지식 결합을 이용한 서로 다른 모델들의 통합

†배재권* · 김진화*

Integration of Heterogeneous Models with Knowledge Consolidation

†Jae Kwon Bae* · Jinhwa Kim*

■ Abstract ■

For better predictions and classifications in customer recommendation, this study proposes an integrative model that efficiently combines the currently-in-use statistical and artificial intelligence models. In particular, by integrating the models such as Association Rule, Frequency Matrix, and Rule Induction, this study suggests an integrative prediction model. Integrated models consist of four models : ASFM model which combines Association Rule(A) and Frequency Matrix(B), ASRI model which combines Association Rule(A) and Rule Induction(C), FMRI model which combines Frequency Matrix(B) and Rule Induction(C), and ASFMRI model which combines Association Rule(A), Frequency Matrix(B), and Rule Induction(C). The data set for the tests is collected from a convenience store G, which is the number one in its brand in S. Korea. This data set contains sales information on customer transactions from September 1, 2005 to December 7, 2005. About 1,000 transactions are selected for a specific item. Using this data set, it suggests an integrated model predicting whether a customer buys or not buys a specific product for target marketing strategy. The performance of integrated model is compared with that of other models. The results from the experiments show that the performance of integrated model is superior to that of all other models such as Association Rule, Frequency Matrix, and Rule Induction.

Keywords : Customer Recommendation, Artificial Intelligence, Association Rule, Frequency Matrix, Rule Induction, Integrative Prediction Model

논문접수일 : 2007년 09월 10일 논문게재확정일 : 2007년 10월 31일
* 서강대학교 경영학과
† 교신저자

1. 서 론

최근 디지털 정보기술의 급속한 발전은 다양한 시장공간을 창출시키고 있으며, 특히 인터넷 매체의 빠른 확산은 새로운 경제현상을 만들어낼 뿐만 아니라 기업의 경쟁전략을 변화시키고 있다. 이러한 시장환경의 변화 속에서 과거와 달리 제품이나 서비스에 대한 고객들의 욕구 또한 더욱 다양화되어 점차적으로 기업에 대한 자신들의 영향력을 증대시키고 있다. 따라서 기업 경쟁력 강화의 중요한 이슈가 되어버린 대량 개별화(mass-customization)의 실행을 위하여 정보기술을 기반으로 고객의 다양한 정보를 획득함과 동시에 고객과의 밀접한 관계를 유지함으로써 기업의 수익성을 증대시키는 고객관계관리(CRM : Customer Relationship Management)에 대한 관심과 활용에 대한 필요성은 점점 더 높아지고 있다. 고객관계관리는 데이터베이스 마케팅의 진보된 형태로서 기업이 고객과 상호작용하는 프로세스를 보다 자동화하고 개선시킨 것이다. 고객관계관리에서는 효과적인 고객관리 전략을 개발하고 지속적으로 수행하는 능력이 중요하며, 이를 위해서는 고객정보를 분석하는 도구로서 데이터마이닝(Data Mining)의 사용이 요구되고 있다[1].

고객관계관리의 여러 분야 가운데에서도 제품을 구매한 기존 고객의 정보를 기반으로 고객에게 맞는 새로운 제품이나 서비스를 제안하기 위하여 고객의 구매 패턴을 파악하고 의도를 예측하는 것은 오늘날 실질적인 판매 전략을 수립하는 마케팅 분야에서 상당히 큰 비중을 차지하고 있다. 일반적으로 고객의 구매의도를 파악하고 예측하는 데는 연관성규칙, 의사결정나무, 신경망 등의 데이터마이닝 기법들이 주로 사용되어 왔다. 그러나 이들 데이터마이닝 기법을 이용한 단일모형은 몇 가지 태생적인 한계점을 가지고 있으며 데이터 특성에 따라 각각의 모형에 대한 예측력 성과가 달라질 수 있기 때문에 어느 모형이 가장 최적의 모형인지 판단하기 어렵다. 따라서 기존의 데이터마이닝 기법들이 가지고 있는 한계점들을 최소화하기 위하여, 이질적인 단일모형들을 지식 결합을 이용하여 시너지 효과를 생산할 수 있는 통합모형을 제시하고자 한다.

본 연구에서는 보다 효과적인 고객구매예측을 위하여, 매장 내의 상품들과 고객구매패턴과의 연관성을 발견하기 위해 가장 널리 활용되고 있는 연관성규칙(Association Rule)과 인공지능적인 방법으로서 최근 널리 사용되고 있는 빈도행렬(Frequency Matrix), 규칙유도기법(Rule Induction)의 3가지 모형을 규칙기반(rule-based)에 의한 지식이 축적된 통합모형을 제시하고자 한다. 통합모형은 연관성규칙(A)과 빈도행렬(B)을 결합한 ASFM(ASsociation rule and Frequency Matrix)모형, 연관성규칙(A)과 규칙유도기법(C)을 결합한 ASRI(ASsociation rule and Rule Induction)모형, 빈도행렬(B)과 규칙유도기법(C)을 결합한 FMRI(Frequency Matrix and Rule Induction)모형, 마지막으로 3가지 모형(A + B + C)을 모두 통합한 ASFMRI(ASsociation rule, Frequency Matrix and Rule Induction) 모형으로 구성되어 있다. 이러한 통합모형의 성과를 증명하기 위해 서울시 용산구에 위치한 G 편의점으로부터 확보한 1,334건의 거래 내역 데이터를 기초로 분석하였고 그 결과를 기존 단일모형과 성과비교를 통하여 그 유용성을 검증해보고자 한다.

본 연구는 다음과 같이 구성되어 있다. 제 2장에서는 구매의도와 관련한 추천 시스템과 통합모형을 이용한 기업부도예측에 관련된 선행연구에 대해 설명한다. 제 3장에서는 본 연구에서 사용될 자료수집과 변수선정 과정에 대해 설명한다. 제 4장에서는 단일모형과 통합모형의 구축과정을 설명하고 통합모형의 구조와 특성을 설명한다. 제 5장에서는 검증데이터의 결과를 모아 단일모형과 통합모형의 예측력 성과비교를 통하여 그 유용성을 검증해본다. 제 6장에서는 결론과 향후 연구방향에 대해 논의한다.

2. 이론적 배경

2.1 구매의도 예측과 추천 시스템

고객은 구매하고자 하는 상품들을 비교, 평가하여

자신의 지불능력에 비추어 가장 마음에 드는 대안에 대한 구매의도를 가지고 구매를 하게 된다. 따라서 각각의 고객이 자사의 특정 상품 혹은 상품군의 구매와 관련해 관심이나 호응을 갖고 있는지, 아닌지를 분류하는 구매의도에 대한 예측은 오늘날 마케팅 분야에서 매우 중요한 이슈 중 하나로 자리매김하고 있다[24, 36].

추천 시스템은 고객들이 구매해보길 원하는 상품들에 대한 가이드를 제시하는 것으로써, 상품 설명서나 새로운 관련 기사 등과 같은 다양한 정보를 통하여 추천을 한다. 특히 온라인 정보와 전자상거래의 급격한 발전으로 인하여, 추천 시스템은 더욱 중요한 도구로써 그 필요성이 급증하고 있다[21]. 특히 추천시스템은 인터넷 고객관계관리(e-CRM : electronic CRM)의 여러 응용분야 중에서도 실무적으로 그리고 학문적으로 가장 활발하게 연구되고 있는 분야 중 하나다. Burke[20]는 협동필터링(Collaborative-Filtering) 기법과 내용기반(Content-Based) 접근법, 지식기반(Knowledge-Based) 접근법의 3가지 추천시스템을 제시하였다. 이들 추천을 위한 방법들 중에서, 지금까지 주류를 이뤄온 방법들은 협동필터링 기법과 내용기반 접근법이다. 그러나 이러한 기존 방법들은 몇 가지 태생적인 한계점으로 인해 고객의 구매 이력이 많지 않은 중소형 업종에 적용하기 어렵다는 단점이 있다.

내용기반 필터링 방법은 과거에 대상 고객이 선호했던 아이템과 가장 유사한 성격을 가진 아이템을 추천하는 방식으로서, 아이템과 아이템 사이(item-to-item)의 연관성을 기반으로 한 추천방식이다[19]. 이 방식은 무엇보다도 사용자(고객)의 선호도와 아이템(상품)의 특성을 어떻게 모델링 할 것인가가 이 기법의 성과를 결정짓는 핵심요인이라 할 수 있다. 내용기반 필터링 방법의 장점은 상품 자체를 모델링하는 기법이기 때문에, 직접적이고 단순하다는 점이다[45]. 단점으로는 추천을 위한 분석의 깊이가 얕을 수밖에 없다는 한계점이 있다. 이는 유사한 아이템을 규명하기 위해서는 각 개별 아이템의 특성을 명확하게 추출해 내야 하는데, 이것이 사람에 의존해야 하기 때문에 효과적으로 이루어지기 어렵다. 또한 추천의 결과가 주로 고객이 이미 구매를 했거나, 평가를 내린 아이템과 관련된 것으로만 결정되는 과도한 특수화(overspecialization) 문제도 존재한다. 이는 추천의 원리가 고객이 이전에 좋게 평가한 상품과 비슷한 상품군을 찾는 방식으로 이루어지기 때문에, 예전에 어떤 상품을 평가했었는가 하는 것에 추천 결과가 너무 의존하게 된다는 점이다. 이러한 내용기반 필터링 기법의 한계점들로 인해, 현실적으로는 협동필터링 접근법이 선행연구에서 더 활발하게 이용되고 있다[3, 6, 8].

협동필터링 접근법은 아이템간의 연관성을 고려하는 내용기반 필터링 방법과는 달리, 사용자간의 연관성을 기반으로 한 추천방식으로, 선호도 또는 구매 패턴이 유사한 고객군을 분류하고, 유사한 고객에 속하는 다른 사람들이 선호하는 상품을 추천하는 방식이다[26, 37, 42]. 협동필터링은 일반적으로 고객들이 동질적인 평가결과를 보이는 상품군에 대해 상대적으로 높은 예측력을 보이며, 데이터가 충분한 경우에는 다른 기법에 비해 상대적으로 높은 예측력을 보이는 장점을 가지고 있다[29, 32]. 이에 따라 협동필터링은 상품추천시스템 관련 연구에서 활발하게 이용되고 있으나 아래와 같은 한계점을 가지고 있다. 협동필터링은 우선 상품에 대한 고객의 선호도 및 구매 데이터를 바탕으로 추천을 하게 되므로 구매 데이터를 많이 보유하고 있는 대형 기업에서는 유용하지만, 구매 데이터가 상대적으로 부족한 중소 기업이나 사업 초기단계의 기업에서는 적용 가능성이 떨어진다. 즉, 협동필터링의 속성상 구매데이터가 부족한 경우에는 추천의 성과가 떨어질 수밖에 없다. 이런 문제점을 희박성 문제(sparsity problem)라고 한다. 또한 협동필터링 방법론은 구매 데이터가 증가함에 따라 유사한 고객군을 찾기 위한 연산처리가 기하급수적으로 증가하는 확장성 문제(scalability problem)가 발생한다[3, 6, 8, 12, 17, 28].

또한 Schafer et al.[36]의 연구에서는 추천 시스템을 비개인화 추천(Non-Personalized Recommendation), 속성기반 추천(Attribute-based Recommendation), 개인간 추천(People-to-People Recommen-

dation), 상품간 추천(Item-to-Item Recommendation)의 4가지로 구분하였다. 최근의 연구에서는 협동필터링 기법과 내용기반 접근법을 결합하는 연구가 진행되고 있다.

2.2 부도예측 연구에서의 통합모형의 적용

경영학 분야에서 통합모형으로 가장 많이 연구되고 있는 분야가 바로 부도예측이다. 부도예측에 관한 최근의 연구들은 전통적인 통계기법(판별분석, 로짓, 프로빗)과 인공지능 기법(인공신경망, 의사결정나무)의 성과를 비교, 분석하는 연구[14, 16, 22, 27, 33, 41, 44, 46]에서 나아가 통합방법론을 통해 모형의 예측력을 향상시키기 위한 방안들을 제시하고 있다. 이에 관련된 연구로 Lee et al.[30, 31]의 연구에서는 인공신경망과 다변량 판별분석, 귀납적 학습방법, SOFM(self organizing feature map) 등의 기법을 통합한 귀납적 학습지원 인공신경망을 제시하였고 실증분석결과 향상된 예측성과를 나타내었다. 추휘석 등[9]의 연구와 Shin and Lee[38]의 연구에서는 다수의 인공신경망 모형을 통합한 부도예측모형을 제시하였다. 다수의 신경망 모형의 결과에 따라 데이터를 분류하고 재분류된 데이터를 학습시켜 보다 나은 데이터의 패턴을 신경망에 적용하였다. 실험결과 다수의 신경망 모형을 통해 데이터를 분류 및 재학습시킨 결과 신경망 예측치와 실제 부도 사이의 일치 여부가 크게 개선되었다.

퍼지 기법은 경영 문제에도 두루 적용되어 왔으며 특히 금융공학 문제 및 경영 의사결정분야에 주로 활용되고 있다. 또한 퍼지 이론은 신용평가 문제에도 성공적으로 적용되고 있는데, 특히 사례기반추론 시스템과의 혼합적 적용에 의하여 기존의 연구에 비해 향상된 결과를 보여준 바 있다. 김경재, 한인구[2]의 연구에서는 퍼지신경망을 이용한 기업부실예측모형을 제안하였다. 이것은 기존 신경망에 퍼지집합의 개념을 적용하여 신경망 학습에 사용될 자료를 퍼지화하고 이를 신경망에 학습시키는 것이다. 퍼지신경망을 기업부도예측에 적용한 결과 기존의 신경망보다 우월한 예측성과를 나타내었다.

또한, 유전자 알고리즘이 기업부도예측에 적용된 연구가 많이 진행된 바 있는데, 이들 연구는 기업부도예측 문제에 다양한 분류 기법들을 통합적으로 적용하기 위하여 유전자 알고리즘을 사용한다. Shin and Lee[39]에서는 유전자 알고리즘을 패턴인식과 학습이 뛰어난 인공신경망의 가중치를 훈련시키거나 아키텍처를 설정하는데 통합하여 사용하는 Neuro-Genetic 인공신경망 모형을 제시하였다. 국외의 연구로는 Anandarajan et al.[15]이 유전자 알고리즘에 기반한 인공신경망 모형을 개발하였으며 이 모형을 역전파 인공신경망, 다변량 판별분석 모형과 예측성과를 상호 비교하여 분석하였다. Chen and Huang[23] and Abdelwashed and Amir[11]의 연구에서도 유전자 알고리즘에 기반한 인공신경망 모형을 제시하였다. 또한 Pendharkar [34]는 유전자 알고리즘에 기반한 새로운 Threshold-varying 인공신경망을 제시하였으며 이 모형을 역전파 인공신경망, 다변량 판별분석 모형 등과 예측성과를 상호 비교하여 분석하였다.

민재형, 이영찬[7]의 연구에서는 자료포괄분석(data envelopment analysis : DEA)을 신용평점모형 개발에 도입하여 실용성이 높은 신용평점화 방법론을 제안하였다. 건전과 부도 여부에 관한 사전적인 정보가 요구되는 기존의 분석방법(다변량 판별분석, 로지스틱 회귀분석, 인공신경망)과는 달리 DEA를 이용한 신용평점모형은 고객기업의 사후적인 정보만으로도 신용평점을 산출할 수 있다는 장점이 있다. 그러나 신용평점모형은 아직까지 국내 금융기관에 실제 적용된 사례가 없는 탐색적 접근방법으로, 기업의 사후적 정보만을 이용한 신용평점모형이기 때문에 다른 부도예측모형에 비해 판별력이 상대적으로 낮은 단점이 있다.

위 모형들은 알고리즘 관점에서 통합한 실질적인 통합모형이다. 실제 응용분석에 있어서 단순히 한 알고리즘만을 선택하여 모형을 적용시키는 것이 아닌 적용 가능한 알고리즘들의 장점을 통합한 통합모형 구축에 대한 이슈는 많은 실무자들에게 연구의 대상이 되고 있다. 또한 통합모형은 단일모형에 의해 추출된 결과들을 통합하여 하나의 결론

으로 도출할 수 있다는 점에서 예측 분야에 유용하게 쓰일 수 있을 것이다.

3. 연구 방법

3.1 자료 수집

고객 구매의도를 다양한 데이터마이닝 알고리즘들을 이용하여 예측하여 보고, 그 성과를 비교 및 분석하기 위하여 본 연구에서는 실제 데이터를 적용하여 해당 결과를 도출하였다.

본 연구에 사용된 데이터는 서울시 용산구에 위치한 *G* 편의점의 판매 자료이다. 1990년 12월에 1호점을 개점한 *G* 편의점은 국내 독자 개발 브랜드로 시작하여 2007년 현재까지 업계 1위를 굳건히 지켜오고 있는 국내 최고의 편의점이다.

G 편의점으로부터 확보한 자료는 지난 2005년 9월 1일부터 12월 7일 사이에 고객들이 구매한 1,334건의 거래 내역 데이터이다. 거래 내역은 *G* 편의점 지점 판매시점 정보관리 시스템(POS system)으로부터 확인하였다. 이 시스템의 필드는 <표 1>에서 보는 바와 같이 판매일자, 판매시간, 담당자, 영수증번호, 상품명, 수량, 구매금액, 구분/비고의 총 8개로 구성되어 있으며 영수증에 기록된 판매 품목만으로 고객의 구매의도를 예측하겠다는 본 연구의 목적에 따라 '상품명' 필드만 추출하여 표본으로 삼았다.

〈표 1〉 판매시점 정보관리 시스템의 테이블 정의서(Table Layout)와 코드(Code)

코 드	필 드	설 명
DP	Date_Purchased	판매일자
TP	Time_Purchased	판매시간
EN	Employee Number	담당자
RN	Receipt Number	영수증번호
IN	Item_Name	상품명
QU	Quantity	수량
PC	Purchase_Cost	구매금액
DE	Description	구분/비고

〈표 2〉 변수 목록

ID	카테고리(변수)	품 목
1	가공식품	동원참치, 천하장사소시지, 유동골뱅이, 오뚜기 3분카레, 햄 등
2	건강음료	베지밀, 비타600, 하늘보리, 녹차를 닮은 마음, 남양 십칠차 등
3	과자	스윙칩, 텅클, 초코다이제, 초코파이, 새우깡, 후렌치파이 등
4	김밥	참치바베큐&제육, 참치마요네즈 캔디김밥, 불고기참치&치킨 등
5	냉동식품	하림 스모크 닭다리, 고향만두, 냉동피자, 볶음밥, 스파게티 등
6	담배	레종, 디스, 말보로, 에세, 던힐, 더원, 디스 플러스, 인디고 등
7	라면	삼양 라면, 안성탕면, 튀김우동 큰사발면, 신라면, 왕뚜껑 등
8	맥주	하이트 355ML, 카프리 병맥주 330ML, OB 500ML, 코로나 등
9	빙과류	쿠엔크바, 크런치킹, 요맘떼 등
10	빵	찐빵, 샤니 페스츄리, 샌드위치, 치즈케익, 샤니 대보름 등
11	생수	퓨리스 , 해태 평창 샘물, 에비앙 등
12	생활용품	덴탈크리닉 2080치약, 스파크일회용 라이타, 위스퍼클린 등
13	소주	진로 참이슬, 두산 산, 백세주, 산사춘 등
14	신문	조선일보, 중앙일보, 스포츠신문, 일반 서적, 잡지 등
15	요구르트	매일 구트, 덴마크요구르트, 남양 불가리스, 생크림요구르트 등
16	우유	매일 우유(초코, 딸기), 서울 우유, 남양 진짜 초콜릿 듬뿍 등
17	주스	서울 아침에 주스, 델몬트 망고 스카시, 후레쉬 믹스, 쿨피스 등
18	초콜릿	스니커즈, 트윅스, 크라운 미니쉘, 가나 초코렛, 자유시간 등
19	캔디	후라보노 껌, 자이리톨 껌, 츄파춥스, 호올스 등
20	커피	레쓰비 마일드, 네스까페, 까페라떼, 프렌치 카페, 산타페 등
21	탄산음료	코카콜라, 칠성 사이다, 데미소다, 밀키스, 맥콜, 환타 등

3.2 변수 선정 및 사전처리

편의점에서 판매되는 제품의 종류가 다양한 관계로 전체 1,334개의 데이터에 포함되어 있는 품목들을 제품이 가지고 있는 성질의 유사성을 기준으로 <표 2>와 같이 총 21개의 카테고리로 분류하였다.

본 연구에서는 카테고리 하나가 실험에서 하나의 변수로 사용되는 것으로, 실험에는 총 21개의 변수가 사용되었다. <표 3>에서 보는 바와 같이 한 건의 거래 내역당 일련번호(N = 1, 2, …, 1334)를 지정해줌으로써 훈련용과 검증용 데이터 셋을 추출할 때 중복되는 현상을 방지하였고, 21개의 카테고리 변수에도 일련번호(W = 1, 2, …, 21)를 부여하였다. 각각의 거래 내역 N에서 고객이 카테고리 변수 W를 구입하였을 경우 1은 구매, 0은 비구매를 나타내도록 지정함으로써 분석이 용이하도록 설계하였다.

입력 데이터에서 총 1,334건의 거래 내역에 구매된 제품의 수는 2,965개이고 이들 구매 제품 중에서 우유가 507개로 전체 17.1%의 가장 큰 비중을 차지하였고, 그 다음으로는 냉동식품이 276개로 전체 9.3%를 차지하였다.

본 연구의 목적은 고객의 특정 상품에 대한 구매 의도를 다른 상품들에 대한 구매 패턴에 근거하여 예측하는 것이기 때문에, 21개의 카테고리 변수들 중에서 하나를 선택하여 종속변수로, 나머지 20개의 카테고리 변수들을 독립변수로 지정하였다. 실험설계로 종속변수는 21개의 카테고리 중에서 구매거래량이 가장 많은 우유로 지정하였으며 이것은 모든 실험의 목표결과가 고객의 우유구매 여부에 대한 예측정확도가 얼마나 높은지에 관한 것임을 의미한다.

모든 분석은 훈련용과 검증용의 두 가지 데이터 셋으로 구성되었으며 우선적으로 전체 1,334건의 거래 내역 중 우유를 구매한 거래 500건과 우유를 구매하지 않은 거래 500건을 무작위로 추출하여 1,000건의 데이터를 생성하였으며, 전체 데이터의 80%(800/1,000)는 훈련용 데이터 셋으로 사용하고, 나머지 20%(200/1,000)는 검증용 데이터 셋으로 사용하였다. 또한 보다 일반화된 연구결과를 얻기 위하여 본 연구에서는 상호검증방법(cross-validation method)을 사용하였다[43]. 따라서 총 10회에 걸친 상호검증방법을 실시하였다.

3.3 분석절차

본 연구는 <그림 1>과 같은 분석절차에 따라 진행된다.

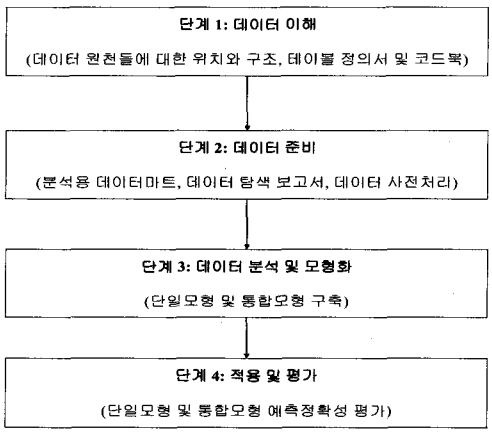

〈그림 1〉 분석절차

〈표 3〉 입력 데이터의 형태*

N \ W	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
1	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	1	0	0	0	0	0
2	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0
3	0	0	0	0	1	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:
1,334	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0

주) * 0 : 비구매, 1 : 구매

단계 1에서는 데이터에 대한 이해와 분석이다. 데이터마이닝의 성공여부는 사용 가능한 데이터의 양과 질에 전적으로 의존하며, 사용 가능한 데이터를 검토하고 데이터들의 특징을 이해하는 것이 좋은 모형을 만들기 위한 첫 단계가 된다. 따라서, 사용 가능한 데이터의 파악, 데이터 원천들에 대한 위치와 구조, 데이터 테이블의 필드와 그들의 코드 분석, 마지막으로 데이터들의 신뢰성, 정확성, 유용성을 검토해야 한다. 단계 2에서는 데이터 사전처리를 실시하는 데이터 준비단계이다. 이 단계에서는 제품 또는 고객단위의 레코드가 구성될 수 있도록 재배열(Rearrangement)해야 한다. 또한 품목들을 제품이 가지고 있는 성질의 유사성을 기준으로 총 21개의 카테고리로 분류하는 그룹화(Grouping) 과정을 실시한다. 단계 3에서는 만들어진 데이터마트를 이용하여 데이터에 대한 분석 및 예측모형의 구축을 수행하는 데이터 분석 및 모형화 단계이다. 본 연구에서는 연관성규칙, 빈도행렬, 규칙유도기법의 단일모형과 이들을 규칙기반(rule-based)으로 통합한 3가지 통합모형을 구축한다. 단계 4에서는 실무 데이터를 가지고 단일모형과 통합모형에 적용시킨 후 다양한 평가도구들을 이용하여 이들 모형의 성능을 평가하고, 최종적인 예측모형을 결정한다.

4. 연구 모형

4.1 연관성규칙(Association Rule)

데이터마이닝 기법 중 하나인 연관성규칙(Association Rule)은 데이터들의 빈도수와 동시발생확률을 이용하여 한 항목들의 그룹과 다른 항목들의 그룹 사이에 강한 연관성이 있음을 밝혀주는 기술이다. <그림 2>는 연관성규칙의 기본 알고리즘을 도식화 한 것이다[13].

(Item set A) → (Item set B)
(if A then B : 만일 A가 일어나면 B가 일어난다).

〈그림 2〉 연관성규칙의 기본 알고리즘

연관성규칙은 상품 혹은 서비스간의 관계를 살펴보고 이로부터 유용한 규칙을 찾아내고자 할 때 이용될 수 있는 기법이다. 동시 구매될 가능성이 큰 상품들을 찾아내기 때문에 시장바구니분석을 다루는 문제에 많이 적용된다. 측정의 기본은 얼마나 자주 구매되었는가 하는 빈도이다. 이 빈도를 기반으로 연관 정도를 정량화하기 위해서 다음의 두 가지 기준을 고려한다[13].

① 지지도(Support) : 전체 거래 중 항목 A와 항목 B를 동시에 포함하는 거래가 어느 정도 인가를 나타내주며 전체적 구매의도에 대한 경향을 파악할 수 있다.

② 신뢰도(Confidence) : 항목 A를 포함하는 거래 항목 B가 포함될 확률이 어느 정도 인가를 나타내주며 연관성의 정도를 파악할 수 있다.

지지도는 생성된 연관규칙이 전체 아이템에서 차지하는 비율을 말한다. 즉, 데이터베이스에 속한 전체 트랜잭션 중 A와 B를 포함하는 트랜잭션의 비율을 의미한다. 신뢰도는 연관규칙의 강도를 의미하며 전제 부를 만족하는 트랜잭션이 결론 부를 만족하는 비율, 즉 A를 포함하는 트랜잭션 중에서 B가 포함된 트랜잭션의 비율을 의미한다[40].

위 기준을 이용해 연관규칙을 탐사하는 과정에는 기본적으로 다음의 두 단계로 구성된다. 첫 번째 단계는 빈발 항목집합들(large itemsets)을 찾아낸다. 빈발 항목집합이란 최소지지도를 설정하여 사용자가 한꺼번에 구매하는 물품들의 집합(트랜잭션)에서 빈번하게 발생하는 트랜잭션이 그 지지도 이상 발생한다면 이것을 빈발 항목집합이라고 한다. 두 번째 단계는 데이터베이스로부터 연관성규칙을 생성하기 위하여 빈발 항목집합을 사용한다. 연관성규칙의 전체 성능은 첫 번째 단계에서 결정된다. 먼저 빈발 항목집합을 확인한 후에 해당되는 연관규칙을 두 번째 단계의 방법으로 쉽게 유도할 수 있다.

연관성 규칙은 일반적으로 구매 행위에 있어서 특정 아이템과 다른 아이템 간에 어떤 연관관계가

있는지를 찾아보는 것이다. 연관성 규칙은 비록 다른 데이터마이닝 기법에 비해 단순하지만, 일반적으로 조건-반응(If-then)으로 결과가 표현되어 이해하기 쉽고 또 이를 바로 실제에 적용하기 용이하다는 장점이 있다.

구매예측을 위한 데이터 셋에 적용되는 연관성 규칙은 *SAS E-Miner 4.0* 패키지를 적용해 도출하였다. 규칙 선정을 위한 기준은 지지도를 0.5%, 신뢰도를 10%로 설정하였으며, 그 결과 <표 4>와 같이 총 11개의 규칙이 추출되었다.

4.2 빈도행렬(Frequency Matrix)

빈도행렬은 인접행렬의 개념에서 출발한다. 인접행렬(Adjacency Matrix)은 데이터의 인접성을 이용하여 의사결정공간에서 유용하게 쓰일 수 있는 개념[4]으로 품목 A와 B가 존재할 때 품목 A와 B가 동시에 구매되었는지, 또는 품목 A가 B의 구매에 영향을 주었는지 그 여부를 확인할 수 있어 데이터마이닝의 기법 중 연관규칙 분석[13, 18]이나, 또는 추천 시스템[35] 및 데이터 시각화[25] 등에서 이용되고 있다. 빈도행렬은 상품들의 구매 빈도를 점수화하여 연관 정도를 파악함으로써 규칙을 추출하는 알고리즘이다. 따라서 빈도행렬을 이용하여 품목들간의 연관성규칙을 발견할 수 있다. 빈도행렬의 원리를 그림으로 구체화하면 <그림 3>과 같은 n × n 행렬로 나타낼 수 있다. <그림 3>에서 보는 바와 같이 거래 N에 구매된 상품이 3(과자)과 7(라면)이라면 3번과 7번이 만나는 교차구역에 1점의 빈도를 추가하는 것이다. 또한 구매 상품이 2(건강음료), 1(가공식품), 6(담배)이라면 상품번호를 {1, 2, 6}과 같이 오름차순으로 정렬한 다음 {1, 2}, {1, 6}, {2, 6}의 형태로 변형시켜 각각의 해당 교차점에 1점의 빈도를 추가하는 것이다. 이는 빈도행렬은 2차원의 형태로 두 가지 상품간의 연관정도만을 측정할 수 있기 때문에 거래 구매상품이 3개 이상인 경우는 위와 같은 형태로 변형시켜야 한다. 이와 같은 방법으로 전체 거래 내역에 대한 빈도행렬을 작성하면 거래 빈도가 제일 높은 상품들의 조합과 그들의 연관성 수치를 알 수 있다.

<그림 4>는 첫 번째 검증용 데이터 셋에서 빈도행렬의 예측기법을 설명한 것이다. 우선, (b)와 (c)에서 보는 바와 같이 전체 훈련용 데이터를 바탕으로 각 구매에 해당하는 빈도를 계산하여 우유구매 행렬과 우유비구매 행렬을 생성한다. 위 두 행렬을 바탕으로 검증용 데이터에서 거래 구매상품에 해당하는 빈도수를 대입하여 각각의 구매레코드에 대한 구매점수와 비구매점수를 산출한다. 예를 들면 (a)의 검증용 데이터 구매 1번은 1(가공식품), 5(냉동식품), 6(담배)를 구매한 형태이다. 이

〈표 4〉 첫 번째 데이터 셋에서의 연관성규칙 적용 결과

지지도(%)	신뢰도(%)	생성된 규칙	해 석
5.5	82	18 → 16	초콜릿 → 우유
3.5	86	1 → 16	가공식품 → 우유
3.5	57	6 → 19	담배 → 캔디
2	50	2 and 10 → 15	건강음료와 빵 → 요구르트
1.5	67	3 and 10 → 8	과자와 빵 → 맥주
1.5	67	14 → 6	신문 → 담배
1	100	16 and 19 → 18	우유와 캔디 → 초콜릿
1	50	9 → 12	빙과류 → 생활용품
1	50	3 and 5 → 7	과자와 냉동식품 → 라면
1	50	2 and 5 → 20	건강음료와 냉동식품 → 커피
1	50	9 → 3	빙과류 → 과자

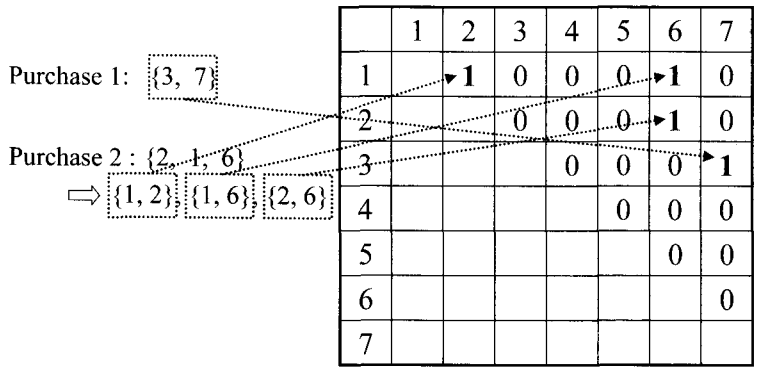

〈그림 3〉 빈도행렬의 학습/훈련 알고리즘

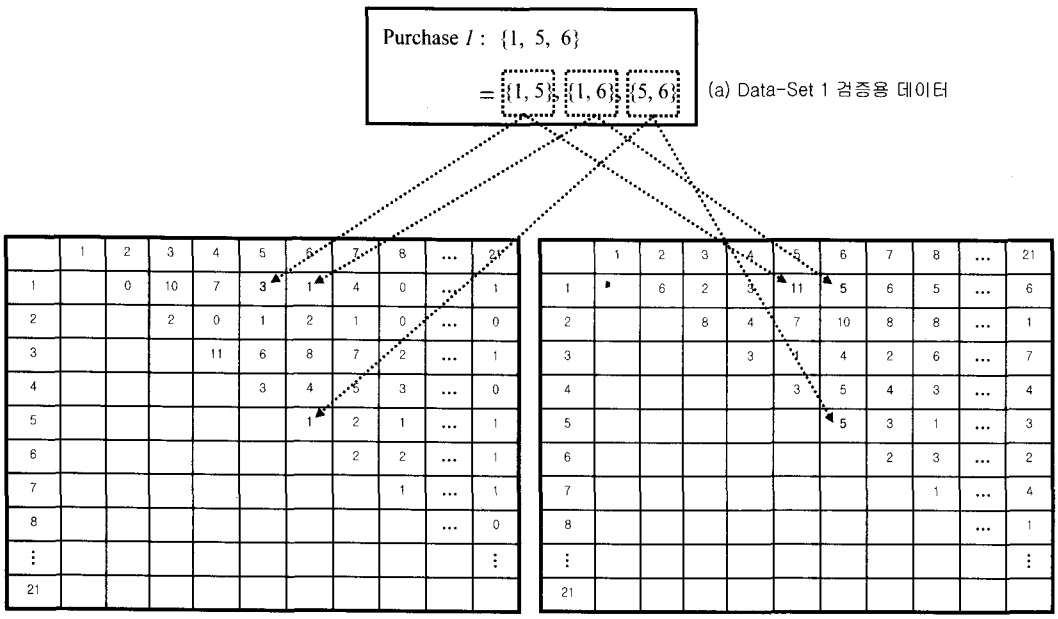

〈그림 4〉 빈도행렬의 예측기법

에 대한 (b)의 우유구매 행렬 값은 {1, 5} = 3, {1, 6} = 1, {5, 6} = 1의 값을 가지며 이들을 모두 합한 구매점수는 5점이 된다. 또한 (c)의 우유 비구매 행렬 값은 {1, 5} = 11, {1, 6} = 5, {5, 6} = 5 값을 가지며 이 값을 모두 합한 비구매점수는 21점이 된다. 따라서 빈도행렬 예측결과는 구매점수와 비구매점수 중에서 큰 값이 예측결과로 채택되며 예제 1번 레코드에서는 우유비구매로 판별된다. 빈도행렬기법은 Microsoft의 *Visual Basic .NET*을 이용하여 구체화하였다.

<표 5>는 첫 번째 데이터 셋에서 빈도행렬 기법을 이용하여 규칙을 추출한 것이다. 첫 번째 데이터 셋에서는 빈도가 최소한 8이상인 규칙 9개가 추출되었다. 9개의 규칙 중에서 빵을 구매하면 동시에 우유를 구매한다는 규칙의 빈도가 65로 가장 높았으며, 냉동식품을 구매하면 동시에 우유를 구

〈표 5〉 첫 번째 데이터 셋에서의 빈도행렬 적용 결과

규칙번호	해 석	빈 도
규칙 1	IF Bread Buy Then Milk Buy(빵을 구매하면 동시에 우유를 구매)	65
규칙 2	IF Frozen food Buy Then Milk Buy(냉동식품을 구매하면 동시에 우유를 구매)	57
규칙 3	IF Sweets Buy Then Milk Buy(과자를 구매하면 동시에 우유를 구매)	34
규칙 4	IF Tobacco Buy Then Milk Buy(담배를 구매하면 동시에 우유를 구매)	31
규칙 5	IF Chocolate Buy Then Milk Buy(초콜릿을 구매하면 동시에 우유를 구매)	20
규칙 6	IF Health beverage Buy Then Milk Buy(건강음료를 구매하면 동시에 우유를 구매)	15
규칙 7	IF Household items Buy Then Milk Buy(생활용품을 구매하면 동시에 우유를 구매)	13
규칙 8	IF Spring water Buy Then Milk Buy(생수를 구매하면 동시에 우유를 구매)	9
규칙 9	IF Processed food Buy Then Milk Buy(가공식품을 구매하면 동시에 우유를 구매)	8

매한다는 규칙의 빈도가 57을 나타냈다. 세 번째와 네 번째 규칙으로는 과자를 구매하면 동시에 우유를 구매한다는 규칙의 빈도가 34를 나타냈으며 담배를 구매하면 동시에 우유를 구매한다는 규칙의 빈도는 31을 나타내었다. 이들 4가지의 규칙은 공통적으로 다른 데이터 셋에서도 높은 빈도 값을 기록하였으며 이것이 이들이 가장 영향력 있는 규칙이라는 것을 의미한다.

4.3 규칙유도기법

본 연구에서는 보다 효과적인 고객구매예측을 위한 방법으로 규칙이라는 형태를 이용한다. 이러한 규칙은 규칙유도기법에 의해 규칙으로 쉽게 전환될 수 있다. 규칙유도기법의 장점은 전체적인 과정에서 불필요한 요소들은 자동적으로 제거가 된다는 것이다. 이것은 사용자 및 분석자에게 데이터에 대해 더 많은 정보를 주게 되고, 사용자가 여타 인공지능 기법을 사용할 때 필드를 선택할 수 있는 기준을 마련하여 더욱 효율적인 인공지능 분석에 도움을 줄 수 있다. 또한 규칙유도기법은 의사결정나무 형식으로 되어 있어 예측 필드에 대해 영향력을 가지고 있는 필드들을 명확히 보여준다. 즉, 규칙이 어떻게 작용하는지 이해하기 위해 웹 분석이나 히스토그램과 같은 방법을 사용할 필요가 없다. 규칙유도기법 시스템은 시스템과 사용자의 상호작용을 가능케 하는 자연어처리 부문, 전문지식을 저장해 놓은 지식베이스, 지식베이스의 내용을 이용하여 사용자의 문제 해결을 도와주는 추론기관의 세 부분으로 구성되어 있다[10].

구매예측에 대한 규칙유도기법 구축과 평가를 위해 *Clementine 8.1* 프로그램을 사용하였다. *Clementine 8.1*에는 C5.0 알고리즘과 Build Rule 알고리즘이라 불리는 2가지 규칙유도 알고리즘이 있으며 이 중에서 C5.0 알고리즘을 사용하였다. 훈련용으로 분류된 데이터를 이용하여 규칙유도기법 모형을 구축한 후 검증용 데이터에 적용하여 분류 예측정확도를 분석하였다.

<표 6>은 첫 번째 데이터 셋에서 규칙유도기법을 이용하여 규칙을 추출한 것이다. <표 6>에서 제시된 신뢰도(confidence)는 이 규칙에 맞게 분류된 비율을 나타내는 것이다. 신뢰도의 범위는 0과 1사이의 값을 가지며 첫 번째 데이터 셋에서는 신뢰도의 값이 0.778이상인 13개의 규칙이 도출되었다. 이들 규칙 중에서 초콜릿과 캔디를 구매하면 동시에 우유를 구매한다는 규칙, 생활용품과 빙과류를 구매하면 동시에 우유를 구매한다는 규칙, 과자와 빵을 구매하면 동시에 우유를 구매한다는 규칙들은 1의 신뢰도 값을 나타내었다. 위 3가지 규칙은 공통적으로 다른 데이터 셋에서도 신뢰도 값이 0.95이상을 기록하였으며 이것은 이들이 가장 영향력 있는 규칙이라는 것을 의미한다.

〈표 6〉 첫 번째 데이터 셋에서의 규칙유도기법 적용 결과

규칙번호	해 석	신뢰도*
규칙 1	IF Chocolate Buy and Candy Buy Then Milk Buy (초콜릿과 캔디를 구매하면 동시에 우유를 구매)	1.0
규칙 2	IF Household items Buy and Ice cream Buy Then Milk Buy (생활용품과 빙과류를 구매하면 동시에 우유를 구매)	1.0
규칙 3	IF Sweets Buy and Bread Buy Then Milk Buy (과자와 빵을 구매하면 동시에 우유를 구매)	1.0
규칙 4	IF Instant noodle Buy and Bread Buy Then Milk Buy (라면과 빵을 구매하면 동시에 우유를 구매)	0.975
규칙 5	IF Tobacco Buy and Carbonated beverage Buy Then Milk Buy (담배와 탄산음료를 구매하면 동시에 우유를 구매)	0.975
규칙 6	IF Rice rolled in dried laver Buy and Frozen food Buy Then Milk Buy (김밥과 냉동식품을 구매하면 동시에 우유를 구매)	0.96
규칙 7	IF Chocolate Buy and Frozen food Buy Then Milk Buy (초콜릿과 냉동식품을 구매하면 동시에 우유를 구매)	0.929
규칙 8	IF Household items Buy and Frozen food Buy Then Milk Buy (생활용품과 냉동식품을 구매하면 동시에 우유를 구매)	0.929
규칙 9	IF Instant noodle Buy and Ice cream Buy Then Milk Buy (라면과 빙과류를 구매하면 동시에 우유를 구매)	0.900
규칙 10	IF Bread Buy Then Milk Buy (빵을 구매하면 동시에 우유를 구매)	0.872
규칙 11	IF Rice rolled in dried laver Buy Then Milk Buy (김밥을 구매하면 동시에 우유를 구매)	0.872
규칙 12	IF Bread Buy and Household items Buy Then Milk Buy (빵과 생활용품을 구매하면 동시에 우유를 구매)	0.845
규칙 13	IF Health beverage Buy and Ice cream Buy Then Milk Buy (건강음료와 빙과류를 구매하면 동시에 우유를 구매)	0.778

주) * 신뢰도 : 최종노드의 예측범주 레코드수 + 1/(최종노드의 전체레코드수 + 전체범주수).

4.4 통합모형

<그림 5>는 통합모형 아키텍처를 설명한 것으로 통합모형을 구축할 경우 오차항(error-term)이 줄어드는 현상을 그림으로 도식화한 것이다. 1단계에서는 구매데이터베이스에서 데이터마이닝 기법을 이용하여 3가지의 구매예측모형을 구축하였다. 각 구매예측모형에서의 설명력(R-square)과 오차항(ε)이 <그림 5>와 같이 다양하게 구성되었으며, 여기서 오차항은 각 모형에서 설명할 수 없는 부분을 의미한다. 2단계에서는 위 3가지의 구매예측 모형을 이용하여 규칙기반(rule-based)의 통합모형을 구축할 경우 오차항이 줄어들면서 설명력이 증가하는 좀더 예측력이 뛰어난 모형 구축이 가능하다. 이러한 통합모형 아키텍처의 이론적 배경이 바로 앙상블 접근법(ensemble approaches)이다. 앙상블 접근법은 한 명의 전문가보다 여러 명의 전문가가 한 예측을 종합했을 때 더 나은 결과를 가져올 수 있다는 점에 기초한다. 특히 여러 명의 전문가가 서로 독립적으로 예측결과를 잘못 만들어낼 때에는 그것을 종합했을 때 더욱 정확한 예측을 할 수 있다.

통합모형 구축과정은 <그림 6>에서 보는 바와 같이 2단계로 구성되어 있다. 첫 번째 단계에서는 연관성규칙, 빈도행렬, 규칙유도기법을 이용하여 구매예측모형을 구축한다. 두 번째 단계에서는 각

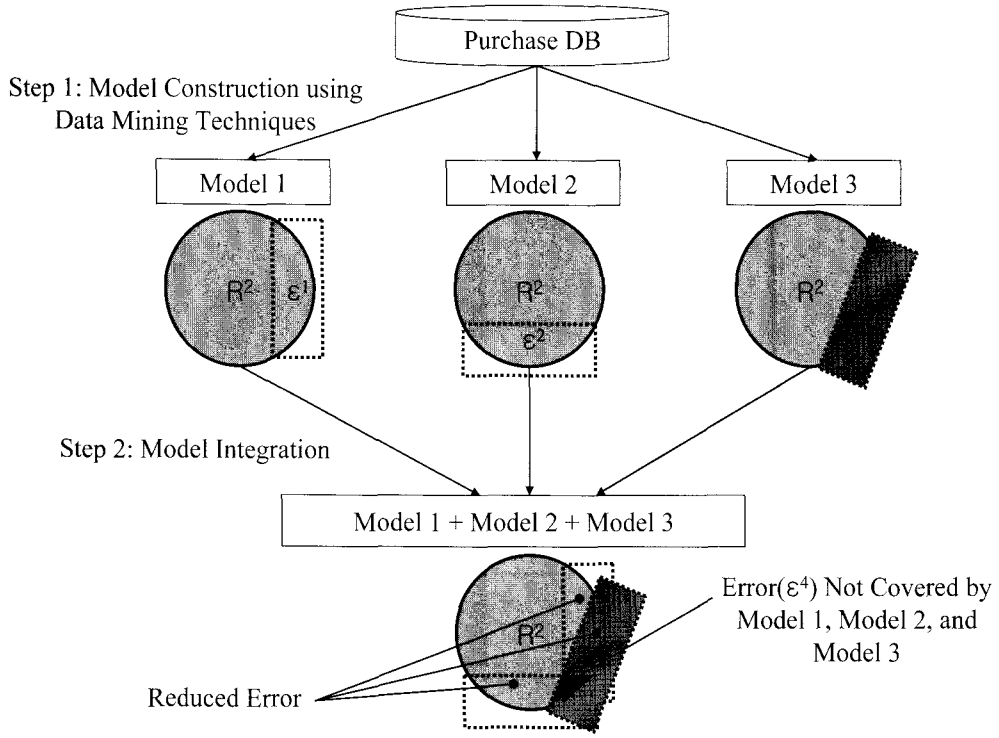

〈그림 5〉 단일모형을 통합한 통합모형 아키텍처

각의 모형에서 규칙들을 도출한 후 이 규칙들을 결합한 통합모형을 구축한다. 이로써 두 번째 단계에서의 규칙(R_1, R_2, R_3)은 <그림 6>에서 보는 바와 같이 통합된 규칙집합(R_1+R_2+R_3)으로 전환되어 통합모형에 적용되는 것이다. 즉, 하나의 데이터 셋을 이용하여 각 모형에서 나온 규칙들을 규칙집합(rule set)이라고 정의한다면 통합모형에서의 규칙들은 누적된 규칙집합이라고 말할 수 있다. 이것은 단일모형에서 얻은 규칙집합이 누적되면서 지식으로 축적되기 때문에 단일모형에서의 규칙집합보다 예측력에서 좀더 뛰어난 성능을 가질 수 있다. 즉, 어느 단일모형에서 만들어진 규칙에 의해 분류되느냐에 따라 서로 다른 클래스(비구매, 구매)로 분류될 수 있지만 그것이 누적되면 결국은 실제 분류되어야 할 값과 같은 값으로 분류될 확률을 높일 수 있다는 것이다. 또한 통합모형은 규칙집합 정보만 필요하기 때문에 규칙이 추출되어 집합의 형태로 된 이후에는 원천 데이터 셋이 더 이상 필요하지 않으므로 저장할 필요가 없다. 이는 통계적으로 고정된 데이터가 아닌 시간의 흐름에 따라 무한히 추가되고 그 성격이 변하는 스트림 데이터에 적용할 경우 저장공간, 메모리, 시간 등의 자원 소모를 크게 줄일 수 있다는 장점이 있다[5]. 요약하면, 통합모형을 이루고 있는 누적된 규칙집합은 데이터 셋 대신에 과거 정보를 유지하는 수단으로 저장되는데 그 크기가 현저하게 작으므로 저장공간의 소모가 작고 하나의 데이터 셋을 이용하여 단일모형에서 얻은 규칙집합이 누적되면서 단 하나의 규칙집합 또는 하나의 단일모형으로 예측하는 것보다 예측력에서 좀더 뛰어난 성능을 가질 수 있다.

통합모형의 알고리즘과 해석방법을 <표 7>로 나타내었다. 우선, 훈련용 데이터에서 연관성규칙, 빈도행렬, 규칙유도기법을 이용하여 예측모형을 구축한 후 각각의 모형에서 규칙들을 도출한다. 이들 단일모형의 모든 규칙들을 누적시킨 규칙집합을 이용하여 200개의 검증용 데이터 셋에 적용한 결과

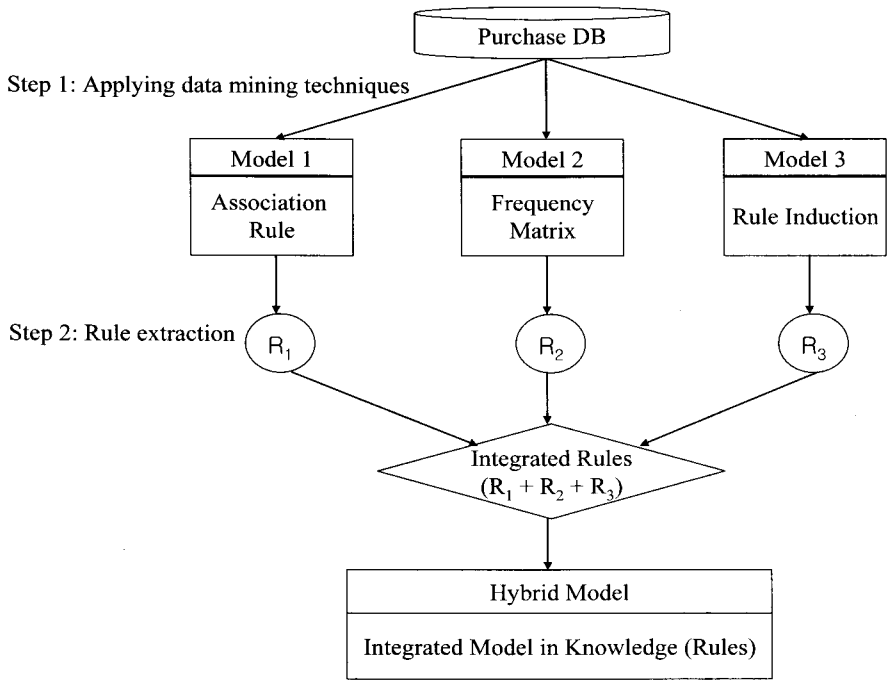

〈그림 6〉 통합모형 구축과정

〈표 7〉 첫 번째 데이터 셋에서의 통합모형 결과의 예

ID	W_1	W_2	W_3	···	W_{21}	Rule 1 (R_1)	Rule 2 (R_2)	···	Rule K (R_K)	ΣRule Set	*Y*
1	0	0	1	···	0	0	1	···	1	2	구매
2	0	0	1	···	1	0	-1	···	0	-1	비구매
3	0	1	1	···	1	-1	-1	···	0	-2	비구매
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
200	1	0	0	···	0	1	1	···	1	3	구매

주) 1) W_i : 21개의 카테고리로 분류된 변수목록 {0 = 비구매, 1 = 구매}.
2) Rule *K* : 연관성규칙, 빈도행렬, 규칙유도기법에서 추출한 K개의 규칙 {−1 = 규칙적용 우유비구매, 1 = 규칙적용 우유구매, 0 = 규칙적용 불가능}.
3) ΣRule Set : 누적된 규칙(규칙집합)의 결과 합계 {0을 제외한 모든 정수}.
4) Y : 통합모형 예측결과{ΣRule Set < 0이면 우유비구매, ΣRule Set > 0이면 우유구매}.

가 바로 통합모형의 예측결과이다. <표 7>에서 보는 바와 같이 1번 레코드에서는 과자(W_3)를 구매한 고객이 우유를 구매할 것인지에 대한 예측결과를 나타낸 것이다. 단일모형에서 추출된 첫 번째 규칙(Rule 1)은 규칙적용이 불가능한 형태이다. 이것은 과자구매에 따른 우유구매 여부에 관한 1번 레코드에는 첫 번째 규칙이 유용성이 없는 규칙이며 다른 레코드에서 적용이 가능하다는 것을 의미한다. 그러나 두 번째 규칙(Rule 2)과 *K* 번째 규칙(Rule *K*)에서는 1번 레코드에 맞는 규칙이 적용되어 우유를 구매한다는 예측결과가 도출되었다. 따라서 이들 누적된 규칙집합의 결과를 합한 값(Σ Rule Set)이 양의 값을 가지면 우유구매로, 음의 값을 가지면 우유비구매로 예측을 하며 1번 레코

드에서는 2의 값이 산출되었으므로 통합모형의 예측결과는 우유구매로 판별한다. 즉, 누적된 규칙집합이 검증용 데이터에 적용되어 구매여부를 예측하고 가장 많이 예측된 결과가 통합모형의 예측결과로 판별된다.

5. 연구 결과

연구결과 분석을 위하여 검증데이터의 결과만을 모아 <표 8>을 구성하였고 <표 8>의 결과를 바탕으로 모형별 평균 예측력을 보여주는 <그림 7>을 구성하였다.

<표 8>과 <그림 7>의 결과에서 나타난 것과 같이 평균예측력은 통합모형인 ASFMRI모형(75.35%)이 전체 방법론과 비교하여 가장 예측력이 높았으며 데이터 셋 별로도 ASFMRI모형이 해당 각 데이터 셋에서 예측력이 가장 높다는 것을 알 수 있었다. 또한 2 가지의 단일모형을 통합한 ASRI모형(73.45%), FMRI모형(69.15%) 또한 단일모형보다 예측력이 더 뛰어났으나 3가지 모형을 통합한 ASFMRI모형(75.35%) 보다는 예측력이 낮다는 것을 알 수 있었다. 또한 단일모형 중에서 빈도행렬은 가장 예측력이 낮은 모형(51.7%)이며 통합에 있어서도 별다른 큰 영향력을 발휘하지 못하였다. 즉, 빈도행렬과 통합한 ASFM모형(65.35%)은 단일모형인 연관성규칙(64.0%) 보다는 예측력이 뛰어났으나 규칙유도기법(67.6%)에 비해서는 예측력이 떨어지는 것을 알 수 있었다. 이에 대한 원인으로 다음 2가지를 들 수 있다. 첫 번째 원인은 빈도행렬은 2차원의 행렬형태로 구성되어 있어 두 가지의 물품 $A \rightarrow B$ 형태의 규칙만 생성되기 때문에 다양한 형태의 규칙이 생성되지 못하는 제약(constraint)이 있다. 두 번째 원인으로는 대부분 빈도행렬에서 추출한 규칙 또는 규칙집합이 연관성규칙이나 규칙유도기법에서 추출한 규칙 또는 규칙집합에 대부분 반영되어 있다는 것을 규칙분석에서 확인할 수 있었다.

<그림 7>의 결과에서 나타난 것과 같이 평균예측력을 모든 방법론과 비교하여 순서대로 나열하면 ASFMRI모형, ASRI모형, FMRI모형, 규칙유도기법, ASFM모형, 연관성규칙, 빈도행렬의 순이다.

상기 기법들간의 예측정확도 차이가 통계적으로 유의한지를 검증하기 위해 검증용 데이터를 대상으로 McNemar 검정을 실시하였다. McNemar 검정은 비모수 통계분석기법으로 이진값을 가지는 명목형 변수에 대해 관련이 있는 두 집단간의 차이

〈표 8〉 전체결과

구 분	연관성 규칙(A)	빈도행렬(B)	규칙유도 기법(C)	ASFM (A + B)	ASRI (A + C)	FMRI (B + C)	ASFMRI (A + B + C)
Set 1	64.0	52.5	68.0	64.0	70.5	68.0	73.5
Set 2	62.5	51.5	69.5	63.5	76.0	69.5	77.5
Set 3	68.5	51.0	73.5	68.5	79.5	73.5	79.5
Set 4	66.5	52.0	73.0	69.5	73.0	75.5	79.0
Set 5	61.5	51.0	64.5	61.5	68.5	65.0	70.0
Set 6	67.0	50.5	70.0	68.0	80.5	70.0	82.5
Set 7	62.0	52.0	68.0	64.5	70.0	69.5	70.0
Set 8	64.5	52.5	64.0	66.5	74.0	69.0	77.0
Set 9	59.0	52.0	64.5	63.0	74.0	66.5	74.0
Set 10	64.5	52.0	61.0	64.5	68.5	65.0	70.5
평 균	64.0	51.7	67.6	65.35	73.45	69.15	75.35
표준편차	2.85	0.67	4.07	2.63	4.25	3.38	4.40

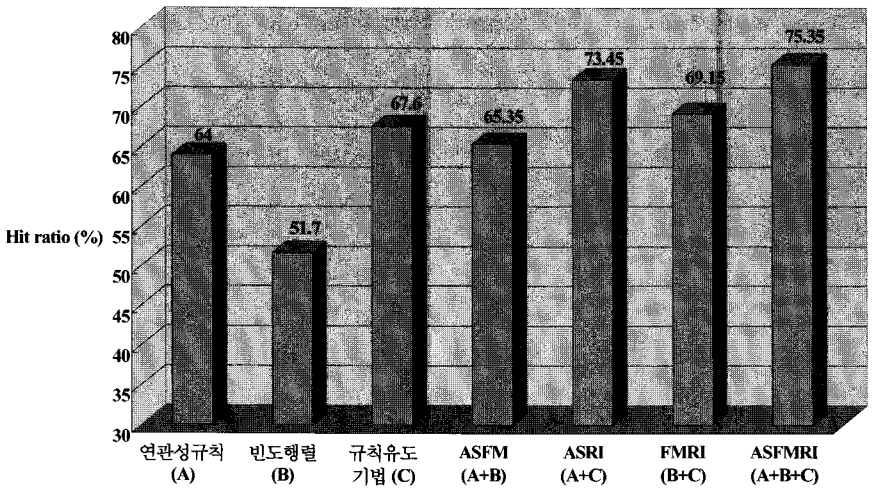

〈그림 7〉 모형별 평균예측력 비교

를 검정할 때 사용된다. 특히, McNemar 검정은 동일한 대상에 대한 처리 전·후의 측정치 비교에 매우 유용한 것으로 알려져 있다.

〈표 9〉 McNemar 검정결과

	연관성규칙 (A)	빈도행렬 (B)	규칙유도기법 (C)
ASFMRI (A + B + C)	8.481 (0.004)**	44.180 (0.000)**	2.813 (0.094)*
연관성규칙		24.038 (0.000)**	0.291[1] (0.590)[2]
빈도행렬			10.223 (0.001)**

주)[1]: McNemar 통계량 값. / [2]: p-값.
*: 유의수준 10%에서 통계적으로 유의함.
**: 유의수준 5%에서 통계적으로 유의함.

<표 9>는 통합모형 중에서 가장 예측력이 뛰어난 ASFMRI모형과 연관성규칙, 빈도행렬, 규칙유도기법의 단일모형과의 McNemar 예측결과를 비교한 것이다. <표 9>에서 보는 바와 같이 ASFMRI 모형은 연관성규칙, 빈도행렬과는 5% 수준에서 유의하였고 규칙유도기법과는 10% 수준에서 유의한 차이를 나타내어 이들 단일모형보다 예측성과가 뛰어남을 확인할 수 있었다.

6. 결 론

본 연구에서는 기존의 데이터마이닝 기법들이 가지고 있는 한계점들을 최소화하기 위하여, 이질적인 단일모형들을 지식 결합을 이용하여 시너지 효과를 생산할 수 있는 통합모형을 제시하였다. 따라서 본 연구에서는 보다 효과적인 고객구매예측을 위하여, 연관성규칙, 빈도행렬, 규칙유도기법의 단일모형을 규칙기반(rule-based)에의한 지식이 축적된 통합모형을 제시하였다. 통합모형은 연관성규칙(A)과 빈도행렬(B)을 결합한 ASFM모형, 연관성규칙(A)과 규칙유도기법(C)을 결합한 ASRI모형, 빈도행렬(B)과 규칙유도기법(C)을 결합한 FMRI모형, 마지막으로 3가지 모형을 모두 통합한 ASFMRI모형(A + B + C)으로 구성되어 있다.

실험결과, 본 연구에서 제안한 통합모형인 ASFMRI모형(75.35%)이 전체 방법론과 비교하여 가장 예측력이 높았으며 데이터 셋 별로도 ASFMRI모형이 해당 각 데이터 셋에서 예측력이 가장 높다는 것을 알 수 있었다. 또한 2가지 단일모형을 통합한 ASRI모형(73.45%), FMRI모형(69.15%) 또한 다른 단일모형보다 보다 예측력이 더 뛰어났으나 3가지 모형을 통합한 ASFMRI모형(75.35%) 보다는 예측

력이 낮다는 것을 알 수 있었다. 또한 단일모형 중에서 빈도행렬기법은 가장 예측력이 낮은 모형(51.7%)이며 통합에 있어서도 별다른 큰 영향력을 발휘하지 못하였다. 즉, 빈도행렬기법과 통합한 ASFM모형(65.35%)은 단일모형인 연관성규칙(64.0%) 보다는 예측력이 뛰어났으나 규칙유도기법(67.6%)에 비해서는 예측력이 떨어지는 것을 알 수 있었다. 이에 대한 원인으로 다음 2가지를 들 수 있다. 첫 번째 원인은 빈도행렬은 2차원의 행렬형태로 구성되어 있어 두 가지의 물품 $A \rightarrow B$ 형태의 규칙만 생성되기 때문에 다양한 형태의 규칙이 생성되지 못하는 제약(constraint)이 있다. 두 번째 원인으로는 대부분 빈도행렬에서 추출한 규칙 또는 규칙집합이 연관성규칙이나 규칙유도기법에서 추출한 규칙 또는 규칙집합에 대부분 반영되어 있다는 것을 규칙분석에서 확인할 수 있었다.

통합모형 중에서 가장 예측력이 뛰어난 ASFMRI 모형과 단일모형과의 McNemar 예측결과를 비교한 결과 ASFMRI모형은 연관성규칙, 빈도행렬과는 5% 수준에서 유의하였고 규칙유도기법과는 10% 수준에서 유의한 차이를 나타내어 이들 단일모형보다 예측성과가 뛰어남을 확인할 수 있었다.

실제 응용분석에 있어서 단순히 특정 한가지의 알고리즘만을 사용하겠다고 미리 가정하고 분석하는 것, 즉, 한 가지 알고리즘만을 선택하여 모형을 적용시킬 것이 아니라, 적용 가능한 알고리즘 전반을 선택한 다음, 각 알고리즘에서 추출한 규칙을 누적된 규칙집합의 형태로 통합한 통합모형을 구축하는 것이 오차항을 줄이고 설명력을 높일 수 있는 안정적인 결과로 도출될 수 있다는 사실을 실험결과를 통해 알 수 있었다. 이러한 통합모형 아키텍처가 바로 앙상블 접근법(ensemble approaches)이다. 앙상블 접근법은 한 명의 전문가보다 여러 명의 전문가가 한 예측을 종합했을 때 더 나은 결과를 가져올 수 있다는 점에 기초한다. 특히 여러 명의 전문가가 서로 독립적으로 예측결과를 잘못 만들어낼 때에는 그것을 종합했을 때 더욱 정확한 예측을 할 수 있다. 즉, 어느 단일모형에서 만들어진 규칙에 의해 분류되느냐에 따라 서로 다른 클래스(비구매, 구매)로 분류될 수 있지만 그것이 누적되면 결국은 실제 분류되어야 할 값과 같은 값으로 분류될 확률을 높일 수 있다는 것이다. 또한 통합모형은 규칙집합 정보만 필요하기 때문에 규칙이 추출되어 집합의 형태로 된 이후에는 원천 데이터 셋이 더 이상 필요하지 않으므로 저장할 필요가 없다. 이는 통계적으로 고정된 데이터가 아닌 시간의 흐름에 따라 무한히 추가되고 그 성격이 변하는 스트림 데이터에 적용할 경우 저장공간, 메모리, 시간 등의 자원 소모를 크게 줄일 수 있다는 장점이 있다. 요약하면, 통합모형을 이루고 있는 누적된 규칙집합은 데이터 셋 대신에 과거 정보를 유지하는 수단으로 저장되는데 그 크기가 현저하게 작으므로 저장공간의 소모가 작고 하나의 데이터 셋을 이용하여 단일모형에서 얻은 규칙집합이 누적되면서 단 하나의 규칙집합 또는 하나의 단일모형으로 예측하는 것보다 예측력에서 좀더 뛰어난 성능을 보여주고 있다.

그러나 통합모형 알고리즘 상에서도 몇 가지 문제점이 발생할 수 있다. 첫째, 누적된 규칙집합의 결과를 합한 값(ΣRule Set)이 양의 값 또는 음의 값을 가지지 않고 0의 값을 가지는 문제이다. 이것은 단일모형에서 추출한 규칙집합이 해당 레코드에 모두 규칙적용이 불가능할 경우와 동일한 수로 구매와 비구매를 예측했을 경우 나타난다. 비록 본 연구에서는 10개의 검증용 데이터 셋 중에서 이와 같은 결과가 약 1.7%(34/2000)로 발생하였으나 데이터의 수가 적거나 누적된 규칙집합이 적을 경우 문제가 발생할 수 있다. 둘째, 단일모형 중 규칙유도기법에서는 규칙도출시 분리기준과 정지규칙을 최적으로 설정하는 문제를 한계로 들 수 있다.

본 연구를 통하여 고객의 상품 구매의도에 대한 가장 높은 예측력을 보이는 기법을 찾아냄으로써 보다 효율적이고 수익성 있는 고객관계관리 전략 수립에 가치 있는 정보를 제공할 수 있을 것으로 기대한다. 통합모형의 알고리즘을 가지고 추천 시스템을 구현하여 좀더 고객들에게 좋은 상품을 추

천할 수 있도록 정보를 제공할 수 있을 것이다.

마지막으로 본 연구가 가지고 있는 한계점을 정리하면서 앞으로의 관련 연구의 방향을 제시하고자 한다. 첫째, 연구결과의 일반화(generalization)에 대한 점이다. 본 연구의 목적은 고객의 특정 상품에 대한 구매 의도를 다른 상품들에 대한 구매 패턴에 근거하여 예측하는 것이다. 따라서, 실험설계에 있어서 종속변수는 21개의 카테고리 중에서 구매거래량이 가장 많은 우유로 지정하였다. 본 연구의 결과는 다른 카테고리(물품)를 대상으로 연구할 경우 그 결과가 달라질 수 있다. 그러므로 향후 연구에서는 연구결과의 일반화 정도를 높이기 위해 다른 물품을 종속변수로 선정한 실험설계를 통하여 통합모델의 예측성과를 비교해 볼 필요성이 있다. 둘째, 본 연구에서 사용된 데이터의 유형은 행동특성 데이터(Behavioral Data)이다. 행동특성 데이터는 시간에 따라 빨리 변화하며, 데이터의 구조도 쉽게 변경되고 갱신될 수 있다는 단점이 있다. 따라서 과거의 유용한 행동특성들이 버려지지 않도록 데이터 웨어하우스와 같은 별개의 저장소에 시간에 따라 요약정보의 형태로 보관되어야 한다. 이들 데이터를 가지고 데이터마이닝을 이용한 구매예측 통합모형을 구축한다면 예측력 향상과 더불어 좀더 의미 있는 결과를 가져올 수 있을 것이다. 셋째, 향후 연구에서는 누적된 규칙집합 중에서도 상대적으로 중요한 규칙집합과 중요하지 않은 규칙집합을 구분하여, 중요도가 높은 규칙집합만으로 예측모형을 구성한 경우와 전체 규칙집합을 유지하면서 중요도 높은 규칙집합과 중요하지 않은 규칙집합에 가중치를 달리 적용하는 실험을 통하여 예측정확도를 비교하는 연구가 필요하다. 위 연구는 통합모형의 한계점인 동일한 수의 구매·비구매 예측결과의 한계점을 극복할 수 있을 것이다. 넷째, 누적된 규칙집합을 이용한 통합모형은 스트림 데이터 적용 분야에 가장 유용할 것이다. 따라서 시간의 흐름에 따라 변화가 심한 주식 시장 자료에 적용하는 연구가 필요하다고 본다. 마지막으로, 규칙집합을 만들 수 있는 여타 인공지능 기법을 이용한 좀더 향상된 통합모형 구축에 관한 연구가 필요할 것이다.

참 고 문 헌

[1] 강현철, 한상태, 최종후, 이성건, 김은석, 엄익현, 김미경, 「고객관계관리(CRM)를 위한 데이터마이닝 방법론」, 자유아카데미, 2006.

[2] 김경재, 한인구, "퍼지신경망을 이용한 기업부도예측", 「한국지능정보시스템학회」, 제7권, 제1호(2001), pp.135-147.

[3] 김재경, 안도현, 조윤호, "개인별 상품추천시스템, WebCF PT : 웹마이닝과 상품계층도를 이용한 협업필터링", 「경영정보학연구」, 제15권, 제1호(2005), pp.63-79.

[4] 김진화, 남기찬, 변현수, "웹 방문 패턴 시각화 및 상품추천 방법에 관한 연구", 「한국경영정보학회 추계학술대회 발표논문집」, 2004, pp.47-55.

[5] 김진화, 민진영, "연속발생 데이터를 위한 실시간 데이터 마이닝 기법", 「한국경영과학회지」, 제29권, 제4호(2004), pp.41-60.

[6] 김종우, 배세진, 이홍주, "협업 필터링 기반 개인화 추천에서의 평가자료의 희소 정도의 영향", 「경영정보학연구」, 제14권, 제2호(2004), pp.131-149.

[7] 민재형, 이영찬, "자료포괄분석(DEA)을 이용한 신용평점모형의 개발 - 정보통신업을 중심으로", 「한국경영정보학회 춘계학술대회 발표논문집」, 2004, pp.460-467.

[8] 조윤호, 박수경, 안도현, 김재경, "재구성된 제품계층도를 이용한 협업 추천 방법론 및 그 평가", 「한국경영과학회지」, 제29권, 제2호(2004), pp.59-75.

[9] 추휘석, 민지경, 이인호, "다수의 인공신경망 모형을 통한 기업데이터의 분류 및 부도예측에 관한 연구", 「연세경영연구」, 제41권, 제2호(2004), pp.514-539.

[10] 허 준, 최병주, 정성원, 「클레멘타인을 이용한 데이터마이닝」, 1판, SPSS아카데미, 2001.

[11] Abdelwashed, T., and E.M. Amir, "New Evolutionary Bankruptcy Forecasting Model Based on Genetic Algorithms and Neural Networks," *Proceedings of the 17th IEEE International Conference on Tools with Artificial Intelligence*, (2005), pp.241-245.

[12] Adomavicius, G. and A. Tuzhilin, "Toward the Next Generation of Recommender Systems : A Survey of the State-of-the-Art and Possible Extensions," *IEEE Transactions on Knowledge and Data Engineering*, Vol.17, No.6(2005), pp.734-749.

[13] Agrawal, R., T. Imielinski, and A. Swami, "Mining association rules between sets of items in large databases," *Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data*, (1993), pp. 207-216.

[14] Altman, E.I., G. Marco, and F. Varetto, "Corporate distress diagnosis : Comparisons using linear discriminant analysis and neural networks (the Italian experience)," *Journal of Banking and Finance*, Vol.18, No.3(1994), pp.505-529.

[15] Anandarajan, M., P. Lee, and A. Anandarajan, "Bankruptcy Prediction of Financially Stressed Firms : An Examination of the Predictive Accuracy of Artificially Neural Networks," *International Journal of Intelligent Systems in Accounting, Finance and Management*, Vol.10, No.2(2001), pp.69-81.

[16] Atiya, A., "Bankruptcy prediction for credit risk using neural networks : a survey and new results," *IEEE Transactions on Neural Networks*, Vol.12, No.4(2001), pp.929-935.

[17] Balabanovic, M. and Y. Shoham, "Fab : Content Based, Collaborative Recommendation," *Communications of the ACM*, Vol. 40, No.3(1997), pp.66-72.

[18] Berry, M., and G. Linoff, *Data Mining Techniques : For Marketing, Sales, and Customer Relationship Management*, John Wiley & Sons, New York, 2004.

[19] Billsus, D. and M. Pazzani, "A Hybrid User Model for News Story Classification," *Proceedings of the Seventh International Conference on User Modeling*, Banff, Canada, (1999), pp.99-108.

[20] Burke, R., "The Wasabi Personal Shopper : A Case-Based Recommender System," *Proceedings of the 11th Conference on Innovative Applications of Artificial Intelligence*, (1999), pp.844-849.

[21] Burke, R., "Knowledge-based Recommender Systems," *Encyclopedia of Library and Information Systems*, Vol.69(2000), pp.1-23.

[22] Charalambous, C., A. Chartious, and F. Kaourou, "Comparative Analysis of Artificial Neural Network Models : Application in Bankruptcy Prediction," *Annals of Operations Research*, Vol.99(2000), pp.403-425.

[23] Chen, M.C., and S.H. Huang, "Credit Scoring and Rejected Instances Reassigning through Evolutionary Computation Techniques," *Expert Systems with Applications*, Vol.24, No.4(2003), pp.433-441.

[24] Chiu, C., "A case-based customer classification approach for direct marketing," *Expert Systems with Applications*, Vol.22, No.2(2002), pp.163-168.

[25] Condon, E., B. Golden, S. Lele, S. Raghavan, and E. Wasil, "A visualization model based on adjacency data," *Decision Support Systems*, Vol.33, No.4(2002), pp.349-362.

[26] Funakoshi, K. and T. Ohguro, "A Content Based Collaborative Recommender System with Detailed Use of Evaluations," *Proceedings of the 4th International Conference on Knowledge Based Intelligent Engineering Systems & Allied Technologies*, (2000), pp.253-256.

[27] Grice, S.J., and T.M. Dugan, "The Limitations of Bankruptcy Prediction Models : Some Cautions for the Researcher," *Review of Quantitative Finance and Accounting*, Vol.17(2001), pp.151-166.

[28] Kim, D. and B. Yum, "Collaborative Filtering based on Iterative Principal Component Analysis," *Expert Systems with Applications*, Vol.28, No.4(2005), pp.823-830.

[29] Konstan, J., B. Miller, D. Maltz, J. Herlocker, L. Gordon, and J. Riedl, "GroupLens : Applying Collaborative Filtering to Usenet News," *Communications of the ACM*, Vol. 40, No.3(1997), pp.77-87.

[30] Lee, K.C., M.J. Kim, and H. Kim, "An Inductive Learning - Assisted Neural Network Approach to Bankruptcy Prediction : Comparison with MDA, Inductive Learning, and Neural Network Models," *Journal of Management Research*, Vol.23, No.3(1994), pp.109-114.

[31] Lee, K.C., I.G. Han, and M.J. Kim, "A Study on the Credit Evaluation Model Integrating Statistical Model and Artificial Intelligence Model," *Journal of Management Science*, Vol.21, No.1(1996), pp.81-100.

[32] Pazzani, M.J., "A Framework for Collaborative, Content-based and Demographic Filtering," *Artificial Intelligence Review*, Vol. 13, No.5-6(1999), pp.393-408.

[33] Peel, M.J., D.A. Peel, and P.F. Pope, "Predicting corporate failure-some results for the UK corporate sector," *Omega International Journal of Management Science*, Vol. 14, No.1(1986), pp.5-12.

[34] Pendharkar, P.C., "A Threshold-varying Artificial Neural Network Approach for Classification and its Application to Bankruptcy Prediction Problem," *Computers and Operations Research*, Vol.32, No.10(2005), pp.2561-2582.

[35] Schafer, J., *Analysis of Incomplete Multivariate Data*, Chapman and Hall, London, 1997.

[36] Schafer, J., J. Konstan, and J. Riedl, "E-commerce Recommendation Applications," *Data Mining and Knowledge Discovery*, Vol.5, No.1(2001), pp.115-153.

[37] Shardanand, U. and P. Maes, "Social Information Filtering : Algorithms for Automating Word of Mouth," *Proceedings of (ACM) (CHI) 1995 Conference on Human Factors in Computing Systems*, Denver, Colorado, USA, (1995), pp.210-217.

[38] Shin, K.S., and K.J. Lee, "Bankruptcy Prediction Modeling Using Multiple Neural Network Models," *Knowledge-Based Intelligent Information and Engineering Systems : 8th International Conference (KES 2004)*, Wellington, New Zealand, 2004a.

[39] Shin, K.S., and K.J. Lee, "Neuro-Genetic Approach for Bankruptcy Prediction Modeling," *Knowledge-Based Intelligent Information and Engineering Systems : 8th International Conference(KES'2 004)*, Wellington, New Zealand, 2004b.

[40] Song, H.S., S.H. Kim, and J.K. Kim, "A Methodology for Detecting the Change of Customer Behavior based on Association

Rule Mining," *Proceedings of the PACIS 2001*, Seoul, Korea, (2001), pp.871-885.

[41] Tam, K., and M. Kiang, "Managerial applications of neural networks : the case of bank failure predictions," *Management Science*, Vol.38, No.7(1992), pp.926-947.

[42] Wang, Y.F., Y.L. Chuang, M.H. Hsu, and H.C. Keh, "A Personalized Recommender System for the Cosmetic Business," *Expert Systems with Applications*, Vol.26, No.3 (2004), pp.427-434.

[43] Weiss, S., and C. Kulikowski, *Computer Systems That Learn*, Morgan Kaufmann, 1991.

[44] Wilson, R. and R. Sharda, "Bankruptcy prediction using neural networks," *Decision Support Systems*, Vol.11, No.5(1994), pp. 545-557.

[45] Wu, K.L., C.C. Aggarwal, and P.S. Yu, "Personalization with dynamic profiler," *Proceedings of the Third International Workshop on Advanced Issues of E-commerce and Web-based Information Systems*, (2001), pp.12-20.

[46] Zhang, G., Y.M. Hu, E.B. Patuwo, and C.D. Indro, "Artificial neural networks in bankruptcy prediction : general framework and cross-validation analysis," *European Journal of Operational Research*, Vol.116(1999), pp.16-32.