

사례기반 추론에 의한 반도체 패키징 공장의 Cycle-time 예측 모형 개발

김규진^a, 서용무^a

^a 고려대학교 경영대학 경영학과

136-701, 서울 성북구 안암동5가 1

Tel: +82-2-3290-1945, Fax: +82-2-922-7220, E-mail: {raccoonjin, ymsuh@korea.ac.kr}

Abstract

반도체 패키징 공장에서 사이클타임(Cycle-time)을 정확히 예측하는 것은 납기일 준수를 통해 고객만족도를 향상시킬 수 있고, 보다 효율적인 스케줄링을 가능하게 하여 공장 가동률을 높일 수 있게 한다. 그러나 반도체 패키징은 제품 종류가 다양하고 제품마다 특화된 기술을 사용할 뿐만 아니라 공정 순서나, WIP¹에 따라 사이클타임이 크게 영향을 받아 그 정확한 예측이 매우 어렵기 때문에 현장 전문가의 판단에 의존하는 경우가 많았다. Fab²공정의 경우 전문가를 도와 좀 더 정확한 예측에 도움을 주기 위해 그 동안 전통적 통계 기법 및 시뮬레이션에 기반한 의사결정 모형이 많이 연구되었는데, 최근에는 기계학습 및 인공지능 기법을 사용한 연구가 눈에 띄고 있으며 기존의 방법보다 우수한 성능을 보여 주는 것으로 나타났다. 하지만 아직 기계학습 및 인공지능을 이용한 충분한 연구가 진행되지 못하고 있는 실정이다. 따라서 본 연구에서는 사례기반 추론을 사용하여 패키징 공정의 사이클타임을 예측하고자 하였으며 그 성능을 인공신경망 모형, 의사결정나무 모형, 그리고 해당 분야 전문가의 예측치와 비교하였다. 실험결과에 따르면 사례기반추론 모형이 가장 뛰어난 성능을 보이는 것으로 나타났다.

Keywords:

Data mining, Cycle-time, Case-based reasoning

1. 서론

제조 공정의 사이클타임(Cycle-time) 관리는 생산관리 분야에서 그 동안 매우 중요한 성과 지표 역할을 해 왔다. 과거에는 짧은 시간내에 많은 제품을 생산

하는 것이 중요했지만 “필요한 것을 필요한 때에 필요한 만큼” 생산한다는 JIT (Just In Time) 개념의 등장과 함께 사이클타임을 정확히 예측해 내는 것이 더욱 중요해 졌다. 왜냐하면 사이클타임을 정확히 예측할 수 있다면 효율적인 생산계획 수립을 통해 공장 가동률을 높일 수 있을 뿐만 아니라 정확한 납기 일정 관리를 통해 고객만족을 향상시킬 수 있고 재고 관리 비용도 줄일 수 있기 때문이다.

특히, 반도체 생산은 생산 라인 건설에 수년간의 시간과 수조원의 투자를 필요로 하는 사업이므로 사이클 타임 관리가 더욱 중요한 분야라고 할 수 있다. 최근에는 Fab부분의 수율³이 점차 높아짐에 따라 백엔드(Back-end) 부분의 생산능력이 주목받고 있으며, 특히 추가적인 투자없이 생산 능력을 향상시키기 위해 사이클 타임의 관리 능력이 생산라인의 중요성과 관리 지표가 되고 있다(Domaschke, Brown et al. 1998).

사이클 타임을 예측하고자 하는 연구는 지금까지 주로 회귀분석과 같은 전통적 방식이 많이 쓰였으며 근래에 시뮬레이션 기법을 이요한 방법이 주목을 받았으나 입력변수의 수가 점차 많아짐에 따라 모형의 수행 시간이 늘어나고, 개별 Lot⁴의 특성에 적합한 예측치를 제시하기 보다 공장의 평균 사이클 타임으로 결과치를 제시하는 경향이 있었다.

소수의 연구들에서 의사결정나무, 인공신경망 등과 같은 기계학습, 인공지능 기법을 사용하였으나 모두 Fab공정의 데이터가 대상이었고 패키징 분야의 사이클타임을 예측하고자 하는 시도는 부족하였다. 따라서 본 연구에서는 사례기반 추론 기법을 이용하여 반도체 패키징 공장에서 수집된 개별 Lot들의 생산 관련 데이터를 바탕으로 각 Lot들의 사이클 타임을 예측하고자 한다.

본 논문은 다음과 같이 구성되어 있다. 2장에서는 문헌 연구를 통해 사이클타임 예측에 관한 연구와 사례기반 추론 기법에 대한 연구를 알아보고 3장에서는 반도체 패키징 공정 및 사이클타임에 대해 간단히 소개한다. 4장에서는 본 연구에 사용된 데이터의 내용 및 전처리 과정, 실험 절차에 관해 기술하였으

¹ Work-In-Process

² Fabrication

³ 한장의 웨이퍼에서 나오는 양품칩의 비율

⁴ 동일한 품질이 보장되는 조건에서 생산되는 작업 단위

며 5장에서는 실험결과에 대한 해석 및 결론을 도출하였다.

2. 문헌연구

2.1 싸이클 타임 예측의 데이터마이닝 적용

Chung 등은 기존의 싸이클타임 예측 방법을 시뮬레이션, 통계적 분석법, Queing 이론에 기반한 분석적 방법, 하이브리드 방법과 같이 4가지로 구분하였다 (Chung and Huang 2002). 이들은 웨이퍼 Fab 공장에서 engineering lots 의 싸이클타임을 예측하는 모형을 세웠으며 여러 기법 중 시뮬레이션 기법이 가장 탁월한 성능을 보였다. 그러나 Backus 등은 시뮬레이션 기법이 너무 복잡할 뿐만 아니라 개별 lot 에 맞는 예측 값보다 공장의 평균 싸이클타임을 결과치로 제시하는 경향이 있다고 지적하면서 데이터마이닝 기법이 더 우수한 성능을 보일 수 있음을 언급하였다(Backus, Janakiram et al. 2006).

Chiu 등은 사례기반 추론 기법을 사용하여 역시 웨이퍼 Fab공정의 싸이클타임을 예측하고자 하였으며 유전자 알고리즘을 사용한 속성 가중치를 적용하였다. 이들은 선정된 유사사례의 속성마다 서로 다른 가중치를 적용하여 성능을 향상시킬 수 있음을 보여 주었다(Chiu, Chang et al. 2003). 그러나 이들의 연구는 시뮬레이션을 통해 인위적으로 형성된 데이터를 사용한 한계가 있다. Liao 등은 인공지능망 기법을 사용하여 Fab공장에서 우선순위를 부여받은 웨이퍼 Lot만의 싸이클타임을 예측하고자 하였다(Liao and Wang 2004).

2.2 사례기반 추론 (Case-based reasoning)

사례기반 추론 방법은 새로운 사례를 해결하기 위해서 과거에 경험한 유사한 사례들을 찾고 그 사례들의 해답으로부터 새로운 사례의 해답을 도출하는 것이다(Aamodt and Plaza 1994). 사례기반 추론의 문제해결 패러다임은 비슷한 문제는 비슷한 해답을 가진다는 것을 전제로 한다. 이는 과거의 경험으로부터 현재의 해답을 찾고자 하는 인간의 문제해결 방식과 유사하다. 본 연구에서 사례기반 추론을 사용하고자 하는 이유도 공장에서 현장 전문가들에게 싸이클타임 예측 업무를 의존하는 것이 그들의 축적된 현장 경험으로부터 답을 얻어내는 방식과 유사하기 때문이다.

사례기반 추론 과정은 크게 <그림 1>와 같은 4REs 순환 과정으로 이루어진다(Aamodt and Plaza 1994).

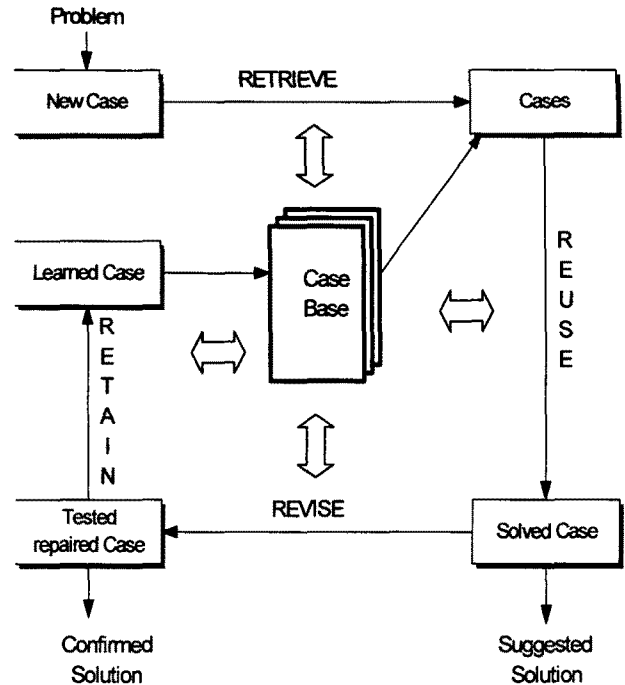
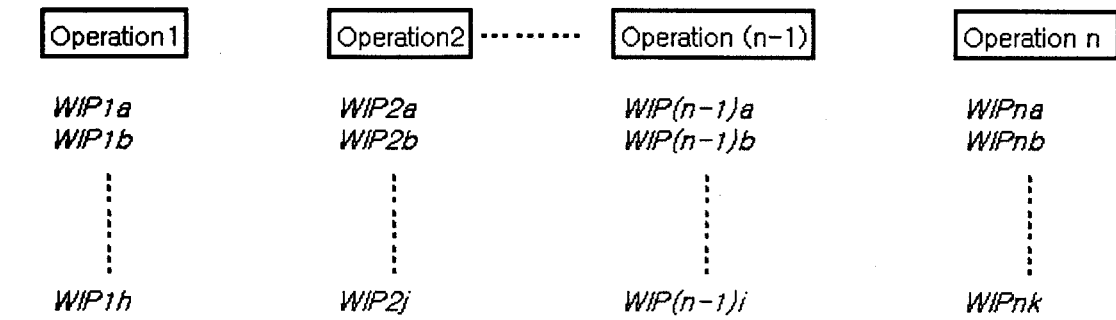


그림 1: The CBR Cycle [Aamodt and Plaza, 1994]

사례기반추론은 지금까지 의학(Park, Kim et al. 2006), 건축(An, Kim et al. 2007), 금융(Shin and Han 1999), 생산관리(Priore, de la Fuente et al. 2001) 등 다양한 분야에 적용 되었으며 그 성능을 향상 시키는 방법에 있어서도 다양한 시도가 이루어 졌다. 데이터에 가장 적합한 유사도 함수를 사용하는 것이 첫번째인데 Mount 등이 기존의 100여가지 CBR 프로젝트를 분석하고 내린 결론에 따르면 지금까지 유클리디안 거리 함수를 포함한 10여 종류의 함수가 가장 빈번하게 사용된 것으로 나타났다(Mount 1998).

유전자 알고리즘을 사용하여 속성간 또는 사례간 가중치를 부여하거나(Shin and Han 1999; Jarmulak, Craw et al. 2000; Chiu 2002; Chiu, Chang et al. 2003) 과거 사례베이스와 새로운 사례간 유사도의 분포를 고려하여 최적의 유사사례 수를 찾아내고자 하는 시도(Park, Kim et al. 2006)등이 있었으며, Park등은 선택된 유사사례들의 해가 일관성이 떨어지는 경우 사용자에게 판단을 유보하는 방법으로 예측력을 높이고자 하는 연구를 수행하였다(Park and Kim 2007).

예측력을 높이기 위한 연구 외에 계산과정의 효율성을 모색하는 연구도 이루어 졌는데 Sha 등은 유사사례를 검색하기 전에 분류모형을 통해 과거 사례 베이스를 분할한 다음 정해진 과거 사례 베이스 내에서만 유사사례를 찾음으로써 검색 효율을 높이고자 하였다(Sha and Liu 2006).



Operation n : n 번째 공정

$WIPnk$: n 번째 공정의 k 형 제품의 WIP

그림 2: 반도체 패키징 공장의 사이클타임 예측 문제

3. 반도체 패키징 사이클 타임 예측

반도체 제조 공정은 크게 선공정(Front-end)인 Fab과 후공정(Back-end)의 패키징, 그리고 테스트로 구분할 수 있다. Fab은 웨이퍼에 회로를 그리는 과정으로 도체와 부도체를 웨이퍼에 덮거나 식각하는 작업을 반복적으로 수행한다. 패키징은 Fab에서 만들어진 웨이퍼를 하나 하나의 칩으로 만들어서 외부의 물리적 충격이나 오염으로부터 보호하고 전기적 신호가 통하게 만들어 하나의 반도체로서 작동하게 만드는 과정으로 비교적 짧은 7일 내외의 사이클타임을 가진다. 테스트는 이렇게 패키징된 제품의 작동 여부를 테스트 하는 과정이다.

패키징 공장에서 생산관리자는 주문의 접수와 함께 예상 납기를 고객에게 통보해야 하며 이 때 예상 사이클타임 산정의 바탕이 되는 것은 제품의 유형과 해당 시점에서 공장의 WIP분포이다. 제품의 종류에 따라 적용되는 공정기술, 순서 등이 달라지므로 이에 따른 사이클타임의 변화는 필연적이며 Little's law에 따르면 사이클타임은 WIP에 비례 한다(Hopp and Spearman 2001).

예를 들어 <그림 2>와 같이 k 개의 제품 유형이 생산 가능한 생산라인에서 b 형 제품 1 Lot를 투입한다고 가정하자. 각 공정에는 서로 다른 수의 작업기계가 있고 제품의 타입에 따라 서로 다른 WIP값이 분포되어 있다. b 형 제품은 1, 2, 4, 6, 9번 공정을 거쳐 작업이 마무리 된다고 한다면, 기계에 따라 제품에 따라 UPH⁵도 다르고 투입된 lot가 생산공정을 거쳐 가

는 동안 WIP는 계속 변화한다. 본 연구에서는 이러한 문제상황 하에서 제품의 유형에 따라 부여된 범주형 변수와 WIP를 나타내는 숫자형 변수를 입력변수로 하여 사례기반 추론을 통해 사이클타임을 예측해 보고자 한다.

4. 데이터 및 사례기반 추론 모형 개발

4.1 데이터

본 연구에 사용된 데이터는 우리나라에 공장을 두고 있는 외국계 반도체 패키징 기업으로부터 수집되었다. 2006년 6월부터 2006년 12월 까지 생산된 28917개 Lot에 대한 생산 관련 데이터이며 크게 패키징 기술 및 제품 형태에 대한 정보와 공정별로 작업 시작 시간과 종료 시간을 기록한 데이터이다.

우리는 각 Lot별로 기록된 작업 시작 시간과 종료 시간을 바탕으로 특정 Lot가 첫 공정에 들어갈 시점에 생산라인 전체의 WIP를 도출했으며 이를 바탕으로 생산공정이 비슷하면서 WIP상태가 유사한 Lot의 기록을 찾아 새로이 직면한 문제의 사이클타임을 예측하고자 했다. 5개 범주형 변수와 37개 연속형 변수로 이루어져 있으며 각 변수들에 대한 설명은 <표 1>과 같다. 전처리 과정을 거쳐 고객사의 요청으로 작업을 중단한 기록이 있는 Lot 및 결측치를 가진 데이터는 삭제했다. 고객사의 요청으로 인한 작업 중단은 고객사의 내부 사정으로 인한 것으로 공장의 정상적인 작업흐름을 벗어나기 때문에 예측 모형을 통해서 예측하는 것이 불가능하다. 최종적으로 22907개 인스턴스를 사용했으며 8:2의 비율로 사

⁵ Unit-Per-Hour: 시간당 생산되는 chip의 수

레베이스 18234건, 테스트 사례 4673건을 사용하였다.

0과 1사이의 값으로 정규화 시킨 후 유클리디안 거리 함수를 사용하여 아래 <그림 3>와 같이 유사도를 계산하였다.

표 1: 변수 정의

변수유형	변수명	정의
범주형	Line code	생산라인 식별자
범주형	Customer	주문 고객사명
범주형	Package	제조기술에 따른 패키지 타입
범주형	Dimension	패키지 크기
범주형	Lot ID	개별 Lot 식별자
숫자형	WIP(1~37)	각 Lot 가 첫 공정을 시작하는 시간을 기준으로 계산된 37개 공정의 WIP
숫자형	Lead	Lead 수
숫자형	Mfg	싸이클타임

$$DIS_{LC,TC} = \sqrt{\sum_{i=1}^n W_i \times (LC_i - TC_i)^2}$$

LC_i : i th feature value of learning case

TC_i : i th feature value of test case

W_i : i th featureweight

그림 3: Euclidian Distance Function

범주형 데이터의 경우 서로 같으면 0, 다르면 1을 거리 값으로 부여하였다. 전문가의 판단에 따르면 범주형 데이터의 경우 제품의 전반적인 기술적 특징들을 나타내고 있으므로 WIP의 분포보다 더 우선적으로 고려해야 할 속성들이므로 일치하는 경우 숫자형 데이터보다 더 높은 유사도를 부여하는 것이 합리적이다. 그러나 본 연구에서는 속성 가중치는 사용하지 않았으며 이 점은 향후 추가 연구를 통해 개선할 부분이다.

4.2 사례기반 추론 모형 개발

지금까지 대부분의 사례기반추론 연구에서는 모든 새로운 사례에 대해서 고정된 수의 유사사례를 사용하여 해를 도출하였다. 그러나 과거 사례 베이스에는 새로 직면하는 문제에 따라서 유사한 사례의 수가 많이 있을 수도 있고 반대의 경우일 수도 있다. 이를 고려하지 않고 일괄적으로 같은 수의 유사사례를 취하여 답을 도출 하면 예측력이 떨어질 수도 있다. 즉, 어떤 새로운 사례에 대해서는 유사사례가 오직 3개만 존재하는데도 고정적으로 5개의 유사사례를 선택해야만 한다면 2개는 동떨어진 사례를 취하게 되어 예측력을 떨어뜨리는 결과를 초래할 것이다. 본 연구에서 우리는 이러한 경우 유사사례의 수를 정하는데 있어 사례들 간 거리의 합을 고려하였다. 즉, 새로운 사례와 과거 사례들 간의 거리의 합이 사용자가 정한 Threshold보다 커질 때까지 선택된 유사사례들만을 사용하여 해를 도출하였다.

4.2.1 유사도 함수

사례기반 추론에서 유사도는 속성간 유사도와 사례간 유사도로 구분할 수 있다. 속성간 유사도는 비교하는 두 사례의 속성과 속성 사이의 거리로 나타낼 수 있고 사례간 유사도는 속성간 유사도의 합으로 표현할 수 있다. 본 연구에서 숫자형 데이터의 경우

4.2.2 예상 싸이클타임

유사사례들 간의 거리 합이 사용자가 지정한 Threshold를 초과할 때, 유사사례들의 개수를 k 라 하면 k 개의 유사사례로부터 예상 싸이클 타임을 구하는 방법은 아래와 같다.<그림 4> 사용자 지정 Threshold는 1부터 7까지 1만큼 증가시키면서 각각의 Threshold에 대해 유사사례의 수 k 를 계산하였다

$$ExpectedTime = \frac{t_1 + t_2 + \dots + t_k}{k}$$

$ExpectedTime$: 새로 투입되는 lot 의 예상 싸이클타임

t_k : k 번째 유사사례의 싸이클타임

k : 거리합이 Threshold 보다 커지는 유사사례의 수

그림 4: 예상 싸이클타임

사례기반 추론 모형은 Java 1.5 와 MS-Access 2003 을 사용하여 개발하였으며, 사례기반 추론 모형과 성능을 비교하기 위해 Clementine v10.0 을 이용한 인공지능망 모델과 CART모형을 선택하였다.

결과 및 해석

실험 결과는 <표 3>에서와 같이 Threshold가 4일 때 가장 우수한 예측력을 보이는 것으로 나타났다. 평균 유사사례 수는 3.864개, RMSE는 21.049, MAE는 14.195 이다. <표 2>은 CBR, CART, Neural Network, Expert 의 결과치를 서로 비교한 것이다. 모형간 비교에서도 CBR이 가장 좋은 정확도를 보이고 있으며 전문가의 예측도는 가장 떨어지는 것으로 나타났다. 전문가의 의견에 따르면 현장 전문가들은 On-time miss를 방지하기 위해서 24시간 정도 시간 여유를 고려하여 예측치를 입력한다고 한다. 그러나 이를 고려하여 계산한다 하더라도 여전히 CART나 인공지능망 모형의 정확도에도 미치지 못하는 것으로 나타났다.

결론 및 향후 연구 과제

본 연구의 의의는 첫째, 사례기반 추론 기법을 사용하여 반도체 패키징 공장의 사이클타임을 예측하는 모형을 구축하였다. 둘째, 유사사례들의 거리 합이

일정 수준을 넘지 않도록 제한하는 방법을 통해 거리가 먼 사례가 유사사례로 채택되는 것을 방지하였다. 실험결과 사례기반 추론 기법이 CART모형, 인공지능망 모형, 전문가의 예측에 의한 것보다 더 우수한 것으로 나타났으며 따라서 향후 반도체 패키징 공장에서 이를 적용하면 현장 전문가 인력 활용 부담을 상당히 덜 수 있을 것은 물론, 전문가들의 결정에도 큰 도움을 줄 것으로 보인다.

향후 연구 과제로 최적의 Threshold를 찾는 방법에 관한 연구 및 속성가중치와 사례가중치를 사용하여 본 연구모델의 성능을 더 향상시키는 부분을 제시할 수 있다. 본 연구에서는 정수형 Threshold를 1부터 7까지 변경하며 최적값을 찾고자 하였다.

표 2: 모형간 결과 비교

모형	CBR	CART	Neural Network	Expert
RMSE	21.049	27.219	29.172	61.496
MAE	14.195	20.264	21.603	49.412

표 3: 실험결과

Threshold	1	2	3	4	5	6	7
avg-K	1.562	2.456	3.037	3.864	4.449	5.22	5.798
RMSE	22.562	21.503	21.232	21.049	21.064	21.057	21.29
MAE	14.826	14.324	14.239	14.195	14.278	14.364	14.584

참고문헌

- Aamodt, A. and E. Plaza (1994). "Case-based reasoning: foundational issues, methodological variations, and system approaches." AI Communications 7(1): 39-59.
- An, S. H., G. H. Kim, et al. (2007). "A case-based reasoning cost estimating model using experience by analytic hierarchy process." Building and Environment 42(7): 2573-2579.
- Backus, P., M. Janakiram, et al. (2006). "Factory cycle-time prediction with a data-mining approach." IEEE Transactions on Semiconductor Manufacturing 19(2): 252-258.
- Chiu, C. (2002). "A case-based customer classification approach for direct marketing." Expert Systems With Applications 22(2): 163-168.

- Chiu, C., P. C. Chang, et al. (2003). "A case-based expert support system for due-date assignment in a wafer fabrication factory." Journal of Intelligent Manufacturing **14**(3): 287-296.
- Chung, S. H. and H. W. Huang (2002). "Cycle time estimation for wafer fab with engineering lots." IIE Transactions **34**(2): 105-118.
- Domaschke, J., S. Brown, et al. (1998). "Effective implementation of cycle time reduction strategies for semiconductor back-end manufacturing." Proceedings of the 30th conference on Winter simulation: 985-992.
- Hopp, W. J. and M. L. Spearman (2001). Factory physics: foundations of manufacturing management, Irwin/McGraw-Hill.
- Jarmulak, J., S. Craw, et al. (2000). "Genetic algorithms to optimise CBR retrieval." Proceedings of the 5th European Workshop on Case-Based Reasoning, Springer.
- Liao, D. Y. and C. N. Wang (2004). "Neural-network-based delivery time estimates for prioritized 300-mm automatic material handling operations." Semiconductor Manufacturing, IEEE Transactions on **17**(3): 324-332.
- Mount, T. W. L. Z. Z. C. (1998). "SIMILARITY MEASURES FOR RETRIEVAL IN CASE-BASED REASONING SYSTEMS." Applied Artificial Intelligence **12**(4): 267 - 288.
- Park, Y.-J. and B.-C. Kim (2007). "An interactive case-based reasoning method considering proximity from the cut-off point." Expert Systems with Applications **33**(4): 903-915.
- Park, Y.-J., B.-C. Kim, et al. (2006). "New knowledge extraction technique using probability for case-based reasoning: application to medical diagnosis." Expert Systems **23**(1): 2-20.
- Priore, P., D. de la Fuente, et al. (2001). "LEARNING-BASED SCHEDULING OF FLEXIBLE MANUFACTURING SYSTEMS USING CASE-BASED REASONING." Applied Artificial Intelligence **15**(10): 949 - 963.
- Sha, D. Y. and C. H. Liu (2006). "Development and evaluation of a tree-indexing approach to improve case-based reasoning: illustrated using the due date assignment problem." International Journal of Production Research **44**(15): 3033 - 3049.
- Shin, K. and I. Han (1999). "Case-based reasoning supported by genetic algorithms for corporate bond rating." Expert Systems with Applications **16**(2): 85-95.