를 병합하여 하므로 생산원가를 증가시키는 단점이 있다. 두 번째 방법은 처리를 위한 인자들과 계측값 사이의 관계를 함수로 표현한 다음, 입력되는 인자값으로 부터 계측값을 예측하는 방법이다. 이 방법은 두 인자들 사이의 관계를 정의하는 함수를 정확히 표현하는 것이 어려운 문제점이 있다. 세 번째 방법은 사전에 수집된 계측값과 이때의 상태자료들을 인공신경망[7]과 같은 패턴인식 모델에 학습시킨 후, 입력된 상태자료와 학습된 상태자료와 비교하여 가장 유사한 상태자료가 가지는 계측값 출력하는 방법이다. 학계에 보고된 대표적인 방법은 최근접 이웃(Nearest neighbor)에 의한 방법[5]과 인공신경망에 의한 방법[6]이 있다. 이 두 방법 모두 특정한 인자값이 정의된 범위 밖으로 벗어나는 것을 감시하는 시스템이므로 모든 인자들에 의하여 만들어지는 최종 ACI(After Clean Inspection)를 예측하지 못하는

단점이 있다. 본 논문에서는 특정한 공정장치가 가지는 인자들의 상태자료를 조합하여 최종 ACI를 예측하여 정상 여부를 판단하는 지능적인 실시간 감시시스템을 제안한다. 제안하는 시스템의 개요도 (그림 1)과 같이 초기화, 학습, 그리고 예측 모듈로 구성된다.



(그림 1) 제안하는 시스템 개요도

초기화는 감시할 공정장치에 대한 초기화 자료를 입력받아 공정 종류에 맞는 시스템으로 초기화하는 모듈로 학습용 자료를 파일에서 읽어오는 기능, 공정장치가 가지는 인자들 각각의 중요도와 유효단계를 설정하는 기능, 그리고 임계값들을 입력하는 기능으로 이루어진다.

학습은 LBG(Linde, Buzo, and Gray)[8] 알고리즘을 사용한 인자별 군집화 즉, 군집의 수와 각 군집의 대표값을 생성하는 모듈이다. 이때, 두 시계열 패턴의 유사도를 산출하기 위하여 본 논문에서는 DTW(Dynamic Time Warping)[9]를 사용한다.

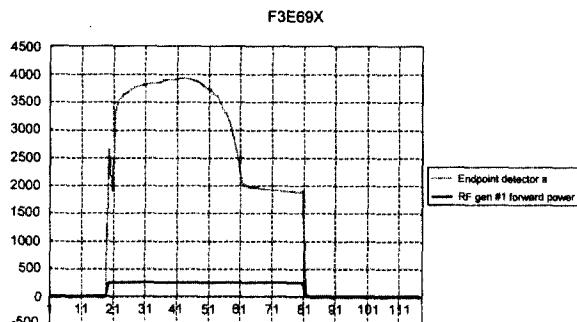
실시간 예측은 공정장치가 처리를 수행하는 동안에 획득되는 상태자료를 실시간으로 입력받아 학습된 자료에 근거하여 계측기로 측정할 경우 예측되는 측정값을 산출하는 모듈이다. 최종적으로 실시간 예측 모듈에 의하여 산출된 예측값이 사전에 정의된 범위 내에 존재하는지 여부를 조사하여 정상유무를 결정한다.

본 논문의 구성은 다음과 같다. 제2장에서는 초기화에 관하여 기술한다. 제3장과 제4장에서는 DTW를 사용하여 두 시계열 패턴의 유사도를 측정하는 방법과 변형 LBG를 사용하여 군집화는 방법에 대하여 각각 설명한다. 그리고 제5장에서는 실험결과 및 성능평가를 보인후, 마지막 제6장에서는 결론 및 향후 연구에 관하여 논술한다.

2. 반도체 공정장치 감시시스템의 초기화

초기화는 감시할 공정장치에 대한 초기 자료를 입력받아 공정 종류에 맞게 학습과 예측을 수행할 수 있는 모듈로 주요기능 유효구간을 설정하는 기능과 인자들 각각의 중요도를 설정하는 기능과 가중치 최적화를 수행하는 기능으로 이루어진다. 물론 가장 먼저 수행해야 할 작업은 감시할 공정종류를 의미하는 웨이퍼 번호를 입력하여야 한다.

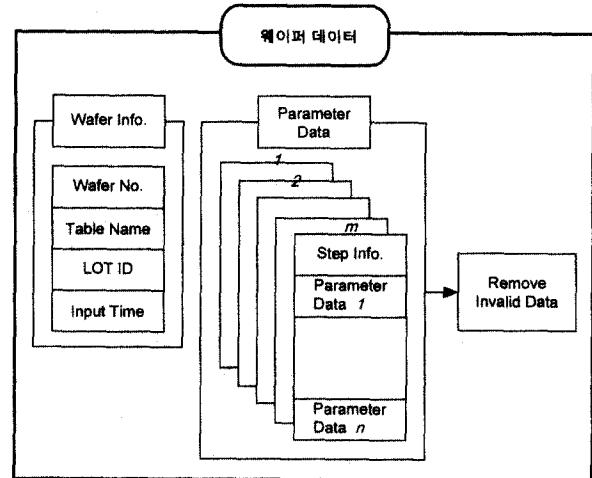
따라서, 초기화 단계에서 입력되는 자료은 공정종류 번호, 유효단계 자료, 인자정보이다. 여기서, 공정종류 번호는 앞에서 언급한 바와 같이 다수의 반도체 생산 공정들 중에서 특정한 하나의 공정을 구분하기 위하여 코드화한 숫자값이다. 유효단계란 공정의 처리 단계들 중에서 공정결과에 영향을 미치는 의미있는 자료들의 연속이다. 인자정보는 감시시스템에서 적용할 인자의 수와 각 인자별 가중치이다. 유효구간을 설정하는 방법과 가중치를 조절하는 방법을 설명하기 전에 본 논문에서 기술하는 감시시스템에 대한 용이한 이해를 위하여 먼저 반도체 생산장치의 특성과 입력되는 웨이퍼 자료구조에 대하여 설명한다.



(그림 2) 식각장치가 가지는 주요 인자들의 상태자료의 예

반도체 생산장치의 특성을 보여주는 (그림 2)는 생산공정 중에서 식각(etching)을 수행하는 장치가 가지는 인자(parameter)들 중에서 중요한 인자 2개에 대한 상태자료를 그림으로 나타낸 것이며 이때의 ACI는 9.789이다. 이 장치는 약 400 종류의 인자들이 있으며, 웨이퍼를 처리하는 동안에는 매초마다 상태자료를 출력하여 관리시스템의 데이터베이스에 저장되거나 폐기되는 것이 일반적이다. (그림 2)에 나타나는 또 다른 하나의 특징은 단계(step)의 구분이 있으며, 매 단계의 시작과 끝 부분에서는 인자들의 상태자료가 불안정하다. 하나의 공정이 성공 또는 실패는 웨이퍼를 처리한 후, 계측기를 사용하여 측정한 값이 정의된 범위에 내에 존재여부(spec in/out)에 따라 결정된다. 이 때, 계측기를 사용하여 측정한 값을 ACI라 한다.

그리고 본 논문에서 사용하는 웨이퍼를 위한 자료구조는 (그림 3)과 같으며 이를 웨이퍼 자료구조라 한다. (그림 3)에서 무효자료(Invalid Data)란 단계가 전환될 때, 각 단계의 앞부분과 끝부분의 상태자료를 의미한다. 각 단계의 앞부분과 끝부분에는 실제 공정에 영향을 미치지 않는 잡음이 존재할 가능성이 높기 때문에 정확한 예측을 위하여 감시시스템의 처리과정에는 이들을 삭제하여 한다. 여기서, 유효자료의 범위는 공정 운용자에 의해서 경험적으로 결정된다.



(그림 3) 웨이퍼의 자료구조

인자의 초기 가중치를 결정하는 방법은 다음과 같다. 먼저, 사용자는 각 인자의 중요도를 상대적인 등급을 숫자로 입력한다. 예를 들어, 인자의 중요도를 3종류로 나누고자 하는 경우 매우 중요한 인자는 3을, 그 다음 2를, 또는 중요도가 가장 낮은 경우는 1로 입력한다. 입력된 중요도를 참조하여 감시시스템에서 사용하는 가중치는 식 (1)을 통하여 산출된다. 식 (1)에서 n 은 중요도가 설정된 인자의 수이고, $L(i)$ 는 i 번째 인자의 중요도이다.

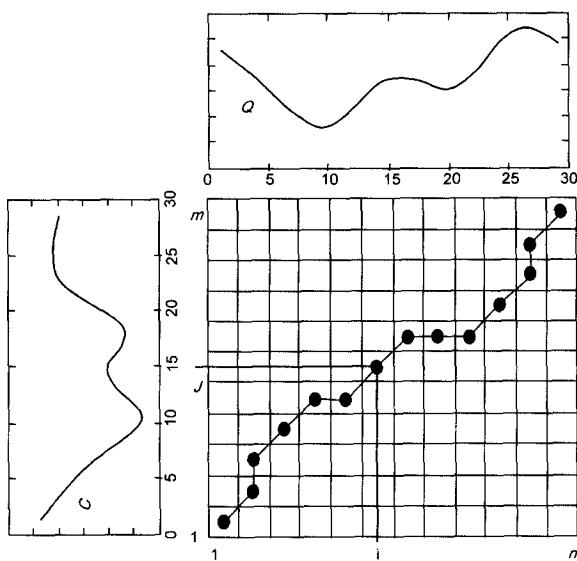
$$w(i) = L(i) \sum_{i=1}^n L(i) \quad (1)$$

3. DTW에 의한 유사도 측정

본 논문에서 사용하는 자료의 형태는 동일한 시간간격마다 변하는 시계열 패턴이다. 따라서, 군집화와 예측을 위하여 두 개의 시계열 패턴 즉, 참조패턴(reference pattern)과 대응패턴(corresponding pattern) 사이의 유사도를 산출하여야 하는데, 패턴의 길이와 위치가 일정하지 않으므로 본 논문에서는 DTW(Dynamic Time Warping)를 사용하여

유사도를 측정한다.

참조패턴과 대응패턴을 각각 $Q = q_1, q_2, \dots, q_n$ 와 $C = c_1, c_2, \dots, c_m$ 라 할 때, DTW 알고리즘을 사용하여 비선형적인 대응관계로부터 유사도를 산출하는 방법은 식 (2)와 같다. 식 (2)의 결과는 정규화되어 있지 않으므로 길이에 따라 유사도가 서로 다르므로 이를 방지하기 위하여 최종적으로 식 (3)과 같이 정규화된 유사도를 사용한다. 엄격한 의미에서 식 (3)의 결과는 유사성이 클수록 적은 값을 가지므로 비유사도(dissimilarity)라 하여야 한다.



(그림 4) 비선형적으로 대응경로를 찾은 예

$$\begin{aligned} \gamma(i, j) &= d(q_i, c_j) + \min\{\gamma(i-1, j-1), \\ &\quad \gamma(i-1, j), \gamma(i, j-1)\} \end{aligned} \quad (2)$$

여기서, $\sqrt{d(q_i, c_j)} = (q_i - c_j)^2$

$$D(R, C) = \gamma(n, m)/n \quad (3)$$

식 (2)는 다음과 같이 DTW 알고리즘이 가지는 제약사항에 근거하여 형성된 것이다. 첫째는 끝점 정렬(end-point alignment) 즉, 참조패턴의 첫 번째 자료는 대응패턴의 첫 번째 자료와 반드시 대응되며, 마지막 자료도 역시 다른 패턴의 마지막 자료와 반드시 대응되어야 하는 조건이다. 둘째는 연속성(continuity)로 인접한 셀로만 이동할 수 있는 조건이다. 셋째는 단조성(monotonicity)으로 시간축을 따라서 증가하여야 하는 조건이다. (그림 4)는 DTW를 통하여 비선형적으로 형성되는 대응관계를 보인 것이다.

지금까지는 길이가 다른 시계열 패턴의 유사도를 산출하는 방법에 관하여 설명하였다. 다음 절에서는 군집화에 관

하여 설명한다.

4. 변형 LBG에 의한 군집화와 ACI 예측

예측단계에서는 기본적으로 실시간으로 입력된 상태자료와 학습 단계에서 수집한 자료와 비교하여 유사도가 큰 시계열 패턴이 가지는 ACI를 선택한 다음 오차의 정도를 산출한다. 이때, 학습자료가 많은 경우는 가장 큰 유사도를 가지는 패턴을 찾는데 너무 많은 계산시간이 소요되는 문제점이 있다. 따라서, 유사한 특성을 가지는 시계열 패턴들을 하나의 집단으로 분류하고 그 집단의 대표를 선택하는 군집화를 수행하여야 한다. 군집화를 위하여 본 논문에서는 LBG 알고리즘 사용한다. LBG 알고리즘의 처리 과정은 K-평균(mean)과 유사하다. 차이점은 군집의 대표를 선택하는 방법 즉, K-평균은 군집을 이루는 패턴들의 평균을 그 군집의 대표로 결정하는 반면, LBG는 군집에 속하는 패턴들 까지 거리의 평균을 최소로 하는 패턴을 그 군집의 대표로 결정한다. 본 논문의 목적은 일반적인 패턴인식 즉, 학습된 자료 중에서 유사도가 가장 큰 패턴의 식별자를 출력하는 것이 아니라 그 패턴이 가지는 ACI와 오차를 출력하는 것이다. 따라서, 군집에 속하는 시계열 패턴의 각 자료들을 평균하는 것은 ACI 역시도 평균하여야 하는데, 이것은 유사한 시계열 패턴은 유사한 ACI 값을 가진다는 조건하에서 성립된다. 불행히도 본 논문에서 취급하는 패턴은 그 형태가 유사하여도 ACI 값이 유사한 것은 아니다. 따라서, 주어진 자료들을 가능한 변경하지 않는 방법으로 군집의 대표를 산출하여야 하므로 본 논문에서는 (알고리즘 I)과 같이 LBG 알고리즘을 약간 변형한 알고리즘을 사용하여 군집화를 수행한다.

<변형 LBG에 의한 시계열 패턴의 군집화>

- Step 1. 자료 입력 : 군집화를 위하여 초기값을 다음과 같이 설정한다.
 1. 2개 이상의 학습용 시계열 패턴들을 입력한다.
 2. 원하는 초기 군집의 수 $K(=2)$ 를 입력한다.
 3. 군집의 최대거리 D 를 입력한다.
- Step 2. 중심 선택 : 각 군집을 대표하는 패턴을 임의로 선택한다.
- Step 3. 왜곡도 설정 : 초기 왜곡도 TD'에 상당히 큰 값을 할당한다.
- Step 4. $TD = TD'$.
- Step 5. 유사도 계산 : 모든 학습용 시계열 패턴 각각에 대하여 다음을 수행한다.
 1. DTW를 사용하여 각 시계열 패턴과 선택된 중심들과 각각 대응경로를 찾는다.
 2. 비유사도와 대응하는 두 자료의 차의 표준편차를 산출한다.
 3. 두 개의 특징에 의한 산출된 거리를 중에서 가장 적은 것을 찾는다.
 4. if (가장 적은 거리가 D 보다 적다) 이 군집에 현재 처리중인 패턴을 할당한다.
 5. else 군집의 수 K 를 1 증가시키고, 현재의 패턴을 새로운 군집의 중심으로 설정한다.

- Step 6. 중심 재선택 : 모든 군집 각각에 대하여 다음을 수행한다.
1. 중심에 속하는 패턴들 사이의 거리를 최소로 하는 Si 패턴을 찾는다.
 2. 군집의 중심을 이 패턴으로 변경한다.
 3. 이때의 거리를 왜곡도 D(Si)에 저장한다.
- Step 7. 왜곡도 산출 : K개의 군집이 가지는 D(Si)를 통하여 왜곡도 TD'에 할당한다.
- Step 8. if(|TD - TD'| > 0에 가까운 매우 적은 값) GoTo Step 5.
- Step 9. 각 군집의 중심 시계열 패턴을 저장한다.

(알고리즘 I)

앞서 언급한 바와 같이 하나의 공정장치가 웨이퍼를 처리하는 중에는 다수의 인자들에 대한 상태자료를 매초마다 생성한다. 이 자료를 본 논문에서는 웨이퍼 상태자료라 하였다. 다수의 웨이퍼 상태자료에 대한 군집화는 인자마다 별도로 이루어진다. 따라서, (알고리즘 I)은 각 인자에 독립적으로 적용된다.

예측단계에서는 학습된 웨이퍼 상태자료 중에서 입력된 웨이퍼 상태자료와 가장 유사한 웨이퍼 상태자료를 찾는 과정을 포함하고 있다. 그런데, 인자마다 독립적으로 군집화를 수행하므로 예측단계에서 인자마다 가장 유사한 상태자료를 선택함에 의하여 찾은 웨이퍼 상태자료는 하나의 웨이퍼를 위한 것이 아니라 여러 개의 웨이퍼 상태자료를 조합한 자료가 되는 문제가 있다. 이 문제를 해결하기 위하여 본 논문에서는 먼저, 학습을 위한 웨이퍼 상태자료를 식 (4)와 같이 각 인자가 속하는 군집의 번호들로 표현한다. 군집의 번호는 각 인자별로 다음과 같이 산출된다. 즉, (알고리즘 I)의 군집화에 의하여 생성된 군집의 중심들 각각과 하나의 학습용 자료와의 비유사도와 차의 표준편차를 DTW를 사용하여 산출한 다음, 이 두 특징에 의하여 산출되는 거리가 가장 적은 군집을 선택함으로써 결정된다.

$$\text{ClassListOfWafer}_i = \{C_{i1}, C_{i2}, \dots, C_{in}\} \quad (4)$$

학습 과정을 통하여 산출되는 정보는 인자별 군집의 수와 각 군집의 중심패턴 그리고 학습용으로 입력된 웨이퍼 상태자료 모두에 대하여 식 (4)와 같은 군집의 번호를 나열한 코드열이다. 효과적으로 이 코드열을 저장하고 검색하기 위하여 본 논문에서는 해싱(hashing)을 사용하였다.

실시간으로 입력되는 상태자료에 근거하여 현재 진행중인 공정의 정상유무를 판단하기 위하여 먼저 학습된 자료를 참조하여 예측값을 산출하여 하는데 그 과정은 다음과 같다. 입력된 상태자료를 코드열로 표현한다. 즉, 각 인자별로 거리가 가장 가까운 군집의 번호를 산출한다. 그 다음은 코드화된 학습용 패턴에서 이 코드열과 동일한 패턴을 선택한 후, 식 (5)와 같이 예측치를 산출한다. 산출된 예측치

의 최대와 최소 모두가 사전에 정의된 범위내에 있으면 정상이고 그렇지 않으면 비정상으로 판정한다.

$$P_V = I_V \pm \sum_{i=1}^N (I_V \times D(i) \times W(i)) \quad (5)$$

식 (5)에서, $P(v)$ 는 예측값을, $I(v)$ 는 코드열이 동일한 학습패턴이 가지는 ACI 즉, 측정값을 각각 의미한다. 그리고, $D(i)$ 와 $W(i)$ 는 i 번째 인자의 비유사도와 가중치를 각각 나타낸 것이다.

5. 실험 및 결과

실험은 펜티엄 III 1.2GHz 칩과 MS WindowsXP를 탑재한 PC에서 수행하였으며, 구현을 위하여 사용한 언어는 MS Visual C++이다. 실험을 위한 자료는 쇠각장치로 부터 획득하였고, 계측기로부터는 ACI 자료를 획득하였다. 따라서, 제안하는 감시시스템을 학습할 때 입력되는 자료는 인자의 시계열 자료와 ACI 자료로 구성되지만, 예측할 때는 인자의 시계열 자료만을 사용하였다. 예측 결과인 출력값은 식각공정의 결과값인 ACI값으로 하였으며, 실제 실시간 실험을 할 수 없는 관계로 실험 자료의 형태는 파일 형태로 하였다. 훈련을 위하여 사용된 자료는 15개의 훈련자료군이다. 각 자료군은 18개의 인자 각각에 대하여 8단계로 구성된 시계열 자료이다. 각 인자의 시계열 자료에 대한 유효단계는 초기화 단계에서 사용자에 의하여 설정된다.

평가에 사용된 예측 자료가 실제 계측기로부터 측정된 ACI 값이 없다는 가정하에 인자들의 상태정보만을 사용하여 학습량의 증가에 따른 예측 ACI 값과 실제 ACI 값의 차이가 어떻게 변화하는지를 평가 방법으로 사용하였다. 실험에 사용된 예측 자료는 총 7개이며, 실험은 주요 인자만을 사용한 경우, 가중치 정보의 변경을 통한 평가, 주요 단계만을 사용한 경우에 대하여 평가하였다.

주요 인자만을 사용한 경우는 전체 18개의 인자 중에서 약 5개의 주요 인자만을 추출하여 학습량 증가와 예측 ACI 값의 정확도 향상을 평가하였으며, 가중치 정보의 변경을 통한 평가는 초기 학습시 각 인자별 가중치 순위의 초기값을 변경하여 가중치를 임의로 변경한 경우 가중치의 적합성에 관한 평가를 하였다. 주요 단계만을 사용한 평가는 총 8개 단계 중에서 공정결과와 밀접한 관련이 있는 단계와 판단되는 3단계와 4단계 자료만을 사용하여 평가하였다.

<표 1>은 7개의 실험자료 F6735X, F674EX, F681YX, F70QAX, F791PX, F791TX, F796UX에 대한 실험결과 중에서 3개의 공정에 대하여 학습 횟수가 증가함에 따라 예

측 ACI 값 그리고 실측 ACI값과의 차이값이 변화하는 것을 보여준다. (그림 5)는 <표 1>에서 차이값이 변화하는 형태를 그림으로 나타낸 것이다. (그림 5)의 결과에 따르면 초기에는 학습량이 부족하여 유사패턴을 찾는데 실패한 경우를 나타내는데, 학습량이 어느 정도 증가하면 그림과 같은 큰 오차를 나타내지는 않음을 알 수 있다.

우가 발생함을 알 수 있다. 이것은 초기화 과정에서 권고되는 가중치 중요도 정보를 사용자가 임의로 변경하여 실험한 경우이다. 따라서, 입력되는 가중치 순위 정보가 적절하지 않을 경우 공정 결과 예측에 나쁜 영향을 미침을 알 수 있다.

(그림 6)은 주요 인자만을 사용하여 평가한 경우를 보여주는데, (그림 5)와 마찬가지로 학습을 진행함에 따라 ACI 차이값이 점차 감소함을 알 수 있다. 따라서, 몇 개의 주요 인자가 ACI 값에 큰 영향을 미치는 것으로 판단된다.

(그림 7)은 가중치 순위 정보의 변경을 통해 평가한 경우를 보여주는데, 학습량이 증가함에도 오차값이 증가하는 경

(그림 8)은 주요 단계 정보만을 사용한 평가를 보여주는 데, 학습량의 증가에 따라 어느 정도는 정확성이 증가함을 알 수 있다. 하지만 현재 실험은 모든 인자의 유효단계가 단계 3과 4인 점을 생각하면 인자별로 좀더 정확한 유효단계 정보가 요구되는 것으로 판단된다.

마지막으로 (그림 9)는 사용자의 선택적 입력이 요구되는 경우를 보여주는데, 그림의 가운데 부분에 큰 오차가 발생한 경우가 있다. 이것은 예측 자료로 사용한 정보가 올바른 것임에도 훈련 자료에 유사한 패턴이 존재하지 않기 때문에 발생하는 것으로 판단된다. 결국 이러한 예측 자료에 대해서는 공정 운용자가 선택적으로 학습을 시키는 과정이 필요함을 알 수 있다.

임의적인 가중치 변경은 학습과 예측에 대한 오류를 가질 수 있음을 보여주었다. 그리고 경험적으로 획득 가능한 공정 장치의 인자별 주요 단계 정보도 중요하게 선택되어야 함을 알 수 있었다. 향후 연구과제로는 진단결과에 오류가 있음을 나타내는 자료에 대한 실험을 통한 연구와 여러 개의 결과값을 가지는 공정에 대한 확장에 관한 연구가 필요하다.

참 고 문 헌

5. 결 론

본 논문에서는 패턴인식 기술을 사용하여 생산장치의 상태자료부터 공정결과를 예측하여 정상 또는 비정상을 판정하는 지능형 감시시스템을 제안하였다. 본 논문에서 제안한 시스템은 시스템 초기화 단계에서 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. 또한 학습 단계는 실시간으로 저장된 공정 장치별 자료와 계측기로부터 획득된 자료를 이용하여 군집화하는 단계인데, 학습량이 많을수록 좀더 정확한 결과값을 예측한다는 것은 본 논문에서 사용한 군집화 알고리즘이 여러 개의 클래스로 이루어진 클래스 시리즈의 유사패턴을 찾아내는데 적당함을 알 수 있었다.

반도체 식각장치에 대하여 실험해 본 결과는 학습량의 증가에 따라 보다 정확한 결과값을 예측하였으며 사용자의

- [1] Suttipan Limanond, Jennie Si and Kostas Tsakalis, "Monitoring and control of semiconductor manufacturing processes," IEEE Control System Magazine, Vol.8, No.6, pp.46-58, December, 1998.
- [2] Sylvie Bosch-Charenay, Jiazhan Xu, John Haigis, Peter A. Resenthal, Peter %R. Solomon, and James M. Bustillo, "Real-time etch-depth measurements of MEMS devices," Journal of Microelectromechanical systems, Vol.110, No.2, pp.111-117, April, 2002.
- [3] T. J. Knight, D. W. Greve, X. Cheng and B. H. Krogh, "Real-time multivariable control of PECVD silicon nitride film properties," IEEE Transaction on Semiconductor Manufacture, Vol.10, No.1, pp.137-145, February, 1997.
- [4] T. L. Vincent, P. P. Khargonekar and F. L. Terry, Jr., "An extended Kalman filtering-based method of processing reflectometry data for fast In-Situ Rate Measurements," IEEE Transaction on Semiconductor Manufacture, Vol.10, No.1, pp.137-145, February, 1997.
- [5] P. J. O'Sullivan, J. Martinez, J. Durham and S. Felker, "Using UPM for real-time multivariate modeling of semiconductor manufacturing equipment," SEMATECH APC/AEC Workshop VII, New Orleans, Louisiana, pp.5-8, November, 1995.
- [6] E. A. Rietman, "A neural network model of a contact plasma etch process for VLSI production," IEEE Transaction on Semiconductor Manufacture, Vol.9, No.1, pp.95-100, February, 1996.
- [7] Richard P. Lippmann, "An introduction to computing with neural nets," IEEE ASSP Magazine, pp.4-22, April, 1987.
- [8] G. W. Gates, "The reduced nearest neighbor rule," IEEE transactions on Information Theory, Vol.13, No.1, pp.21-27, 1972.
- [9] H. Sakai and S. Chiba, "Dynamic programming algorithm optimization for spoken word recognition," IEEE Transactions on Acoustic, Speech, and Signal Processing, Vol.26, No.1, pp.43-49, 1978.

이 중 재

e-mail : jjhop@vision.ssu.ac.kr
1999년 숭실대학교 전자계산학과(공학사)
2001년 숭실대학교 대학원 컴퓨터학과
(공학석사)
2001년~현재 숭실대학교 대학원
컴퓨터학과 박사과정

관심분야 : 패턴인식, 증강현실, 의료영상처리 등임

권 오 범

e-mail : xanado74@hotmail.com
2001년 경희대학교 전자계산공학과
(공학사)
2003년 숭실대학교 대학원 컴퓨터학과
(공학석사)
현재 (주)임프 연구원

관심분야 : 패턴 인식, 컴퓨터 비전, 영상처리 등임

김 계 영

e-mail : gykim@computing.soongsil.ac.kr
1990년 숭실대학교 전자계산학과(공학사)
1992년 숭실대학교대학원 컴퓨터학과
(공학석사)
1996년 숭실대학교대학원 컴퓨터학과
(공학박사)
1996년~1997년 11월 한국전자통신연구원(Post Doc.)
1997년~2001년 한국전력공사 전력연구원(선임연구원)
2001년~현재 숭실대학교 컴퓨터학부(조교수)
관심분야 : 컴퓨터비전, 형태인식, 생체인식, 증강현실, 영상 및
신호처리 등임