

비동기 설비 신호 상황에서의 강건한 공정 이상 감지 시스템 연구

고종명¹ · 최자영¹ · 김창욱^{1*} · 선상준² · 이승준²

¹연세대학교 정보산업공학과 / ²삼성전자 생산기술연구소

Robust Process Fault Detection System Under Asynchronous Time Series Data Situation

Jong Myoung Ko¹ · Ja Young Choi¹ · Chang Ouk Kim¹ · Sang Joon Sun² · Seung Jun Lee²

¹Department of Information and Industrial Engineering, Yonsei University, Seoul, 120-749

²Manufacturing Innovation Team, Mechatronics and Manufacturing Technology Center,
Samsung Electronics Co., Ltd., Suwon, 443-370

Success of semiconductor/LCD industry depends on its yield and quality of product. For the purpose, FDC (Fault Detection and Classification) system is used to diagnose fault state in main manufacturing processes by monitoring time series data collected by equipment sensors which represent various conditions of the equipment. The data set is segmented at the start and end of each product lot processing by a trigger event module. However, in practice, segmented sensor data usually have the features of data asynchronization such as different start points, end points, and data lengths. Due to the asynchronization problem, false alarm (type I error) and missed alarm (type II error) occur frequently. In this paper, we propose a robust process fault detection system by integrating a process event detection method and a similarity measuring method based on dynamic time warping algorithm. An experiment shows that the proposed system is able to recognize abnormal condition correctly under the asynchronous data situation.

Keyword: FDC system, data asynchronization, robust process fault detection system, process event detection, dynamic time warping

1. 서론

반도체/LCD(Liquid-crystal Display) 제품은 하나의 제품이 생산되기 위해서 긴 시간이 소요되는 복잡한 단계를 거치게 된다. 반도체/LCD 산업에서 제품의 품질과 산출량은 중요한 평가 지표이다. 따라서 각 단계별 핵심 설비들의 생산 공정 관리가 매우 중요하다. 반도체의 경우 하나의 웨이퍼(Wafer) 가공을 통해 한

번에 수백 개의 반도체 칩을 생산하기 때문에 하나의 웨이퍼가 비정상 가공될 경우 발생하는 반도체 칩 생산의 손실이 매우 크다(Iwai *et al.*, 2005). LCD 제품 역시 배치 생산(Batch Production)을 통해 생산되는 경우가 많아서 비정상 가공이 발생될 경우 그 시점에 가공된 전체 로트(Lot)를 폐기해야 하는 큰 손실이 발생된다(Su *et al.*, 2006). 이러한 손실을 최소화 하고 제품의 고품질을 유지하며 제품 생산성을 높이기 위해서는 핵심

본 연구는 삼성전자 과제의 연구비 지원으로 수행되었음.

본 논문의 서론 부분을 작성하는데 큰 도움을 주신 한국기술교육대학교 산업디자인공학과 홍주표 교수님께 감사드립니다.

*연락처 : 김창욱 교수, 120-749 서울시 서대문구 신촌동 134 연세대학교 정보산업공학과, Fax : 02-364-7807, E-mail :

kimco@yonsei.ac.kr

2007년 07월 접수, 2회 수정 후 2007년 08월 게재확정.

프로세스를 구성하는 설비들을 실시간으로 모니터링하고 이상을 진단하는 공정 관리가 필요하다.

현재 반도체/LCD 현업에서는 공정의 이상 유무를 판단하기 위해 웨이퍼나 LCD 패널(Panel)의 박막(Thin Film) 두께, 에칭(Etching) 상태와 같은 가공 결과를 측정하여 공정의 이상을 파악하는 방법이나 공정 진행을 위해 설정해야 되는 전력(RF Power), 압력(Chamber Pressure), 기체 유량(Gas Flow)과 같은 중요 공정 매개변수(Process Parameter)들을 측정하는 방법 등이 사용된다. 만약 플라즈마(Plasma)를 사용하는 공정과 같이 직접적인 예측이 어려운 경우에는 공정 챔버(Chamber) 표면에 부착된 SEERS(Self-Excited Electron Resonance Spectroscopy)를 통한 플라즈마의 주파수별 진동 관측, OES(Optical Emission Spectroscopy)를 통한 플라즈마로부터 방출되는 빛의 스펙트럼 분석 등의 방법을 통해 공정의 상태를 실시간으로 모니터링 할 수 있다. <그림 1>은 플라즈마를 사용하는 공정 설비에서 공정 매개변수나 OES, SEERS를 이용한 모니터링을 위한 설비의 구조를 나타낸다. 각 공정 매개변수는 설비에 직간접적으로 연결되어 설비가 운영되는 공정 환경을 제어하는 역할을 수행하며, 제어 상황이 실시간으로 모니터링 된다. 이와 같이 공정이 진행되는 도중에 발생하는 비정상 상황을 감지하고 발생 원인을 찾아내는 것을 FDC(Fault Detection and Classification)라고 한다. FDC의 핵심은 설비의 센서 데이터를 이용하여 설비가 정상 작동하는지를 판단하는데 있다(Goodlin *et al.*, 2003; ITRS, 2005). 최근, 설비 상태를 실시간으로 모니터링 할 수 있는 in-situ 계측 장비를 이용한 공정 관리 방법의 도입 비용이 감소하고 공정 설비에 대한 강건한 측정법이 개발되면서 FDC의 성능이 향상되었다.

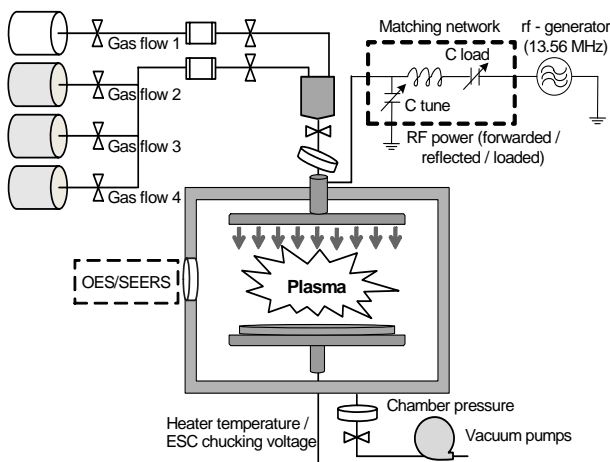


그림 1. 플라즈마 사용 공정의 모니터링을 위한 설비 구조

1.1 센서 데이터를 이용한 기존의 공정 관리 방법

반도체/LCD 제조 공정에서 설비 센서 데이터를 공정 이상 감지에 사용하는 기존의 연구 접근방법은 모델 기반의 접근법

과 레퍼런스(Reference) 패턴 기반 접근법이 있다. 모델 기반 접근법은 공정이 정상적으로 진행된 상황에서 수집된 공정 매개변수 데이터를 이용하여 통계적 시계열 모형을 수립하거나 데이터 마이닝 모형을 학습시킨다. Guo *et al.*(1991)은 플라즈마 에칭 공정을 대상으로 센서별로 ARIMA(Autoregressive Integrated Moving Average) 모형을 수립하고 실제 센서 데이터와의 예측 오차를 측정하여 공정의 이상 여부를 판단하는 방법을 제안하였다. Kim and May(1997)와 Hong and May(2004)는 인공 신경망 모형을 RIE(Reactive Ion Etching) 공정의 이상 진단에 적용하였다. 두 연구는 공통적으로 여러 소스에서부터 얻어진 공정관련 데이터를 근거 추론 방법인 Dempster-Shafer 이론에 적용하여 최종 이상 여부를 판단하였다. Baek *et al.*(2002)는 LCD 공정 이상 진단을 위해 의사 결정 나무(Decision Tree)를 이용하여 이상의 원인-결과 지식을 학습하였다. 그러나 모델 기반의 접근법은 모델 설정의 어려움과 통계적 검증 또는 데이터 마이닝을 위한 학습 데이터의 제한성 때문에 수립된 모형이 과잉맞춤(Over-fitting)될 가능성이 있으며, 또한 공정의 상태를 정확히 반영하는 매개변수를 알아내는데 많은 시간이 소요되는 단점이 있다.

일반적으로 공정이 정상적으로 진행되면 각 공정 시행(Run)마다 설비 센서가 생성하는 데이터는 유사한 모양을 갖는다. 레퍼런스 패턴 기반 접근법은 정상 진행된 공정에서 획득된 시계열 데이터를 레퍼런스 패턴으로 정의한다. 레퍼런스 패턴은 <그림 2>와 같이 공정의 정상 진행에 따른 일정한 패턴을 보여준다. Dolins *et al.*(1988)과 Barna(1992)는 레퍼런스 패턴의 영역별 특징의 허용범위를 설정하는 규칙을 생성하고 새롭게 수집된 공정 데이터를 대상으로 규칙기반의 추론을 통해 비공정 여부를 판단하였다. 최근 Salvador *et al.*(2004)은 각 단계별로 공정이 지켜야할 조건을 상태(State)로 표현하고 단계의 변화를 상태 전이 로직으로 표현하여 새롭게 들어오는 공정 데이터의 모양에 근거하여 비정상 상태를 판별하는 새로운 방법을 제안하였다. 하지만 이러한 레퍼런스 패턴 기반의 접근법이 공정의 이상을 정확하게 진단하기 위해서는 각 공정 상황 별로 영역별 특징의 종류와 허용범위를 정확히 묘사해야 된다. 이런 과정의 요구에 따라 현업의 경험을 토대로 레퍼런스 패턴을 작성하더라도 설비 신호의 비동기성이나 데이터 수집 능력의 한계로 인해 부정확한 공정 진단 알람 발생 빈도가 높아 해당 레퍼런스 패턴의 현실적 적용이 힘들다. 최근 Lada *et al.*(2002)은 이산 웨이블릿 변환(Discrete Wavelet Transform)을 반도체 설비 이상 진단 분야에 응용하여 미리 레퍼런스 패턴의 특징과 허용범위를 정의하지 않는 성과를 거두었다. 이산 웨이블릿 변환은 소수의 웨이블릿 계수(wavelet coefficients)만을 가지고도 대량의 시계열 데이터가 생성하는 패턴을 표현할 수 있다. 이 연구에서는 변형된 Hotelling의 T2 통계치를 이용하여 레퍼런스 패턴을 나타내는 웨이블릿 계수와 입력된 데이터의 웨이블릿 계수간의 가설 검정을 이용한 이상 진단을 수행하였다. 그러나 정확한 공정 상황을 진단하기에는 다음과 같은 현실적인




그림 2. 레퍼런스 패턴의 예

반도체/LCD 공정의 문제점이 존재한다.

1.2 설비 센서 신호의 비동기성으로 인한 부정확한 패턴 인식 문제

반도체/LCD 제조 공정을 구성하는 설비는 챔버 유형의 설비와 인라인(Inline) 유형(Type)의 설비로 나눌 수 있다. 챔버 설비는 웨이퍼나 LCD 패널 가공 시 해당 재료를 개별적으로 투입하는 형태로 운영된다. 인라인 설비는 LCD 제조 공정의 몇몇 특정 단계에서 사용되며 로트 단위의 여러 장의 패널을 한 공정 설비에 연속적으로 투입하는 형태로 운영된다. 이러한 두 유형의 핵심 설비들에 부착된 센서들은 공정 매개 변수를 온라인으로 모니터링 하게 된다. 공정 매개 변수 데이터는 공정/비공정 단계의 데이터를 모두 포함하며 시간에 따라 형태가 변화하는 시계열 패턴의 특성을 갖는다. 일반적인 경우 비공정 단계의 데이터는 공정의 이상에 영향을 주지 않기 때문에 이상 진단에 유용한 공정 단계의 데이터를 구분하는 것이 중요하다. 이를 위해 챔버 설비의 경우에는 공정 시작과 종료 단계를 나타내는 트리거 이벤트를 발생시켜 공정의 시작 및 종료 정보를 추출한다. 하지만 구형 공정 설비의 경우에는 이러한 트리거 이벤트의 정확도가 떨어져 공정 데이터를 유실하거나 비공정 데이터를 포함하는 경우가 많다. 신형 설비의 경우에도 통신이나 연산 지연으로 트리거 이벤트의 발생 시점이 시스템에 정확하게 인식되지 않는 경우가 발생한다. 그리고 설비에 웨이퍼나 패널이 투입된 후 세부 공정 순서와 공정내의 우선순위에 따라 불규칙한 대기 시간이 발생할 수 있으며 공정 내의 변동성은 공정 시간의 불규칙성을 만들어낸다. 인라인 설비의 경우에는 재료를 연속적으로 투입하기 때문에 트리거 이벤트를 사용하여 공정/비공정 단계를 구분하는 것이 사실상 불가능하여 개별 가공 단위의 데이터를 얻기가 힘들다. 이러한 문제들로 각 공정마다 얻어진 데이터들의 시작과 종료 시점이 정확히 일치하지 않고, 공정 데이터 간의 길이가 차이가 나는 데이터 비동기성 특성을 갖는다. 특히 인라인 설비 센서 데이터의 경우에는 투입되는 로트의 크기에 의존적인 길이를 갖는 시계열 패턴이 생성되는 현상이 발생한다.

데이터 비동기성은 시계열 패턴 인식을 통한 공정 이상 진단 시 각 영역간의 시점 불일치로 인해 패턴을 부정확하게 인식하는 문제를 발생시킨다. 이를 극복하기 위해서는 공정 매개 변수 데이터의 변동성과 방향성을 고려한 정확한 공정 시작

및 종료 시점 인식과 데이터의 길이차이에 유연한 패턴 인식 알고리즘 기반의 이상 감지 기법이 필요하다. 인라인 설비 데이터의 경우에는 데이터 길이 차이를 줄일 수 있는 추가적인 전처리 방법이 필요하다.

1.3 비동기적 설비 신호에 강건한 이상 감지 시스템의 제안

공정 이상 진단의 궁극적인 목표는 공정의 정상/비정상 여부 판별의 신뢰성이 높고, 실시간으로 공정 매개 변수의 모니터링 결과가 자동적으로 공정 진행에 반영되어 이후 제품의 가공 시 비정상 요소 제거에 유용한 시스템의 개발에 있다. 본 논문에서는 실시간으로 발생하는 공정 매개 변수 데이터를 이용하여 특정 모델 구축이 아닌 데이터의 패턴을 명확히 인식하는 패턴 인식 기법을 이용하여 비동기적 설비 신호에도 사용할 수 있는 공정 이상감지 시스템을 제안하고자 한다.

데이터 비동기성 상황에서 시계열 데이터 패턴을 정확하게 인식하기 위해 본 논문에서는 DTW(Dynamic Time Warping) 기법을 사용하였다. DTW는 데이터 변환이나 압축 등의 전처리 작업 없이 데이터 비동기성 상황에서 패턴을 인식하는데 유용한 기법으로 음성인식, 문자인식 분야 등에서 오랫동안 사용되어 왔다(Rabiner *et al.*, 1978; Sakoe and Chiba, 1978). DTW는 DP(Dynamic Programming)에 기반을 두고 있기 때문에 두 시계열 데이터간의 유사도 측정은 두 시계열 데이터를 각각 일정한 간격으로 분할하고 두 데이터상의 모든 점을 연결하는 거리를 최소화하는 과정을 통해 이루어진다(Berndt and Clifford, 1996). 두 시계열 데이터의 유사도는 매핑된 점들 간의 누적거리를 통해 구해진다. 만약 서로 비동기적인 두 공정 매개 변수 데이터를 매핑할 경우 DTW 기반의 비선형 매핑(nonlinear mapping)은 <그림 3>과 같이 한 데이터 시점에 다른 데이터의 여러 데이터 시점들의 매칭을 허용함으로써 두 데이터 간의 유사도를 효과적으로 측정할 수 있다.

Dolins and Reese(1992)과 Kassidas *et al.*(1998)의 기존 연구들에서도 공정상에서 발생하는 길이가 불규칙한 패턴들의 인식을 위해 DTW를 이용한 패턴 매칭을 제안하였다. Dolins and Reese(1992)는 온도 및 압력 설정, 기체 유입과 관련한 공정 매개 변수의 기울기 및 지속 시간을 분석하여 이상 상황을 추론하였다. 하지만 진단된 이상 유형이 온도의 비정상적인 높고 낮음, 시간의 지연 등 직관적이고 간단했다. Kassidas *et al.*(1998) 역시 DTW를 사용하여 공정 매개 변수 데이터가 서로 다른 지속 시

간을 가짐으로 발생하는 부정확한 이상 분류 문제 해결을 제안하였다. 이 연구는 길이 변동성으로 인해 발생 가능한 거짓 이상 알람을 줄일 수 있음을 증명했지만 Dolins and Reese(1992)와 마찬가지로 본 연구에서 다른 반도체 및 LCD 공정상에서 발생하는 현실적인 data asynchronization 문제까지는 고려하지 않았다. 본 논문은 공정 데이터의 길이 변동성뿐만 아니라 트리거 이벤트 성능으로 인해 유발되는 비동기성 문제까지 고려한 패턴 인식 기법으로써 DTW를 적용하였으며 두 연구에서 다루지 않은 인라인 유형의 데이터에도 DTW를 적용시켰다.

비를 이용하는 공정에서 얻어진 데이터와 인라인 설비를 이용하는 공정에서 얻어진 데이터를 이용하여 연구의 방법론을 적용한다. 두 공정에서 중요하게 다루어지는 압력, 기체 유입, 전압, 온도 등의 공정 매개 변수 데이터를 추출하여 공정이 정상적으로 진행되는지를 모니터링하고 패턴 매칭 기법을 통해 비정상적인 공정 패턴을 구분하는 성능을 측정한다. 본 논문은 다음과 같이 구성된다. 제 2장에서는 이상 감지를 위한 시스템 아키텍처와 데이터 비동기성 문제를 해결하기 위한 알고리즘을 소개한다. 제 3장에서는 제안하는 기법의 성능을 평가하고 통계적 분석 결과를 정리한다. 제 4장에서는 결론을 제안한다.

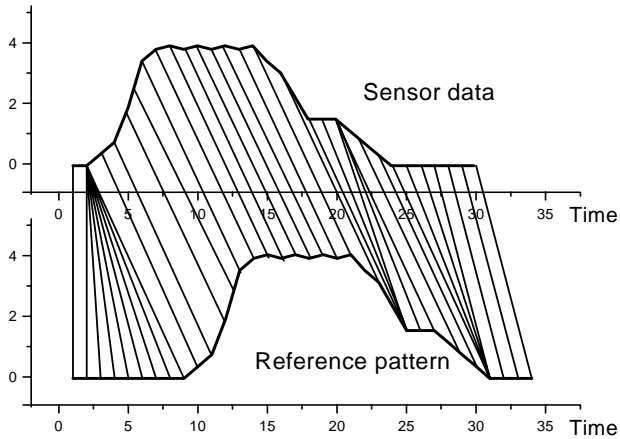


그림 3. DTW를 이용한 두 시계열 데이터의 패턴 매칭

본 논문에서는 이상 감지의 성능을 평가하기 위해 챔버 설

2. 강건한 공정 이상 감지 시스템

본 논문에서 제안하는 이상 감지를 위한 시스템의 아키텍처는 <그림 4>와 같다. 본 시스템의 핵심은 공정상에서 발생하는 중요한 변화(이벤트)를 감지하는 알고리즘과 구분된 이벤트를 대상으로 공정의 이상상황을 감지하는 알고리즘이다.

2.1 공정 이벤트 감지 모듈(Process Event Detection Module)

공정 이벤트 감지 모듈은 공정의 시작과 종료 시점을 발견하여 실제 공정 기간의 데이터를 구분해주는 역할을 한다. 본 모듈은 다음의 세부 모듈로 구성이 된다.

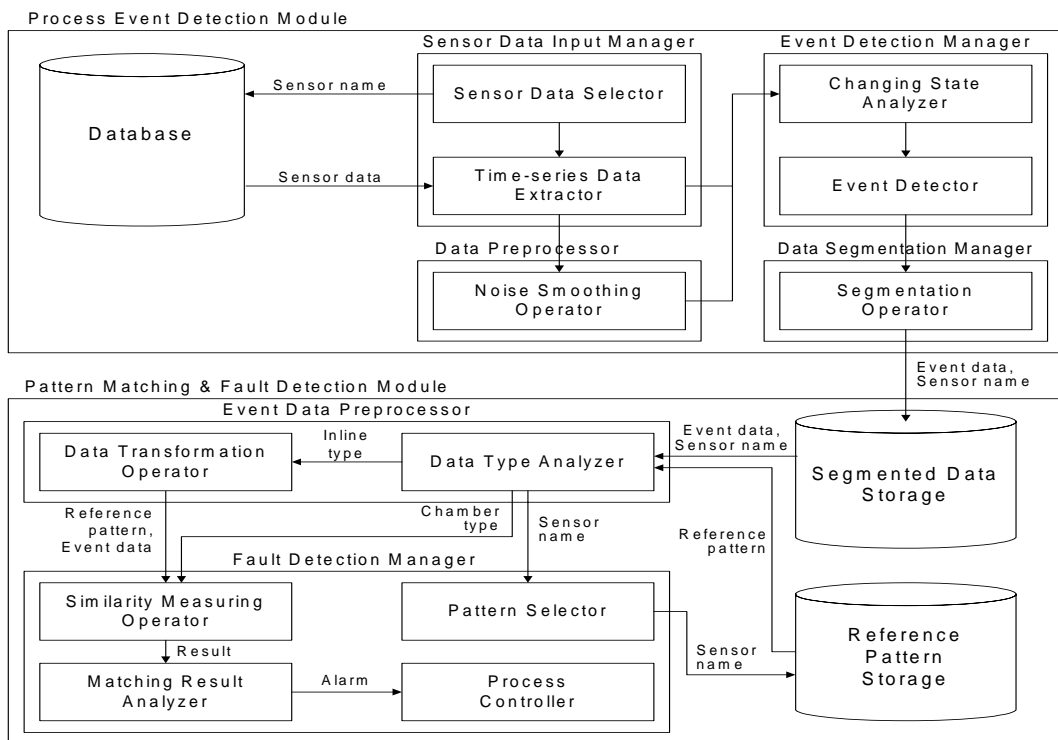


그림 4. 시스템 아키텍처

2.1.1 센서 데이터 입력 관리자(Sensor Data Input Manager)

센서 데이터 입력 관리자는 연속적으로 들어오는 센서 데이터를 데이터베이스로부터 가져오는 역할을 수행한다.

2.1.2 데이터 전처리기(Data Preprocessor)

데이터 전처리기는 설비의 고유 특성이나 특수한 환경 설정으로 인해 공정에 영향을 주지 않는 데이터의 잡음 여부를 판단하여, 필요한 경우 잡음을 제거하고 분석에 적합한 형태의 데이터로 변형하는(Noise Smoothing Operator) 역할을 수행한다.

2.1.3 이벤트 감지 관리자(Event Detection Manager)

이벤트 감지 관리자는 공정의 실제 시작과 종료를 감지하는 역할을 수행한다. 이를 위해 데이터의 변동성과 방향성을 분석하고(Changing State Analyzer) 공정상의 중요한 변화를 감지하여 공정의 시작과 종료 시점을 판단한다(Event Detector). 비공정에서 공정 상태로 변경(Start Event)되거나, 공정에서 비공정 상태로 변경(End Event)되는 이벤트 감지 알고리즘은 다음 순서대로 진행된다.

단계 1: 이벤트를 감지하기 위해 공정이 시작된 후 일정시간 동안 비공정 상태가 유지된다는 가정 하에 일정 시간 동안 얻은 데이터 값을 바탕으로 평균(X)과 표준편차(σ)를 이용하여 $X \pm 3\sigma$ 를 비공정 상태의 범위로 설정한다.

단계 2: 설정된 비공정 상태의 범위에 대해서 데이터의 방향이 변경되는 일반적인 형태에 대해 <그림 5>와 같이 6가지 형태를 정의한다. 비공정 상태에서는 증가하는 방향으로 방향성이 변화된다(1). 증가하는 방향에서는 감소하는 방향으로 변화되거나(2), 비공정 상태로 변화된다(3). 감소하는 방향에서는 증가하는 방향으로 변화되거나(4), 비공정 상태로 변화된다(5). 그리고 같은 방향을 유지하는 경우도 발생한다(6).




그림 5. 데이터 방향 변화 형태

단계 3: <그림 5>의 일반적인 변화 방향성으로부터 실제 공정 시작과 종료 이벤트는 <표 1>과 같이 추측된다. (4)의 경우 공정 종료와 동시에 시작이 발생하는 이벤트를 의미한다.

단계 4: 단계 2와 단계 3을 바탕으로 선택한 센서 데이터의 공정 시작과 종료를 구분하기 위해서 공정과 비공정 상태의 특성이 명확한 핵심 센서를 보조센서로 사용한다. 즉, 공정 이벤트로 결정한 최소한의 임계치를 지정

하여 선택 센서가 시작 이벤트 상태가 되고 이벤트 상태인 보조센서의 수가 임계치 이상이 될 경우 실제 공정의 시작으로 판단하고 종료 이벤트의 경우에도 같은 방식을 사용한다.

표 1. 공정 시작 및 종료 이벤트의 추측

공정 이벤트	이벤트 특성
시작 이벤트	비공정 상태에서 증가하는 방향으로 변하는 경우(1) 감소하는 방향에서 증가하는 방향으로 변하는 경우(4)
종료 이벤트	감소하는 방향에서 증가하는 방향으로 변하는 경우(4) 증가하는 방향에서 비공정 상태로 변하는 경우(3) 감소하는 방향에서 비공정 상태로 변하는 경우(5)

2.1.4 데이터 구분 관리자(Data Segmentation Manager)

데이터 구분 관리자는 이벤트 감지 관리자로부터 판단된 공정의 시작과 종료 시점을 바탕으로 실제 공정 데이터(Event data)를 구분하여 저장소(Segmented Data Storage)에 저장하는 역할을 수행한다(Segmentation Operator).

2.2 패턴 매칭 및 공정 이상 감지 모듈(Pattern Matching & Fault Detection Module)

구분된 데이터 저장소(Segmented Data Storage)에 저장된 실제 공정 부분 데이터를 이용하여 레퍼런스 패턴 저장소(Reference Pattern Storage)에 보관된 레퍼런스 패턴과의 유사도를 측정하여 현 공정이 정상적으로 진행되고 있는지의 여부를 판단하고 비정상적으로 의심되는 결과가 나올 경우 작업자에게 현 공정의 상태를 알리는 역할을 수행하는 모듈이다.

2.2.1 공정 데이터 전처리기(Event Data Preprocessor)

인라인 설비에서 추출되는 공정 매개 변수 데이터는 투입되는 LCD 패널의 양에 의존적인 길이를 갖는 특징을 갖는다. 따라서 서로 투입된 양이 다른 두 데이터의 유사도를 측정하는 경우에는 서로 길이가 비슷하도록 조정하는 전처리가 필요하다. 여러 개의 LCD 패널을 처리할 경우 설비가 가동된 기간 동안 추출된 데이터는 <그림 6>과 같이 대부분 내부적인 주기를 띄거나 일정 경계선 안에서 공정이 이루어진다.




그림 6. 인라인 설비에서 추출된 공정 매개 변수 데이터

인라인 설비 데이터의 전처리는 패턴 매칭을 위한 두 데이터의 길이를 최대한 비슷하게 맞춰주는 것을 목적으로 수행된다. 이를 위해 구분된 실제 공정 데이터와 레퍼런스 패턴과의 길이 비율을 계산하고 데이터를 복제하는 방식의 전처리 규칙을 사용하였다. 전처리 규칙은

짧은 길이의 데이터를 길이가 긴 데이터에 근접해지도록 짧은 쪽 데이터를 긴 쪽 길이에 근접한 배율만큼 복제하거나(규칙 1), 긴 쪽 데이터를 2배, 짧은 쪽 데이터를 3배씩 각각 복제하거나(규칙 2), 원래의 두 데이터를 그대로 이용하는(규칙 3) 방식을 사용한다. 이 3가지 규칙 외에 복제 배율을 다양하게 하여 더 근접한 결과를 얻을 수 있지만 패턴 매칭의 유사도 측정 속도 및 다양성만큼 성능 개선 효과가 많이 않음을 고려하여 다른 규칙은 고려하지 않는다. 규칙 1, 규칙 2, 규칙 3의 사용은 두 데이터의 길이 비율을 가장 근접하게 만드는 규칙 사용을 원칙으로 한다. 즉, 다음의 수리적 증명을 통해 기준이 되는 두 데이터 간의 길이 비율이 구해진다. 식 (1)에서 긴 데이터의 길이를 100으로 가정하며, [X]는 X를 넘지 않는 최대 정수를 의미한다.

$$\frac{\min([100/57+0.5] \times 57, 100)}{\max([100/57+0.5] \times 57, 100)} > \frac{57 \times 3}{100 \times 2},$$

$$\frac{\min([100/58+0.5] \times 58, 100)}{\max([100/58+0.5] \times 58, 100)} < \frac{58 \times 3}{100 \times 2}, \quad (1)$$

$$\frac{100 \times 2}{81 \times 3} > \frac{81}{100}, \quad \frac{100 \times 2}{82 \times 3} < \frac{82}{100}$$

식 (1)의 증명에 의해 전처리 규칙을 적용하는 기준은 <표 2>와 같다.

표 2. 공정 데이터 전처리 규칙 적용

길이 비율	적용 규칙
(0%, 57%]	규칙 1
(57%, 81%)	규칙 2
[81%, 100%]	규칙 3

<표 2>에서 길이 비율(R)은 식 (2)에 의해서 구해진다.

$$R = \left[\frac{\min(\text{Event data}, \text{Reference data})}{\max(\text{Event data}, \text{Reference data})} \times 100 + 0.5 \right] (\%) \quad (2)$$

예를 들어, 규칙1을 적용하여 <그림 7>의 이벤트 데이터 1과 데이터 2의 유사도를 측정할 경우 두 데이터는 다음 그림과 같이 두 데이터 모두 변환된다.

2.2.2 공정 이상 감지 관리자(Fault Detection Manager)

공정 이상 감지 관리자는 분석 대상 센서 정보를 바탕으로 해당 센서 데이터의 레퍼런스 패턴을 추출하고(Pattern Selector) 공정 데이터와의 패턴 매칭을 통한 유사도를 측정한다(Similarity Measuring Operator). 두 데이터의 유사도를 측정하기 위해서

DTW를 사용하며 DTW는 다음 과정을 통해 두 시계열 데이터의 유사도를 측정한다.

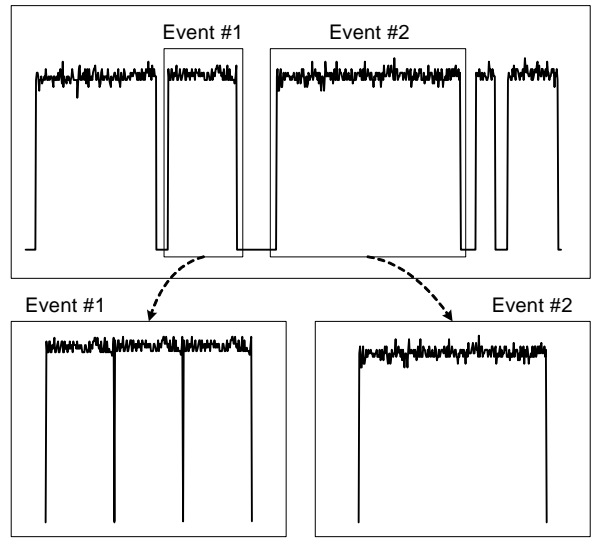


그림 7. 인라인 설비 데이터의 전처리 규칙 적용의 예

시계열 데이터로 구성된 두 개의 패턴 $S(S = \{s_1, s_2, s_3, \dots, s_n\})$ 와 $T(T = \{t_1, t_2, t_3, \dots, t_m\})$ 가 있을 경우, 두 패턴의 길이에 의해 $n \times m$ 의 2차원평면이 생성된다. <그림 8-(a)>에서 보듯이 이평면은 s_i 와 t_j 가 서로 매핑된 포인트인 (i, j) 의 원소를 가지게 되며 매핑 포인트의 집합을 와핑 거리(W: Warping path)라고 한다. 즉, W의 k번째 원소는 $w_k = (i_k, j_k)$ 라고 정의가 된다. W의 요소들이 갖는 개별 거리는 유클리드 거리(Euclidean distance)에 의해 측정된다. 거리를 최소화하는 최적 와핑 거리는 W가 총 K개의 원소로 이루어졌을 경우 식 (3)과 같으며 $DTW(S, T)$ 는 S와 T의 최종적인 유사도이다. K는 평균 거리를 구하기 위한 스케일링 요인으로 정의된다. 데이터 비동기성으로 인해 발생하는 시계열 데이터 간의 길이차이에 독립적인 유사도를 구하기 위해서는 K를 이용한 누적거리의 스케일링이 필요하다.

$$DTW(S, T) = \min_w \left\{ \sum_{k=1}^K d(i_k, j_k) / K \right\} \quad (3)$$

$$d(i_k, j_k) = (s_{i_k} - t_{j_k})^2 \quad (\text{단, } 1 \leq i_k \leq n, 1 \leq j_k \leq m)$$

DP에 의해서 optimal warping path를 찾는 재귀 함수식은 식 (4)와 같다.

$$y(i_k, j_k) = d(i_k, j_k) + \min \{ y(i_k - 1, j_k), y(i_k - 1, j_k - 1), y(i_k, j_k - 1) \}$$

$$y(i_1, j_1) = d(1, 1) = (s_1 - t_1)^2 \quad (4)$$

DTW를 통한 두 시계열 데이터의 최종적인 패턴 매칭 결과가 <그림 8-(a)>와 같다면, <그림 8-(b)>의 W는 (1, 1), (1, 2), (2,

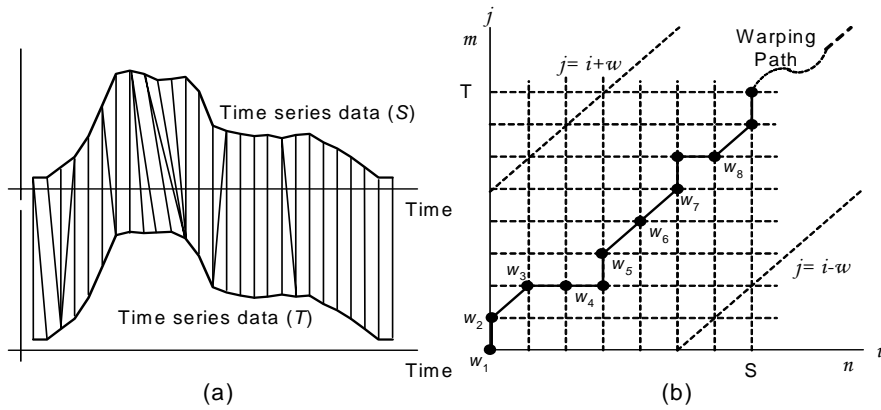


그림 8. DTW를 이용한 두 시계열 데이터의 패턴 매칭

3), (3, 3), ..., (n, m)을 원소로 갖는다. DTW는 다음과 같은 제약 조건을 통해 탐색 범위를 줄여 유사도 판단을 신속하게 하는 장점이 있다(Berndt and Clifford, 1996). 먼저, W 의 방향이 시계열의 증가 방향에 역행할 수 없다(Monotonicity). 둘째, $n \times m$ 평면에서는 최대 한 단계씩만 이동 가능하다(Continuity). 셋째, 외평 제약에 의해 w_k 가 선택될 수 있는 범위가 제한된다. 예를 들어, $|i_k - j_k| \leq \omega$ (ω : 양의 정수) 정도의 범위로 탐색 범위가 제한된다(Global Constraint). ω 가 0인 경우는 유클리드 거리가 된다. 넷째, W 의 진행 방향을 특정 기울기를 갖는 함수가 만들어내는 영역을 초과하지 못하도록 제한함으로써, W 가 한 방향으로 극단적인 움직이는 것을 방지한다(Slope Constraint). W 의 시작과 종료는 각각 $w_1 = (1, 1)$, $w_k = (n, m)$ 으로 지정된다(Boundary Conditions). 본 논문에서는 한 방향으로의 극단적인 움직임으로 인한 극심한 비선형 매핑을 방지하기 위하여 공정 데이터가 갖는 길이의 차이의 평균값을 이용하여 ω 를 설정하였다.

측정된 유사도 값을 바탕으로 공정 이상 여부를 분석하고 (Matching Result Analyzer) 이상이 있을 경우 관리자에게 알리는 역할을 수행한다(Process Controller). 이상 여부는 I 관리도(Individual Chart)를 이용하여 분석하였다.

I 관리도는 개별 데이터를 관리도에 표기하여 정상/비정상을 판별하는데 사용된다(John, 1990). 즉, 현재 입력된 시계열 데이터와 레퍼런스 패턴과의 유사도 측정값은 I 관리도에 기반을 둔 정상 허용범위를 기준으로 정상 또는 비정상으로 구분된다. 본 논문에서는 최근 정상 패턴 중 레퍼런스 패턴을 선정하여 기존 정상 가공된 패턴들과의 유사정도를 나타내는 거리값들의 평균(m)과 표준편차의 추정값($\hat{\sigma}$)을 이용하여 $[0, m + 3\hat{\sigma}]$ 의 정상 가공 범위를 지정한다.

3. 실험

본 논문에서는 제안하는 두 핵심 알고리즘인 공정 이벤트 감지 알고리즘과 DTW 기반의 이상 진단 알고리즘을 적용한

시스템의 성능을 평가하기 위해 다음과 같은 실험을 수행하였다. 실험은 앞서 언급한 RIE 공정 설비와 포토 스피너 공정 설비에 부착된 센서로부터 얻어진 압력, 기체 유입, 전압, 온도와 같은 공정 매개 변수 데이터를 이용하여 본 시스템이 정상/비정상 패턴을 정확하게 분류하는지를 평가하였다. 실험에는 챔버 유형의 경우 데이터의 변동이 강한 데이터 2종류, 중간인 데이터 2종류, 약한 데이터 2종류를 사용하였으며, 인라인 유형의 경우 해당 설비에서 변동성이 강한 데이터가 발견되지 않아 변동성이 약한 데이터 2종류를 사용하였다. 각 센서는 편의상 CS(Chamber Type Sensor), IS(Inline Type Sensor)의 명칭을 사용하였으며 사용된 레퍼런스 패턴의 형태는 <그림 9>와 같다.




그림 9. 실험에 사용된 레퍼런스 패턴

챔버 유형의 경우 트리거 이벤트에 의해 추출된 공정 데이터의 정상/비정상 패턴 분류 성능과 이벤트 감지 알고리즘에 의해 추출된 공정 데이터의 정상/비정상 패턴 분류 성능을 비교하여 제안하는 시스템의 성능을 평가하였다. 인라인 유형의 경우 트리거 이벤트에 의한 패턴 추출이 현실적으로 불가능하기 때문에 이벤트 감지 알고리즘에 의해 추출된 공정 데이터를 변환하고 변환된 데이터의 정상/비정상 패턴 분류 성능을 비교하였다.

3.1 챔버 설비 센서 데이터를 이용한 성능 평가

3.1.1 공정 이벤트 감지 성능 평가

공정의 시작, 종료 이벤트를 감지하는 성능을 평가하기 위해 6개 센서로부터 얻어진 트리거 이벤트 정보와 이벤트 감지 알고리즘에 의해 판단된 이벤트 정보를 비교해보았다. 트리거 이벤트의 경우 실제 공정의 시작과 종료 시점을 감지하는 기능을 수행하지만 공정의 이상 여부와 관계없는 더미 데이터를 포함하는 경우가 발생했다. 본 실험에서는 이벤트 감지 알고리즘이 공정의 시작과 끝을 감지하는 장치인 트리거 이벤트에 의해 감지되는 실제 이벤트를 얼마나 정확하게 감지하는지를 측정하였다. 또한, 이벤트 감지 알고리즘에 의해 구분된 공정 데이터와 트리거 이벤트에 의해 구분되었을 때의 공정 이벤트의 길이를 비교하여 기존 트리거 이벤트에 의해 구분된 데이터가 어느 정도의 더미 데이터가 포함되는지를 분석하였다.

표 3. 각 센서 데이터 별 이벤트 감지 회수

	CS1	CS2	CS3	CS4	CS5	CS6
전체 이벤트 수	102	100	101	108	104	102
누락 이벤트 수	0	0	0	0	0	0
거짓 이벤트 수	2	0	1	8	4	2
정확도 (%)	98.0	100.0	99.0	92.6	96.2	98.0

<표 3>은 트리거 이벤트가 총 100회의 공정 상태(시작 이벤트부터 종료 이벤트까지를 한 공정으로 간주)를 감지했을 경우 이벤트 감지 알고리즘의 이벤트 감지 회수를 분석한 것이다. 누락 이벤트(Missed Event)는 트리거 이벤트에 의해 측정된 부분을 감지하지 못한 경우이며, 거짓 이벤트(False Event)는 비공정 상태에서 데이터의 불규칙한 변동성으로 인해 이벤트로 오인한 경우를 의미한다. 비공정 상태의 범위를 정의하기 위해 7초 동안의 데이터를 사용했으며 한 센서의 정확한 이벤트 감지를 위해 3개의 보조 센서 중 2개 이상이 핵심 센서와 같은 방향성을 가질 경우 이벤트로 감지되도록 하였다. 실험결과 각 센서 별로 평균 97% 정도의 정확성을 보여주었다. CS1의 경우에는 트리거 이벤트가 도출해 낸 100회의 이벤트 외에 변동성이 있는 비공정 상태에서 2회의 이벤트 더 감지하였다. 즉, 누락 이벤트는 없었으나 2회의 거짓 이벤트를 감지했으며 102회 중 100회의 이벤트가 정확하므로 약 98%의 정확도를 나타

냈다. 이처럼 이벤트가 정확히 감지되지 못하는 부분은 이벤트 감지를 위해 설정하는 핵심 센서들을 선택하는 기준에 대한 명확한 틀이 존재하지 않고 선택된 핵심 센서들의 변동성 및 방향성이 일관성 있게 움직이지 않는데 기인한다. 하지만 이벤트 감지 알고리즘은 비공정 부분과 공정 부분을 구분하는데 우수한 성능을 보여주었다.

표 4. 두 방법론에 의한 평균 데이터 길이

	이벤트 감지 알고리즘		트리거 이벤트	
	데이터 길이(초)	더미 데이터(초)	데이터 길이(초)	더미 데이터(초)
CS1	165.15	2.30	181.47	14.02
CS2	85.48	1.42	115.98	29.08
CS3	105.20	2.02	122.82	15.60
CS4	86.25	0.46	115.11	28.40
CS5	103.06	1.12	116.64	12.46
CS6	150.22	0.78	163.76	12.76

<표 4>에서 보듯이 트리거 이벤트는 이벤트 감지 알고리즘에 비해 공정 데이터 추출 시 상당부분 더미 데이터를 포함시키는 경향이 있었다. 더미 데이터로 인해 발생하는 부정확한 공정 이상 감지에 대해서는 3.1.2에서 다루었다.

3.1.2 정상/비정상 패턴 분류 성능 평가

정상/비정상 패턴의 분류 정확성을 평가하기 위해 트리거 이벤트와 이벤트 감지 알고리즘으로 추출된 각 센서 별 100개 데이터를 대상으로 DTW를 적용한 패턴 분류 실험을 수행하였다.

<표 5>에서 보듯이 이벤트 감지 알고리즘에 의해 추출된 데이터를 이용할 경우 트리거 이벤트에 의한 경우보다 성능이 더 우수하게 도출되었다. 특히, 이벤트 감지 알고리즘을 이용해 공정 데이터를 구분하고 DTW를 이용하여 패턴 매칭을 수행할 경우 평균 97% 이상의 이상 감지 성능이 도출되었다.

표 5. 정상/비정상 패턴 분류 성능 평가

센서이름	이벤트 감지 알고리즘		트리거 이벤트	
	정상 패턴	비정상 패턴	정상 패턴	비정상 패턴
CS1	98/100	99/100	96/100	98/100
CS2	99/100	98/100	97/100	79/100
CS3	97/100	92/100	93/100	69/100
CS4	99/100	97/100	98/100	87/100
CS5	96/100	100/100	91/100	90/100
CS6	96/100	96/100	91/100	97/100
정확도(%)	97.5	97.0	94.3	86.7

공정 데이터를 구분하는 두 방법론을 바탕으로 DTW를 이용한 패턴 분류 성능의 차이가 신뢰도 95% 수준에서 유의한지

윌콕슨 부호 순위 검정(Wilcoxon Signed-rank Test)을 이용하여 검정해보았다. 이벤트 감지 알고리즘을 이용한 경우의 분류율의 평균을 μ_1 , 트리거 이벤트를 이용한 경우의 분류율의 평균을 μ_2 라고 할 경우 귀무가설 $H_0: \mu_1 - \mu_2 = 0$ 에 대한 p-value의 값은 <표 6>과 같았다.

표 6. 두 방법론의 패턴 분류 성능 비교

	정상 패턴 분류	비정상 패턴 분류
p-value	0.027*	0.027*
귀무가설	기각	기각

* : p-value < α 인 경우.

유의수준(α)은 0.05로 설정하였다. 검증 결과 두 분류율의 차이가 없다는 가설은 기각되어 이벤트 감지 알고리즘을 이용할 경우가 더 우수하다는 결론이 도출되었다.

3.2 인라인 설비 센서 데이터를 이용한 성능 평가

인라인 설비 센서 데이터는 트리거 이벤트를 적용하기 힘들기 때문에 이벤트 감지 알고리즘과 DTW를 이용한 패턴 매칭을 이용한 이상 감지 성능이 어느 정도 되는지를 측정하는 실험을 진행하였다. 레퍼런스 패턴과 입력된 공정 데이터는 투입된 재료의 양의 차이가 클수록 길이 차이가 컸으며 길이 차이가 큰 두 데이터의 유사도를 측정하기 공정 데이터 전처리 규칙을 사용하였다. 각 센서마다 100개 데이터를 대상으로 DTW를 적용한 패턴 분류 실험을 수행하였다. <표 7>에서 보듯이 정상 패턴과 비정상 패턴 분류 성능은 평균 97% 이상으로 우수한 결과를 나타냈다.

표 7. 정상/비정상 패턴 분류 성능 평가

	정상 패턴	비정상 패턴
IS1	99/100	100/100
IS2	95/100	100/100
정확도(%)	97.0	100.0

공정 센서 데이터가 갖는 비동기성은 정확한 이상 진단을 수행하는데 악영향을 미친다. 본 실험에서 검증되었듯이 이벤트 감지 알고리즘을 통한 정확한 공정 시점 감지와 DTW 기반의 유연한 패턴 매칭을 통해 서로 길이가 다른 시계열 패턴의 유사도를 측정을 통한 이상 감지는 강건한 공정 이상 감지 시스템을 설계하는데 매우 유용하게 쓰일 수 있다.

4. 결 론

본 논문에서는 반도체/LCD 제조 공정 설비 센서로부터 발생

하는 데이터를 이용하여 공정의 시작과 종료를 명확히 감지하고 데이터 비동기성 상황에서 유용한 DTW 기반의 패턴 매칭을 통해 공정의 이상 여부를 감지하는 강건한 공정 이상 감지 시스템을 제안하였다. 향후 본 시스템을 현업에 성공적으로 적용하기 위해서는 공정 이벤트 감지를 위한 핵심 센서 선택에 대한 기준과 유사도 측정시 극단적인 비선형 매핑을 제한하기 위한 DTW를 보완하는 일반적인 알고리즘이 필요하다. 핵심 센서 선택에 대한 기준을 마련하기 위해서는 실제 공정이 매우 복잡한 설비들과 각 설비마다 많은 센서들이 부착되어있음을 고려해서 센서들 간의 연관성, 공정 상태의 설명력 등에 대한 연구가 진행되어야 할 것이다. 그리고 극단적인 비선형 매핑 역시 센서 데이터의 특성을 파악하여 데이터 변동성에 적응하는 형태의 알고리즘이 보완되어야 할 것이다. 끝으로 이러한 기법들을 바탕으로 정상/비정상이 알려지지 않은 데이터에 대해서 여러 센서 데이터들의 상관관계를 분석하고 Hotelling의 T2 통계치를 적용할 실제 이상 감지 연구로 이어져야 할 것이다. 향후 연구를 통해 이런 부분들이 보완된다면 본 시스템은 공정 이상 진단을 위한 적응력 있고 강건한 기술로써 더욱 명확한 의미를 가질 것이다.

참고문헌

Baek, J. G., Kim, C. O., and Kim, S. S. (2002), Online learning of the cause-and-effect knowledge of a manufacturing process, *International Journal of Production Research*, 40(14), 3275-3290.

Barna, G. G. (1992), Automatic problem detection and documentation in a plasma etch reactor, *IEEE Transactions on Semiconductor Manufacturing*, 5(1), 56-59.

Berndt, D. J. and Clifford, J. (1996), Finding Patterns in Time Series: A Dynamic Programming Approach. *Advances in Knowledge Discovery and Data Mining*, The MIT Press, 229-248.

Dolins, S. B. and Reese, J. D. (1992), A Curve Interpretation and Diagnostic Technique for Industrial Processes, *IEEE Transactions on Industry Application*, 28(1), 261-267.

Dolins, S. B., Spivastava, A., and Flinchbaugh, B. E. (1988), Monitoring and Diagnosis of Plasma Etch Processes, *IEEE Transactions of Semiconductor Manufacturing*, 1(1), 23-27.

Goodlin, B. E., Boning, D. S., Sawin, H. H., and Wise, B. M. (2003), Simultaneous Fault Detection and Classification for Semiconductor Manufacturing Tools, *Journal of Electrochemical Society*, 150(12), 778-784.

Guo, H.-F., Spanos, C. J., and Miller, A. J. (1991), Real time statistical process control for plasma etching, *In Proceedings of IEEE/SEMI International Semiconductor Manufacturing Science Symposium*, 113-118.

Hong, S. J. and May, G. S. (2004), Neural Network-Based Real-Time Malfunction Diagnosis of Reactive Ion Etching Using In Situ Metrology Data, *IEEE Transaction on Semiconductor Manufacturing*, 17(3), 408-421.

International Technology Roadmap for Semiconductors (ITRS) (2005) Metrology.

Iwai, H., Kakushima, K., and Wong, H. (2005), Challenges for future semiconductor manufacturing, *International Journal of high Speed Electronics and systems*, 16(1), 43-81.

John, P. W. M. (1990), *Statistical Methods in Engineering and Quality Assurance*, Wiley-Interscience, 144-163.

Kassidas, A., MacGregor, J. F., and Taylor, P. A. (1998), Synchronization of Batch

Trajectories Using Dynamic Time Warping, *AIChE Journal*, 44(4), 864-875.
 Kim, B. and May, G. S. (1997), Real-Time Diagnosis of Semiconductor Manufacturing Equipment Using Neural Networks, *IEEE Transaction on Components, Packaging and Manufacturing Technology-Part C*, 20(1), 39-47.
 Lada, E. E., Lu, J.-C., and Wilson, J. R. (2002), A Wavelet-Based Procedure for Process Fault, *IEEE Transactions on Semiconductor Manufacturing*, 15(1), 79-90.
 Rabiner, L., Rosenberg, A., and Levinson, S. (1978), Considerations in dynamic time warping algorithms for discrete word recognition, *IEEE Acoustics, Speech, and Signal Processing*, 26(6), 575-582.

Sakoe, H., and Chiba, S. (1978), Dynamic Programming Algorithm Optimization for Spoken Word Recognition, *IEEE Transactions on Acoustics, Speech, and Signal Processing*, ASSP, 26(1), 43-49.
 Salvador, S., Chan, P., and Brodie, J. (2004), Learning States and Rules for Time Series Anomaly Detection. In Proceedings of the 17th International Florida Artificial Intelligence Research Symposium.
 Su, Y.-C., Hung, M.-H., Cheng, F.-T., and Chen, Y.-T. (2006), A Processing Quality Prognostics Scheme for Plasma Sputtering in TFT-LCD Manufacturing, *IEEE Transaction on Semiconductor manufacturing*, 19(2), 183-194.



고종명

연세대학교 컴퓨터산업공학과 학사
 연세대학교 컴퓨터산업공학과 석사
 현재: 연세대학교 정보산업공학과 박사과정
 관심분야: 실시간 데이터 마이닝, SCM, Fault Detection and Classification




최자영

연세대학교 컴퓨터산업공학과 학사
 현재: 연세대학교 정보산업공학과 석사과정
 관심분야: 실시간 데이터 마이닝, RFID기반 물류정보시스템



김창욱

고려대학교 산업공학과 학사
 고려대학교 산업공학과 석사
 Purdue University 산업공학과 박사
 현재: 연세대학교 정보산업공학과 교수
 관심분야: 정보시스템 설계, RFID기반 물류시스템, 실시간 데이터 마이닝



선상준

중앙대학교 전자전기 제어공학부 학사
 중앙대학교 전자전기 제어공학부 석사
 현재: 삼성전자 기술총괄 생산기술연구소 선임연구원
 관심분야: Pattern Recognition, Fault Detection and Classification, Data mining



이승준

고려대학교 산업공학과 학사
 고려대학교 산업공학과 석사
 고려대학교 산업공학과 박사
 현재: 삼성전자 기술총괄 생산기술연구소 책임연구원
 관심분야: Fault Detection and Classification, Statistical Process Control, Pattern Recognition, Combination Optimization