

## Genetic Algorithm과 Neural Network을 이용한 Tube Hydroforming의 성형공정 최적화에 대한 연구

양재봉\* · 전병희\*\* · 오수익\*\*\*

(2000년 9월 7일 접수)

### A Study on Optimal Process Design of Hydroforming Process with a Genetic Algorithm and Neural Network

J. B. Yang, B. H. Jeon and S. I. Oh

#### Abstract

Tube hydroforming is recently drawing attention of automotive industries due to its several advantages over conventional methods. It can produce wide range of products such as subframes, engine cradles, and exhaust manifolds with cheaper production cost by reducing overall number of processes. A successful tube hydroforming depends on the reasonable combination of the internal pressure and axial load at the tube ends. This paper deals with the optimal process design of hydroforming process using the genetic algorithm and neural network. An optimization technique is used in order to minimize the tube thickness variation by determining the optimal loading path in the tube expansion forming and the tube T-shape forming process.

**Key Words :** Optimization, Hydroforming, Genetic Algorithm, Neural Network

#### 1. 서 론

튜브 하이드로포밍 공정은 90년대 들어서 자동차 부품 산업에 이용되면서 급속히 발전하기 시작하였다. 자동차에 대한 소비자의 요구는 승객 및 화물의 운송이라는 기본적인 기능 외에 외관, 주행 성능, 승차감, 안전성, 연비 및 환경문제 등 다양한 면으로 확대되고 있다. 이에 대응하여 미국, 일본, 유럽 등의 선진 자동차업계에서는 경

쟁력 확보를 위하여 고안전 차체의 설계, 경량화 등 신기술 개발에 계속 박차를 가하고 있는데 하이드로포밍(hydroforming), 레이저 용접 판재(tailor welded blank), 스페이스 프레임(space frame), 알루미늄 차체 등이 그 대표적인 예이다. 하이드로포밍은 경량화 및 안전성 확보에 대한 요구를 충족시키면서 가격 경쟁력이 있는 제품을 생산하기 위한 기술로서 횡방향 부재(cross member), 서브프레임(subframe), 필라(pillar) 등 자동차의 많은 부품

\* 서울대학교 대학원  
\*\* 인덕대학 기계설계과  
\*\*\* 서울대학교 기계항공공학부

에 적용될 수 있는 방법이며 기존의 스템핑(stamping)에 비하여 많은 장점이 있다. 스템핑의 경우 2개의 판재를 따로 성형하여 스토톤접에 의하여 결합하는 반면 하이드로포밍은 1개의 튜브를 사용하므로 부품 개수 및 공정 수가 감소되며, 높은 강성을 갖는 부품을 생산할 수 있으며, 스토톤접을 위한 플랜지가 없으므로 경량화 및 소재 수율 면에서 유리하며, 형상이 복잡한 부품을 생산할 수 있다.<sup>(1~6)</sup>

튜브 하이드로포밍 성형공정은 크게 예비 굽힘 공정(pre-bending process)과 액압 성형공정(hydroforming process)의 2단계로 나누어진다. 다른 성형공정과 마찬가지로 하이드로포밍 공정에서도 양호한 제품을 성형하기 위해서는 다이 내의 재료 유동을 적절히 제어하는 것이 중요하다. 하이드로포밍 공정의 특성상 일단 다이와 접촉한 부위의 소재는 내부의 유체에 의한 압력으로 소재와 다이간의 마찰력이 커지기 때문에 다이와의 상대 이동이 거의 발생하지 않는다. 이는 소재의 변형을 일부분에서만 발생하게 하여 성형에 불리한 점으로 작용한다. 따라서 소재의 양단에서 압축력을 가하여 보다 원활한 소재의 유동을 발생시키는 방법을 사용한다. 이러한 튜브의 내압과 축방향 압축력의 적절한 선정은 하이드로포밍 제품의 두께분포에 큰 영향을 주므로 이의 선정이 중요한 과제라 할 수 있다.<sup>(7)</sup>

김형종, 전병희 등은 T형 부품을 성형하는 데 있어서 튜브 내압과 축방향 압축력 등의 공정 조건의 영향을 유한요소법을 사용하여 해석하였으며<sup>(8)</sup>, Altan 등은 PAM-STAMP를 사용하여 튜브 벌징(tube bulging) 시 각 공정 조건간의 상호 관계를 연구하였다.<sup>(9)</sup> Fuchizawa는 해석적인 방법을 통하여 튜브 벌징의 성형 문제를 해석하고 이를 실험과 비교하였는데, 소재의 물성치와 다이의 형상 등을 변화시킬 때 변형률 분포와 소재-다이간의 접촉 길이를 구하였다.<sup>(10)</sup> Bruggemann 등은 하이드로포밍 공정의 설계변수와 최적화 대상에 관해서 연구하였으며<sup>(11)</sup>, Ghouati, Gelin 등은 튜브 확관 공정의 두께분포 최적화를 수행하였다.<sup>(12)</sup>

본 연구에서는 튜브 하이드로포밍 공정의 설계변수 최적화에 대하여 연구하였다. 하이드로포밍 공정의 최적화를 위하여 유전자 알고리즘(genetic algorithm)을 이용하였으며, 신경회로망(neural network) 알고리즘을 이용하여 목적함수 값을 근사화 하였다. 튜브 하이드로포밍 성형공정에 대하여 내부 유체압력과 축방향 압입량(axial displacement)을 설계변수로 하여 성형후 튜브의 두께분포 최적화를 수행하였다.

## 2. 최적화 과정

설계변수에 대한 최적화 과정은 다음과 같은 목적함수의 최소화로 표현된다.

$$\begin{aligned} & \text{minimize } f(p) \quad p \in H \\ & \text{subject to } g_i(p) \leq 0 \quad i=1,2,\dots,m \end{aligned} \quad (1)$$

여기서  $f(p)$ 는 최소화될 목적함수이며,  $p$ 는 설계변수이며,  $H$ 는 설계변수의 한계를 결정하는 설계공간이며,  $g_i(p)$  제한조건이다.

제한 최소화 문제를 풀기 위한 방법으로는 여러 가지가 있지만 대부분의 방법은 설계변수에 대한 목적함수의 민감도(sensitivity) 계산을 바탕으로 하는 방식을 사용하고 있으며, 벌칙함수(penalty function)나 라그랑지 승수(Lagrange multiplier)를 이용하는 방법과 경사도투영법(gradient projection method), 유용방향법(feasible direction method), 제약 유사뉴턴법(constrained quasi-Newton method) 등이 있다. 이러한 민감도 해석을 이용한 최적화의 경우에는 목적함수에 따라서 민감도 값이 불연속이거나 또는 여러 개의 국소 최소점이 존재하는 경우가 발생하게 되며, 따라서 최적화가 불가능하거나, 국소 최소값으로 수렴될 가능성이 있다.<sup>(13)</sup>

본 연구에서는 목적함수의 민감도 계산이 필요치 않은 유전자 알고리즘을 이용하여 최적화를 수행하였다. 이러한 유전자 알고리즘을 이용한 최적화의 경우에는 많은 수의 목적함수의 계산이 필요하므로 이에 대한 적절한 근사화가 필요하게 된다. 함수의 근사에 많이 사용되는 것으로는 반응표면분석법(response surface method)과 신경회로망(neural network)에 의한 근사화 등이 있다. 본 연구에서는 신경회로망에 의한 근사화를 수행하였다. Fig. 1에 유전자 알고리즘과 신경회로망을 이용한 하이드로포밍공정 최적화 과정을 나타내었다. 먼저 주어진 초기조건(내부 유체압력과 축방향 압입량)을 포함하는 다수의 설계변수 집합에 대하여 하이드로포밍 해석을 수행하여 목적함수 값과 제한조건 값을 구한 후 신경회로망을 학습한다. 학습된 신경회로망에 대하여 유전자 알고리즘을 이용한 최적화를 수행하여 최적치를 구한다. 구하여진 최적치가 수렴조건을 만족하면 탐색을 중지하고, 그렇지 않을 경우 다시 구하여진 최적치를 포함하는 설계변수 집합을 구성하여 수렴조건을 만족할 때까지 반복계산을 수행한다.

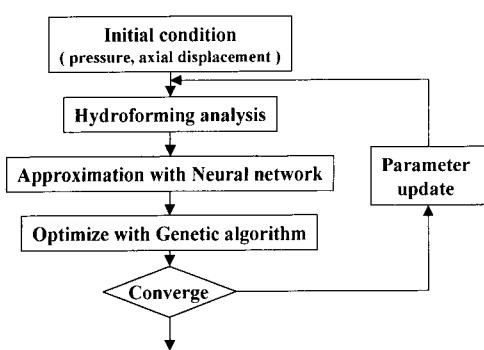


Fig. 1 schematic diagram of hydroforming optimization

### 3. 유전자 알고리즘

본 연구에서는 유전자 알고리즘을 이용하여 최적화를 수행하였다. 유전자 알고리즘은 진화 알고리즘 중 하나로 자연진화의 모델에 기초를 둔 확률 최적화 알고리즘이다.<sup>(14~15)</sup> 유전자 알고리즘은 3가지 연산자 즉, 교배(crossover), 돌연변이(mutation), 선택(selection)을 이용하여 진화과정을 인위적으로 수행하는 것으로 각 연산자의 역할과 최적화 과정에 대한 기본개념을 다음 4가지로 분류할 수 있다.

1) n 개의 염색체로 구성된 최초의 유전자 집단을 무작위로 구성한다.

2) 선택(selection) : 다음 세대를 구성하는 염색체 후보들을 선별하는 과정으로서 적합도가 높은 개체를 확률적인 방법으로 선택한다.

3) 교배(crossover) : 선택된 유전자에서 확률적으로 선택된 한 쌍을 상호 교배시켜 새로운 염색체를 구성한다.

4) 돌연변이(mutation) : 어떤 유전자가 미처 검증 받지 못하고 도태되는 것을 방지하기 위해 미리 주어진 확률에 의해 돌연변이 시킨다.

선택될 확률은  $F_i / \sum F_i$  로 하였다. 여기서  $F_i$ 는  $i$  설계점의 적합성의 크기를 나타내는 값으로 다음과 같이 정의하였다.

$$F_i = K - (f_i + \sum \text{Penalty}) \quad (2)$$

여기서  $f_i$ 는  $i$  설계점의 최소화할 목적함수 값이며  $K$ 는  $F_i$  값을 양수로 만들기 위한 충분히 큰 값으로 정의되며,  $\text{Penalty}$ 는 제한조건을 위반한 값을 나타낸다.

다.

이와 같이 유전자 알고리즘은 각 세대에서 적합도가 낮은 열성 유전자를 도태시키고 우성개체끼리 상호교차시켜 우수한 새로운 세대를 만드는 과정을 반복적으로 수행함으로서 최적해를 구하게 된다.

### 4. 신경회로망

목적함수의 극사화를 위하여 신경회로망을 이용하였다. 본 연구에 사용된 신경회로망은 1개의 입력층과 1개의 은닉층 그리고 1개의 출력층으로 구성된 다중 피드포어드 신경회로망(multilayer feed forward neural network)을 사용하였다. Rumelhart McClelland에 의해 제안된 역전파(backpropagation) 학습알고리듬을 이용하여 목표 출력 값과 신경회로망에 의한 출력 값의 차이를 최소화하도록 각층간의 연결강도와 임계값을 조정하여 원하는 신경회로망을 구성한다.<sup>(16)</sup>

각 노드에서의 입력은 전 층의 노드 출력의 하중 합(weighted sum)에 임계값(threshold value)을 더한 값으로 아래 식과 같이 나타난다.

$$\text{net}_k = \sum w_{kj} O_j + \theta_k \quad (3)$$

여기서  $\text{net}_k$ 는 k 번째 노드로의 입력,  $O_j$ 는 전 층 j 번째 노드의 출력,  $w_{kj}$ 는 전 층 j 번째 노드와 현재 층 k 번째 노드 사이의 하중계수,  $\theta_k$ 는 k 번째 노드에서의 임계값이다.

각 노드의 출력은 입력의 시그모이드(sigmoid) 함수 형태로 다음과 같이 나타난다.

$$O_k = f(\text{net}_k) = \frac{1}{1 + \exp(-\text{net}_k)} \quad (4)$$

목표 출력 값과 신경회로망에 의한 출력 값의 차이를 나타내는 오차함수 E는 다음과 같이 나타나는데  $T_k$ 와  $O_k$ 는 출력 노드 k에서 각각 학습 샘플의 출력과 신경회로망의 출력이다.

$$E = \frac{1}{2} \sum (T_k - O_k)^2 \quad (5)$$

오차 값을 최소화하기 위하여 최속강하법(steepest descent method)을 사용하여 하중계수와 임계값을 다음

과 같이 순차적으로 계산된다.

$$\Delta w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj} \quad (6)$$

$$\theta_k(n+1) = \theta_k(n) + \Delta \theta_k \quad (7)$$

먼저 출력층에 대한 하중계수와 임계값의 증분량을 계산하면 다음과 같다.

$$\begin{aligned} \Delta w_{kj} &= -\eta_w \frac{\partial E}{\partial w_{kj}} \\ &= -\eta_w \frac{\partial E}{\partial \text{net}_k} \frac{\partial \text{net}_k}{\partial w_{kj}} \\ &= \eta_w \delta_k O_j \end{aligned} \quad (8)$$

$$\begin{aligned} \Delta \theta_k &= -\eta_t \frac{\partial E}{\partial \theta_k} \\ &= -\eta_t \frac{\partial E}{\partial \text{net}_k} \frac{\partial \text{net}_k}{\partial \theta_k} \\ &= \eta_t \delta_k \end{aligned} \quad (9)$$

$$\begin{aligned} \delta_k &= -\frac{\partial E}{\partial \text{net}_k} \\ &= -\frac{\partial E}{\partial O_k} \frac{\partial O_k}{\partial \text{net}_k} \\ &= (T_k - O_k) O_k (1 - O_k) \end{aligned} \quad (10)$$

여기서  $\eta_w, \eta_t$ 는 learning-rate parameters이다.

다음으로 은닉층에 대한 하중계수와 임계값의 증분량을 계산하면 다음과 같다.

$$\begin{aligned} \Delta w_{ji} &= -\eta_w \frac{\partial E}{\partial w_{ji}} \\ &= \eta_w \delta_j O_i \end{aligned} \quad (11)$$

$$\Delta \theta_j = \eta_t \delta_j \quad (12)$$

$$\delta_j = O_j (1 - O_j) \sum w_{kj} \delta_k \quad (13)$$

처음 계산을 시작할 때 임의의 하중계수와 임계값을 사용하며 이들은 반복과정이 진행됨에 따라 안정화되게 된다. 학습하는 동안 학습샘플의 입력이 입력층에 주어지고 네트워크의 통하여 출력층의 출력으로 나타나게 되면, 이 값을 근거로  $\delta$  값들이 식(10)과 (13)에서 출력층과 중간층에 대하여 각각 계산되고, 최종적으로 식(6)과 (7)에 의하여 하중계수와 임계값의 조정이 이루어진다.

## 5. 하이드로포밍 성형공정 최적화

### 5.1 사각 투브 성형해석

원형의 투브를 직사각형으로 확관하는 성형공정에서의 두께 최적화를 수행하였다. Fig. 2에 투브 확관 성형해석의 금형 형상과 치수를 나타내었다. 해석에 사용한 투브는 외경이 80mm이며 두께는 2.0mm이다. 금형은 가로 120mm, 세로 30mm이다. 사용된 투브의 응력-변형률 관계는 다음과 같다.

$$\bar{\sigma} = 0.5673(0.0071 + \bar{\epsilon})^{0.2637} GPa \quad (14)$$

목적함수는 다음과 같이 투브의 초기두께  $t_0$ 와 성형후 최소두께  $t_{\min}$ 의 차이로 정하였다.

$$f = t_0 - t_{\min} \quad (15)$$

하이드로포밍 성형공정 최적화를 위하여 투브의 양단에서 가하는 압축력에 의한 축방향 변위와 유체의 성형압력을 설계변수로 설정하였으며, 성형압력은 3차의 B-스플라인 곡선으로 표현하였다. B-스플라인 곡선의 매개변수를  $u$ 라 하고  $(n+1)$ 개의 조정점을  $P_0, P_1, \dots, P_n$ 이라고 하면 차수가  $k$ 인  $k$ 차 B-스플라인은 다음과 같이 주어진다.

$$P(u) = \sum_{i=0}^n P_i N_{i,k}(u) \quad (16)$$

여기서

$$N_{i,0}(u) = \begin{cases} 1 & \text{if } t_i \leq u \leq t_{i+1} \\ 0 & \text{otherwise} \end{cases} \quad (17)$$

$$N_{i,k} = \frac{(u - t_i)N_{i,k-1}}{t_{i+k-1} - t_i} + \frac{(t_{i+k} - u)N_{i+1,k-1}}{t_{i+k} - t_{i-1}} \quad (18)$$

$$t_m = \begin{cases} 0 & \text{if } m < k \\ m - k + 1 & \text{if } k \leq m \leq n \\ n - k + 2 & \text{if } m > n \end{cases} \quad (19)$$

성형압력을 스플라인으로 표현하기 위하여 8개의 조정점을 이용하였다. Fig. 3에 8개의 조정점을 가진 스플라인으로 표현된 성형압력 곡선을 나타내었다. 여기서  $P_0$ 은 0.0 MPa로 고정하였으며, 마지막 조정점인  $P_7$ 은 100.0 MPa로 고정하였다. 따라서 설계변수는  $P_1$ 에서  $P_6$ 까지 6개의 성형압력변수와 1개의 축방향 변위를 나

타내는 변수로 하였다.

성형시간이 증가함에 따라 성형압력은 전 단계의 성형압력보다 항상 크게 유지하도록 하였다. 따라서 제한 조건을 다음과 같이 정하였다.

$$g_i = P_i - P_{i+1} \leq 0 \quad i = 0, 1, \dots, 6 \quad (20)$$

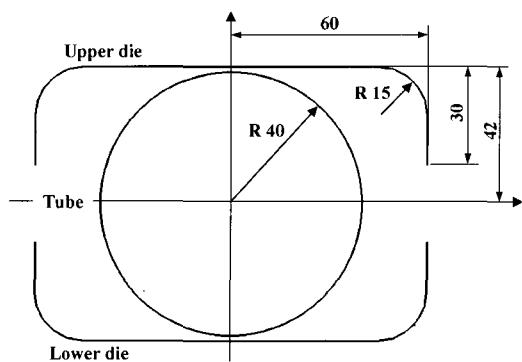


Fig. 2 Tool geometry of the tube bulge process

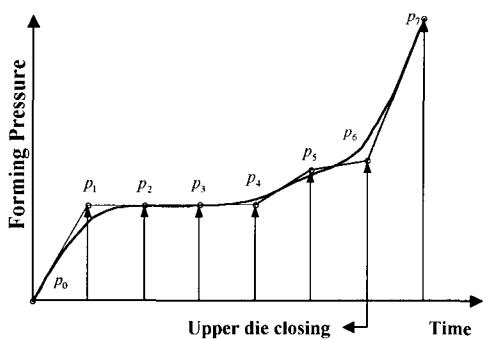


Fig. 3 B-spline curve for the internal pressure and axial displacement

본 연구에 사용된 신경회로망은 1개의 입력층과 1개의 은닉층 그리고 1개의 출력층으로 구성된 신경회로망을 사용하였다. 입력층에는 내부압력과 축방향 변위를 나타내는 7개의 입력노드를 가지며, 출력층은 식(15)에 정의된 목적함수 값을 나타내는 1개의 노드를 가진다.

Fig. 4에 초기의 28개의 데이터를 이용하여 신경회로망을 학습한 결과를 나타내었다. 시뮬레이션으로 구한 목적함수 값을 신경회로망에 의한 목적함수 값을 정규화하여 비교하였다. Fig. 5는 신경회로망의 학습과정에서의 오차항의 분포를 나타내었다.

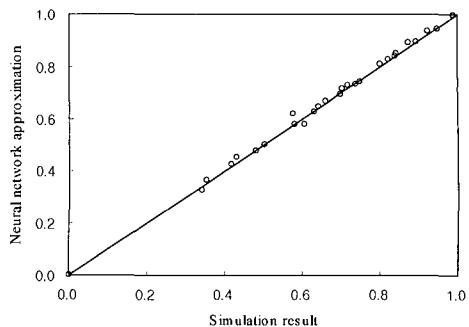


Fig. 4 Correlation between simulation results and neural net approximation

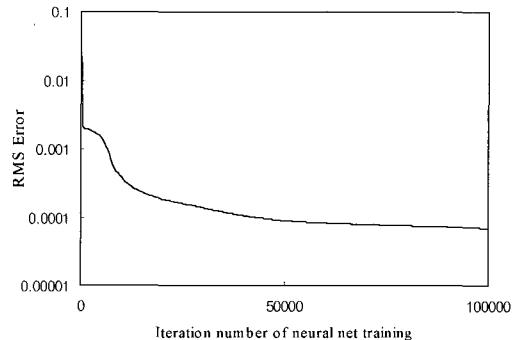


Fig. 5 RMS error according to the iteration of neural network training

학습된 신경회로망에 대하여 유전자 알고리즘을 이용하여 최적화를 수행하였다.

Fig. 6에 초기 데이터에 대한 최적화가 진행되는 과정에서의 목적함수 값을 나타내었다. 목적함수 값은 100000 세대가 지난 후 3.15에서 2.15로 감소하였다.

신경회로망의 학습과 유전자 알고리즘을 이용한 최적화를 반복 수행하여 목적함수 값의 최적치를 구하였다.

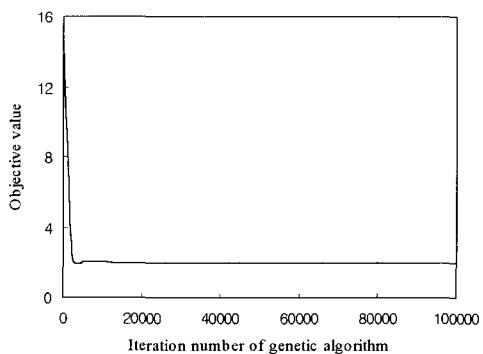


Fig. 6 Objective value according to the genetic iteration

Fig. 7 은 최적화가 진행되는 과정에서의 목적함수 값을 나타낸 것이다. 전체적으로 5번의 반복계산을 통하여 목적함수 값은 3.15에서 0.86으로 감소하였다.

Fig. 8 은 내부 압력과 축방향 압입량의 초기 곡선 및 최적화 수행후의 곡선을 나타낸 것이다. 초기조건으로는 축방향 압입량은 10mm, 내부 압력은 금형이 닫히기 전 까지 12.5MPa을 유지하다가, 금형이 닫힌 후 100MPa까지 증가하였다. 최적화된 조건은 축방향 압입량은 20mm 까지 증가하였으며, 내부 압력을 금형이 닫히기 전까지 25MPa까지 증가하고 최종단계에서 100MPa까지 증가하였다.

Fig. 9 에는 초기 및 최적화된 투브의 두께분포를 나타내었다. 초기 조건에서는 두께의 최대최소 편차가 0.41mm이었으며 최소 두께는 1.52mm 이었다. 최적화 수행후 두께의 최대최소 편차는 0.06mm 이었으며 최소 두께는 1.88mm 이었다.

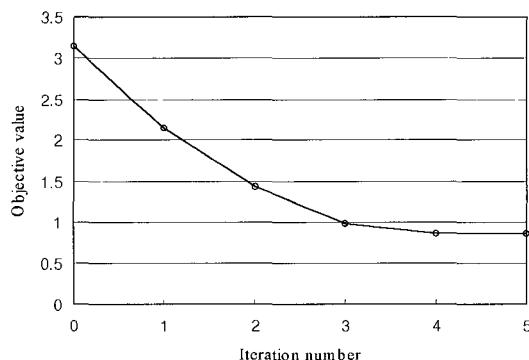


Fig. 7 Variation of the objective value

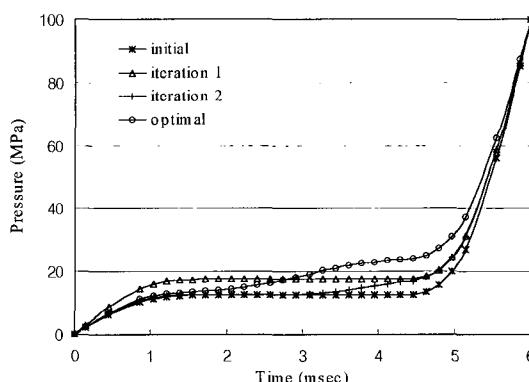


Fig. 8 Pressure curve

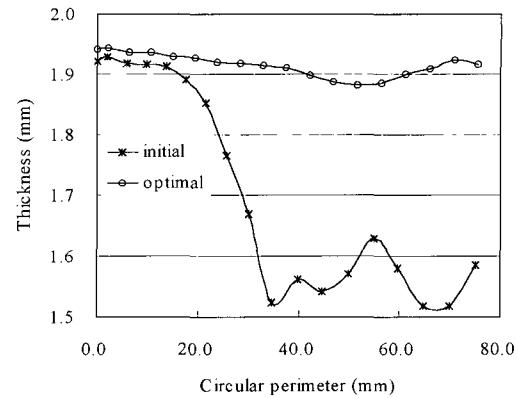


Fig. 9 Thickness distribution of hydroformed tube

## 5.2 투브 확관 성형해석

투브 확관 성형(tube expansion forming)에서의 두께 최적화를 수행하였다. Fig. 10에 투브 확관 성형해석의 금형 형상과 치수를 나타내었다. 해석에 사용한 투브는 외경이 42mm이며 두께는 1.98mm이다.

성형공정 최적화를 위하여 투브의 양단에서 가하는 압축력과 유체의 성형압력을 설계변수로 설정하였다. 성형후 두께분포를 균일하게 갖도록 하기 위하여 최소화할 목적함수를 투브의 초기두께를  $t_0$  라하고 성형완료후 각 요소의 두께를  $t_i$  라 할 때 다음과 같이 성형전후의 요소 두께 차의 제곱의 합으로 정의하였다.

$$f = \left( \sum_{i=1}^N \left| \frac{t_i - t_0}{t_0} \right|^2 \right)^{1/2} \quad (21)$$

여기서 N은 요소의 개수이다.

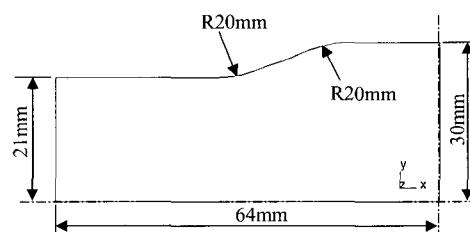


Fig. 10 Tool geometry of the tube bulge process

신경회로망의 학습과 유전자 알고리즘을 이용한 최적화를 반복 수행하여 목적함수 값의 최적치를 구하였다. Fig. 11은 최적화가 진행되는 과정에서의 목적함수 값을 나타낸 것이다. 전체적으로 5번의 반복계산을 통하여 목적함수 값은 1.45에서 0.40으로 감소하였다.

Fig. 12는 내부 압력과 축방향 압입량의 초기 곡선 및 최적화 수행후의 곡선을 나타낸 것이다. 초기조건은 축방향 압입량은 5mm, 내부 압력은 60MPa 까지 선형으로 증가하였다. 최적화된 조건은 축방향 압입량은 10mm 까지 증가하였으며, 내부 압력은 18MPa 을 유지하다가 최종단계에서 60MPa 까지 증가하였다.

Fig. 13에는 초기 및 최적화된 투브의 두께분포를 나타내었다. 초기 조건에서는 두께의 최대최소 편차가 0.5mm이었으며 최소 두께는 1.66mm 이었다. 최적화 수행 후 두께의 최대최소 편차는 0.2mm 이었으며 최소 두께는 1.94mm 이었다.

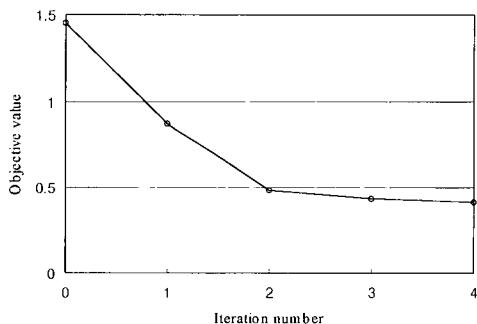


Fig. 11 Variation of the objective value

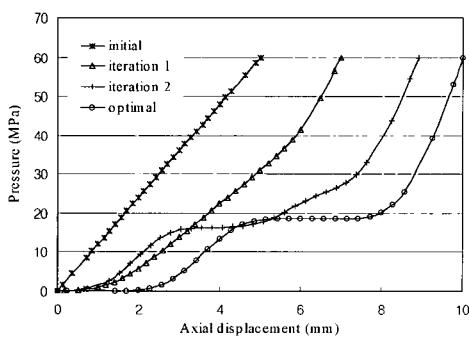
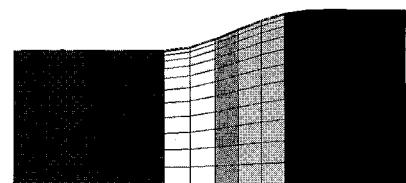


Fig. 12 Pressure-axial displacement curve



(a) initial case



(b) optimal case

Fig. 13 Thickness distribution of hydroformed tube

### 5.3 T-형상 성형해석

하이드로포밍을 이용한 T-형상의 투브성형과정에 대하여 두께 최적화를 수행하였다. 설계변수로는 내부 압력과 축방향 압입량을 설정하였으며, 목적함수는 식(15)와 같이 정하였다.

해석에 사용한 투브는 외경이 50mm이며 두께는 1.98mm이다. Fig. 14에 T-형상 하이드로포밍 금형의 형상과 치수를 나타내었다. Fig. 15는 내부 압력과 축방향 압입량의 초기 관계 및 최적화 수행후의 관계를 도시하였다. Fig. 16은 최적화가 진행되는 과정에서의 목적함수 값을 나타낸 것이다. 전체적으로 7번의 반복계산을 통하여 목적함수 값은 1.79에서 0.58로 감소하였다.

Fig. 17에는 초기 및 최적화된 T-형상 투브의 두께분포를 나타내었다. 초기 조건에서 최소 두께는 0.18mm 이었으며 최적화된 투브의 최소 두께는 1.39mm 이었다.

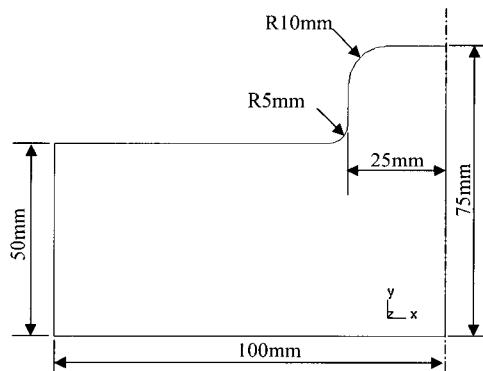


Fig. 14 Tool geometry of the T-shape process

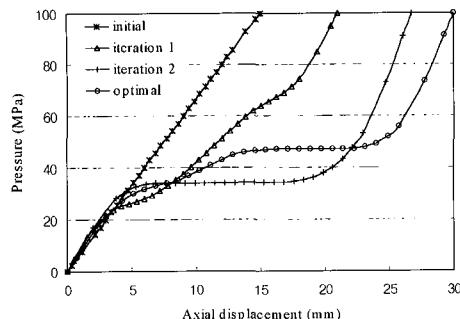


Fig. 15 Pressure-axial displacement curve

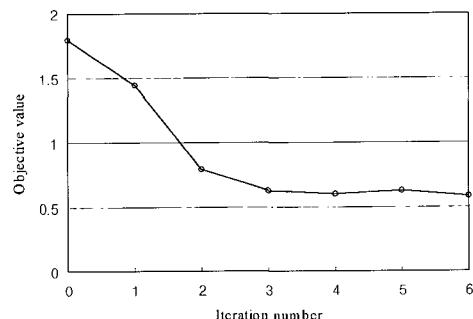


Fig. 16 Variation of the objective value

## 6. 결 론

본 연구에서는 신경회로망(neural network)과 유전자 알고리즘(genetic algorithm)을 이용하여 투브 하이드로포밍 공정의 최적화를 수행하였다.

사각형 투브 성형과 투브 확관(tube expansion) 성형 공정, 그리고 T-형상 성형공정에 대하여 내부 유체압력과 축방향 압입량(axial displacement)을 설계변수로 하여 성형후 투브의 두께분포 최적화를 수행하였다. 사각형 투브 성형공정에서는 성형후 투브의 최소 두께를 초기 1.52mm에서 성형공정 최적화 이후 1.88mm로 증가하였고, 투브 확관 성형공정에서는 투브의 최소 두께를 1.66mm에서 성형공정 최적화 이후 1.94mm로 증가하였으며, T-형상 성형공정에서는 0.18mm에서 1.39mm로 증가하였다.

## 참 고 문 헌

- (1) S. Nakamura, H. Sugiura, H. Onoe, K. Ikemoto,

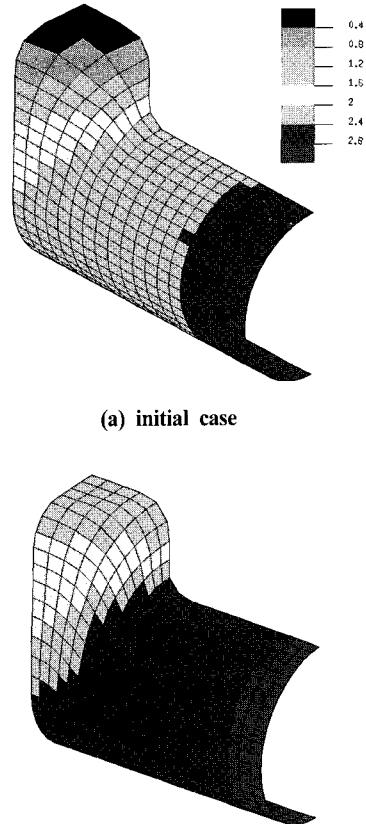


Fig. 17 Thickness distribution of hydroformed T-shaped tube

- 1994, "Hydromechanical drawing of automotive parts", Journal of Materials Processing Technology, vol.46, pp. 491~503.  
 (2) M. Mason, 1996, "Tube Hydroforming : Advancements Using Sequenced Forming Pressures", Innovations In Hydroforming Technology, Tube and Pipe Association International.  
 (3) F. Dohmann, Ch. Hartl, 1997, "Tube hydroforming -research and practical application", Journal of Materials Processing Technology, vol.71, pp. 174~186.  
 (4) M. Ahmetoglu, T. Altan, 1999, "Tube hydroforming-state-of-the-art and future trends", SAE, International Congress and Exposition, Detroit, Michigan.  
 (5) J. B. Yang, B. H. Jeon, S. I. Oh, 1999, "Simulation

- of tube hydroforming for an automotive part", Numisheet'99, pp. 491~496.
- (6) Laurence Oldacre, 1997, "Introduction to Tube Bending for Hydroforming Applications", TPA's 2nd Annual Automotive Tube Conference, pp. 37~68.
- (7) D. Schmoeckel, C. Hessler, B. Engel, 1992, "Pressure Control in Hydraulic Tube Forming", Annals of the CIRP, vol.41, pp. 311~314.
- (8) H.J. Kim, B.H. Jeon, H.Y. Kim, J.J. Kim, 1993, "Finite Element Analysis of the Liquid Bulge Forming Processes", Advanced Technology of Plasticity, pp. 545~550.
- (9) T. Sokolowski, T. Altan, 1998, "Evaluation of tube formability and material characteristics in tube hydroforming", Report No.ERC/NSM-R-98-25, The Ohio State University, Columbus, Ohio.
- (10) S. Fuchizawa, 1990, "Deformation of Metal Tubes under Hydrostatic Bulge Forming with Closed Die", Advanced Technology of Plasticity, pp. 1543~1548.
- (11) C. Bruggemann, S. Shah, 1997, "Hydroforming Product and Process : Requirements and Implementations" TPA's 2nd Annual Automotive Tube Conference, pp. 85~103.
- (12) O. Ghouati, H. Lenoir, P. Paquier, J. C. Gelin, 1999, "Control techniques for the hydroforming of tubes and flanges", Numisheet'99, pp. 473~478.
- (13) J. S. Arora, 1989, Introduction to Optimum Design, McGraw-Hill, New York.
- (14) D. Quagliarella, 1998, Genetic Algorithms and Evolution Strategy in Engineering and Computer Science, John Wiley & Sons, England.
- (15) K. Krishnakumar, 1989, "Micro-genetic algorithms for stationary and non-stationary function optimization", SPIE Proc. 1196, pp.289~296.
- (16) S. Haykin, 1994, Neural networks, Macmillan, New York.