

프로브 검사 결점 수 데이터를 이용한 패키지 칩 품질 예측 방법론

박진수 · 김성범[†]

고려대학교 산업경영공학과

Predicting Package Chip Quality Through Fail Bit Count Data from the Probe Test

Jin Soo Park · Seoung Bum Kim

Department of Industrial Management Engineering, Korea University

The quality prediction of the semiconductor industry has been widely recognized as important and critical for quality improvement and productivity enhancement. The main objective of this paper is to predict the final quality of semiconductor chips based on fail bit count information obtained from probe tests. Our proposed method consists of solving the data imbalance problem, non-parametric variable selection, and adjusting the parameters of the model. We demonstrate the usefulness and applicability of the proposed procedure using a real data from a semiconductor manufacturing.

Keywords: Quality prediction, Probe test, SMOTE, Non-parametric feature selection

1. 서론

높은 품질의 제품은 고객 만족도 향상과 함께 신뢰도를 높여 기업 경쟁력을 높인다. 이러한 이유로 현재 많은 제조 기업들이 품질 향상을 위하여 다각적인 노력을 기울이고 있다(Kang and Kim, 2011). 한국 반도체 산업은 2013년 세계 반도체 칩 판매액 3,179억 달러 가운데 501억 달러(15.8%)를 차지하며 2위에 오른 것으로 추정되고 있다(Yoon, 2014). 이처럼 반도체 시장은 계속 성장하고 있으며, 제조업체들은 그 안에서 경쟁력을 유지하기 위하여 신제품 조기 개발, 양산성 향상, 품질 관리 등에 집중하고 있다. 품질 관리는 크게 사전 예측과 사후 관리로 나눌 수 있다. 전자는 제조 공정 변수 및 제품 특성에 따른 품질을 예측하여 사전에 불량을 방지하는 것이고, 후자는 고객 클레임이 발생하였을 때 이에 따른 대응 및 조치를 하는 것이다. 기업의 신뢰도를 높이기 위해서는 무엇보다 품질 예측 및 그에 따른 불량률의 사전 감지 및 조치가 중요하다고 볼 수 있다.

반도체는 200~300여 개의 정밀하게 구성된 단위 공정들로 제조되며, 최종제품이 나올 때까지 일반적으로 3~4개월이 걸린다. 반도체 공정은 FAB(Fabrication) 공정, 프로브 검사(Probe test), 조립(Assembly), 패키지 검사(Package test) 등 4단계로 구분할 수 있으며, <Figure 1>과 같이 설명할 수 있다(Baek and Nam, 2002; Chen *et al.*, 1988).

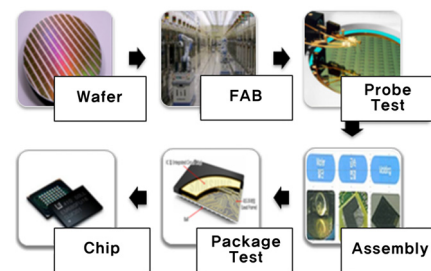


Figure 1. Semiconductor Manufacturing Process

제10회 석사논문경진대회 수상논문.

[†] 연락저자 : 김성범 교수, 136-701 서울시 성북구 안암로 145 고려대학교 산업경영공학과, Tel : 02-3290-3397, Fax : 02-929-5888,

E-mail : sbkim1@korea.ac.kr

2015년 2월 9일 접수; 2015년 4월 18일 수정본 접수; 2015년 5월 11일 게재 확정.

반도체 공정의 약 80%를 차지하는 FAB 공정은 순수한 웨이퍼(Wafer)에 포토, 에치 공정 등의 단위 공정을 거치며 수백~수천 개의 칩을 형성하는 공정이다. 프로브 검사는 웨이퍼에 형성된 칩에 전류를 흘려 불량 여부를 판별하는 단계이며 조립 공정은 프로브 검사를 통과한 칩들을 웨이퍼에서 분리하여 외부의 물리적 충격으로부터 보호하기 위한 패키징을 하는 공정이다. 패키지 검사는 사용자가 사용하는 환경보다 열악한 환경에서 검사하여 칩의 최종 불량 여부를 판별하는 단계이다 (Kim and Baek, 2014; Kumar *et al.*, 2006).

프로브 검사는 칩별 데이터가 발생하는 최초 단계이며, 레이저 리페어가 진행되는 중요한 공정이다. <Figure 2>는 본 논문에서 다룬 결점 수 데이터가 생성되는 프로브 검사에 관하여 자세하게 설명하고 있다. FAB 공정을 거쳐 형성된 웨이퍼 내의 칩들은 프로브 검사를 통하여 정상 칩과 불량 칩으로 구분된다.




Figure 2. Probe Test Process

하지만 정상 칩도 다수의 결점을 가지고 있다. 현재의 반도체 메모리는 수십 나노 단위의 미세 공정으로 만들어진다. <Figure 3>과 같이 한 장의 웨이퍼는 수백~수천 개의 칩으로 이루어져 있으며, 한 개의 칩에는 기가 단위의 셀(cell)이 존재한다. 이 하나하나의 셀 안에 0과 1이라는 데이터를 저장하여 반도체 메모리가 동작하는데 이처럼 수십 나노 단위의 미세 공정으로 기가 단위의 셀을 만들기 때문에 모든 셀을 무결점으로 하기는 불가능하다. 그러므로 결점을 없애기 위한 공정이 필요하다. 제품 설계 시 치료를 위하여 만든 여유 셀(Spare Cells)의 집합을 리던던시(Redundancy)라고 하며, 여유 행(Spare rows)과 여유 열(Spare columns)로 분할되어 있다. 이 리던던시를 사용할 수 있게 하는 공정을 레이저 리페어(Laser Repair)라고 하며, 이 공정을 통하여 결점 셀을 여유 셀로 대체하여 칩을 양품으로 만들어 수율을 증가시킨다. 대체할 수 있는 여유 셀보다 결점이 많으면 해당 칩을 불량 칩으로 판별할 수밖에 없지만, 여유 셀보다 결점이 적다면 치료하여 양품으로 만드는 것이 효율적이다(Suh and Lee, 2002).

이 레이저 리페어를 완료한 웨이퍼가 리페어가 잘 되었는지 최종 검사(Final Test)를 통하여 검증한 후 프로브 검사공정을 마치게 된다.

본 논문에서는 프로브 검사에서 발생하는 칩별 결점 수 데이터를 이용하였다. 결점 셀은 레이저 리페어를 통하여 여유 셀로 대체되지만, 결점 셀이 많은 칩은 잠재 불량이 많다는 것을 의미하므로 이를 활용하여 최종 칩 품질을 예측하였다.




Figure 3. Architecture of the DRAM Chip

반도체에서의 수율은 FAB 수율, 프로브 수율, 조립 수율, 패키지 수율로 나눌 수 있다(An *et al.*, 2009). FAB 수율은 투입된 웨이퍼 장수 대비 FAB 공정으로부터 생산된(FAB out) 웨이퍼 장수의 비율로 나타내며 프로브 수율은 웨이퍼의 총 Die (Net Die) 대비 Good Die(Repairable Die)의 비율이다. 조립 수율과 패키지 수율은 투입된 칩 대비 완성된 칩의 비율로 나타낸다. 이 4가지 수율을 곱하면 CUM 수율(Cumulation yield)이 되는데, 이 CUM 수율은 FAB 투입량 대비 최종 완제품의 비율이 된다(Baek and Nam, 2002; Cunningham *et al.*, 1995).

반도체 제조업에서는 수율을 높임과 동시에 품질을 향상하는 방안을 다양한 방법을 통하여 연구하고 있다. 특히, 프로브 검사에서 품질향상에 관한 많은 연구가 이루어지고 있는데, 그 이유는 프로브 검사 데이터의 특수성 때문이다. 앞에서 언급하였듯이, 프로브 검사는 칩 단위의 데이터가 발생하는 최초의 공정으로 최종 칩 품질 예측에 중요한 역할을 한다. 프로브 검사 단계에서의 칩 품질 예측을 통하여 고품질 칩과 저품질 칩을 사전에 구분한 후 품질에 따른 패키지 검사의 이원화, 제조 공정의 이원화를 이끌어 낼 수 있다. 이를 통하여, 제조 공정 시간의 단축과 수율 향상도 꾀할 수 있다. 이처럼 프로브 검사 공정이 중요하므로 프로브 검사 데이터를 이용한 연구가 다양하게 이루어졌다. Support Vector machine 알고리즘을 이용한 최종 검사 수율 예측(An *et al.*, 2009), 웨이퍼 빈 맵(Wafer Bin Map)의 활용을 통한 패키지 검사 수율 예측(Hsu and Chien, 2007), OPTICS 기반 특질 추출을 이용한 품질 예측(Kim and Baek, 2014) 등이 있으나, 랫 단위로 수율 예측을 하거나, 칩 단위의 품질 예측이더라도 불량 칩에 대해 올바른 예측력을 판단할 수 있는 민감도(Sensitivity) 관점이 아닌 민감도와 특이도(Specificity) 모두를 고려한 전반적인 모델의 정확도(Accuracy)에 초점을 맞춘 경우가 대부분이었다. 따라서 민감도가 낮더라도 특이도가 높으면 전반적인 모델의 정확도는 상승하게 되어 있는데 이는 결코 신뢰성 있는 예측 모델이라고 할 수 없다. 특히, 반도체 데이터는 불량보다 정상이 압도적으로 많은 불균형 데이터로 다수인 정상 데이터들로 인하여 정확도(식 (3))의 왜곡이 발생할 수 있다. 본 연구에서는 이러한 프로브 결점 수 데이터의 특성을 고려한 효율적인 품질 예측 방법론을 제시하고자 한다.

본 논문의 구성은 다음과 같다. 제 2장에서는 본 논문에서 다룬 데이터와 성능 척도에 대하여 기술하였고, 제 3장은 프로브 검사 결점 수 데이터를 이용한 품질 예측 방법에 대하여 설

명하였다. 제 4장에서는 예측 결과를 정리하였고 마지막으로 제 5장에서는 본 연구의 요약과 추후 연구 과제를 제시하였다.

2. 데이터 설명 및 성능 척도

본 연구에서 사용한 데이터는 실제 반도체 프로브 검사 결점 수 데이터이며 변수는 29개, 정상 관측치는 2,000개, 비정상 관측치는 623개로 구성되었다.

Table 1. Probe Test Fail Bit Count Data

Wafer	X1	X2	...	X28	X29	Y
1	9	14	...	1	0	0
2	8	12	...	0	0	0
...
2622	5	20	...	0	1	1
2623	4	15	...	2	0	1

<Table 1>에서 보듯이, 예측변수 X는 프로브 검사로부터 생성된 결점 수 데이터이며 반응변수 Y는 최종 패키지 품질 정상 유무를 나타내는 이진변수이다(0 : 정상, 1 : 불량). <Figure 4>는 주성분 분석을 이용하여 29차원의 원 데이터를 3차원으로 축소하여 데이터를 시각화한 것이다(Hastie et al., 2009). 그림에서 보듯 정상과 불량이 겹쳐 있는 것을 볼 수 있으며, 불량은 정상보다 좀 더 퍼져있는 형태인 것을 알 수 있다. 실험 결과의 신뢰도를 높이기 위하여 10-fold Cross Validation을 이용하여 결과를 도출하였으며 본 연구의 모든 성능 척도는 식 (1)의 민감도로 하였다(James et al., 2013).

$$Sensitivity = \frac{TP}{TP + FN} \tag{1}$$

$$Specificity = \frac{TN}{FP + TN} \tag{2}$$

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \tag{3}$$

여기서 TP(True positive), FN(False negative), FP(False negative), TN(True negative)는 각각 불량을 불량으로 정분류한 경우, 이상을 정상으로 오분류한 경우, 정상을 불량으로 오분류한 경우, 정상을 정상으로 정분류한 경우로 아래 <Table 2>에 요약하였다.

Table 2. Confusion Matrix

		Predicted	
		불량	정상
Actual	불량	TP	FN
	정상	FP	TN

즉, 민감도는 실제 총 불량품 대비 모델이 올바르게 불량이라고 예측한 경우의 비율을 의미하며 특이도는 실제 총 정상품 대비 모델이 올바르게 정상이라고 예측한 경우의 비율을 나타낸다.




Figure 4. A Three-Dimensional Principal Component Score Plot

3. 프로브 검사 결점 수 데이터를 이용한 패키지 칩 품질 예측 방법

본 논문에서는 다음과 같은 3단계를 이용하여 품질 예측을 하였다. 1단계는 SMOTE 기법을 이용하여 데이터 불균형문제를 해결하였고, 2단계에서는 가용한 29개 예측변수 중에 정상과 불량을 구분하는 데 중요한 영향을 미치는 변수를 선택하였으며, 마지막 3단계에서는 선택된 주요변수를 이용하여 민감도가 최대화될 수 있도록 분류모델의 파라미터를 적절하게 조절하였다. 단계별 자세한 내용은 다음과 같다.

3.1 1단계 : 데이터 불균형 이슈 및 해결

신뢰성 있는 데이터마이닝 예측모델은 기본적으로 각 범주 간 데이터의 수가 비슷하다는 가정으로 구축된다(Kang and Cho, 2006). 하지만 반도체 공정 데이터는 불량 관측치 수가 정상 관측치 수보다 월등히 많으며 이를 불균형 문제라고 부른다. 불균형 문제가 있는 데이터에 일반적인 예측 모델을 적용할 경우 소수 범주에 대한 예측력이 현저히 떨어지는 등 예측 관련 심각한 문제를 일으킬 수 있다(TAN et al., 2006). 따라서 데이터 불균형 문제를 해결하여야 하는데 이를 해결하는 방법에는 크게 세 가지가 있다. 첫째, 다수 범주를 under sampling하여 소수 범주의 수에 맞추주는 방법이다(Kubat and Matwin, 1997). 이 방법은 샘플링되는 다수 범주의 데이터에 따라 모델 성능이 크게 좌우된다는 단점이 있지만, 계산 복잡도가 줄어드는 장점이 있다. 둘째, 소수 범주를 다수 범주의 수에 맞게 over sampling하는 방법이다(Chawla et al., 2002; Chawla et al., 2003). 이는 모든 데이터를 사용한다는 장점이 있지만, 계산 시간이 길어진다는 단점이 있다. 셋째, 위 두 가지 방법을 조합하여 사용하는 방법인데 다수 범주 데이터는 under sampling하고 소수 범주 데이터는 over sampling하여 적절한 수로 범주 간

데이터 비율을 맞춰준다(Solberg and Solberg, 1996). 일반적으로 다수 범주 데이터를 under sampling하는 방법이 소수 범주 데이터를 복원 방식으로 over sampling하는 방식보다 성능이 좋다. 또한, 이 두 방식을 조합하는 기법의 성능은 많은 경우 under sampling 기법 성능에 좌우되는 한계가 있다(Chawla et al., 2002). 복원 방식의 over sampling 기법은 같은 데이터를 복제하는 것이기 때문에, 소수 범주의 결정 경계를 생성할 수는 있지만 넓혀지는 못한다. 이 때문에 과적합의 문제가 발생할 수 있는데 이를 해결하기 위하여 제안된 방법이 SMOTE (Synthetic Minority Over-sampling Technique)이다.

SMOTE는 다수 범주는 under sampling 기법을, 소수 범주는 비복원방식의 over sampling 기법을 이용한 방법이다. over sampling 기법은 기존의 관측치와 k 개의 근접 이웃(k -nearest neighbor) 사이에 직선을 연결하여 그 선 위의 임의의 위치에 새로운 소수 범주 데이터를 생성하는 기법이다. 이를 통하여, 소수 범주의 결정 경계를 넓히는 효과를 볼 수 있다. 본 연구에서는 SMOTE 기법을 이용하여 데이터 불균형을 해결하였다.

3.2.2 단계 : 비모수 가설검정 기반 주요 변수 선택법

반도체 공정과 같은 하이텍 제조공정에서는 다량의 변수가 생성되는데 이 중 많은 변수가 서로 강한 상관관계를 가지고 있으며 반응변수에 영향을 미치지 않는 변수들 또한 다수 포함되어 있다. 이 경우 모든 변수를 예측 모형 구축에 사용하면 과적합이 발생할 수 있고, 불필요한 변수들이 다수 포함되어 있기 때문에 모델의 정확도가 떨어지게 된다(Shmueli et al., 2010). 이를 해결하기 위해서는 중요한 변수만을 찾는 변수 선택 과정이 필수적이다. 본 연구에서 사용할 프로브 결점 수 데이터는 아주 많은 수의 변수를 가지고 있지는 않지만, 예측에 꼭 필요한 변수 선택 과정이 필요하다. 범주를 예측하는 분류 모델에서 쉽게 사용할 수 있는 변수 선택 방법은 각 변수에 대하여 two-sample t-검정(Walpole et al., 1993)을 실시하여 범주 간 평균이 통계적으로 유의미하게 다른 변수를 주요 변수로 선택하는 것이다. 하지만 이 방법은 데이터가 정규분포를 따른다는 가정을 가지고 있어 데이터 분포가 정규분포를 따르지 않거나 분포가 알려지지 않았을 경우 사용하기 어렵다.




Figure 5. The Distribution of the Fail Bit Count Data

본 연구에서 사용하는 프로브 결점 수 데이터 역시 <Figure 5>와 같이 정규분포를 따르지 않으므로 일반적인 two-sample t-검정을 통한 주요 변수 선택법을 사용할 수 없다. 따라서 본 연구에서는 모집단 데이터의 확률분포를 모른다는 가정 하에 사용할 수 있는 비모수 resampling t-검정을 사용하였다(Kim et al., 2008).

이 기법은 기존의 t-통계량과 그룹별 구분 없이 sampling을 이용한 t-통계량을 비교하여 통계적으로 유의한 주요 변수를 찾는 방법이다. 이 때, 각 변수별 귀무가설은 정상 그룹과 불량 그룹 간 평균이 같다는 것이다. 만약 두 그룹 간 평균이 통계적으로 유의미하게 다르다면 귀무가설은 기각된다. 우선 정상 그룹과 불량 그룹에 대하여 식 (4)를 이용하여 일반적인 two-sample t-검정을 실행한다.

$$t_i = \frac{\overline{X_{i,정상}} - \overline{X_{i,불량}}}{\sqrt{\frac{S_{i,정상}^2}{n_{정상}} + \frac{S_{i,불량}^2}{n_{불량}}}} \quad (4)$$

$i=1, 2, \dots, 29$. 여기서 i 는 예측 변수의 인덱스이며, $\overline{X_{i,정상}}$ 과 $S_{i,정상}^2$ 은 i 번째 변수에서 정상 그룹의 표본 평균과 분산이다. 마찬가지로, $\overline{X_{i,불량}}$ 과 $S_{i,불량}^2$ 은 불량 그룹에서 구할 수 있다. 이를 이용하여 귀무가설이 참이라는 가정 하에 29개의 t-통계량을 구할 수 있다. 두 그룹 간 평균의 차이가 없다면, 두 그룹을 임의로 섞은 후 t-통계량을 구하더라도 먼저 구한 t-통계량과의 차이가 없을 것이다. 이에 착안하여, 두 그룹을 N 번 섞은 후 그룹의 구분 없이 two-sample t-검정을 실행하여 N 개의 변수별 t-통계량을 다음과 같이 구한다. $t_{i1}^n, t_{i2}^n, \dots, t_{i29}^n, n=1, 2, \dots, N$. 이를 이용하여 $N=1,000$ 이고, 변수 개수가 29일 때, i 번째 변수에 해당하는 비모수 p-value는 식 (5)와 같이 구할 수 있다.

$$p_i = \frac{\sum_{n=1}^{1000} \sum_{k=1}^{29} \mathcal{I}(n_k)}{29 \cdot 1000}, \quad (5)$$

$$\text{where } \mathcal{I}(n_k) = \begin{cases} 1 & \text{if } |t_k^n| \geq |t_i|, (k=1, 2, \dots, 29) \\ 0 & \text{otherwise} \end{cases}$$

각 변수 별 p-value를 구했으면 다중검정 시 Type I 에러를 조정하는 값인 FDR(False Discovery Rate)를 이용하여 주요 변수 선택을 하였다(Benjamini and Hochberg, 1995). FDR 기반 주요 변수 선택 기법의 단계는 다음과 같이 요약할 수 있다.

- p-value를 작은 것부터 큰 순서로 다음과 같이 순위화 한다. ($p(1) \leq p(2) \leq \dots \leq p(29)$) 여기서 $p(i)$ 는 크기가 i 번째인 p-value를 의미한다.
- 0과 1사이에서 원하는 FDR 수준($=\alpha$)을 정한다. 본 논문에서는 0.05로 한다.
- 선택될 수 있는 가장 많은 변수의 개수인 w 를 식 (6)과 같이 구한다.

$$w = \max \left[i : p(i) \leq \frac{i}{m} \frac{\alpha}{\delta} \right] \quad (6)$$

m 은 전체 변수의 개수인 29이고, δ 는 선택될 수 있는 변수의 개수를 조절하는 파라미터이다. δ 의 설정에 대한 다양한 연구가 있지만, 본 논문에서는 가장 보편적이고 보수적인 값인 $\delta = 1$ 을 사용한다.

- p-value의 기준점은 $p_{(w)}$ 가 되며, $p_i \leq p_{(w)}$ 일 때에만 유의하다고 본다.

본 연구에서는 $w = 13$ 으로 29개의 변수 중 13개가 주요 변수로 선택되었다.

3.3 3단계 : 분류 모델 파라미터 조절

<Figure 4>의 주성분 분석 스코어 도표에서 보듯이, 본 데이터는 고품질 관측치와 저품질 관측치가 상당수 겹쳐 있음을 알 수 있다. 품질 예측에서는 저품질을 저품질로 정확히 예측하는 것이 매우 중요하므로, 민감도를 높이기 위하여 분류 모델의 파라미터를 조절하였다. 본 논문에서는 로지스틱 회귀 모델의 오분류 기준을 조절하였다. 로지스틱 회귀모델에서 두 범주 중 어느 범주에 속할지 판단하는 기준을 오분류 기준이라고 하는데, 이 오분류 기준을 조절하여 각 범주에 속할 확률을 결정할 수 있다. 로지스틱 모델의 결과는 특정 범주에 속할 확률 값으로 구해진다(James et al., 2013).

범주 간 데이터 수가 비슷한 균형 데이터일 경우 오분류 기준은 보통 0.5로 설정하며 이 경우 관측치가 특정 범주에 속할 확률이 0.5보다 클 경우 해당 범주로 분류한다. 하지만 본 연구에서 다루고 있는 데이터는 범주 간 관측치 수의 차이가 많은 불균형 데이터이다. 이 경우 0.5의 기준값을 단순히 사용할 경우 소수범주를 제대로 분류하지 못하는 문제가 발생한다. 따라서 본 연구에서는 기준값을 조절하여 민감도가 최대가 되는 오분류 기준값을 찾아 분류 시 적용하였다. 실제 현업에서는 제품 초기의 고품질 물량을 선별하기 위하여 정상 물량의 분류 정확도를 고려하지 않기도 하지만 본 연구에서는 특이도(식 (2))가 적어도 50%가 되도록 오분류 기준을 설정하였다.

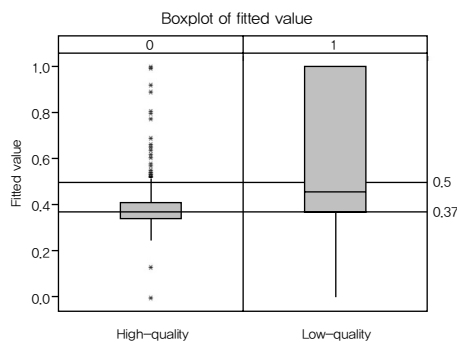


Figure 6. Fitted Value of the Logistic Regression with Different Thresholds(0.5 and 0.37)

<Figure 6>은 범주 간 로지스틱 모델 확률값의 분포를 비교한 상자 도표이다. 오분류 기준을 일반적 기준인 0.5로 설정하면 정상 관측치의 대부분은 옳게 분류가 되지만 불량 관측치는 50% 이상을 틀리게 분류하게 됨을 볼 수 있다. 본 연구에서는 특이도가 적어도 50%가 되는 한도 내에서 민감도가 최대가 되는 오분류 기준인 0.37로 설정하였다.

4. 예측 결과

<Table 3>은 본 연구에서 제안한 데이터 불균형 해소, 주요 변수 선택, 그리고 모델의 파라미터 조절을 적용한 결과를 보여 주고 있다. 예측모델로는 로지스틱 회귀분석을 사용하였다. 결론적으로 SMOTE를 이용해 데이터 불균형 문제를 해결하여 약 12%의 민감도가 향상되었으며, 비모수 기반 주요 변수 선택을 하여 29개 변수 중 13개 변수를 선택한 결과, 1%의 추가 민감도 향상을 가져왔다. 변수 선택의 경우 민감도가 크게 향상되지는 않았지만 도메인 지식을 바탕으로 살펴보면, 선택되지 않은 변수들은 변수 간 상관관계가 크거나 결과변수에 영향을 주지 않는 변수들임을 알 수 있었다. 마지막으로, 로지스틱 모델의 오분류 기준을 조절하여 민감도를 28% 추가로 향상하였다. 민감도를 최대한 높이기 위하여 특이도는 50%까지 낮추었다. 민감도가 중요한 본 문제의 특성상 특이도는 낮아졌지만, 제품 초기에는 고품질 물량보다 저품질 물량의 정확한 검출이 더 중요하기 때문에 최소한의 특이도 안에서 민감도를 높이는 데 중점을 두었다. 위의 세 가지 방법을 사용함으로써 최종적으로 41%의 민감도 향상 효과를 얻을 수 있었다. 이는 본 연구에서 제안한 세 가지 단계가 프로브 결점 수 데이터를 이용한 최종 품질을 예측하는 데 매우 효과적으로 적용됨을 보여주었다.

Table 3. Sensitivity values for various scenarios

구 분	민감도(Sensitivity)
Original Data	29.70%
SMOTE	41.57%
SMOTE + 변수 선택	42.86%
SMOTE + 변수 선택 + 오분류 기준 조절	70.95%

5. 결론

프로브 검사는 칩별 데이터가 발생하는 최초의 공정으로써, 최종 칩 품질 예측에 매우 중요한 단계이다. 본 연구에서는 프로브 검사 결점 수 데이터의 특성을 고려한 효과적인 패키지 칩 품질 예측 방법론을 제시하였다. 데이터마이닝의 분류 기법은 기본적으로 각 범주 데이터 간의 비율이 비슷하다는 가정을 가지고 있다. 하지만 프로브 검사 결점 수 데이터는 데이

터 불균형 문제를 가지고 있으며 이를 해결하기 위하여 본 연구에서는 SMOTE 기법을 이용하였다. 또한, 정규분포를 따르지 않는 결점 수 데이터에서 주요 변수를 찾기 위하여 비모수 기반 주요 변수 선택법을 이용하였으며, 최종적으로 예측모델의 파라미터를 조정하여 최종 목표인 민감도를 높일 수 있었다. 본 연구로부터 구축된 예측모델을 이용하여 품질 이상 물량을 효과적으로 선별할 수 있을 것이며, 이를 통하여 품질과 수율 개선에 많은 기여가 될 것으로 기대된다.

추후 과제로는 민감도 향상과 함께 특이도도 높일 수 있는 방법을 연구해 볼 것이다. 즉, 본 연구에서는 특이도를 50%선에서 만족하다고 가정하고 민감도를 최대화하는데 주안점을 두었는데 민감도가 매우 중요한 본 문제에는 어느 정도 합리적일 수 있으나 일반적으로 적용하기 위해서는 특이도 역시 합리적인 수준이 되어야 할 것으로 보인다. 또 다른 추후 과제로는 본 연구에서는 로지스틱 회귀모델에 국한한 실험결과를 보여 주었는데 보다 다양한 예측 모델을 이용하여 본 연구에서 나온 결과를 일반화할 수 있도록 하겠다.

참고문헌

- An, D., Ko, H. H., Gulambar, T., Kim, J., Baek, J. G., and Kim, S. S. (2009), A semiconductor yields prediction using stepwise support vector machine. In *Assembly and Manufacturing, 2009. ISAM 2009, IEEE International Symposium on*, 130-136. IEEE.
- Baek, D. and Nam, J. (2002), Semiconductor yield improvement system using the data mining, *IE interfaces*, 2002 single issue, 293-300.
- Benjamini, Y. and Hochberg, Y. (1995), Controlling the false discovery rate : a practical and powerful approach to multiple testing, *Journal of the Royal Statistical Society, Series B (Methodological)*, 289-300.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., and Kegelmeyer, W. P. (2002), SMOTE : synthetic minority over-sampling technique, *Journal of Artificial Intelligence Research*, **16**, 321-357.
- Chawla, N. V., Lazarevic, A., Hall, L. O., and Bowyer, K. W. (2003), SMOTEBoost : Improving prediction of the minority class in boosting, In *Knowledge Discovery in Databases : PKDD 2003, Springer Berlin Heidelberg*, 107-119.
- Chen, H., Harrison, J. M., Mandelbaum, A., Van Ackere, A., and Wein, L. M. (1988), Empirical evaluation of a queueing network model for semiconductor wafer fabrication, *Operations Research*, **36**(2), 202-215.
- Conover, W. J. (1999), *Practical Nonparametric Statistics*, 3, Wiley, New York.
- Cunningham, S. P., Spanos, C. J., and Voros, K. (1995), Semiconductor yield improvement : results and best practices. *Semiconductor Manufacturing, IEEE Transactions on*, **8**(2), 103-109.
- Hastie, T., Friedman, J., and Tibshirani, R. (2009), *The elements of statistical learning*, **2**(1), Springer, New York.
- Hsu, S. and Chien, C. (2007), Hybrid data mining approach for pattern extraction from wafer bin map to improve yield in semiconductor manufacturing, *International Journal of Production Economics*, **107**(1), 88-103.
- James, G., Witten, D., Hastie, T., and Tibshirani, R. (2013), *An introduction to statistical learning*, Springer, New York.
- Kang, J. and Kim, S. (2011), Bootstrap-Based Fault Identification Method, *Journal of Korean Society for Quality Management*, **39**(2), 234-244.
- Kang, P. and Cho, S. (2006), EUS SVMs : Ensemble of under-sampled SVMs for data imbalance problems, In *Neural Information Processing*, 4232, 837-846.
- Kim, K. and Baek, J. (2014), A prediction of chip quality using OPTICS (Ordering Points to Identify the Clustering Structure)-based feature extraction at the cell level, *Journal of the Korean Institute of Industrial Engineers*, **40**(2), 151-160.
- Kim, S. B., Chen, V. C., Park, Y., Ziegler, T. R., and Jones, D. P. (2008), Controlling the false discovery rate for feature selection in high resolution NMR Spectra, *Statistical Analysis and Data Mining*, **1**(2), 57-66.
- Kubat, M. and Matwin, S. (1997), Addressing the curse of imbalanced training sets : one sided selection, In *Proceedings of the Fourteenth International Conference on Machine Learning*, 179-186.
- Kumar, N., Kennedy, K., Gildersleeve, K., Abelson, R., Mastrangelo, C. M., and Montgomery, D. C. (2006), A review of yield modelling techniques for semiconductor manufacturing, *International Journal of Production Research*, **44**(23), 5019-5036.
- Shmueli, G., Patel, N., and Bruce, P. (2010), *Data Mining for Business Intelligence : Concepts, Techniques, and Applications in Microsoft Office Excel with XLMiner*, 2, Wiley, New York.
- Solberg, A. and Solberg, R. (1996), A large-scale evaluation of features for automatic detection of oil spills in ERS SAR images, In *International Geoscience and Remote Sensing Symposium*, 1484-1486.
- Suh, J. H. and Lee, C. G. (2002), Redundancy analysis simulation for EDS process, *Journal of the Korea society for simulation*, **11**(3), 49-58.
- Tan, P., Steinbach, M., and Kumar, V. (2006), *Introduction to data mining*, 1, Addison Wesley.
- Walpole, R. E., Myers, R. H., Myers, S. L., and Ye, K. (1993), *Probability and statistics for engineers and scientists*, 5, Macmillan, New York.
- Yoon, H. W. (2014.01.20), Korea Semiconductor market share overtakes Japan in thirty years, *Seoul Economic Daily*.