

감성모델링 기법 차이에 따른 휴대전화 고급감 모델의 비교 평가

김인기¹ · 이 철² · 윤명환¹

¹서울대학교 산업공학과 / ²서울대학교 공학연구소

A Comparison of Modeling Methods for a Luxuriousness Model of Mobile Phones

In Ki Kim¹, Cheol Lee², Myung Hwan Yun¹

¹Department of Industrial Engineering, Seoul National University, Seoul, 151-744

²Research Institute of Engineering Science, Seoul National University, Seoul, 151-744

ABSTRACT

This study aims to compare and contrast the Kansei modeling methods for building a luxuriousness model that people feel about appearance of mobile phones. For the evaluation based on Kansei engineering approaches, 15 participants were employed to evaluate 18 mobile phones using a questionnaire. The results of evaluation were analyzed to build luxuriousness models through quantification I method, neural network, and decision tree method, respectively. The performance of Kansei modeling methods was compared and contrasted in terms of accuracy and predictability. The result of comparison of modeling methods indicated that model accuracy and predictability was closely related to the number of variables and data size. It was also revealed that quantification I method was the best in terms of model accuracy while decision tree method was the best modeling method with small variance in terms of predictability. However, it was empirically found that quantification I method showed extremely unstable predictability with small number of data. Consequently, it is expected that the research findings of this study might be utilized as a guideline for selecting proper Kansei modeling method.

Keyword: Luxuriousness, Kansei engineering, Quantification I method, Neural network, Decision tree, Mobile phones

1. 서 론

감성공학은 인간의 감성을 물리적인 설계요소로 번역해 감성에 맞는 제품을 설계하는 기술이다(Nagamachi, 1995). 통계적이고 수리적인 기법을 사용하여, 사람의 주관적 반응을 측정하는데 머무르지 않고 이것을 물리적인 설계요소와 연결시켜 설계에 활용하거나 신제품에 대한 감성적 반응을 예측하는데 감성공학의 특징이 있다. 최근 들어 감성공학에

대한 관심과 수요가 급증하고 있으나, 국내에서 감성을 반영한 제품의 성공사례가 흔하지 않은 것은 제품의 감성만족도와 설계변수들을 연결하는 적절한 모델의 부족을 한 원인으로 들 수 있다. 따라서 감성공학적 접근에 있어 정확한 모델링 기법의 선택은 필수적인 고려사항이다(한성호, 2001).

기존의 감성공학 연구에 사용되었던 감성모델링 기법들을 분류한 결과에 따르면, 많은 사례 연구에서 수량화1류기법(quantification I method)을 사용하고 있다(표 1 참조). 수량화1류기법은 Hayashi에 의해 개발된 정성적 변수를

교신저자: 이 철

주 소: 151-744 서울시 관악구 신림동 산56-1, 전화: 02-885-1403, E-mail: iehis@snu.ac.kr

위한 다중회귀분석으로, 주관적인 감성과 범주형 설계변수의 함수관계를 모델링하는데 널리 사용되고 있다(Jindo & Hirasago, 1997).

표 1. 감성모델링 기법 적용사례

모델링 기법	적용사례
수량화1류기법	- 여대생 의복개발(Nagamachi et al., 1988) - 주택설계(Nagamachi, 1991) - Nissan社의 자동차 내장설계(Jindo et al., 1991) - Komatsu社의 건설기계내장설계(Nakata et al., 1994) - Itoki社의 3D 이미지에 의한 사무용 의자설계(Jindo et al., 1995)
신경망기법	- 감성언어와 설계요소 간의 추론능력을 향상(Ishihara et al., 1995) - 자동차 안락감 모델(Kolich, 2004)
나무구조	- Ford社의 'Taurus'개발(Petersen, 1992)
컨조인트분석	- 다양한 제품 속성에 대한 선호도 차이분석(Green & Desarbo, 1987)
범주도표	- 다양한 소비자요구 유형을 제품윤곽과 연결(Kano et al., 1984)
퍼지추론시스템	- 소비자 선호에 대한 언어의미해석(Turksen & Wilson, 1993) - 지능형 컬러프린트 설계(Fukushima et al., 1995)
QFD + 퍼지시스템	- QFD를 통하여 체계화된 소비자 요구사항을 퍼지추론모델과 결합(Fukuda & Matsuura, 1993)
행렬접근법	- 소비자 요구사항과 제품기능 간의 행렬구축(McAdams et al., 1999)
이산선택모델	- 설계옵션에 의해 좌우되는 소비자 선택 예측(Louviere & Timmermans, 1990)

적절한 감성모델링 기법의 선택에는 수리적 기법 자체의 특성과 함께 감성 데이터 고유의 특성이 고려되어야 한다. 모델링에 빈번하게 사용되는 수리적 기법들은 크게 아래의 세 범주로 나눌 수 있다.

① 변수 간 선형결합을 전제로 한 기법: 다항회귀분석, 로짓회귀분석(Hosmer & Lemeshow, 1989), 수량화1류기법

② 학습을 통해 적응력을 극대화한 기법: 신경망기법(Kolich, 2004), 퍼지추론모델, 신경망-퍼지네트워크, 베이저안 모델

③ 데이터 집합의 분할을 통해 군집화하는 기법: 군집분석, 의사결정나무기법(Breiman et al., 1984)

첫 번째 범주의 대표적인 기법인 다항회귀분석은 종속변수와 독립변수 간의 관계를 이해하기 쉬운 장점이 있으나(Razi & Athappilly, 2005), 선형관계의 가정으로 인해 감성을 설명하는데 한계가 있다고 여겨진다(Shimizu & Jindo, 1995). 수량화1류기법도 더미변수의 해석에 있어 문제가

제기되고 있다(Han & Hong, 2003). 두 번째 범주의 신경망 기법은 다항회귀분석에 비해 기존 지식의 저장능력, 패턴인식능력, 잡음 선별력, 새로운 데이터 추론능력이 뛰어나나, 모델의 성능이 표본의 크기에 민감하다(Taylor, 1996). 세 번째 범주의 의사결정나무기법(Decision Tree)은 데이터마닝 영역에서 처음 제안된 분류 및 예측 기법으로 신경망 기법에서 다루기 힘든 작은 규모의 데이터 예측에 장점을 보이며(Markham et al., 2000), 데이터의 분포에 대한 가정이 불필요하나, 분류 기법이므로 예측 결과가 범주형으로 표현되어 정밀성이 떨어지는 단점이 있다. 보다 구체적으로, 위의 세 범주에 속하는 수리적 기법들 간의 성능비교 연구들은 표 2와 같다.

표 2. 수리적 모델링 기법 비교 연구

모 델	성능비교	데이터 크기	설명변수	
			개수	구분
Multimodal model (Brown et al., 1993)	NN>DT DT>NN	2500 60	3 13	연속 연속
Market response model (Hruschka, 1993)	NN>Reg	60	4	연속
Image processing (Perner et al., 2001)	NN>DT	1024	7	연속
Box-office prediction (Sharda & Delen, 2003)	NN>DT >IReg	834	7	연속1 이산6
Heat stress prediction (Brown-Brandl et al., 2005)	NN>Reg	2000	5	연속
Smoking effect model (Razi & Athappilly, 2005)	DT>NN >nReg	3652	4	이산

주) NN(신경망기법), DT(의사결정나무기법), Reg(다항회귀분석), IReg(로지스틱회귀분석), nReg(비선형회귀분석)

표 2의 비교 연구 결과에 따르면, 신경망기법이 의사결정 나무기법이나 회귀분석에 비해 대체로 우수한 예측성능을 보이고 있으나, Brown et al. (1993)에 의하면 데이터 크기와 변수의 수에 따라서 예측성능은 달라질 수 있다. 의사결정 나무기법의 경우, 연속변수의 분할에 의해 발생하는 정보의 손실을 고려하면 변수의 특성도 모델의 성능을 좌우하는 요인으로 작용할 수 있다. 그러나 몇 가지 사례의 비교를 통해 성능에 대한 일반적인 결론을 내리기는 어렵기 때문에, 연구 영역에 특화된 모델링 기법의 비교가 필요하다(Razi & Athappilly, 2005).

감성모델링에서 측정된 감성은 피실험자의 대상 제품과 다감각적 상호작용(multi-sensory interaction)에 의해 추출한 복합적이고 동적인 변수이다(Liu, 2003). 따라서 실험에 있어 대상 제품과의 상호작용 내용에 의해 감성 측정의 결과가 달라질 수가 있으며, 개인차에 따른 분산의 폭도 크

다. 감성의 복합적·다차원적 특성을 밝히기 위해 감성의 2차원 구조에 대한 연구(Russel, 1980; Russel & Steiger, 1982), 위계구조에 대한 연구(Laros & Steenkamp, 2005) 등이 있으나 감성의 구조화로 인해 얻는 간결함의 이득보다 세부적인 분석능력의 손실이 더 클 수도 있다(Ekkekakakis & Petruzzello, 2002). 또한, 감성어휘와 설계요소를 혼용하여 사용하는 경우, 분산의 상대적 크기 차이에 의해 감성 모델이 왜곡된 결과를 가져올 수 있다(Nagamachi, 1996). 따라서, 감성모델은 분산이 크고 작은 변수들이 뒤섞여 있고 모수 통계적 가정들이 빈번하게 위배되는 상황에 대하여 설명력을 유지할 수 있는 강건한(robust) 특성이 요구된다. 특히, 감성모델은 연구대상 제품에 종속적이며, 대상 제품군은 지속적으로 진화하므로 감성모델이 예측력을 갖추기 위해서는 변화하는 데이터에 대한 적응력을 가지는 것이 바람직하다(한성호, 2001).

본 연구에서는 휴대전화 외형 디자인의 고급감 모델링 사례를 중심으로 수량화1류기법, 신경망기법, 그리고 의사결정나무기법의 성능을 예측력과 설명력의 관점에서 비교 분석하였으며, 표 2의 연구 결과를 바탕으로 예측력과 설명력에 영향을 줄 수 있는 모델변수의 개수와 데이터의 크기를 고려하였다. 이러한 비교 연구는 성능 측면에서 감성공학 분야에 특화된 적절한 모델링 기법을 선택하는 지침을 제안하는 목적을 가진다.

2. 연구 방법

2.1 감성평가실험

감성모델링 기법의 비교를 위한 사례연구로 '휴대폰 외형의 고급감(luxuriousness)'에 대한 감성평가실험을 수행하였다. 휴대폰은 기능성을 넘어서 고객의 감성분석을 바탕으로 한 휴대전화 평가 및 개발이 강조되고 있는 제품이며(이민훈, 2003), 다양한 인터페이스 디자인 요소들이 개별적인 것이 아니라 하나의 단일체로 인식되는 경향이 강한 제품이다(Yun et al., 2003). 휴대폰의 외형은 제품과 관련된 다양한 속성들 중에 소비자에게 가장 중요하게 인식되는 것으로 알려져 있다(Sethuraman et al., 2005).

휴대폰의 감성은 다른 제품군에 비해 분산이 작고 설계변수와의 관계를 설명하기가 쉽다. 특히, 휴대폰의 고급감은 제품에 대한 전반적 만족도와 상관관계가 높고, 고급감 모델의 설명력은 만족도 모델에 비해 설명력이 높다(Yun et al., 2003). 기존의 연구 결과에 따르면, 휴대폰의 외형 고급감에 대한 감성평가 결과는 성별과 연령의 차이가 통계적으로 유의하지 않으나, 20~30대의 경우 10대와는 달리 제품에

따른 극단적인 선호도 차이를 보이지 않아 안정적인 데이터를 얻을 수 있다(Yun et al., 2003).

본 연구에서는 휴대폰의 외형과 관련된 17개의 설계변수를 도출하였다. 체계적인 설계변수의 도출을 위해 요소/속성행렬(Han et al., 2000)을 이용하였고, 휴대폰의 버튼, 디스플레이 패널, 크기, 형태, 색상, 재질의 속성 등에 해당하는 설계변수들은 표 3과 같다. 감성평가실험 대상 휴대폰은 기존의 다양성을 고려하여 6개사 18종의 모델을 선정하였고, 표 3의 측정항목에 대하여 측정 및 평가를 수행하였다. 범주형 측정항목의 경우 가능한 모든 범주 대신 실험에 사용된 휴대폰에 해당되는 범주로 제한하였다. 이는 수량화 기법의 경우 범주가 늘어날수록 더미(dummy)변수가 증가하여 모델링 및 해석이 어려워지기 때문이다.

표 3. 감성평가실험에 사용된 휴대폰 설계변수

설계변수	측정항목	척도
휴대폰 크기 ^a	휴대폰의 가로길이(cm)	계측
	휴대폰의 세로길이(cm)	계측
	휴대폰의 두께(cm)	계측
표면 광택	강하다 ↔ 약하다	평가
전체적 외부색깔	흰색/적색/블루/황색/은색계열	범주
모서리 처리	둥글다 ↔ 각지다	평가
폴더 유형	플립형/폴터형	범주
안테나 유형	고정길이/가변길이	범주
안테나 길이	길이(cm)	계측
좌 측면 버튼	버튼 개수	계측
우 측면 버튼	버튼 개수	계측
버튼색깔	외부색과 통일/다름	범주
버튼의 LED색깔	적색/블루/황색계열	범주
버튼 형태	원형 ↔ 사각형	평가
내부 LCD 크기 ^b	인치(inch)	계측
카메라 위치	전면(외부LCD부위)/접이 부위	범주
중량	중량(g)	계측

주) ^a안테나 길이 제외. 폴터의 경우 닫힌 상태의 길이, ^b슬라이드의 LCD포함

감성평가실험에 참여한 피실험자는 휴대폰 사용경력이 1년 이상인 20~30대의 남자 사용자 15명으로 구성하였다. 사용자 집단의 평균 연령은 25.5세이며, 휴대폰 사용경력은 3.1±1.2년이다. 감성평가실험 수행 시간은 일인당 80분이 소요되었다. 휴대폰의 외형 고급감에 대한 감성평가는 피실험자들이 평가대상 휴대폰들의 실물을 보고, 만지고, 조작해본 결과를 100점 척도로 평가한 후, 평가 결과는 개인별로 0과 1사이의 값으로 정규화(normalization)하였다.

2.2 분석 방법

감성평가실험 결과를 바탕으로 수량화1류기법, 신경망기법, 그리고 의사결정나무기법을 사용하여 휴대폰의 외형 고급감을 모델링하였다. 모델링을 위한 통계분석에는 통계프로그램 SAS(ver. 9.1)을 이용하였다.

수량화1류기법은 모델에 포함될 변수선별과정을 포함하고 있지 않으므로, 모델링에 앞서 일반선형모델(general linear model) 분석을 통해 외형 고급감에 유의한 영향($\alpha=0.05$)을 주지 않는 변수들을 제거하였다. 신경망기법은 3개의 다층구조로, 학습 방법은 표준 back propagation 방법을 선택하였고, 모든 변수를 포함한 네트워크를 대상으로 사전분석(preliminary analysis)을 수행하여 가중치를 부여할 연결을 탐색한다. 의사결정나무기법은 신경망기법과 마찬가지로 모든 변수들을 대상으로 F-검정($\alpha=0.05$)을 수행하여 분할된 데이터 집단 간의 동질성을 반복적으로 검토하면서 동질성이 유지되는 선까지 분할을 계속하였다.

감성평가실험을 통해 얻어진 데이터의 전체 크기는 총 288개이다. 각 기법의 적용에 앞서 학습(training), 검증(validation), 평가(test)를 위하여 전체 데이터를 4:3:3의 비율로 임의 분할하였다. 학습데이터는 수량화1류기법의 회귀계수 추정, 신경망기법의 노드 가중치 계산 및 의사결정나무의 분할에 사용되어 모델을 구축하는 역할을 한다. 검증데이터는 신경망기법과 의사결정나무기법에 사용되어 학습과 분할의 최적 횟수를 결정하는 역할을 한다. 평가데이터는 세 가지 기법에 각각 대입하여 새로운 데이터에 대한 예측력을 비교, 평가하는 역할을 한다.

모델링 기법의 성능은 크게 네 가지 측면(예측력, 설명력, 예측비용 및 학습성능)에서 비교 분석이 가능하다. 예측력(predictive power or prediction accuracy)은 구축된 모델이 새로운 조건에 대해 얼마나 정확하게 예측하는지에 대한 기준(Razi & Athappilly, 2005)으로, 모델의 일반화 능력(generalization capability)의 척도이다(Petra et al., 2001). 설명력(explanatory power)은 데이터로부터 도출된 모델이 그 데이터를 얼마나 충분하게 표현하고 있는가의 측면으로, 데이터의 전반적인 양상과 패턴을 표상한다는 의미에서 표상능력(representation capability) 이라고도 부른다. 예측비용의 측면에서는, 모델에 사용된 변수의 수가 많을수록 예측을 위해 측정해야 하는 변수가 늘어나므로 경제적이지 않다고 판단한다. 학습성능의 측면에서는 반복계산을 수행하는 모델링에 있어 소요되는 시간 및 계산단계의 수가 적을수록 효율적이라고 판단한다. 본 연구에서는 기법 간에 계량적인 1대1 비교가 가능한 예측력과 설명력의 측면에서 성능비교를 수행하였다. 예측력과 설명력의 계량화된 지수는, 평균 제곱오차의 제곱근(Root Mean Squared Error; RMSE),

예측과 실제의 상관계수, 평균절대비율오차(Mean Absolute Percentage Error; MAPE), 대예측오차(Large Prediction Error; LPE) 등이 사용된다(Zhang et al., 2004).

본 연구에서는 예측력과 설명력의 척도로 RMSE들의 평균값을 채택하였으며, RMSE의 평균값이 통계적으로 유의한 차이가 없는 경우에는 RMSE의 표준편차로 성능의 판단 기준을 삼았다. 이를 위해, 통계적인 분석을 위해 동일한 조건에서 각 기법에 대하여 모델링을 10회 반복하여 얻어진 RMSE의 평균과 표준편차를 계산하였다. 계산 결과의 해석에 있어서 평균 RMSE가 작은 기법이 예측력이나 설명력의 측면에서 우수한 성능을 가진다고 판단하였다. 그리고, 통계적 유의성 검정을 통해 동일한 수준의 평균 RMSE를 가지는 것으로 나타난 경우 RMSE의 표준편차가 작은 기법의 성능이 우수한 것으로 판단하였다.

한편, 기존 연구(표 2 참조)에 의하면, 모델에 포함된 변수의 개수와 모델링에 사용된 데이터의 크기는 모델의 성능에 영향을 주는 것으로 예상하여 분석과정에 포함하였다. 수량화1류기법을 사용한 모델링에서는 사전에 변수의 유의성 검증을 통하여 유의하지 않은 변수를 제거하나, 신경망기법에서는 모든 변수를 모델에 포함하며 의사결정나무기법에서는 모델링의 과정에서 F-검정에 의해 유의하지 않은 변수에 의한 분할을 수행하지 않으므로 내부적으로 변수를 선별한다고 할 수 있다. 따라서 결과적으로는 세 기법에 포함된 변수의 수가 동일하지 않음으로 발생하는 모델성능의 차이를 보정하기 위해 변수의 개수 변화에 따른 성능을 비교하였다. 위와 동일한 방법으로 데이터의 크기 변화에 따른 성능 비교를 위해, 모델구축에 사용되는 학습데이터의 크기를 10부터 100까지 증가시키면서 설명력과 예측력을 관찰하였다.

모든 관찰에서 데이터로부터 학습데이터를 추출하는 과정의 임의효과와 기법적용 시에 나타나는 임의효과를 고려하여 10회의 반복실험을 통해 설명력과 예측력의 지수인 평균제곱오차를 계산하였다. 학습데이터를 추출하는 과정의 임의효과는 일정 비율의 학습데이터를 임의로 추출하는 과정에서 포함된 데이터가 추출 시마다 동일하지 않은 것으로, 표본추출을 반복하여 특정사례(case)의 영향력을 감소시킴으로써 줄일 수 있다. 기법적용 시의 임의효과는 같은 학습데이터를 사용하여 모델링을 하더라도 매번 모델링의 결과가 조금씩 다르게 나타나는 경우로, 수량화1류기법에서는 완전모델(full model)의 부분 집합인 부분모델로 모델링을 할 때 복수의 부분모델이 존재할 수 있고 계수가 유일하게 결정되지 않는 경우도 있다. 신경망기법이나 의사결정나무기법에서도 학습 또는 분할의 최적 횟수를 결정하는 과정에서 내부적으로 임의효과가 나타나 매 시행마다 나타나는 결과가 조금씩 다를 수 있다. 이러한 추출과 시행의 임의효과를 고려하기 위해 반복추출 및 반복시행을 모든 비교 분석에 대해 수행하였다.

3. 감성모델링 및 모델링 성능비교

3.1 수량화1류 모델

수량화1류기법을 적용한 결과, 외형 고급감에 영향을 미치는 통계적으로 유의한 요인은 핸드폰 중량, 크기(가로길이 및 세로길이), 전체적 외부색깔, 좌 측면 버튼수인 것으로 나타났으며, 주요 요인들의 고급감에 대한 기여도는 표 4의 유효 T값(effective T-value)으로 표현된다. 유효 T값은 표준화된 회귀계수의 검정통계량을 자유도로 나눈 값으로, 요인 또는 세부요소의 유효 T값의 부호가 음(-)인 경우는 고급감을 약화시키는 요인임을 나타낸다. 중량은 가장 고급감에 큰 영향을 주는 요인으로 방향이 양(+)이므로 중량의 국지적 증가는 고급감을 높이는 것으로 해석된다. 가로길이와 세로길이는 중량 다음으로 고급감에 영향을 주는 요인으로, 방향이 음이므로 크기가 국지적으로 작을수록 고급감을 향상시키는 것으로 해석된다. 특히 세로보다는 가로길이를 짧게 하는 것이 고급감 증가의 효과가 더 크다. 전체적 외부색깔에 있어서는 은색계열이 고급감을 향상, 푸른색계열이 약화시킨다. 동일한 개념으로, 좌 측면 버튼수를 줄일수록 고급감은 향상되는 것으로 파악되었다.

표 4. 주요 요인의 고급감 기여정도

설계변수	내용	effective T-value
중량	중량	3.6410
휴대폰 크기	가로길이	-1.2670
	세로길이	-0.8480
전체적 외부색깔	황색계열	0.0009
	은색계열	0.4850
	블루계열	-0.5030
좌 측면 버튼수	버튼개수	-0.6070

3.2 신경망모델

신경망모델에 의한 네트워크 구조는 그림 1과 같다. 학습에 사용된 17개의 설계변수들은 3개의 노드와 연결되어 있으며 각 연결에 대하여 가중치가 설정된다. 노드는 3단계의 층을 거쳐 고급감에 해당하는 출력 노드와 연결되는 구조로 이루어진다.

네트워크의 가중치를 계산하기 위해 최적의 학습을 하기 위한 반복계산의 횟수를 결정해야 한다. 반복계산이 지나치게 많으면 학습데이터에 대한 설명력은 커지고(training error의 감소) 검증데이터에 대한 예측력은 줄어든다(validation error의 증가). 따라서 설명력과 예측력이 적절한 균

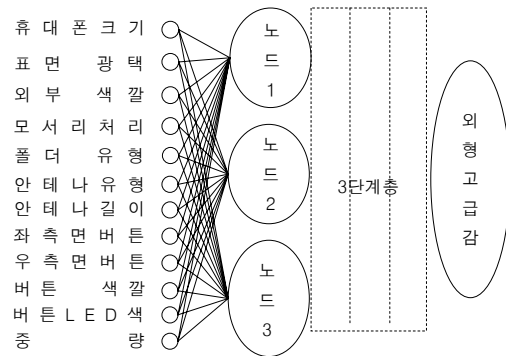


그림 1. 신경망 네트워크 구조

형을 이루는 수준에서 반복계산을 중단한다는 점에서 신경망기법의 장점이 있다. 그림 2는 신경망모델링의 최적 반복계산을 결정하는 과정으로, y축은 목표값과의 평균오차를, x축은 반복계산횟수를 나타낸다. 두 평균오차그래프의 추이로부터, x=79인 지점에서 최적의 학습이 이루어졌다고 판단하여 계산을 중단하였으며 중단조건은 수렴 기준(Relative Change Function Convergence Criterion; FCONV)이 0.0001 미만이 되도록 설정하였다.

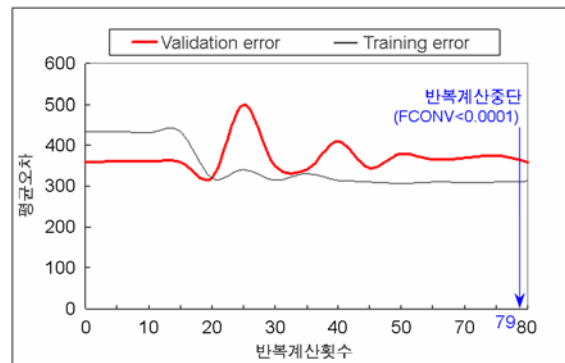


그림 2. 반복계산횟수의 결정과정

3.3 의사결정나무모델

의사결정나무모델은 사전에 유의한 변수를 선별하는 수량화1류 모델이나 모든 변수를 포함하여 학습하는 신경망모델과는 달리 내부적으로 유의한 분할을 하는 변수에 대한 F-검정을 통해 변수를 선별한다. 그런데, 변수의 선별은 데이터의 크기나 패턴, 전체 후보변수의 개수 등의 요인에 의해 시행마다 달라진다. 10회의 반복시행을 통해 가장 빈번하게 나타난 분할의 예는 그림 3과 같다. 최적의 분할을 얻기 위해서 분할과 관련된 제약조건은 사용하지 않았다.

예를 들어, 외장 색상이 은색계열이고, 우측 사이드 버튼

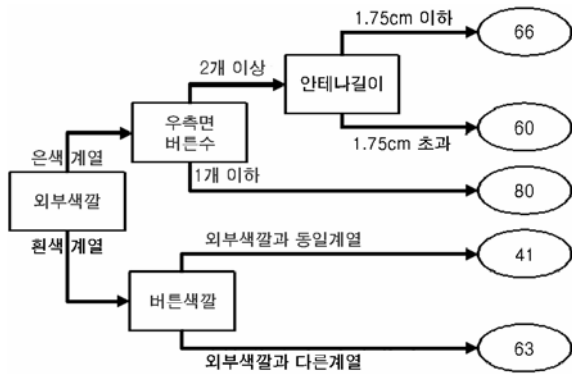


그림 3. 의사결정나무모델

의 수가 5개, 안테나의 길이가 3cm인 휴대폰은 외형 고급감이 60점 수준이라고 예측된다. 의사결정나무기법의 경우, 고급감의 예측값이 범주화되어 정밀성이 떨어지나 전술한 바와 같이 모델의 시행에 따라 매번 분지의 양상이 달라지는 뛰어난 적응성을 통해 이와 같은 정밀성의 문제를 해결하는 것으로 볼 수 있다.

3.4 감성모델링 기법의 비교

구축된 세 가지 감성모델에 대한 비교 분석을 위해서 학습데이터로 모델의 설명력을 평가하고, 평가데이터로 예측력을 평가하였다. 이러한 평가에는 구축된 세 모델이 주어진 학습데이터를 통해 얻어진 최적 성능의 모델이라는 가정이 전제되어 있다. 이러한 가정을 충족시키기 위해, 수량화1류 모델은 고급감에 유의한 변수만을 선별하였고, 신경망모델은 최적반복계산횟수를 결정하였으며, 의사결정나무모델은 분할과 관련한 제약사항을 두지 않았다. 각 기법의 최적 모델에 대하여 반복적으로 표본추출(학습 40%, 검증 30%, 평가 30%)을 10회 수행한 결과는 표 5와 같다.

표 5의 데이터를 요약하여 모델링 기법 별로 도시하면 그림 4와 같다. y축은 학습데이터에 대한 10개의 RMSE값을 기법 별로 평균한 것으로 모델의 데이터 설명력을 의미한다. 설명력은 y축 값이 작을수록 높은 것으로 해석된다.

Kruskal-Wallis H Test에 의한 비모수집단의 평균 동질성 검증 결과, 설명력에 있어서 신경망기법은 통계적으로 유의한 정도로 수량화1류기법이나 의사결정나무기법에 비해 우수하다($\chi^2=10.31$, p -value=0.006). 한편, 예측력에 있어서는 세 기법의 성능은 통계적으로 유의한 차이가 없는 것으로 파악되었다. 신경망기법은 설명력이 높을 뿐만 아니라 설명력의 편차도 가장 작다. 표 5에서 신경망기법의 설명력에 대한 편차(0.64)는 수량화1류기법의 편차(1.25)와 의사결정나무의 편차(1.95)에 대해 각각 51%,

표 5. 반복적 표본추출에 대한 RMSE

표본추출 횟수	수량화1류		신경망기법		의사결정나무	
	학습 데이터	평가 데이터	학습 데이터	평가 데이터	학습 데이터	평가 데이터
1	16.00	19.05	14.32	18.84	15.39	17.20
2	16.03	19.13	14.97	20.27	16.34	19.49
3	17.46	16.73	15.49	17.49	16.67	19.87
4	18.33	16.64	15.00	15.26	17.94	18.11
5	18.00	21.02	15.76	20.45	21.33	18.81
6	14.46	21.61	14.39	18.97	15.23	18.65
7	16.46	20.20	14.03	20.83	16.55	18.06
8	15.49	19.03	15.97	18.38	15.56	17.80
9	17.49	18.41	15.06	18.71	17.35	19.90
10	15.59	16.52	14.56	17.03	14.35	20.98
평균	16.60	18.90	15.90	18.70	16.80	18.90
표준편차	1.25	1.80	0.64	1.71	1.95	1.16




그림 4. 모델링 기법 별 최적 모델의 평균 RMSE

33%에 불과하여 안정된 성능을 보여준다.

하지만 이러한 결과를 전적으로 신뢰하기에는 두 가지 측면에서 한계가 있다. 첫째, 모델링에 사용된 변수의 개수가 다르다. 수량화1류 모델에는 7개, 신경망모델에는 17개, 의사결정나무에는 4개의 변수가 포함되어 있어, 2.2절에서 언급한 예측비용의 관점에서 보면 설명력이 높게 나타난 신경망기법의 비용이 가장 크다. 둘째, 데이터에 따라 성능비교의 결과가 달라지는 경우가 종종 발생한다. 대부분의 경우 설명력은 예측력을 상회하지만 표 5의 3회와 4회에서 수량화1류 모델의 설명력이 현저하게 감소하여 설명력이 예측력보다 낮아진 현상을 보였다. 그러나 같은 데이터에 대하여 다른 모델들에서는 현저한 설명력의 감소가 나타나지 않고 있다. 이는 데이터의 내용에 따라 모델성능이 역전될 가능성을 가지고 있음을 의미하며, 개인차가 큰 감성데이터의 특성을 고려할 때 데이터의 크기 선택 문제와 연결된다.

3.5 변수 개수에 따른 성능비교 분석

변수의 개수를 모든 모델에서 같도록 조작하여 3.4절과 동일한 기준으로 성능을 비교하고, 변수의 개수를 점차 변화시켜 가면서 위의 과정을 반복하여 분석을 시도하였다. 비교를 위해 수량화1류기법으로 모델링이 가능한 변수의 최대 개수인 11개부터 유의성이 가장 작은 변수를 하나씩 제거해 가면서 각 모델을 구성하였다. 제거대상 변수는 일반선형모델 분석을 통해 유의확률이 가장 낮은 변수를 우선적으로 선정하였다. 정해진 변수 개수에 대하여 최적 모델링과 마찬가지로의 방법으로 표본추출의 임의성과 기법의 임의성을 제거하기 위하여 학습데이터를 10회 반복 표본추출하여 RMSE를 얻었다. 표 6에서는 10회 반복 표본추출한 RMSE의 평균값을 변수의 개수에 따라 정리하였다.

표 6. 변수 개수에 따른 RMSE의 평균

변수 개수	수량화1류		신경망기법		의사결정나무	
	학습 데이터	평가 데이터	학습 데이터	평가 데이터	학습 데이터	평가 데이터
2	18.8	17.0	19.1	17.1	17.9	17.5
3	17.4	19.2	18.0	19.1	17.3	19.6
4	16.3	19.6	16.2	19.6	16.9	19.0
5	14.9	18.7	15.4	18.6	15.9	18.7
6	15.6	18.8	15.4	18.7	16.8	18.3
7	14.8	19.7	16.0	18.5	15.9	18.6
8	14.6	19.9	15.9	19.2	16.3	19.3
9	14.5	20.7	14.5	20.1	15.8	20.1
10	14.7	19.9	16.8	19.2	17.2	19.9
11	13.7	17.5	15.8	17.7	17.8	18.5

우선, 변수의 개수를 망라하여, 각 기법 별 RMSE의 평균의 동일성을 분산분석을 통해 검증해본 결과, 설명력에 있어서는 기법 간에 통계적으로 유의한 차이가 있는(F=4.851, p-value=0.010) 반면, 예측력에 있어서는 통계적으로 유의한 차이가 없는 것으로 나타났다. 그림 5는 기법 별 설명력의 RMSE의 분포를 나타내고, 그림 6은 기법 별 예측력의 RMSE의 분포를 나타낸 상자도표이다. 상자 가운데의 검은 띠는 중간값이다.

변수의 개수가 동일한 조건에서는 모델링 기법의 설명력은 수량화1류기법>신경망기법>의사결정나무기법의 순으로 성능이 우수하며, 예측력은 평균의 관점에서 성능의 차이가 없다.

그림 7은 표 6의 데이터에 대하여, 변수의 개수에 따른 각 기법 별 설명력의 추이를 나타낸 것이다. Kruskal-Wallis H




그림 5. 모델링 기법 별 설명력




그림 6. 모델링 기법 별 예측력

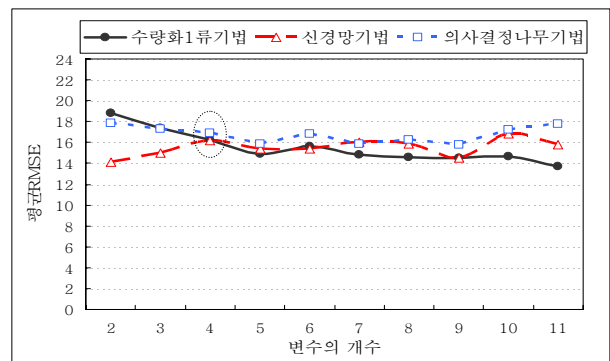


그림 7. 변수 개수에 따른 설명력의 추이

Test에 의한 비모수집단의 평균 동질성 검증 결과에 의하면, 수량화1류기법과 신경망기법은 변수의 개수에 따른 설명력의 변화가 통계적으로 유의하다(수량화1류기법: $\chi^2=21.81$, p-value=0.010; 신경망기법: $\chi^2=18.70$, p-value=0.020). 특히, 그림 7에서 변수 4개를 기준점으로, 변수가 적은 경우에는 신경망기법, 많은 경우에는 수량화1류기법의 설명력이 우수한 것을 볼 수 있다. 의사결정나무기법은 변수 개수의 증감에 의해 설명력이 통계적으로 유의한 변화를 가져오지 않았다.

한편, 변수의 개수에 따른 예측력의 변화는 통계적으로 유의하지 않았다. 이는 모델에 포함되는 변수의 개수의 조절에

의해 설명력은 높일 수 있으나 예측력을 조절하기는 어려움을 의미한다. 기법 별로 예측력의 차이가 없고 변수의 개수에 의해 예측력을 조절할 수 없으므로 평균의 측면에서는 예측력의 우열을 비교할 수 없다. 이 경우 2.2절에서 언급했듯이, 예측력의 평균에 있어서 세 기법이 통계적으로 다르지 않다면 예측력의 편차의 관점에서 세 기법을 분석해 볼 필요가 있다. 그림 6에서 개략적으로 나타나듯이, 예측력의 평균은 통계적으로 차이가 없으나, 예측력의 표준편차는 신경망기법(1.55)이 수량화1류기법(2.11)과 의사결정나무의 표준편차(1.72)에 대해 73%, 90%에 해당하여 상대적으로 안정적인 성능분포를 보이므로, 예측력을 높이기 위해서는 신경망기법을 선택하는 것이 바람직하다.

변수 개수가 동일한 조건에서의 분석을 정리하면 다음과 같다. 세 기법을 설명력의 측면에서 비교하면 수량화1류기법 >신경망기법>의사결정나무기법의 순으로 성능이 우수하나 예측력에 있어서는 유의한 차이가 없다. 세부적인 분석을 위해 변수의 개수를 변화시켜보면, 변수의 개수가 4개 미만일 경우에는 신경망기법의 설명력이, 4개 이상일 경우에는 수량화1류기법의 설명력이 우수한 것으로 파악되었다. 의사결정나무기법의 설명력은 변수 개수의 변화에 통계적으로 유의한 영향을 받지 않는다. 한편, 예측력은 변수의 개수에 통계적으로 유의한 영향을 받지 않으나, 상대적으로 예측력이 안정적으로 유지되는 신경망기법을 선택하는 것이 바람직하다고 파악되었다.

3.6 데이터의 크기와 모델의 성능

모델링에 사용되는 학습데이터의 크기는 모델의 성능에 영향을 끼치는 요인이 될 수 있다. 학습데이터에서 특정 피실험자, 핸드폰 모델 또는 입력오류로 인한 데이터 케이스가 모델링의 결과에 미치는 영향력은 데이터의 크기가 커질수록 작아지므로, 소수의 이상값(outlier)이 모델을 불규칙하게 변동시킬 위험이 줄어들 수 있다. 하지만 데이터 수집의 비용을 고려하면 적절한 설명력과 예측력을 보장하는 데이터 크기를 결정하는 것이 필요하다. 데이터의 크기를 고려하기 위해 3.5절과 유사한 방법으로 변수의 개수를 11개로 동일하게 유지하면서 학습데이터의 크기가 100개, 80개, 60개, 40개, 30개, 20개, 10개인 경우에 대하여 모델의 설명력과 예측력을 비교하였다. 동일한 학습데이터의 크기에 대해 표본을 10회 반복추출하여 계산한 RMSE를 평균한 결과가 표 7과 같고, 세 기법 별 설명력과 예측력의 분포는 그림 8과 그림 9로 나타내었다.

기법을 처리요인으로 하는 분산분석 결과에 의하면, 모델링 기법들의 설명력과 예측력은 통계적으로 유의한 차이를 나타내었다(설명력: $F=14.29, p\text{-value}=0.000$; 예측력: $F=$

표 7. 학습데이터 크기에 따른 RMSE의 평균

학습 데이터 크기	수량화1류		신경망기법		의사결정나무	
	학습 데이터	평가 데이터	학습 데이터	평가 데이터	학습 데이터	평가 데이터
10	7.4	58.1	13.6	22.9	16.1	23.4
20	10.3	107.9	14.7	16.9	17.4	16.4
30	15.2	24.4	20.2	21.3	21.4	21.1
40	13.4	23.2	16.1	18.3	16.6	19.5
60	13.0	30.4	15.6	19.4	16.1	20.2
80	13.7	17.5	15.8	17.7	17.8	18.5
100	15.3	19.8	17.0	18.6	18.2	20.2




그림 8. 모델링 기법 별 설명력




그림 9. 모델링 기법 별 예측력

7.82, $p\text{-value}=0.001$). RMSE 평균값을 기준으로 한 기법의 설명력은 수량화1류기법>신경망기법>의사결정나무기법의 순으로, 예측력은 신경망기법>의사결정나무기법>수량화1류기법의 순으로 성능이 우수한 것으로 파악되었다. 편차의 측면에서 살펴보면, 수량화1류기법의 예측력의 편차는 (32.84) 신경망기법(2.11)이나 의사결정나무(2.17)에 비해 매우 불안정한 성능편차를 보이고 있다.

한편, Kruskal-Wallis H Test의 결과에 의하면 수량화1류기법의 설명력은 데이터의 크기에 따라 통계적으로 유의한 차이를 보인다($\chi^2=16.31, p\text{-value}=0.012$). 데이터의

크기에 따른 설명력의 추이는 그림 10과 같다. 그림 10에 따르면 수량화1류기법의 설명력은 데이터의 크기가 10일 때가 가장 높고 데이터가 증가함에 따라 점차 감소하다가 30 이상이 되면 통계적으로 차이가 없는 수준에서 일정하게 유지되는 양상을 관찰하게 된다. 신경망기법과 의사결정나무기법은 데이터의 크기에 따라 설명력이 통계적으로 유의한 영향을 받지 않는 것으로 나타나고 있다. 예측력의 경우에는 세 기법 모두에서 데이터의 크기에 따라 통계적으로 유의한 차이가 없다.




그림 10. 데이터 크기에 따른 설명력 추이

수량화1류기법의 불안정한 예측력 편차의 원인을 파악하기 위해 학습데이터의 크기에 따른 수량화1류기법의 예측력 추이를 살펴보면 그림 11과 같다. 그림 11은 x축의 데이터의 크기에 대하여 수량화1류기법, 신경망기법, 의사결정나무기법의 순서로 각각의 모델의 RMSE의 95% 신뢰구간을 비교, 군집하여 표현한 오차막대이다. 그림 11에 의하면 데이터의 크기가 30미만일 때 수량화1류기법의 예측력 편차가 다른 기법들에 비해 상대적으로 크게 나타났다.

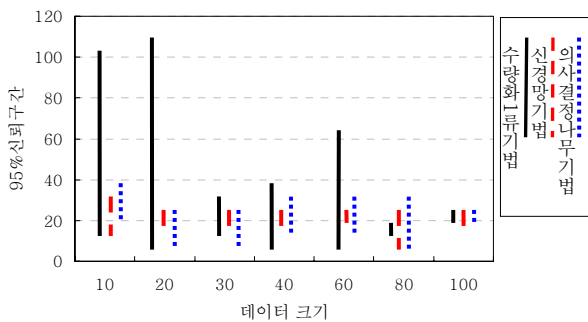


그림 11. 데이터의 크기에 따른 오차막대

또한, 학습데이터의 크기가 30개 미만이라든 신경망기법과 의사결정나무기법은 비교적 영향을 받고 있지 않음을 알 수 있다. 이와 같은 결과는 의사결정나무기법이 상대적으로

로 작은 규모의 데이터 예측에 장점을 보인다는 Markham et al.(2000)의 연구 결과와 일치하며, 수량화1류기법을 사용한 감성모델링에서 실험표본의 수가 30개 미만일 경우 모델의 예측력에 의문을 제기할 수 있는 가능성을 시사한다.

4. 토의 및 결론

본 연구에서는 핸드폰의 고급감 감성 연구에 있어 선형, 학습 및 분류 방식을 사용하는 통계적 모델링 기법의 성능을 비교하였다. 성능비교의 척도로 RMSE를 사용하여 학습데이터와 평가데이터에 대한 설명력과 예측력을 비교 분석하였다. 데이터 표본추출로 인해 발생하는 임의효과와 모델링과정에서 발생하는 임의효과를 고려하여 10회 반복하여 RMSE의 평균값을 얻었다. RMSE의 평균이 낮을수록, 평균이 동일한 경우에는 RMSE의 편차가 작을수록 성능이 우수하다고 판단하였다.

모델링 기법을 감성공학 분야에 적용할 경우, 설명력이 높은 모델은 제품에 대한 감성평가에 중요하며 예측력이 높은 모델은 제품의 설계에 더 큰 비중을 차지한다. 왜냐하면, 감성평가는 이미 만들어진 제품에 대한 평가과정으로 설계변수가 측정 가능하므로 예측보다는 설명이 추가 되는 반면 신제품의 설계에 있어서는 설계변수에 대한 정보가 없으므로 설명보다는 예측이 추가 되기 때문이다. 따라서, 기존 제품의 감성평가를 위한 감성모델을 구축하는 경우 동일한 변수 조건(동일한 예측비용)에서는 설명력을 높이기 위해 수량화1류기법>신경망기법>의사결정나무기법의 순위로 기법을 선택하는 것이 바람직하며, 변수의 수가 적은 경우에는 신경망기법이 수량화1류기법에 비해 우수할 수 있다는 점도 고려해야 한다. 단, 수량화1류기법은 성능의 편차가 크다는 사실을 감안하여 여러 차례 반복실험을 하거나 신경망기법과 병행하여 모델링하는 것이 바람직하다. 한편, 동일한 데이터 크기의 조건에서는 수량화1류기법>신경망기법>의사결정나무기법의 순위로 모델링기법을 선택하는 것이 바람직하다. 특히, 데이터의 크기가 30개 미만인 경우에는 수량화1류기법의 설명력이 매우 높아질 수 있는 반면에 예측력이 나빠질 수 있음을 고려할 필요가 있다. 따라서 설명력만이 모델링기법의 유일한 비교기준이 아니라면 신경망기법이나 의사결정나무기법이 예측력과 결과의 신뢰성 측면에서 고려될 수 있다.

신제품의 개발에 앞서 감성만족도를 극대화하는 설계변수들의 최적값을 파악하고자 감성모델링을 하는 경우에는 모델링기법의 설명력도 중요하지만 새로운 제품의 설계치수에 대한 예측력의 비중이 더 크다. 따라서, 고려해야 할 변수의

개수가 같은 모델링 조건에서는 예측력에는 차이가 없으나 성능의 편차가 작은 의사결정나무기법이 안정적이다. 또한, 데이터의 크기가 동일한 모델링 조건에서도 예측력 평균에는 차이가 없으나 편차가 작은 의사결정나무기법이 안정적이다. 특히, 데이터의 크기가 30개 미만인 데이터에 대해서 수량화1류기법을 사용하면 예측력이 큰 편차를 낼 수 있음을 반드시 고려해야 한다.

사례 연구에 제시한 휴대폰의 외형 고급감 모델링에 사용한 변수 개수, 데이터의 크기, 한정된 통계적 기법의 제약으로 인해 본 연구의 결과를 일반화하기에는 무리가 따르나, 최근 각광받고 있는 감성공학분야에서 빈번하게 사용되는 감성모델링 기법들의 장단점을 파악하고, 구체적인 응용 사례에 대한 지침을 제시함으로써 연구환경의 특성에 따른 적절한 감성모델링 기법을 선정하는데 도움이 되리라 기대된다.

참고 문헌

- 이민훈, *기술과 감성의 융합시대*, 삼성경제연구소 CEO Information, 417, 8-9, 2003.
- 한성호, 제품디자인의 감성만족도 평가 및 예측모델 개발, *대한인간공학회지*, 20(1), 87-113, 2001.
- Breiman, L., Friedman, J. H., Olshen, R. A. and Stone, C. J., *Classification and Regression Trees*, Wadsworth Statistic/Probability Series, Wadsworth Advanced Books and Software, Belmont, CA, 1984.
- Brown, D. E., Corruble, V. and Pittard, C. L., A comparison of decision tree classifiers with backpropagation neural networks for multimodal classification problems, *Pattern Recognition*, 26(6), 953-961, 1993.
- Brown-Brandl, T. M., Jones, D. D. and Woldt, W. E., Evaluating Modeling Techniques for Cattle Heat Stress Prediction, *Biosystems Engineering*, 91(4), 513-524, 2005.
- Ekkekakis, P. and Petruzzello, S. J., Analysis of the affect measurement conundrum in exercise psychology: IV. A conceptual case for the affect circumplex, *Psychology of Sport and Exercise*, 3, 35-63, 2002.
- Fukuda, S. and Matsuura, Y., Prioritizing the customer's requirements by AHP for concurrent design, *Design for Manufacturability*, 52, 13-19, 1993.
- Fukushima, K., Kawata, H., Fujiwara, Y. and Genno, H., Human sensory perception oriented image processing in color copy system, *International Journal of Industrial Ergonomics*, 15(1), 63-74, 1995.
- Green, P. E. and DeSarbo, W. S., Additive Decomposition of Perceptions Data Via Conjoint Analysis, *Journal of Consumer Research*, 5, 58-65, 1987.
- Han, S. H., Yun, M. H., Kim, K. J. and Kwahk, J. Y., Evaluation of product usability: development and validation of usability dimensions and design elements based on empirical models, *International Journal of Industrial Ergonomics*, 26, 477-488, 2000.
- Han, S. H. and Hong, S. W., A systematic approach for coupling user satisfaction with product design, *Ergonomics*, 46(13), 1441-1461, 2003.
- Hosmer, D. W. and Lemeshow, S., *Applied Logistic Regression*, New York, Wiley, 1989.
- Hruschka, H., Determining market response functions by neural network modeling: A comparison to econometric techniques, *European Journal of Operational Research*, 66, 27-35, 1993.
- Ishihara, S., Ishihara, K., Nagamachi, M. and Matsubara, Y., An automatic builder for a Kansei Engineering expert system using self-organizing neural networks, *International Journal of Industrial Ergonomics*, 15(1), 13-24, 1995.
- Jindo, T. and Nagamachi, M., The development of a car interior image system incorporating knowledge engineering and computer graphics, In: Queinnec, Y. and Daniellou, F. (Eds.), *Proceedings of the 11th Congress of the International Ergonomics Association*, 625-627, 1991.
- Jindo, T., Hirasago, K. and Nagamachi, M., Development of a design-support system for office chairs using 3-D graphics, *International Journal of Industrial Ergonomics*, 15(1), 49-62, 1995.
- Jindo, T. and Hirasago, K., Application studies to car interior of Kansei engineering, *International Journal of Industrial Ergonomics*, 19(2), 105-114, 1997.
- Kano, N., Seraku, N., Takahashi, F. and Tsuji, S., Attractive quality and must be quality, *Hinshitsu, The Journal of the Japanese Society for Quality Control*, 14(2), 39-48, 1984.
- Kolich, M., Predicting automobile seat comfort using a neural network, *International Journal of Industrial Ergonomics*, 33(4), 285-293, 2004.
- Laros, F. J. M. and Steenkamp, J.-B.E.M., Emotions in consumer behavior: a hierarchical approach, *Journal of Business Research*, 58, 1437-1445, 2005.
- Liu, Y., Engineering aesthetics and aesthetic ergonomics: Theoretical foundations and a dual-process research methodology, *Ergonomics*, 46(13/14), 1273-1292, 2003.
- Louviere, J. and Timmermans, H., Stated preference and choice models applied to recreation research: a review, *Leisure Sciences*, 12, 9-32, 1990.
- McAdams, D. A., Stone, R. B. and Wood, K. L., Functional Interdependence and Product Similarity Based on Customer Needs, *Research in Engineering Design*, 11, 1-19, 1999.
- Markham, I. S., Mathieu, R. G. and Wray, B. A., Kanban setting through artificial intelligence: A comparative study of artificial neural networks and decision trees, *Integrated Manufacturing*, 11(4), 239, 2000.
- Nagamachi, M., Image technology based on knowledge engineering and its application for design consultation, In: Adams, A.S., Hall, R.R., McPhee, B. J., Oxenburgh, M. S. (Eds.), *Proceedings of the 10th Congress of the International Ergonomics Association*, 72-74, 1988.
- Nagamachi, M., An image technology expert system and its application to design consultation, *International Journal of Human-Computer Interaction*, 3(3), 267-279, 1991.
- Nagamachi, M., Kansei Engineering: A new ergonomic consumer-oriented technology for product development, *International Journal of Indu-*

ustrial Ergonomics, 15, 3-11, 1995.

Nagamachi, M., Kansei engineering and implementation of human-oriented product design, In: Koubek, R.J., Karwowski, W. (Eds.), *Manufacturing Agility and Hybrid Automation-I*, IEA Press, Louisville, KY, 77-80, 1996.

Nakata, K., Iwata, T. and Nagamachi, M., Color and Kansei on mini-construction vehicle, *Human Interface*, 9(1), 23-26, 1994.

Perner, P., Zscherpel, U. and Jacobsen, C., A comparison between neural networks and decision trees based on data from industrial radiographic testing, *Pattern Recognition Letters*, 22, 47-54, 2001.

Petersen, D., *Teamwork: New Management Ideas for the Nineties*, Victor Gollancz, London, 1992.

Razi, M. A. and Athappilly, K., A comparative predictive analysis of Neural Networks (NN's), Nonlinear Regression and Classification and Regression Tree (CART) models, *Expert Systems with Applications*, 29(1), 65-74, 2005.

Russell, J. A., A circumplex model of affect, *Journal of Personality and Social Psychology*, 39, 1161-1178, 1980.

Russell, J. A. and Steiger, J. H., The structure in person's implicit taxonomy of emotions, *Journal of Research in Personality*, 16, 447-469, 1982.

Sethuraman, R., Kerin, R. A. and Cron, W. L., A field study comparing online and offline data collection methods for identifying product attribute preferences using conjoint analysis, *Journal of Business Research*, 58, 602-610, 2005.

Sharda, R. and Delen, D., Predicting box-office success of motion pictures with neural networks, *Expert Systems with Applications*, 243-254, 2003.

Shimizu, Y. and Jindo, T., A fuzzy logic analysis method for evaluation human sensitivities, *International Journal of Industrial Ergonomics*, 15, 39-47, 1995.

Taylor, J. G., *Neural networks and their applications*, Wiley, England, 1996.

Turksen, I. B. and Wilson, I.A. Consumer preference models: fuzzy theory

approach, *Proceeding of SPIE*, 2061, 203-211, 1993.

Yun, M. H., Han, S. H., Hong, S. W. and Kim, J. S., Incorporating user satisfaction into the look-and-feel of mobile phone design, *Ergonomics*, 46(13/14), 1423-1440, 2003.

Zhang, W., Cao, Q. and Schniederjans, M. J., Neural networks earning per share forecasting models: A comparative analysis of alternative methods, *Decision Sciences*, 35(2), 205-237, 2004.

● 저자 소개 ●

❖ 김 인 기 ❖ lookat2@hanmail.net

서울대학교 산업공학과 학사
 현 재: 서울대학교 산업공학과 석사과정
 관심분야: 인간공학, 감성공학, HCI, 멀티미디어 디자인

❖ 이 철 ❖ ichis@snu.ac.kr

펜실베니아주립대학교 산업공학과 박사
 현 재: 서울대학교 공학연구소 선임연구원
 관심분야: 인간공학, 감성공학, 제품디자인, HCI, 사용성 평가

❖ 윤 명 환 ❖ mhy@snu.ac.kr

펜실베니아주립대학교 산업공학과 박사
 현 재: 서울대학교 산업공학과 교수
 관심분야: 인간공학, 감성공학, 제품개발 및 디자인, HCI

논 문 접 수 일 (Date Received) : 2006년 03월 03일

논 문 수 정 일 (Date Revised) : 2006년 05월 03일

논문게재승인일 (Date Accepted) : 2006년 05월 09일