

# 승용차 A-Pillar Trim의 치수설계를 위한 소프트컴퓨팅기반 반응표면기법의 응용

김승진\* · 김형곤\* · 이종수\* · 강신일\*\*  
(2000년 10월 4일 접수, 2000년 12월 28일 심사완료)

## Application of Soft Computing Based Response Surface Techniques in Sizing of A-Pillar Trim with Rib Structures

Seungjin Kim, Hyoung-Gon Kim, Jongsoo Lee and Shinill Kang

**Key Words:** Approximate Optimization(근사최적화), Evolutionary Fuzzy Modeling(진화퍼지모델링), Neuro-Fuzzy Modeling, Automotive Interior Part, A-Pillar(승용차내장재), Head Injury Criterion(두부상해치)

### Abstract

The paper proposes the fuzzy logic based global approximate optimization strategies in optimal sizing of automotive A-pillar trim with rib structures for occupant head protection. Two different strategies referred to as evolutionary fuzzy modeling (EFM) and neuro-fuzzy modeling (NFM) are implemented in the context of global approximate optimization. EFM and NFM are based on soft computing paradigms utilizing fuzzy systems, neural networks and evolutionary computing techniques. Such approximation methods may have their promising characteristics in a case where the inherent nonlinearity in analysis model should be accommodated over the entire design space and the training data is not sufficiently provided. The objective of structural design is to determine the dimensions of rib in A-pillar, minimizing the equivalent head injury criterion HIC(d). The paper describes the head-form modeling and head impact simulation using LS-DYNA3D, and the approximation procedures including fuzzy rule generation, membership function selection and inference process for EFM and NFM, and subsequently presents their generalization capabilities in terms of number of fuzzy rules and training data.

### 1. 서 론

자동차 충돌사고 중 차량과 충돌물 사이의 1차 충격량보다 탑승자와 자동차 내장재간의 2차 충격량이 승원의 안전에 더욱 치명적임이 판명되었다. 이에 따라 북미교통안전협회(NHTSA)는 자동차안전법규 FMVSS 201(내장재 충격에 관한 승

원보호법률)을 개정하게 되었고,<sup>(1)</sup> 그 결과 자동차 내장재의 구조와 부분 모델 테스트의 비중이 커지게 되었다. 본 논문에서는 승객의 안전을 고려한 자동차구조설계로서 승객의 두부상해치(head injury criterion, HIC)를 최소화할 수 있는 승용차 상부내장재 중에 하나인 A-pillar trim의 rib 구조의 치수를 최적화하고자 한다. NHTSA는 HIC를 최소화하고 특히 1000 이하가 되도록 규정하고 있는데 충격에너지 흡수하는 방법으로 자동차내부의 플라스틱으로 된 trim과 차체 강판 사이에 foam을 넣거나 rib를 이용하는 방법이 있다. 본 연구에서는 생산비용이 많이 드는 foam 구조형 대신 강성의 적절한 변화를 이용하여 에너지를 충분히 흡수할 수 있는 rib 구조형 A-pillar

---

\* 연세대학교 대학원 기계공학과  
† 책임저자, 회원, 연세대학교 기계전자공학부  
E-mail: jleej@yonsei.ac.kr  
TEL : (02)2123-4474 FAX : (02)362-2736  
\*\* 연세대학교 기계전자공학부

---

설계방법을 선택하였다.

이러한 충격해석과 같은 비선형역학문제를 기반으로 수치최적화방법을 통해 치수나 형상을 도출하기 위해서는 유한요소해석에 의한 CAD/CAE 모델링의 반복적인 작업과 적절한 최적화 알고리즘과의 효과적인 연계가 필요하다. 그러나 CAE 도구와 최적화 알고리즘간의 원활한 데이터 교환 및 해석/설계시스템의 통합화 및 자동화가 구축되지 않은 경우이거나 시뮬레이션 모델링과정에 많은 시간이 요구되는 경우에는 효율적인 최적화방법으로 근사최적화(approximate optimization)기법이 사용되고 있으며 이를 위해 다양한 반응표면법(response surface method, RSM)이 공학설계문제에 적용되고 있다.<sup>(2-4)</sup> 특히, 승용차 내장재 설계와 같이 설계공간이 비선형인 경우에는 다량의 국부해가 존재할 가능성이 높으므로 전역해를 탐색할 수 있는 최적화방법이 필요하다. 유전알고리즘(genetic algorithms, GA's)은 이러한 설계해의 다양성 및 전역성을 보장할 수 있는 효율적인 방법으로서 치수 최적화문제에 적합하다.<sup>(5)</sup> 본 논문에서는 HIC를 최소화하는 A-pillar trim의 rib 구조의 치수를 선정하기 위해 유전알고리즘을 사용하며, 계산비용이 방대한 최적화과정의 단점을 보완하기 위해 적은 수의 설계데이터로부터 생성된 정확도가 높은 반응표면을 통해 전역근사최적화를 수행한다.

근사화모델을 구축하기 위해서는 다량의 설계데이터가 요구되는데 제품개발기간이 중요한 요소로 작용하는 경우 즉, 주어진 시간 내에 많은 양의 실험 및 시뮬레이션에 의한 설계데이터가 확보되지 않은 상황에서는 불충분한 개수의 데이터를 이용하여 근사화 모델을 만들고 이를 통해 최적설계를 수행해야 한다. 기존의 반응표면근사화방법은 분산분석을 통한 실험계획법에 의해 설계데이터를 생성하고 2차 또는 3차의 다항식으로 설계공간을 모델링하였다. 이때에는 강한 비선형성에 의한 설계공간에 내재된 multimodality를 충분히 표현하기 어렵고 이를 연속근사최적화(sequential approximate optimization, SAO)방법과 연계한 경우에는 반응표면의 반복적인 재구성이 요구된다. 따라서 본 논문에서는 해석 및 설계문제에 존재하는 비선형성(nonlinearity)/비오목성(nonconvexity)를 고려할 수 있고 설계 데이터가 충분히 확보되지 않은 상황에서 시스템모델링을 수행할 수 있는 방법으로 진화퍼지모델링

(evolutionary fuzzy modeling, EFM) 및 뉴로퍼지모델링(neuro-fuzzy modeling, NFM)에 의한 전역근사방법을 이용하여 승용차 내부구조의 rib의 치수를 설계하고자 한다. EFM 및 NFM은 유전알고리즘, 신경회로망 및 퍼지추론시스템(fuzzy inference system, FIS)의 기능을 융합시킨 적응형 모델링방법으로서 비선형 시스템의 입출력관계를 규명하기 위한 소프트컴퓨팅(soft computing)기반 전산지능(computational intelligence)기술이다.<sup>(6)</sup> 불확실성(uncertainty) 및 불완전성(incompleteness)이 내포된 비선형 시스템의 강건한 모델링을 구축하기 위해 제어공학 및 패턴인식분야 등에서 적응화 및 학습화기능을 갖는 퍼지추론방법이 다양하게 연구, 적용되고 있다.<sup>(7,8)</sup> 본 연구에서의 EFM과 NFM은 설계데이터가 불충분한 경우에 입출력 설계데이터간의 퍼지관계로부터 특정 반응함수의 국부적 표현구간을 나타내는 퍼지함수 매개변수(fuzzy membership parameter)를 유전알고리즘을 통해 최적화하거나, 신경망모델을 따르는 방식으로 적은 수의 설계데이터를 이용하여 근사화모델을 구축하는 방법을 제안하고자 한다. 또한, 두 가지 소프트컴퓨팅기반 반응표면기법을 통해 승용차 내장재의 치수설계를 수행하고 각각의 최적해를 비교함으로써 각 방법의 특성 및 장단점을 분석하고자 한다.

## 2. 퍼지응용시스템모델링

### 2.1 퍼지추론시스템

퍼지집합이론(fuzzy set theory), 퍼지규칙(fuzzy if-then rules) 및 퍼지추론(fuzzy inference)에 바탕을 둔 FIS는 일반적으로 3가지의 개념적인 성분들로 이루어져 있다.<sup>(9)</sup> 퍼지규칙을 포함하고 있는 규칙베이스(rule base), 퍼지규칙에 사용된 멤버십

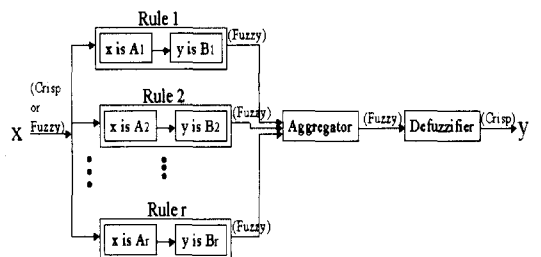


Fig. 1 Reasoning mechanism of FIS in Ref.[x]

함수(membership function)를 정의하는 데이터 베이스(data base) 및 타당한 출력 또는 결론을 유도하는 규칙들과 주어진 사실에 바탕을 두고 있는데 Fig. 1에서는 간략화된 퍼지시스템의 추론 메커니즘을 보여주고 있다. 이를 바탕으로 퍼지 알고리즘(fuzzy algorithms)을 나타내면 다음과 같이 표현된다. 우선, 해석모델의 수치적 입력값 또는 경향으로부터 퍼지규칙을 생성하고 이들을 퍼지화(fuzzification)한다. 이후, 퍼지연산자를 이용하여 퍼지관계를 표현하고, 퍼지집합의 통합된 관계를 적용하여 단일의 퍼지출력값을 생성한다. 마지막으로 이 퍼지출력값을 도시법(centroid method) 등과 같은 비퍼지화(defuzzification)를 통해 크리스프 출력값(crisp output)을 만든다.

2.2 진화퍼지모델링

EFM은 유전알고리즘과 같은 진화연산(evolutionary computing)에 의해 최적화된 퍼지시스템으로부터 입력설계변수와 비선형 반응함수간의 관계를 정량적으로 표현하는 시스템 모델링의 한 방법이다. 적은 수의 설계 데이터와 퍼지함수의 비선형적인 특성을 이용하여 전역근사모델 생성한다. 즉, EFM은 모델을 결정하는 퍼지규칙과 멤버쉽 함수의 매개 변수들을 결정하는 최적화 과정이라고 할 수 있다. 퍼지멤버쉽함수와 규칙의 수에 있어서도 최적화 과정동안 변화하는 방법으로 수식화할 수 있지만, 본 논문에서는 멤버쉽 함수의 모양을 정의하는 매개 변수들만을 설계변수 고려하였다. 그러므로 GA's은 설계변수로서 멤버쉽함수 매개변수의 조합을 다루고, 퍼지출력값과 실제 설계데이터에 의한 목적값 사이의 오차가 최소로 될 때까지 계속된다.

만일  $m$ 개의 입력변수에 의한  $n$ 개의 출력값을 가지고 있는 모델을 EFM을 수학적으로 표현하면 다음의 식 (1)과 같이 나타낼 수 있다.<sup>(10)</sup>

$$\text{Minimize } E_{EFM} = \frac{1}{n} \sum_{j=1}^n [y_j - t_j]^2 \quad (1)$$

subject to  $v_i^L \leq v_i \leq v_i^U, \quad i=1, \dots, m$

여기서,  $E_{EFM}$ 는 EFM에 의한 출력( $y_j$ )과 실제 출력( $t_j$ ) 사이의 평균제곱오차이다. 또한,  $v_i$ 는 EFM

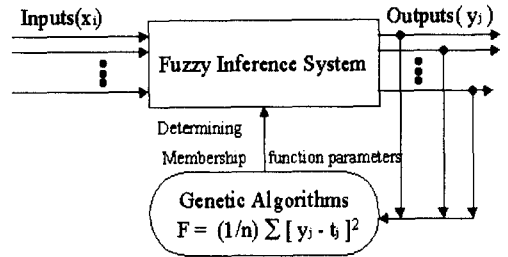


Fig. 2 GA's based evolutionary fuzzy modeling

문제의 설계변수이고  $v_i^L$ 와  $v_i^U$ 는 각각,  $v_i$ 의 하한 및 상한값이다. 각 설계변수들은 멤버쉽 함수를 정의하는 매개변수들을 표현한다. 이런 설계 문제에 대한 최적해는 가장 적합한 근사치를 발생시키는 멤버쉽 함수의 매개변수 조합이다.

EFM의 전체적인 개략도는 Fig. 2에서 보여준다. 퍼지추론시스템에 의해 출력값이 생성되는 과정에서 실제 출력값과의 오차를 최소화하도록 입력 및 출력 멤버쉽함수의 형상을 결정하는 매개변수를 GA's에 의해 조절한다.

2.3 뉴로퍼지모델링

NFM은 퍼지시스템의 성능을 향상을 위해 신경망의 구조나 학습방법을 모방한 시스템모델링 방법이다.<sup>(12)</sup> 즉, 퍼지시스템에 대해 멤버쉽 함수 등의 파라미터를 조정하기 위해 급속강하(steepest descent)기법 등과 같은 전통적인 신경망의 학습 알고리즘을 변형하여 적용한 것이다. 이때 입출력 관계를 나타내는 데이터를 이용하여 주어진 입력에 대한 출력과 기대되는 출력 사이의 오차를 멤버쉽 함수의 파라미터를 조정하는데 사용된다. NFM을 수학적으로 표현하면 다음과 같이 나타난다. 만일  $m$ 개의 입력과  $n$ 개의 출력을 가지고 있는 모델을 최적화 시키기 위해서 식 (2)와 같이 최적화문제를 구성한다.<sup>(12)</sup>

$$\text{Minimize } E_{NFM} = \frac{1}{2} \sum_{j=1}^n [y_j - t_j]^2 \quad (2)$$

subject to  $v_k^L \leq v_k \leq v_k^U, \quad k=1, \dots, m$

여기서,  $E_{NFM}$ 는 NFM에 의한 출력( $y_j$ )과 실제 출력( $t_j$ ) 사이의 제곱오차로 표현되는 값이고  $v_k$

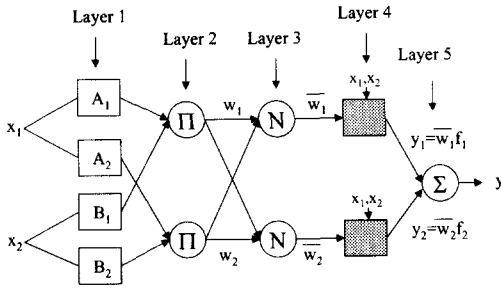


Fig. 3 Architecture of NFM

는 설계변수이다. 또한,  $v_k^L$ 와  $v_k^U$ 는 각각,  $v_k$ 의 하한 및 상한값이다.

이때 설계변수들은 EFM의 경우와 같이 선택되는 퍼지멤버십 함수를 정의하는 매개변수가 된다. EFM에서는 퍼지규칙의 조건부(antecedent part)와 결론부(consequent part)를 모두 퍼지함수에 의해 표현하게 되지만 NFM에서는 퍼지함수선택 자체에 대한 부담을 최소화하기 위해 결론부에 대해서는 선형관계식(linear Sugeno model)을 통상적으로 취하게 된다.<sup>(13)</sup> 만일, 두 개의 입력변수와 한 개의 출력의 관계를 두 개의 퍼지규칙으로 표현하면 본 논문에서 사용한 NFM의 퍼지규칙은 다음의 식 (3)과 같다.

If  $x_1$  is  $A_1$  and  $x_2$  is  $B_1$ , then  $y = p_1x_1 + q_1x_2 + r_1$  (3)

If  $x_1$  is  $A_2$  and  $x_2$  is  $B_2$ , then  $y = p_2x_1 + q_2x_2 + r_2$

여기서  $A_1, A_2, B_1, B_2$  는 퍼지함수로 표현되며 결론부는 퍼지함수의 형태가 아닌 다항식으로서 계수인  $p, q, r$  등을 설계변수로 고려하여 식 (2)의 과정을 반복 수행한다.

Fig. 3은 식 (3)과 같은 규칙을 기반으로 구성된 뉴로퍼지시스템의 구성도를 보여준다. 우선, 1번 층에서는 멤버십 함수의 값들을 계산하여 각각의 뉴론요소(neuron)에 입력한다. 이렇게 만든 각각의 뉴론요소들은 2번층에서 규칙에 대한 뉴론을 만들기 위해 퍼지결합연산자에 의해 재평가된다. 이렇게 각 뉴론은 3번층에서 정규화된다. 이때 결론부 매개변수인  $p, q, r$  등은 특이값분해법(singular value decomposition)으로부터 구한다. 그 결과, 4번층에서는 규칙출력들의 비율이 구해지며, 각 뉴론으로부터의 규칙출력들은 5번층에서

결합하여 NFM응답값을 생성하게 된다. 식 (2)의 제곱오차식에 대해 편미분의 관계를 이용하여 연쇄규칙으로부터 조건부에 있는 멤버십 함수를 결정하는 각 매개변수에 대한 미분을 반복 수행함으로써 매개변수가 갱신된다.

### 3. A-pillar Trim의 Rib 설계

자동차 내장재의 일부분인 A-Pillar trim은 충돌 사고시 2차 충격에 의한 승객의 상해를 최소화 시켜주기 위한 에너지 흡수용 부품이다. 승원안전을 고려한 자동차 부품 및 구조물에 대한 시뮬레이션기반 설계의 경우, 비선형유한요소 및 CAE 등에 의한 구조해석이 요구되는데 각 설계 사양에 대한 시뮬레이션 모델링 및 구조해석을 하는 과정에서 엄청난 계산시간 및 비용이 소요된다. 따라서 이러한 설계문제는 반응표면기반 근사최적화기법이 활용되는데 본 논문에서는 진화퍼지 근사화모델 및 뉴로퍼지 근사화모델에 의한 최적설계를 수행하고자 한다.

적용하고자 하는 자동차 내장재의 설계문제는 인간의 머리를 모델링한 두부형상(headform)과 내장재 사이의 15mph 충돌시험시 두부상해치의 기준인 HIC를 최소화 할 수 있는 A-pillar trim의 외부크기를 선정하는 것이다. Trim의 치수설계를 위한 최적화문제는 다음과 같다.<sup>(14)</sup>

Minimize  $HIC(d)$  (4)

subject to  $t_i^L \leq t_i \leq t_i^U \quad i=1, 2, 3$

$$HIC = \max \left[ \frac{1}{t_2 - t_1} \int_{t_1}^{t_2} a \, dt \right]^{2.5} (t_2 - t_1)$$

$$a_r = \sqrt{a_x^2 + a_y^2 + a_z^2}$$

$$t_2 - t_1 \leq 36 \text{ m sec}$$

$$HIC(d) = 0.75466 \times HIC + 166.4$$

여기서, HIC(d)는 두부모형의 무게중심에 위치한 3축의 가속도계로부터 얻은 신호를 처리하여 얻은 HIC의 equivalent한 값이며 다음의 관계식으로 표현된다. 본 설계문제에서는 Fig. 4의 A-pillar trim의 충격흡수구조 rib을 설계하기 위해 rib의 가로 방향 간격( $t_1$ ), 세로 방향 간격( $t_2$ ) 및 두께( $t_3$ ) 등의 3가지 인자를 설계변수로 정의하였다.

시뮬레이션해석을 위해 LS-DYNA3D를 이용하였으며, 임의의 rib 구조에 대한 충격해석의 결과는 Fig. 5와 같다.<sup>(14)</sup>

본 논문에서는 실험계획법에 의하여 시뮬레이션 설계데이터를 생성하였다. 가로방향 및 세로방향의 rib 간격과 rib 두께에 대한 기본 치수를 각각 20.0mm, 20.0mm, 1.00mm로 고려하여 이들을 중심점 (0,0,0)으로 놓고 Table 1에 표시된 값들을

중심합성법(CCD) 및 full factorial design(FFD)에 적용하여 Table 2와 같은 33개의 설계데이터를 산출하였다.

Table 1 Design of experiment

	$t_1$	$t_2$	$t_3$
$-\sqrt{3}$	11.3mm	11.3mm	0.74mm
-1	15.0mm	15.0mm	0.85mm
0	20.0mm	20.0mm	1.0mm
1	25.0mm	25.0mm	1.15mm
$\sqrt{3}$	28.7mm	28.7mm	1.26mm

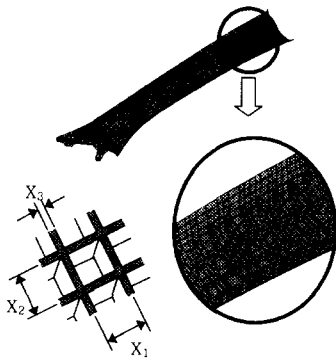


Fig. 4 Rib structure of trim

Table 2 Design data using CCD and FFD

Case	$t_1$	$t_2$	$t_3$	HIC(d)
1	-1	-1	-1	834.4
2	-1	-1	0	888.2
3	-1	-1	1	1060.6
4	-1	0	-1	867.1
5	-1	0	0	813.2
6	-1	0	1	931.8
7	-1	1	-1	911.4
8	-1	1	0	860.4
9	-1	1	1	956.8
10	0	-1	-1	911.8
11	0	-1	0	886.3
12	0	-1	1	961.2
13	0	0	-1	947.5
14	0	0	0	870.3
15	0	0	1	838.3
16	0	1	-1	1001.2
17	0	1	0	978.5
18	0	1	1	892.9
19	1	-1	-1	955.4
20	1	-1	0	899.7
21	1	-1	1	980.2
22	1	0	-1	901.9
23	1	0	0	866.1
24	1	0	1	822.1
25	1	1	-1	1164.2
26	1	1	0	1060.1
27	1	1	1	989.2
28	$\sqrt{3}$	0	0	928.1
29	$-\sqrt{3}$	0	0	981.2
30	0	$\sqrt{3}$	0	881.3
31	0	$-\sqrt{3}$	0	1040.3
32	0	0	$\sqrt{3}$	867.0
33	0	0	$-\sqrt{3}$	1040.5




Fig. 5 Headform modeling and deformed shape

4. 결과 및 고찰

4.1 진화퍼지모델링에 의한 근사최적화

본 논문에서 제안한 EFM을 이용하기 위해서 먼저 Table 2에서 제시된 33개의 설계데이터를 이용하여 만들 수 있는 최대 규칙의 수가 33개이므로 Table 3과 같이 33개의 규칙을 만들고 33 훈련데이터를 이용하였다. 입력변수의 멤버십 함수(very low, low, medium, high, very high)로는 식 (5)와 같은 가우시안멤버십함수로 고려하였다. 또한 목적함수를 표현하기 위한 멤버십 함수(HIC1~HIC20)로는 HIC의 최소 및 최대값의 범위를 고려하여 식 (6),(7)과 같은 사다리꼴함수와 삼각형 함수를 혼합하여 사용하였다.

$$gaussian(x ; a, \sigma) = e^{-\frac{1}{2} \left(\frac{x-a}{\sigma}\right)^2} \quad (5)$$

$$triangle(x ; a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (6)$$

$$trapezoid(x ; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \\ 0, & d \leq x \end{cases} \quad (7)$$

Table 3에서 VL: very low, L: low, M: medium, H: high, VH: very high 등으로 퍼지문장을 표현한다. 33개의 규칙으로 구성된 EFM에 의한 근사화모델의 정확도를 검증하기 위해 설계데이터에 포함되지 않은 9개의 새로운 데이터를 이용하여 HIC의 실제 계산된 반응량과 EFM에 의한 예측값을 비교하였다. Table 4에 그 결과를 비교하였으며 이 경우 평균오차가 4.65% 범위 내에 있다. Table 4의 각 설계변수는 실험계획법의 full factorial design에 의해 환산된 데이터이다.

규칙의 수의 영향을 파악하기 위해서 규칙의 수를 15개로 감소하였다. 15개의 규칙을 만들기 위해서 33개의 설계데이터 중에서 중심합성계획법을 이용하여 만든 15개의 설계데이터를 선택하여 Table 5와 같이 제시하였다.

Table 3 Generation of 33 fuzzy rules

Rule ID	t <sub>1</sub>	t <sub>2</sub>	t <sub>3</sub>	HIC(d) ID
1	L	L	L	HIC3
2	L	L	M	HIC6
3	L	L	H	HIC19
4	L	M	L	HIC4
5	L	M	M	HIC1
6	L	M	H	HIC11
7	L	H	L	HIC9
8	L	H	M	HIC4
9	L	H	H	HIC13
10	M	L	L	HIC9
11	M	L	M	HIC6
12	M	L	H	HIC14
13	M	M	L	HIC12
14	M	M	M	HIC5
15	M	M	H	HIC3
16	M	H	L	HIC17
17	M	H	M	HIC15
18	M	H	H	HIC7
19	H	L	L	HIC13
20	H	L	M	HIC7
21	H	L	H	HIC16
22	H	M	L	HIC8
23	H	M	M	HIC4
24	H	M	H	HIC2
25	H	H	L	HIC20
26	H	H	M	HIC19
27	H	H	H	HIC16
28	VH	M	M	HIC10
29	VL	M	M	HIC16
30	M	VH	M	HIC6
31	M	VL	M	HIC18
32	M	M	VH	HIC4
33	M	M	VL	HIC18

Table 4 Generalization of EFM using 33 rules

No	t <sub>1</sub>	t <sub>2</sub>	t <sub>3</sub>	actual HIC(d)	EFM HIC(d)
1	-1.5	-0.48	-1.0	892.2	857.3
2	-1.5	-0.48	-0.5	912.2	870.8
3	-1.5	-0.48	0.0	964.6	989.3
4	-1.0	-0.48	-1.0	924.1	914.5
5	-1.0	-0.48	-0.5	855.1	919.7
6	-1.0	-0.48	0.0	864.9	923.5
7	-0.5	-0.48	-0.1	930.7	957.7
8	-0.5	-0.48	-0.5	857.4	923.4
9	-0.5	-0.48	0.0	868.7	910.5

**Table 5** Design data using CCD

Case	$t_1$	$t_2$	$t_3$	HIC(d)
1	-1	-1	-1	834.4
2	-1	-1	0	888.2
3	-1	-1	1	1060.6
4	-1	0	-1	867.1
5	-1	0	0	813.2
6	-1	0	1	931.8
7	-1	1	-1	911.4
8	-1	1	0	860.4
9	-1	1	1	956.8
10	0	-1	-1	911.8
11	0	-1	0	886.3
12	0	-1	1	961.2
13	0	0	-1	947.5
14	0	0	0	870.3
15	0	0	1	838.3

**Table 6** Generation of 15 fuzzy rules

IF	$t_1$	$t_2$	$t_3$	HIC(d) ID
1	L	L	L	HIC3
2	L	L	M	HIC1
3	L	L	H	HIC11
4	L	M	L	HIC5
5	L	M	M	HIC7
6	L	M	H	HIC7
7	L	H	L	HIC8
8	L	H	M	HIC12
9	L	H	H	HIC9
10	M	L	L	HIC6
11	M	L	M	HIC8
12	M	L	H	HIC4
13	M	M	L	HIC10
14	M	M	M	HIC2
15	M	M	H	HIC10

선택된 데이터를 바탕으로 15개의 규칙을 만들었고 Table 6에 제시하였다. 입력멤버쉽함수(VL, L, M, H, VH)는 33개의 규칙을 만들때와 동일하게 식 (5)와 같은 가우시안 멤버쉽 함수를 선택하였고, 출력멤버쉽함수(HIC1~HIC12)는 식 (6),(7)과 같은 사다리꼴 멤버쉽함수와 삼각형멤버쉽함수를 선택하였다. 15개의 규칙으로 구성된 EFM에 의한 근사화모델의 정확도를 검증하기 위해 설계데이터에 포함되지 않은 9개의 새로운 데이

**Table 7** Generalization of EFM using 15 rules

No	$\overline{t_1}$	$\overline{t_2}$	$\overline{t_3}$	actual HIC(d)	EFM HIC(d)
1	-1.5	-0.48	-1.0	892.2	968.9
2	-1.5	-0.48	-0.5	912.2	996.0
3	-1.5	-0.48	0.0	964.6	1052.2
4	-1.0	-0.48	-1.0	924.1	1010.1
5	-1.0	-0.48	-0.5	855.1	947.2
6	-1.0	-0.48	0.0	864.9	955.9
7	-0.5	-0.48	-0.1	930.7	1023.9
8	-0.5	-0.48	-0.5	857.4	945.1
9	-0.5	-0.48	0.0	868.7	969.9

**Table 8** EFM based optimization results

# of rules	$t_1^*$	$t_2^*$	$t_3^*$	HIC
15	12.3mm	12.3mm	0.747mm	885.5
33	12.5mm	11.7mm	0.746mm	842.3

터를 이용하여 HIC의 실제 계산된 반응량과 EFM에 의한 예측값을 비교하였다. Table 4에 그 결과를 비교하였으며 이 경우 평균오차가 9.93% 범위내에 있다. Table 4의 각 설계변수는 실험계획법의 full factorial design에 의해 환산된 데이터이다.

이렇게 만든 근사화 모델들을 가지고 A-pillar trim의 유전알고리즘기반 최적설계의 결과를 규칙의 수의 변화에 따른 결과를 서로 비교하여 Table 8에 나타내었다. Table 8에서 보는 바와 같이 규칙의 수를 증가할수록 HIC는 더욱 감소함을 알 수가 있다. 이처럼 EFM은 규칙의 수에 더욱 영향을 미친다. 이때 규칙의 수에 따른 설계변수  $t_1$ 에 대한 최적의 입력 멤버쉽함수를 Fig. 6과 Fig. 7에 나타내었다. 적은 수의 퍼지규칙을 이용한 경우에는 5개의 입력 멤버쉽함수의 최대값이 -1.7에서 1.7사이에 골고루 분포하는 반면에 규칙의 수가 33개인 경우에는 입력 멤버쉽함수의 최대값들이 -1.7쪽으로 향하는 경향을 띄고 있다. 이는 규칙의 수를 증가시킴으로써 퍼지모델링의 비선형적인 특성이 설계공간의 상한근방에서 보다 두드러지게 나타남을 알 수 있다.




Fig. 6 Optimized membership functions of  $t_1$  from 33 rules in EFM




Fig. 7 Optimized membership functions of  $t_1$  from 15 rules in EFM

4.2 뉴로퍼지모델링에 의한 근사최적화

먼저 NFM에서는 규칙을 만드는데 있어서 결론부 항은 설계변수들에 대한 1차 다항식으로 주어진다. 예를 들면  $n$ 번째 규칙은 다음과 같이 구성된다.

$$HIC(t_1, t_2, t_3) = p_n t_1 + q_n t_2 + r_n t_3 + s_n \quad (8)$$

여기서  $p_n, q_n, r_n, s_n$  는 결론부 계수이다. 따라서 33개 설계데이터를 이용하여 이들 계수를 결정하기 위해서는 최대 규칙의 수는 8개가 필요하다. 우선 Table 2의 설계데이터 중에서 HIC(d)의 최대와 최소 사이를 8등분하였다. 그 사이에 포함된 HIC(d)의 값 중에 대략 중심에 위치한 8개의 설계데이터를 선택하였으며 그 결과를 Table 9에 나타내었다. 보는 바와 같이 설계변수들, 즉  $t_1, t_2, t_3$ 은 각각, -1,0,1로 표현되며 이들의 설계점을 또한 각각 L(low), M(medium), H(high) 등의 퍼지표현으로 변환할 수 있다. 이렇게 선택

Table 9 Design data for 8 fuzzy rules

Case ID	$t_1$	$t_2$	$t_3$	HIC(d)
1	1	0	1	822.1
2	-1	1	0	860.4
3	1	-1	0	899.7
4	0	0	-1	947.5
5	0	1	0	978.5
6	0	1	-1	1001.2
7	1	1	0	1060.1
8	1	1	-1	1164.2

Table 10 Generalization of NFM using 8 rules

No	$\bar{t}_1$	$\bar{t}_2$	$\bar{t}_3$	actual HIC(d)	NFM HIC(d)
1	-1.5	-0.48	-1.0	892.2	971.9
2	-1.5	-0.48	-0.5	912.2	998.6
3	-1.5	-0.48	0.0	964.6	1059.8
4	-1.0	-0.48	-1.0	924.1	999.8
5	-1.0	-0.48	-0.5	855.1	951.9
6	-1.0	-0.48	0.0	864.9	958.6
7	-0.5	-0.48	-0.1	930.7	1024.5
8	-0.5	-0.48	-0.5	857.4	949.6
9	-0.5	-0.48	0.0	868.7	953.3

된 설계데이터를 바탕으로 만일 3번째 규칙을 표현하면 식 (9)와 같이 나타낼 수 있다.

Rule3 If  $t_1$  is H and  $t_2$  is L and  $t_3$  is M,  
 then  $HIC = p_3 t_1 + q_3 t_2 + r_3 t_3 + s_3 \quad (9)$

입력멤버쉽함수(L,M,H)들은 EFM에서 적용할 때와 동일하게 식 (5)와 같은 가우시안멤버쉽함수를 선택하였다. 보는 바와 같이 결론부 파라미터는 3개이므로 33개 훈련데이터를 이용하여 결정할 수가 있다. 8개의 규칙으로 구성된 NFM에 의한 근사화모델의 정확도를 검증하기 위해 설계데이터에 포함되지 않은 9개의 새로운 데이터를 이용하여 HIC(d)의 실제 계산된 반응량과 NFM에 의한 예측값을 비교하였다. Table 10에 그 결과를 비교하였으며 이 경우 평균오차가 9.91% 범위 내에 있다. Table 10의 각 설계변수는 실험계획법의 full factorial design에 의해 환산된 데이터이다. 이는 33개의 규칙으로 구성된 EFM 보다는 정확도가 떨어지지만 15개의 규칙으로 구성된 EFM과 비슷함을 알 수 있다.



**Table 11** Design data for 4 fuzzy rules

Case ID	$t_1$	$t_2$	$t_3$	HIC
1	-1	-1	-1	834.4
2	-1	1	1	956.8
3	-1	-1	1	1060.6
4	1	1	-1	1164.2

NFM에서도 규칙의 수의 감소가 근사화모델의 정확도에 얼마나 영향을 미치는지 파악하기 위해서 규칙의 수를 4개로 감소시켰다. 그러기 위해서 Table 2에서 제시된 설계데이터 중에서 HIC의 최대와 최소 사이를 4등분하여 그 사이에 포함된 대략 중심에 위치한 설계데이터를 선정하여 4개의 설계데이터를 선택하여, Table 11에서 보여주고 있다.

Table 11에서의 설계변수들, 즉  $t_1, t_2, t_3$ 은 -1 (L: low)과 1(H: high)로 표현된다. 이 경우에도 식 (9)와 같은 NFM의 퍼지규칙을 생성한다. 입력 멤버쉽함수(L,H)은 규칙의 8개일 때와 동일하게 식 (5)와 같은 가우시안 멤버쉽함수를 선택하였다. 식 (10)에서 보는 바와 같이 결론부 파라미터의 개수가 총 16개이므로 33개의 훈련데이터를 이용하면 결론부 파라미터를 결정할 수 있다. 4개의 규칙으로 구성된 NFM에 의한 근사화모델의 정확도를 검증하기 위해, 설계데이터에 포함되지 않은 9개의 새로운 데이터를 이용하여 HIC의 실제 계산된 반응량과 NFM에 의한 예측값을 비교하였다. Table 10에 그 결과를 비교하였으며 이 경우 평균오차가 17.34% 범위 내에 있다. Table 12의 각 설계변수는 실험계획법의 full factorial design에 의해 환산된 데이터이다. 이는 33 및 15개의 규칙으로 구성된 EFM 방법보다는 정확도가 떨어지고 8개의 규칙으로 구성된 NFM 방법보다 나쁘다. 이는 EFM에서와 동일하게 규칙의 수에 근사화모델의 정확도에 영향을 미치는 사실을 알 수 있다.


이렇게 만든 근사화 모델을 사용하여 A-pillar trim의 유전알고리즘기반 최적설계의 결과를 규칙의 수의 변화에 따른 결과를 서로 비교하여 Table 13에 나타내었다. 이 경우, 규칙의 수의 증가는 HIC값을 감소시킴을 알 수 있다. NFM에서 얻은 설계변수  $t_1$ 에 대한 최적의 멤버쉽 함수를 Fig. 8 및 Fig. 9에 나타내었다. 보는 바와 같이 규칙이 8개일 때와 4개일 때 동일하게 입력공간

**Table 12** Generalization of NFM using 4 rules


No	$\bar{t}_1$	$\bar{t}_2$	$\bar{t}_3$	actual (HIC)	EFM (HIC)
1	-1.5	-0.48	-1.0	892.2	1038.9
2	-1.5	-0.48	-0.5	912.2	1060.1
3	-1.5	-0.48	0.0	964.6	1151.1
4	-1.0	-0.48	-1.0	924.1	1135.9
5	-1.0	-0.48	-0.5	855.1	998.9
6	-1.0	-0.48	0.0	864.9	974.2
7	-0.5	-0.48	-0.1	930.7	1118.9
8	-0.5	-0.48	-0.5	857.4	989.7
9	-0.5	-0.48	0.0	868.7	1008.2

**Table 13** NFM based optimization results

# of rules	$t_1^*$	$t_2^*$	$t_3^*$	HIC
4	12.3mm	13.8mm	0.803mm	938.4
8	11.5mm	12.3mm	0.747mm	884.2



**Fig. 8** Optimized input membership functions of  $t_1$  from 8 rules in NFM



**Fig. 9** Optimized input membership functions of  $t_1$  from 4 rules in NFM

전구간에 걸쳐서 입력멤버쉽 함수가 최대 값을 취함을 알 수 있다.

Table 14 Number of tuning parameters

	EFM		NFM	
	15rules	33rules	4rules	8rules
Antecedent	15-G	15-G	2-G	3-G
Consequent	9-TR	16-TR	16-CPN	32-CPN
	3-TZ	4-TZ		
Total	69	94	20	38

#### 4.3 근사최적화결과의 비교

EFM과 NFM의 방법상의 다른점은 EFM은 조건부항을 멤버쉽 함수로 나타내는 반면 NFM은 설계변수에 대한 1차 다항식으로 표현된다. 그리고 본 논문의 승용차내장재 설계에서 알 수 있듯이 EFM을 이용한 방법이 NFM을 이용한 방법보다 훨씬 개선된 설계해를 제시하였다. 이는 EFM을 이용한 방법은 결론부 항을 멤버쉽함수의 형태로 표현하기 때문에 설계변수의 1차 다항식을 이용한 NFM 방법보다는 보다 정확하게 표현하기 때문으로 판단된다. 더욱이 제한된 설계데이터를 이용할 경우, EFM을 이용한 방법은 설계데이터를 충분히 이용하여 규칙을 구성할 수 있는 반면에 NFM은 결론부 매개변수를 결정하기 위해 제한된 규칙으로 구성된다. Table 14에서는 각 근사화모델링을 수행하는 경우에 요구되는 퍼지 매개변수의 수를 제시하였다. 여기서, G는 가우시안 함수, TR은 삼각형함수, TZ는 사다리꼴함수 및 CPT는 NFM에서의 결론부 Sugeno model에 대한 계수를 의미한다.

보는 바와 같이 33개의 설계데이터만 있는 경우에는 EFM은 33개의 설계데이터를 이용하여 규칙을 만들 수 있는 반면, NFM은 결론부 계수의 총 수가 33개 이하로 제한된다. 그러나 근사화모델을 최적화하는 경우, EFM은 GA's에 의한 전역최적화기법을 사용하지만, NFM은 구배 (gradient)기반의 전통적인 신경망기법을 사용한다. 그러나 본 연구에서 적용한 EFM은 GA's에 의한 근사모델링의 최적화는 많은 양의 계산시간을 요구하는 단점이 있다.

### 5. 결론

본 논문에서는 설계 데이터의 개수가 불충분하

거나 수치적으로 명확하게 표현되지 않는 경우에 적합한 근사최적화방법으로써 진화퍼지모델링과 뉴로퍼지모델링을 제안하였다. 그리고 두 가지 방법의 타당성을 검증하기 위해서 설계 데이터를 충분히 확보할 수가 없는 비선형 구조시스템인 승용차 A-pillar trim 설계에 적용하여 검증하였다. 이러한 적용결과 두 방법 모두 규칙의 정확한 표현에 영향을 미침을 확인하였다. 뉴로퍼지모델링 기법은 결론부 계수들을 결정하기 위해 규칙의 수가 제한되는 단점이 있으나 진화퍼지모델링은 제한된 설계데이터를 충분히 이용하여 규칙을 구성할 수가 있다. 계산비용에 있어서는 뉴로퍼지모델링이 진화퍼지모델링보다 단 기간 내에 근사화 모델을 생성할 수 있는 장점을 지니고 있다. 추후, 주어진 시스템에 대하여 퍼지공간을 임의 선택으로 분할하는 것보다는 주어진 데이터의 특성을 부여한 공간을 퍼지클러스터링 알고리즘을 사용하여 분할하는 기법에 대한 연구, 근사화의 정확성을 판별하는 기준으로서의 신뢰할 만한 분산분석에 관한 연구 그리고 퍼지멤버쉽함수의 선택을 위한 학습형 알고리즘의 개발이 필요하다.

### 후 기

이 연구는 한국과학재단 지정 최적설계신기술 연구센터(Center of Innovative Design Optimization Technology, iDOT)의 연구비 지원과 두뇌한국 21(Brain Korea 21)사업의 지원으로 이루어진 것이므로 이에 관계자 여러분들께 감사드립니다.

### 참고문헌

- (1) Standrad No 201 1995, : Head Impact Protection, Part 571 - Federal Motor Vehicle Safety Stadard, National Highway Traffic Safety Administration, Department of Transportation, US.
- (2) Carpenter, W. C., and Barthelemy, J.-F. M.,1993, "A Comparison of Polynomial Approximations and Artificial Neural Networks as Response Surface," *Structural Optimization*, Vol. 5, pp. 166~174.
- (3) Roux, W. J., Stander N., and Haftka, R. T., 1996, "Response Surface Approximations for Structural Optimization," AIAA Paper No.

96-4042.

- (4) Lee, J., and Hajela, P., 1996, "Parallel Genetic Algorithm Implementation in Multidisciplinary Rotor Blade Design," *Journal of Aircraft*, Vol. 33, No. 5, pp. 962~969.
- (5) Hajela, P., and Lee, J., 1995, "Genetic Algorithms in Multidisciplinary Rotor Blade Design," *Proceedings of the 36th SDM Conference*, AIAA Paper No. 95-1144, New Orleans, LA.
- (6) Jang, J.-S. R., Sun, C.-T., and Mizutani, E., 1997, *Neuro-Fuzzy and Soft Computing*, Prentice Hall.
- (7) Yamakawa, T., 1992, "A Neo Fuzzy Neuron and Its Applications to System Identification and Prediction of the System Behavior," *Proceedings of the 2nd International Conference on Fuzzy Logic & Neural Networks*, pp. 477~483.
- (8) Berenji, H. R., and Khedkar, P., 1992, "Learning and Tuning Fuzzy Logic Controllers Through Reinforcements," *IEEE Transactions on Neural Networks*, Vol. 3, No. 5, pp. 724~740.
- (9) Zadeh, L.A., 1992, "Fuzzy Logic, Neural Networks and Soft Computing, Department of Computer Science," the University of California at Berkeley, Berkeley, CA.
- (10) Kim, S., and Lee, J., 2000, "Development of Global Function Approximations for Design Optimization Using Evolutionary Fuzzy Modeling," to appear in *KSME International Journal*, November.(in press)
- (11) Jang, J.-S. R., 1993, ANFIS: Adaptive Network Based Fuzzy Inference System, *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 23, pp. 665~685.
- (12) Kim, S., and Lee, J., 2000, "Applications of Fuzzy Inference Systems in Global Approximate Design Optimization," *Proceedings of the 8th AIAA/USAF/NASA/ISSMO Symposium on Multidisciplinary Analysis and Optimization*, Long Beach, CA.
- (13) Sugeno, M., and Kang, G. T., 1988, "Structure Identification of Fuzzy Model," *Fuzzy Sets and Systems*, Vol. 28, pp. 15~33.
- (14) Kim, H.-K., and Kang S., 2000, "Optimum Design of An A-Pillar Trim with Rib Structures for occupant Head Protection," *Proceedings of Symposium on Advanced Vehicle Technologies, ASME, International Mechanical Engineering Congress and Exposition*, Orlando, FL, November.