

앙상블 학습을 이용한 DRAM 모듈 출하 품질보증 검사 불량 예측

김민석¹ · 백준걸^{2*}

¹SK하이닉스 / ²고려대학교 산업경영공학과

Fail Prediction of DRAM Module Outgoing Quality Assurance Inspection using Ensemble Learning Algorithm

Min-Seok Kim¹ · Jun-Geol Baek²

¹SK Hynix

²Dept. of Industrial Management Engineering, Korea University

The DRAM module is an important part of servers, workstations and personal computer. Its malfunction causes a lot of damage on customer system. Therefore, customers demand the highest quality products. The company applies DRAM module Outgoing Quality Assurance Inspection(OQA) to secures the highest quality. It is the key process to decides shipment of products through sample inspection method with customer oriented tests. High fraction of defectives entering to OQA causes inevitable high quality cost. This article proposes the application of ensemble learning to classify the lot status to minimize the ratio of wrong decision in OQA, observing a potential in reducing the wrong decision.

Keyword: decision tree(C4.5), ensemble learning, semiconductor manufacturing, DRAM module

1. 서론

반도체 산업은 차세대 기술과 공정이 지속 발전하는 고부가가치 산업인 동시에 과열 경쟁 산업으로 경쟁을 극복하기 위해 품질향상을 통해 수익창출을 한다(Pieter, 2000). 반도체 산업에서 생산되는 제품 중 DRAM 모듈은 많은 수익을 창출하는 제품이다(Kim, 2007). 하지만 DRAM 모듈 제품은 높은 품질을 유지 어렵기 때문에 품질유지를 위해 생산주기, 제작업율, 공정 변동, 공정재고, 수율 등을 관리해야만 한다(An *et al.*, 2009). <Figure 1>과 같이 많은 단위 공정을 통해 DRAM 모듈이 제작되기 때문에 공정관리만으로는 고객이 요구하는 품질을 만족시키기 어렵다. DRAM 모듈은 실리콘 웨이퍼 공정인 FAB(Fab-

rication Process)과 DRAM IC(Integrated Circuit)를 만드는 패키지(Package) 공정, DRAM IC를 모듈로 만드는 모듈 조립공정(Module Assembly)을 통해 제작된다. 또한 DRAM 모듈은 모듈검사(Module Test)공정에서 전기적 특성, Cell 및 동작문제를 검사하는 특성검사와 외관상의 문제를 검사하는 외관검사(Visual Test)를 거친다. 따라서 다중 제조공정(Multi Process)으로 생산되는 반도체 DRAM 모듈은 작은 변화에도 출하품질의 변동이 커질 수 있기 때문에 기업은 DRAM 모듈의 출하 품질보증(이하 '출하 품질보증 검사')을 위해 많은 노력을 한다(Aghaie, 2010).

<Figure 2>의 공정은 고객요구의 다양한 검사를 통해 불량 이 될 로트를 검출하고 불량으로 판정된 로트는 생산 공정에서 재검사(Retest)된다. 불량로트는 출하 품질보증 검사의 불량

이 논문은 2011년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2011-0002761). 본 과제는 정보통신산업진흥원의 SW공학 요소기술 개발과 전문 인력 양성사업의 결과물임을 밝힙니다.

*연락처 : 백준걸 교수, 136-701 서울시 성북구 안암동 5가 고려대학교 산업경영공학과, Fax : 02-929-5888, E-mail : jungeol@korea.ac.kr
투고일(2011년 12월 16일), 심사일(1차 : 2012년 01월 21일, 2차 : 2012년 03월 22일), 게재확정일(2012년 03월 22일).

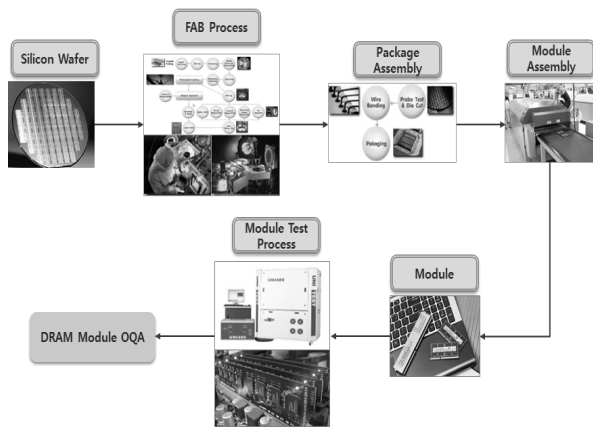


Figure 1. DRAM Module Manufacturing

률을 증가시킨다. 또한 공정이상으로 다량의 불량을 내재한 제품이 출하 품질보증 검사로 들어오면 불량률을 낮추기 위해 샘플 수량이 증가하게 됨으로 공정에 병목현상이 발생한다. 기업은 이러한 문제를 해결하기 위해 검사시간과 장비를 투자하여 불량률을 감소시키고, 재검사 로트를 처리하지만 많은 비용이 소모된다. 또한 불량로트의 출하로 인한 고객의 반품은 또 다른 비용손실을 가져올 수 있으므로 출하 품질보증 검사를 효율적으로 운영해야 한다. 출하 품질보증 검사의 불량률과 공정 처리시간을 개선하기 위해서는 모듈검사 공정의 데이터를 분석하여 불량과 양품을 예측할 수 있는 방법이 필요하다. 따라서 본 연구는 모듈 생산 검사공정의 데이터를 기반으로 하는 앙상블 학습(Ensemble Learning)으로 출하 품질보증 검사 전에 불량로트와 정상로트를 예측할 수 있는 방법을 제안하고자 한다.

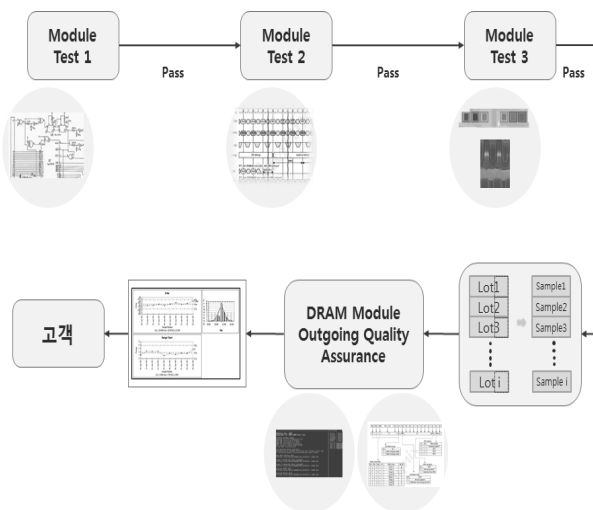


Figure 2. DRAM Module Outgoing Quality Assurance Inspection

불량검출의 기존연구는 FAB과 Probe 공정에 국한되어 연구가 진행 되었으며, DRAM 모듈 분야의 연구도 저가 모듈의 생산수율 예측 연구가 대부분이다. An et al.(2009)의 단계적 지

도벡터를 이용하여 Probe 검사의 수율을 예측하는 연구는 단계별 지지도벡터기계(Stepwise Support Vector Machine), 인공신경망(Artificial Neural Network)과 선형 판별분석(Linear Discriminant Analysis)의 성능을 비교했다. 이 가운데 단계별 지지도벡터기계(Stepwise Support Vector Machine)가 가장 좋은 성능을 나타냈다. 하지만 DRAM 모듈 분야가 아닌 Probe 공정의 수율 예측 분야였으며, 단계적 변수선택 방법은 다양한 입력변수들의 부분 집합을 고려하지 못하는 문제가 존재한다(Frank, 2005). Park et al.(2010)은 지지도벡터 회귀학습(Support Vector Machine Regression)으로 주기신호 데이터의 이상탐지를 통해 반도체 공정의 관리도 문제를 해결했다. Son and Yun(2011)은 지도학습 기법과 특정분포의 가정이 필요 없는 SVDD를 이용한 모니터링 모델로 공정의 이상을 탐지했다. 이처럼 다양한 수율예측과 불량감지연구가 진행되고 있지만 DRAM 모듈의 연구사례는 매우 적다. Shih and Shih(2009)은 파라미터 결정(Parameter determination)을 위해 스캐터 탐색(Scatter Search)으로 변수를 선택하고 지지도벡터기계 회귀 학습으로 저가 DRAM 모듈의 수율 예측 연구를 했다. Lee et al.(2008)의 연구에서는 Particle Swarm Optimization으로 변수를 선택하고 역전파 신경망 학습방법(Backpropagation Neural Network)을 사용하여 저가 DRAM 모듈의 수율을 예측했다. 두 연구 모두는 저가 DRAM IC(Integrated Circuit)로 DRAM 모듈을 만드는 경우를 근거로 하고 있으며 불량이 많은 상태에서 DRAM 모듈 수율을 예측하는 분야의 연구이다.

이처럼 제한적 자료를 바탕으로 하는 연구는 실제 현업에 적용하기 어려운 일반화 문제를 내포한다. 하지만 본 연구는 기존의 소량의 시뮬레이션 데이터 사용 시 발생하는 문제를 해결하기 위해 실제 반도체 DRAM 모듈 공정의 데이터를 사용한다. 몇 개의 구축된 모형을 조합하여 정확도가 향상된 모형을 만드는 앙상블 학습방법을 사용한다(Han and Kamber, 2006). 앙상블 학습에 사용된 분류 알고리즘은 다양한 연구에서 뛰어난 분류성능을 나타낸 지지도벡터기계, 인공신경망, 의사결정나무(C4.5), REPTree, ADTree를 사용한다. 이 학습방법 중 분류 성능이 뛰어난 학습방법을 선택하여 출하 품질보증 검사의 불량로트와 정상로트를 예측하며, 생산의 이원화된 검사공정을 제안한다. 본 연구의 제 2장에서서는 출하 품질보증 검사에 대해 구체적인 설명과 함께 변수선택 방법, 데이터와 앙상블 학습, 다양한 학습방법과 실험방법에 대해 설명한다.

2. 앙상블 데이터마이닝을 이용한 DRAM 모듈의 불량예측

2.1 DRAM 모듈 출하 품질보증 검사

출하 품질보증 검사는 모듈 생산 공정을 모두 거친 후 합격된 로트만이 들어오는 공정이며, 샘플링을 통해 모든 로트를 동일한 조건으로 검사하고 출하여부를 결정한다. 이 공정에서

불량으로 판정된 로트는 기존 생산조건보다 강한 조건으로 재검사된다. <Figure 3>은 모듈조립공정 후에 출하 품질보증 검사까지의 모든 절차를 나타낸 것으로 반도체 회사의 관리기준과 고객환경의 검사 장비를 사용하여 고객이 요구하는 DRAM 모듈 내부 I/O(Input/Output)간의 신호를 바탕으로 하는 전기적 이상 검사, 기능상(Function) 특성인 DRAM 모듈 내부의 신호를 통한 데이터 전송과 관련된 오류를 검사와 고객 환경에서의 동작 특성을 검사하는 공정으로 이루어져있다. 출하 품질보증 검사는 출하제품의 반품과 영업이익과도 직접적인 관련이 있는 핵심공정이며 기업의 품질수준을 대변한다.

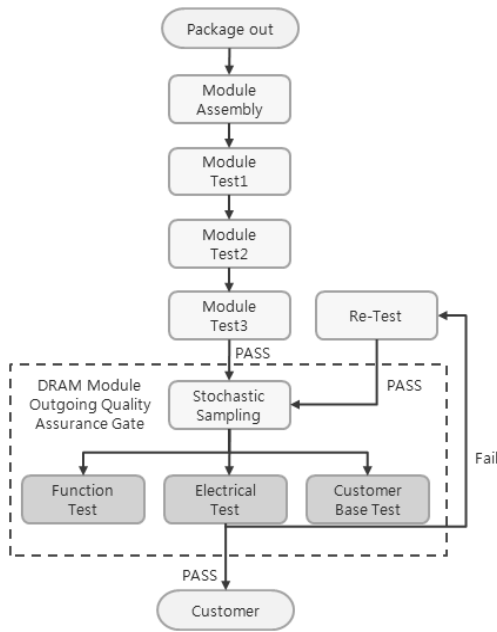


Figure 3. Current DRAM Module Test Process

DRAM 모듈의 경우 최종 제품인 노트북, 서버(Server), 개인용 PC에 사용되기 때문에 고객은 출하되는 제품의 모든 로트에 대해 검사를 요구하고 고품질의 제품이 출하되기를 요구한다(Leon, 1987). 또한 고객은 다양한 출하검사방법을 요구한다. 특히 출하품질은 통계적 품질관리 등의 다양한 방법으로 이루어

진다(Kwok and Tommla, 1998). 이 방법 중 기업은 고객이 요구하는 평균출하품질(Average Outgoing Quality) 관리를 사용하여 불량률을 관리한다(Leon, 1987). 평균 출하품질은 출하 품질보증 검사에서 품질을 관리하는 주요한 관리지표이다. 다량의 불량을 내재한 로트가 출하 품질보증 검사로 들어오면 불량률이 증가하고 동시에 공정의 병목현상이 발생한다. 따라서 비용과 시간의 손실이 발생한다. 또 다른 문제는 현재 검사에서 단변량 데이터 분석방식만으로는 다중 공정에서 나오는 다양한 파라미터간의 관련성과 누적된 파라미터에 의해 변화된 오차를 알 수 없다(Jang, 2009). 따라서 단변량 데이터 분석을 통해 특정 공정문제를 파악하는데 많은 시간이 소모된다. 하지만 고객은 빠른 검사 시간과 다수의 관리기준을 요구하기 때문에 납기의 문제도 존재한다. <Figure 3>의 출하품질 검사 이전에 불량이 될 로트를 예측하는 분류공정을 적용하면 출하 품질보증 검사의 불량을 줄이는 동시에 공정 병목현상을 해소하고 비용을 줄일 수 있다. 특히 다중공정인 반도체 공정의 불량 원인파악 시간이 감소하며, 이를 통해 다량의 불량이 발생하는 시기에 납기문제와 품질문제를 동시에 해결 할 수 있다.

2.2 대상 데이터

본 연구는 국내 반도체 제조회사 H사의 DRAM 모듈 생산 검사공정의 데이터를 사용했다. 공정의 데이터 예는 <Table 1>과 같으며, <Figure 4>은 기술한 공정의 데이터가 기록되는 공정이다. 모듈 검사 1, 2, 3의 모든 변수를 A_i 로 정의한다. 변수 A_i 는 모듈 생산 검사 공정의 센서에서 발생하는 변수는 67개 ($A_i, i = 1, 2, 3, \dots, 67$)이다. 출하 품질보증 검사의 정상과 불량률의 로트를 $O_j(j = Lot Number)$ 로 정의하며 불량로트는 '0'으로 정상로트는 '1'로 표시한다.

2.3 학습을 위한 변수 선택

일반적인 데이터 집합에는 학습에 영향을 미치지 않은 데이터가 포함되어 있으며 분류성능에 영향을 준다. 따라서 데이터에 섞여 있는 잡음을 최소화하기 위해 변수선택 과정이 필

Table 1. Example of DRAM Module Test Data

A_1	A_2	A_3	A_4	A_5	A_6	A_7	A_{20}	A_{21}	A_{22}	A_{23}	A_{24}	A_{25}	A_{26}	A_{27}	A_{28}	A_{29}	A_{30}	A_{31}	A_{32}	A_{33}	A_{34}	A_{35}	A_{36}	A_{37}	A_{38}	A_{66}	A_{67}	O	
4	2	1	1	1	1	3	3	3	1	2	3	6	1.58	1.58	1	1	6	2	6	1	1	1	1	1	1	8	6	2	0
2	7	4	1	14	4	2	1	1	1	1	1	6	1.42	1.59	6	3	1	3	3	1	8	1	1	1	1	1	6	2	1
2	6	16	6	5	16	1	1	4	1	1	1	6	1.42	1.42	3	1	3	6	6	1	4	1	3	1	2	6	3	1	
2	1	4	2	1	6	6	7	1	2	1	1	6	1.42	1.42	3	6	1	1	3	1	1	4	1	1	6	6	2	1	
2	15	5	15	6	2	4	2	1	1	1	1	6	1.58	1.58	1	1	1	1	1	2	1	1	1	1	1	6	3	1	
4	1	13	1	1	13	13	1	8	3	1	1	6	1.6	1.58	3	1	1	2	3	6	5	1	1	2	1	1	1	1	1
2	16	15	16	6	6	14	1	6	2	1	1	6	1.42	1.58	1	1	1	1	1	1	1	1	1	1	2	6	1	1	
4	1	1	1	4	1	2	3	2	9	1	3	6	1.42	1.42	1	1	3	3	2	3	1	1	1	1	1	6	3	1	
2	16	12	15	1	12	2	8	1	3	4	1	6	1.42	1.41	2	3	1	1	2	1	2	1	1	1	3	6	1	0	
2	13	4	4	6	6	4	1	1	1	1	1	6	1.42	1.42	1	4	4	1	1	3	1	1	1	2	1	6	3	0	
2	6	3	4	13	15	1	1	7	1	1	2	6	1.42	1.42	1	1	3	1	3	1	1	1	3	1	1	6	2	0	

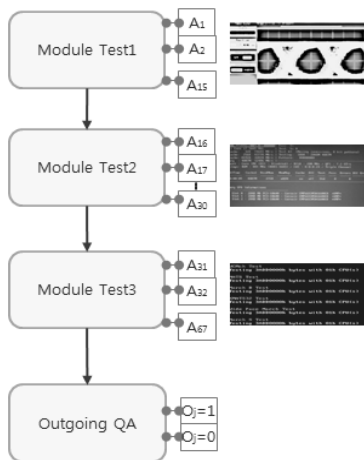


Figure 4. The Measurement of DRAM Module Test

요하다. 본 연구는 학습의 효과를 높이고 잡음을 최소화하기 위해 Meinshausen and Buhlmann(2010)에 의해 제안된 Stability selection을 사용했다. Stability Selection은 학습방법의 성능을 높일 수 있는 변수선택법이다(Shan and Richard, 2011). 본 연구에서 사용한 Stability Selection은 Lasso의 방법에 부분집합(Subset)의 개념을 적용한 학습방법으로 데이터를 $[n/2]$ 의 subsample로 구성하여 임의로 여러 번 적용하는 방식이며, 이를 통해 subsample에서 가장 빈도가 높은 변수를 선택한다. 기존의 방법론인 LARS, Lasso, 단계적 회귀 분석(Stepwise Regression Analysis) 등의 변수선택(Variable Selection)방법은 지역최적화(Local Optimal) 문제가 있다(Kim *et al.*, 2009). 본 연구에서 사용한 Stability selection은 지역최적화 문제가 개선되었으며 일반적으로 변수선택이 어렵고 잡음수준을 알지 못하는 경우에도 다른 변수선택법 대비 강건(robust)하다(Meinshausen and Buhlmann, 2010). 특히 실험 데이터는 <Figure 5>와 같이 주성분 분석결과 변수간의 상관관계로 인해 데이터의 변수에 따른 분류가 어렵다.




Figure 5. Result of Principle Component Analysis

따라서 확률을 확인할 수 있는 방법 중 앞의 장점을 갖는 Stability Selection 변수선택법을 사용했다. 학습을 위해 <Table 1>과 <Figure 4>에서 기술한 67개의 변수의 데이터를 사용했다. 변수선택을 하기 위해 일반적으로 다양한 분야에 사용되는 R 통계 패키지를 사용했다. Bootstrap과 n번의 Step을 사용한 Vert

(2010)에 의해 제안된 R의 Stability selection을 사용하여 98% 신뢰도로 변수를 추출했다. <Figure 6>의 결과를 바탕으로 67개 변수 중에서 41개를 선택했다.

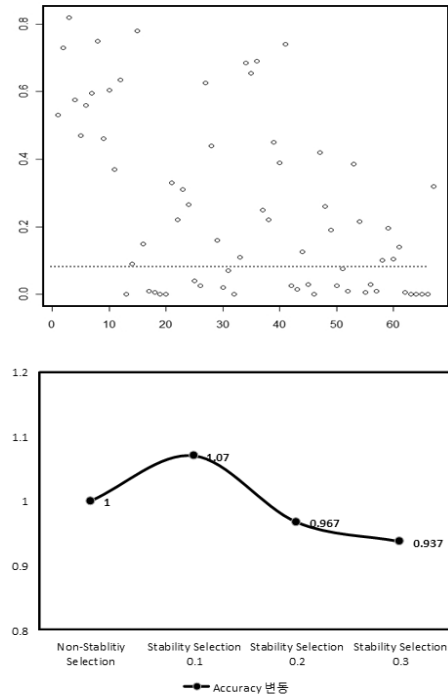


Figure 6. Stability Selection Accuracy

2.4 이상불 학습을 통한 분류성능 향상

본 연구는 선택된 변수를 사용하여 이상불 방법과 함께 5가지 학습방법으로 실험했다. 성능비교에 사용한 학습방법 중 첫 번째는 지지도벡터 분류기로(Cortes and Vapnik, 1995) FAB 수율 및 DRAM 모듈 수율예측 등의 다양한 분야에서 활용됐다. 두 번째 의사결정나무는 Quinlan에 의해 1986년에 개발된 학습방법인 의사결정나무로 속성 값들이 결과에 영향을 주는 지 파악하기 쉬우며 모듈 공정에서 나오는 명목형(Categorical) 값들에 대해서도 전처리 없이 분류를 진행할 수 있으며, 특히 학습시간이 다른 알고리즘에 비해 짧은 장점을 가지고 있다(Han and Kamber, 2006). 세 번째는 지지도벡터 분류기와 함께 보편적으로 사용되는 인공신경망으로 학습 성능이 뛰어나다. 네 번째로 Reduced error-pruning을 사용한 이진분류기인 REP Tree를 사용하였다(Khoshgoftaar *et al.*, 2007). 마지막으로 이진분류에서 효과적인 성능을 나타내는 ADTree(Freund and Mason, 1999)를 사용했다. 이상불 학습방법인 부스팅(Boosting)과 배깅을 5가지 학습방법과 조합한 방법으로 실험했다. 이상불 방법은 일반적으로 알고리즘의 분산을 줄이고 학습이 바이어스 되는 것을 방지한다(Breiman, 1996). 또한 클래스 불균형 데이터 분석에 효과적이다(Kang *et al.*, 2006). <Figure 7>은 이상불 학습의 절차를 나타낸다. 데이터 집합 D_k 를 사용하여 모델 M_k 를 구축하

고 각기 다른 새로운 데이터 D_j 가 들어오면 앙상블 학습은 최적의 학습방법을 구성한다. 새로운 관찰 값의 클래스를 부여한다. 따라서 본 연구에서는 다양한 학습방법을 적용한 앙상블 학습을 통해 출하 품질보증 검사의 불량로트와 정상로트를 예측한다.

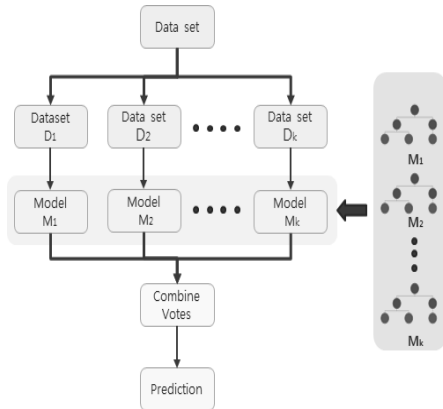


Figure 7. The Logical Flow of Ensemble Learning

본 연구에서 사용한 통계 프로그램은 일반적으로 비즈니스와 학계의 연구에 많이 사용되고 다양한 학습방법을 지원하는 Waikato 대학의 웨카(Weka) 3.6이다(Mark, 2009). 이 실험에서 앙상블 방법은 웨카의 배깅과 아다부스트(AdaBoost)를 사용했다. 또한 파라미터로는 높은 분류성능을 보인 기본 값을 사용했다.

3. 실험계획 및 결과

3.1 실험환경

본 연구의 실험은 일반적으로 분류성능이 좋은 5가지 학습방법을 앙상블 방법에 적용하여 출하 품질보증 검사의 불량로트와 정상로트를 효과적으로 예측하는 모델을 구축한다. 이를 통해 현업의 분류공정 적용가능성을 평가한다. 성능평가를 위해 국내 반도체 제조기업인 H사의 2011년 3, 4, 5월의 모듈 검사공정에서 수집된 공정데이터는 불량로트 41.4%와 정상로트는 58.6%로 구성된다. 또한 수율 및 기타 생산 공정의 파라미터들이 변수로 간주되었다. 특히 검사장비에서 나오는 데이터는 모듈 기능상의 특성을 검사하는 항목과 전기적 특성, 반도체 셀(Cell) 특성 및 실제 사용자의 환경에서 문제가 될 수 있는 값들이 발생한다. 수집된 1500로트는 모형검증을 위해 총 90%의 데이터를 사용하고 모형구축을 위해 나머지 10% 데이터를 사용한다. 불량로트 비율로 구성된다.

<Figure 8> 실험절차를 나타내고 <Table 2>의 10가지 앙상블 학습을 사용하여 분류성능을 비교했다. 모형검증용 로트는 10-교차 타당법(10-fold Cross Validation)을 사용하여 최소의 오차를 나타낼 수 있게 분류 모델을 평가한다(Kang, 2007).

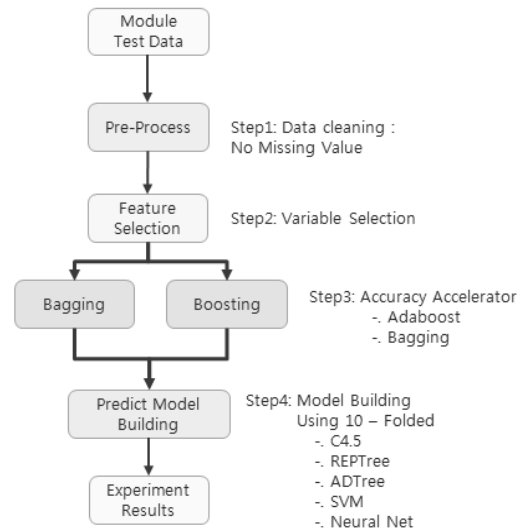


Figure 8. Experiment flow

Table 2. The Combination of Ensemble Learning

구 분	앙상블
No.1	Boosting Support Vector Machine
No.2	Boosting C4.5
No.3	Boosting Neural Network
No.4	Boosting REPTree
No.5	BoostingADTree
No.6	Bagging Support Vector Machine
No.7	Bagging C4.5
No.8	Bagging Neural Network
No.9	Bagging REPTree
No.10	BaggingADTree

3.2 결과 및 성능평가

본 연구는 앙상블 학습의 예측 정확도 비교와 출하 품질보증 검사 시 불량로트 감소율 결과를 품질비용으로 계산하여 성능평가 척도로 사용한다. 첫 번째 성능평가 척도인 예측 정확도는 전체 데이터 중에서 클래스를 정확하게 예측하는 비율을 의미하며(Kang et al., 2004), 식 (1)과 같다. 두 번째 성능평가 척도는 제 3.3절에서 다룬다.

• Classification Accuracy :

$$= \frac{TP + FN}{TP + FN + TN + FP} \quad (1)$$

TP : True Positive

FN : False Native

TN : True Native

FP : False Positive

첫 번째 분류기의 예측 정확도 성능평가의 결과는 <Figure 9>와 같다. 예측 정확도 평균과 표준오차에 대해 배깅과 AD Tree 조합(No.10), 배깅과 REPTree 조합(No.9), 배깅과 의사결정나무 조합(C4.5, No.7)이 우수한 성능을 나타냈다. 배깅과 REPTree 조합(No.9)은 77.04%의 예측 정확도를 보였지만 배깅과 의사결정나무 조합(C4.5)보다 1.7%p 낮게 나타났다. REPTree는 데이터에서 작은 특성의 변화가 생기면 분류의 결과가 변하는 불안정한 분류 문제가 있다(Kotsiantis, 2007).

반면 지지도벡터 기계과 인공신경망은 앙상블 학습 후에도 분류 성능은 크게 증가하지 않았으며, 표준오차도 감소하지 않았다. 배깅과 의사결정나무(C4.5, No.7)의 조합이 78.74%로 다른 알고리즘 대비 최소 1.7%p 높은 예측 정확도를 나타냈다. 표준오차도 0.46으로 최소 0.41 낮은 오차를 보였다. 따라서 앙상블 학습방법 중 배깅(Bagging)과 의사결정나무(C4.5)를 조합한 학습방법이 가장 뛰어난 예측 정확도를 나타냈다.

Breiman(1996)의 배깅(Bagging) 학습방법은 의사결정나무 예측 정확도를 향상 시키고, Breiman(1996)의 실험에서도 의사결정나무는 인공신경망과 다중판별식보다 뛰어난 성능을 보였다.




Figure 9. Experiment Result

의사결정나무는 학습시간이 다른 학습방법에 비해 짧으며, 조정하는 파라미터의 값들이 복잡하지 않고, 다른 학습 방법과 달리 다중 공정에서 나타나는 값들이 정규분포로 되어있지 않은 경우도 적용 가능하다(Son et al., 2009). 또한 공정 데이터의 검사항목 중 어떤 항목이 공정에 문제가 되는지를 직관적으로 설명할 수 있다. 따라서 본 연구는 의사 결정나무를 사용

한 앙상블 학습 방법을 사용하여 실제 출하 품질보증 검사의 불량을 예측했다.

3.3 분류기를 이용한 출하 품질보증 검사의 불량예측 공정 제안

기존 출하 품질 보증 검사방식은 불량을 다량으로 내재한 제품이 들어오면 불량률이 증가하고, 공정의 병목현상으로 인해 검사 비용이 증가한다. 따라서 출하 품질보증 검사의 불량률을 줄이기 위해 본 절에서는 제 3.1절, 제 3.2절의 실험에서 기술한 학습방법을 사용하여 출하 품질보증 검사에서 정상로트와 불량로트를 예측하는 분류공정을 제안한다. <Figure 10>은 제안하는 분류기를 사용한 분류공정으로써 Module Test 1, 2, 3의 검사 항목을 기반으로 하고, 배깅과 의사결정나무를 결합한 앙상블 학습을 통해 분류된 로트를 Module Test 4로 전달한다. Module Test 4는 학습 시 사용된 검사항목 중 유의한 항목을 선별하여 재검사하는 공정으로써 <Figure 3>의 생산 재검사 공정의 통상적인 검사시간 보다 적은 시간으로도 불량을 효율적으로 검출할 수 있다. 또한 Module Test 4에서 불량로트가 선별되어 분류기의 성능만큼 출하 품질보증 검사의 불량로트가 감소한다.

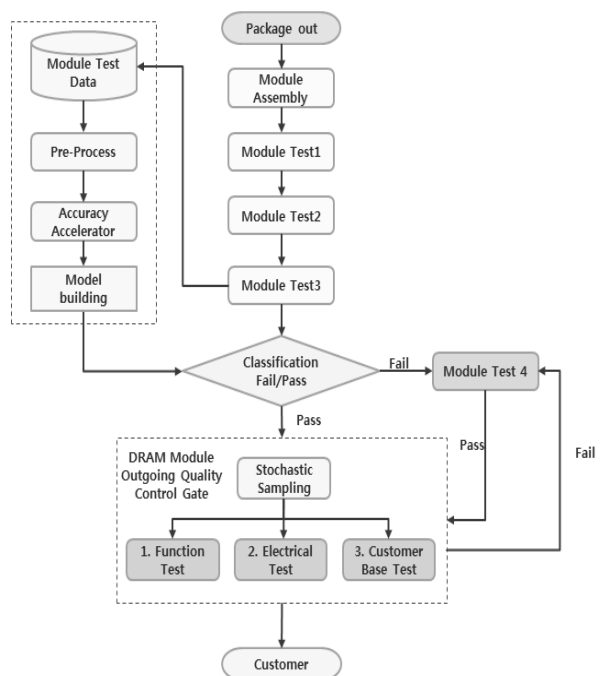


Figure 10. Classification Process of OQA using Ensemble Learning

특히 출하품질에 문제가 되는 불량로트를 정상로트로 예측하는 경우에도 출하 품질보증 검사에서 선별됨으로 실제 고객 품질에는 영향을 주지 않는다. 식 (2)는 분류기에서 불량로트지만 오분류 되는 비율을 나타냄과 동시에 출하 품질보증 검사 불량로트의 감소율을 의미한다.

출하 품질 검사 불량 발생 Lot 비율 :

$$\text{검사 불량 발생 Lot} = \frac{PP}{TF} \times N \quad (2)$$

N : 출하 품질보증 검사 불량 Lot 수(N)

PP : Predict Pass(실제 불량 중 예측 정상 제품)

TP : True Fail

<Figure 11>은 식 (2)를 사용하여 평가한 결과이다. 출하품질 불량률은 출하 품질보증 검사에서 발생된N개의 불량로트가 분류공정을 통해 $N \times (PP/TF)$ 비율로 줄어든 비율을 나타낸다. 10가지 학습방법 중 배깅과 의사결정나무(C4.5, No.7)를 조합한 분류기는 불량로트 비율이 34%로 감소시키며 타 경우보다 2%p 이상의 불량로트 감소 효과를 보인다. 하지만 아다부스트와 인공신경망 조합(No.3)의 경우는 줄어든 불량로트 비율이 47% 수준으로 발생하기 때문에 다른 학습방법 대비 적용효과가 떨어진다. 따라서 출하 품질 보증 검사 시 투입되는 불량로트가 감소한다.




Figure 11. Reduction rate of Reject Lots in OQA

불량의 감소율을 사용하여 성능평가의 척도인 품질비용을 계산한다. 품질비용(Quality Cost)은 품질관리 활동의 효과와 경제성을 평가하며, 국제적으로 인정받는 Feigenbaum(1956)이 제창한 품질비용을 사용한다. 품질비용은 불량품 발생을 막기 위해 소모되는 예방비용(Prevention Cost), 시장에서 불량을 발생시키지 않기 위해 사용하는 평가비용(Appraisal Cost)와 품질

불량에 의해 발생하는 사내 실패비용과 사외 실패비용인 실패비용(Failure Cost)으로 구성된다. <Table 3>은 Feigenbaum(1956)의 분류 기준에 따른 품질비용을 내부 인건비와 모든 관리비용을 포함하는 내부 기준에 근거하여 품질그룹에서 산출했다. 적용전의 비용은 기준 값으로 비교를 위해 '1'로 산출했다. 산출했다. 적용 후 품질비용은 앙상블 학습 방법 중 <Figure 9>와 <Figure 11>에서 효과가 가장 좋은 배깅과 의사결정나무(C4.5, No7)를 조합한 분류기 적용 결과를 바탕으로 산출됐다.

Table 3. Comparison of Quality Cost

분류	정의	적용 전	적용 후	
품질 비용	예방 비용	품질계획	1	0.8
		Design Review	1	1
		설계사항의 명세화	1	0.8
		품질 Data의 수집분석	1	1
		품질에 관한 보고	1	0.8
		교육 훈련	1	1.2
		기타	1	1
	검사 비용	품질관리(수입검사 포함)	1	1
		Process Control Cost	1	1
		최종 제품의 관리	1	0.7
Test 기기의 Maintenance test		1	1	
실패 비용	사내 실패 비용	스크랩	1	1
		Rework	1	0.5
		재시형	1	1
		설비 유휴	1	1
		고장 수리	1	1
		기타	1	1
	사외 실패 비용	Claim	1	1
		보증	1	0.6
		반품	1	1
		기타 관련	1	1

<Table 3>의 품질비용의 세부적인 항목들은 아래와 같다.

(1) 예방비용

사전에 불량 발생을 예방에 필요한 비용으로 설계, 인사, 품질과 제품과 관련된 분야에 소모되는 비용을 포함한다. 또한 예방과 측정의 비용도 포함되어 있다.

(2) 평가비용

DRAM 모듈의 관리기준을 평가하는 비용과 불량을 선별하기 위한 검사에 수반되는 모든 비용이 포함된다.

(3) 사내 실패 비용

DRAM 모듈의 출하이전에 출하 품질보증 검사의 불량을 개선하기 위해 필요한 비용과 제반된 장비의 유지보수 비용을 포함한다.

(4) 사의 실패 비용

DRAM 모듈 출하 후에 고객으로부터 요청되는 반품, 재검사와 운송비용을 포함한 고객의 요구사항을 수행하는데 소모되는 모든 비용이다.

품질비용 중 교육훈련 비용만이 '0.2' 증가하며 교육훈련 비용의 증가는 데이터 마이닝 학습방법의 적용으로 인한 엔지니어 교육비가 포함되었기 때문이다. 교육비를 제외하고 품질계획, 품질 데이터의 수집분석, 최종제품의 관리, 제작업, 보증비용은 모두 감소했다. 따라서 현재 공정에서 소모되는 '22' 품질비용 대비하여 배경과 의사결정나무(C4.5, No.7) 분류공정을 적용한 후의 품질비용이 '19.6'으로 품질비용이 '11%' 감소한다. 특히 실패비용이 가장 크게 감소했으며, 실패비용 중 반품과 Claim 비용은 최소 3개월 후에 고객을 통해 통보받을 수 있는 비용임으로 고객 통보 후에 비용을 재 산출하면 감소효과가 증가 할 것으로 기대된다.

4. 결론 및 추후 연구

본 연구는 기존의 데이터마이닝 학습방법을 실제 기업의 사례에 적용한 연구로써 정상로트와 불량로트를 예측하는 학습방법을 제안한다. 수집된 로트 데이터를 사용하여 분류 성능을 최대화 할 수 있는 양상불 학습을 통해 모형을 구축하고, 동일한 현장의 데이터로 성능을 비교 했다. 성능평가 결과 배경과 의사결정나무(C4.5)를 조합한 모형의 우수성을 확인했고 현업 적용가능성도 확인했다. 또한 다른 검사공정에서도 본 연구가 제안하는 분류공정에 적용할 수 있을 것으로 판단된다.

하지만 본 논문은 보다 효율적인 검사 공정을 제안하기 위해 불량로트의 예측 정확도를 높이는 연구가 필요하며 양상불 학습 시 사용되는 입력 파라미터를 선택하는 방법에 대한 연구 및 유의한 검사항목 선택을 위한 효율적인 변수선택방법에 대한 추후연구도 필요하리라 판단한다. 실제로 현장 적용 시 현업 엔지니어와 협업연구를 통해 모든 분야에서 직면할 수 있는 변수선택에 문제를 해결할 수 있다면 분류 성능을 더욱 향상시킬 수 있을 것으로 기대한다.

참고문헌

Aghaie, A., Samimi, Y., and Asadzadeh, S. (2010), Monitoring and diagnosing a two-stage production process with attribute characteristics, *Iranian Journal of Operations Research*, 1-16.
 An, D. W., Ko, H. H., Baek, J. G., Kim, S. S., and Kim, J. Y. (2009), A Yield

Prediction in the Semiconductor Manufacturing Process Using Stepwise Support Vector Machine, *IE Interfaces*, 252-253.
 Cortes, C. and Vapnik, V. (1995), Support-vector networks, *Machine Learning*, 273-297.
 Freund, Y. and Mason, L. (1999), The alternating decision tree learning algorithm, *Proceeding of the Sixteenth International Conference on Machine Learning*, 124-133.
 Frank, V. G. (2005), LARS Library : Least angle Regression Stagewise Library www.applied-mathematics.net/identification/LARSLibdoc.pdf.
 Han, J. and Kamber, M. (2006), K-Folded Cross Validation, *Data Mining*, 344-345.
 Jang, D. J. and Bae, S. J. (2009), Hybrid Dcataming Algorithm for Monitoring Input Variables in Semiconductor Manufacturing Process, *Conference of the Korean Institute of Industrial Engineers*, 1-7.
 Kang, S. P., Cho, S. J., and Lee, H. J. (2006), Ensemble of Under-Sampled SVMs for Data Imbalance Problems, *Neural Information Processing*, 837-846.
 Khoshgoftaar, T. M., Jason, V. H., Chris, S., and Zhao, L. (2007), The multiple imputation quantitative noise corrector, *Journal of Intelligent Data Analysis*, 11, 245-263.
 Kim, D. I., Park, J. S., Beak, J. G., and Kim, S. S. (2009), Multi-objective Genetic Algorithm for Variable Selection in Linear Regression Model and Application, *Journal of Korea Society for Simulation*, 137-148.
 Kim, Y. J. (2007), In the second half of the semiconductor industry outlook, *Industrial Research*, 1-20.
 Kotsiantis, B. S. (2007), Combining Bagging and Additive Regression, *Journal of Computational and Mathematical Sciences*, 62-67.
 Kwok, K. Y. and Tummala, V. M. (1998), A quality control and improvement system based on the total control methodology (TCM), *Journal of Quality and Reliability Management*, 13-48.
 Lee, Z. J., Ying, K. C., Chen, S. C., and Lin, S. W. (2008), Applying PSO-based BPN for predicting the yield rate of DRAM modules produced using defective ICs, *Journal of Advanced Manufacturing Technology*, 9-12.
 Leo, B. (1996), Bagging Predictors, *Machine Learning*, 123-140.
 Meinshausen, N. and Bühlmann, P. (2010), Stability selection, *Journal of the Royal Statistical Society*, 417-473.
 Park, S. H., Kim, J. S., Kim, S. S., Park, C. S., and Baek, J. G. (2010), A Fault Detection of Cyclic Signals Using Support Vector Machine-Regression, *Journal of The Korean Operations Research and Management Science Society*, 354-362.
 Pesotchinsky, L. (1987), Problems Associated with Quality control Sampling in Modern IC Manufacturing, *IEEE Transaction on Hybrids and Manufacturing Technology*, 101-107.
 Pieter, P. B. (2000), 2000 Begins with a revised industry roadmap, *Solid State Technology*, 31-44.
 Shah, R. and Richard, J. (2011), Variable selection with error control, *Another look at Stability Selection arXiv.org*, 1-33.
 Shih, W. L. and Shih, C. (2009), Predicting the Yield Rate of DRAM Modules by Support Vector Regression, Global Perspective for Competitive Enterprise, *Economy and Ecology Advanced Concurrent Engineering*, 747-755.
 Son, J. H., Ko, J. M. and Kim, C. O. (2009), Feature Based Decision Tree Model for Fault Detection and Classification of Semiconductor Process, *IE Interfaces*, 126-134.
 Son, Y. T. and Yun, D. K. (2011), Detection to Non-linear Multivariate Process Using Supervised Learning Methods, *IE interfaces*, 8-14.

**김민석**

광운대학교 전기공학과 학사
 현재 : SK하이닉스 품질보증실
 고려대학교 산업공학과 석사과정
 관심분야 : 데이터마이닝, FDC

**백준걸**

고려대학교 산업공학과 학사
 고려대학교 산업공학과 석사
 고려대학교 산업공학과 박사
 현재 : 고려대학교 산업경영공학과 부교수
 관심분야 : 첨단공정제어, 지능형 이상 진단,
 데이터마이닝 응용