

〈論 文〉

## 신경망과 유한요소법을 이용한 단조품의 초기 소재 형상 결정

김동진\* · 고대철\* · 김병민\*\* · 최재찬\*\*

(1995년 2월 21일 접수)

### Determination of Initial Billet Size using The Artificial Neural Networks and The Finite Element Method for a Forged Product

D. J. Kim, D. C. Ko, B. M. Kim and J. C. Choi

#### Abstract

In the paper, we have proposed a new method to determine the initial billet for the forged products using a function approximation in the neural network. The architecture of neural network is a three-layer neural network and the back propagation algorithm is employed to train the network. By utilizing the ability of function approximation of a neural network, an optimal billet is determined by applying the nonlinear mathematical relationship between the aspect ratios in the initial billet and the final products. The amount of incomplete filling in the die is measured by the rigid-plastic finite element method. The neural network is trained with the initial billet aspect ratios and those of the unfilled volumes. After learning, the system is able to predict the filling regions which are exactly the same or slightly different to the results of finite element simulation. This new method is applied to find the optimal billet size for the plane strain rib-web product in cold forging. This would reduce the number of finite element simulation for determining the optimal billet size of forging product, further it is usefully adapted to physical modeling for the forging design.

**Key Words :** Metal Forming Process, Initial Billet, Artificial Neural Network, Function Approximation, Back Propagation Training Algorithm

#### 1. 서 론

주요한 금속 성형 공정 중의 하나인 단조

공정은 원소재로부터 최종 제품이 되기까지 초기의 간단한 기하학적 형상을 표면이나 내부 결함없이 보다 복잡한 제품으로 성형하는 것이다. 단조공정은 금속유동에 따라 자유형과 밀폐형 단조로 나눌 수 있다.

밀폐 단조공정에서 성형한계는 많은 공정

\*부산대학교 대학원

\*\*부산대학교 정밀정형 및 금형가공 연구센터

변수들에 의해 영향을 받는다. 이 중에서 주요 공정변수들은 소재의 초기형상, 예비성형된 소재의 형상과 금형의 기하학적 형상 등이다. 특히 소재의 예비성형체 형상을 대부분 금속유동의 영향을 받는다. 따라서 어떤 특정한 기하학적 형상은 금속의 유동 결합, 금형의 조기파손 등을 일으킨다. 결국 금속유동은 공정 중에 제어하기가 곤란하므로 초기형상으로 금속유동을 가장 적절하게 제어해야 한다.

초기소재의 결정에 있어서는 Altan 등<sup>(1)</sup>이 금속유동을 압출형과 업셋형으로 분류하고 금속유동면과 유동방향에 따라서 초기형상을 결정하였다. N. Alberti 등<sup>(2)</sup>은 밀폐단조에서 금형내를 충만시키고 금속유동결합 및 연성파괴를 일으키지 않는 최적의 예비성형체 형상을 결정하기 위해 성형 경로를 역추적하여 예비성형체 형상을 바꿔가면서 반복적으로 유한요소해석을 수행하였다. Lanka 등<sup>(3)</sup>은 평면변형 리브-웨브 제품의 공정수와 각 금형형상의 설계과정을 개발하기 위해 등각 사상(conformal mapping)기법을 이용해 예비성형체 형상을 유한요소해석으로 예측하였다.

그러나 위와 같은 방법들은 제품성형공정에 미치는 많은 공정변수들의 영향을 조사해야 하고, 실험이나 유한요소해석으로 검증하는데 비용과 시간이 너무 많이 듈다. 또 초기 형상의 결정에 있어서는 거의 전문가의 경험이나 시행착오에 의해서 결정하였다.

최근에는 이러한 단점을 보완하기 위하여 인공지능이나 신경망과 같은 새로운 기법을 이용한 방법들이 제안되고 있다. K. Osakada 등<sup>(4)</sup>은 신경망의 형상 분류 능력을 이용하여 유한요소해석으로 얻어진 데이터를 학습시켜, 다른 공정조건에 대한 제품결합 및 금형의 파손 여부를 예측하였고, A. Barcellona<sup>(5)</sup>는 2가지 공정조건에 대한 유한요소해석 결과를 신경망으로 학습시켜,

해석하지 않은 공정조건에 대하여 재료의 내부결함(central burst)발생 여부를 판단하였다. D. Y. Yang 등<sup>(6)</sup>은 퍼지 로직을 이용한 전방 특사법으로 금형 내의 재료 충만성을 만족하는 초기 소재의 형상을 제안하여 유한요소해석의 회수를 줄이고자 하였다.

본 연구에서는 신경망의 함수 근사(function approximation) 능력을 이용하여<sup>(7~10)</sup> 금속 유동 측면에서 금형 내의 재료 충만성을 좋게 하는 여러 가지 초기 소재 형상을 결정하는 방법을 제안하고자 한다. 유한요소해석 결과인 최종 제품형상의 미충만 체적을 계산하고, 이에 해당하는 소재 형상비(소재 높이/폭)를 신경망의 학습 데이터로 사용하였다. 이 데이터를 신경망으로 학습시켜 유한요소해석을 하지 않은 소재 형상비에 대하여 미충만 부분의 체적을 예상하였다. 예상된 체적은 유한요소해석으로 검증되며, 그 오차가 한계치보다 크면 이 데이터로 신경망을 재학습시켜 금형 내를 완전히 충만시키는 초기 소재 형상을 찾아내었고, 한계치보다 작으면 이 때의 결과가 금형 내를 완전히 충만시키는 초기 소재 형상이다. 이러한 방법을 리브-웨브형 제품의 평면변형 단조에 적용하였다.

## 2. 다층 퍼셉트론 신경망

Rumelhart<sup>(11)</sup>가 제안한 다층 퍼셉트론(multilayer-perceptron) 신경망은 비선형 문제, 형상 분류, 인식, 제어 등의 분야를 해결하는 데 우수한 특성을 가지고 있고, 최근에는 함수근사에까지 그 응용범위가 확대되었다. Kolmogorov<sup>(7)</sup>는  $[0, 1]^m$ 에서  $R^n$ 으로 사상하는 어떠한 다변수 연속함수도 일변수 연속함수의 선형 조합에 의해 근사화될 수 있다는 것을 증명하였고, Irie 와 Miyake,<sup>(8)</sup> Funahashi,<sup>(9)</sup> Hornik<sup>(10)</sup> 등도 다층 퍼셉트론 신경망의 함수 근사화에 관

한 이론적 연구를 하였다.

다층 퍼셉트론 신경망은 크게 입력층, 은닉층과 출력층으로 구성되어 있으며, (Fig. 1) 역전파 학습 알고리즘에 의해 학습된다. 역전파 학습 알고리즘은 먼저 입력값으로부터 출력값을 계산하는 전향 단계(feed-forward)와 출력값과 실제 원하는 값(교사데이터)의 오차를 계산하여 가중치를 계산하는 후향 단계(feed-backward)로 이루어져 있다.<sup>(12)</sup>

전향 단계에서는 입력층에서 입력값을 받아 은닉층을 통해 출력값을 계산하는 과정이다. 은닉층의 출력은 입력값을 은닉층 뉴런에 연결된 입력층 뉴런들의 가중치에 곱하여 모두 합한 다음 활성화 함수를 거쳐 계산된다. 여기서 사용된 활성화 함수는 시그모이드 함수(sigmoid function)이다. 이 은닉층의 출력  $o_{pj}$ 는 다음과 같이 계산된다.

$$net_{pj} = \sum_i w_{ji} o_{pj} + \theta_j \quad (1)$$

$$o_{pj} = f_j(net_{pj}) \quad (2)$$

여기서,  $f_j(net_{pj})$ 는 활성화 함수로 다음과 같이 정의된다.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

여기서,  $o_{pj}$ 는 은닉층에서 출력되는 값이고,  $w_{ji}$ 는 입력층과 은닉층 사이의 연결강도,  $\theta_j$ 는 은닉층의 임계치를 나타낸다. 은

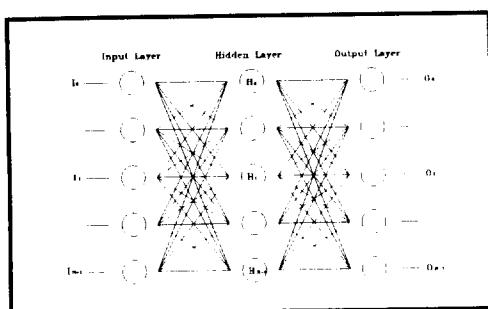


Fig. 1 The architecture of three layer neural network

닉층에서 출력층의 출력값도 위와 같은 방법으로 계산된다.

후향 단계는 전향 단계에서 계산된 실제 출력과 원하는 출력과의 오차를 계산하여 연결 가중치를 조절한다. 이때 전체 오차 함수  $E$ 는 다음과 같이 정의된다.

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_k (T_{pk} - O_{pk})^2 \quad (4)$$

여기서,  $E_p$ 는  $p$ 번째 입력치의 오차이고,  $T_{pk}$ 는  $p$ 번째 입력치에 대한  $k$ 번째 출력 뉴런의 원하는 출력치이고  $O_{pk}$ 는 실제 출력이다. 이 오차에 대한 최소화 방법에 의하여 가중치의 증분량을 계산하면 다음과 같다.

$$\Delta_p w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} \quad (5)$$

$$= \eta \delta_{pk} O_{pk} \quad (6)$$

여기서,  $\eta$ 는 학습계수(learning rate)이며  $0 < \eta < 1$ 의 범위를 가진다.  $\delta_{pk}$ 의 값을 계산하면,

$$\begin{aligned} \delta_{pk} &= (T_{pk} - O_{pk}) f'(net_{pk}) \\ &= (T_{pk} - O_{pk}) O_{pk} (1 - O_{pk}) \end{aligned} \quad (7)$$

그리고 은닉층에 대한 결과는 위와 같은 방법에 의하여,

$$\Delta_p w_{ji} = \eta \delta_{pj} O_{pi} \quad (8)$$

가 되고  $\delta_{pj}$ 의 값은,

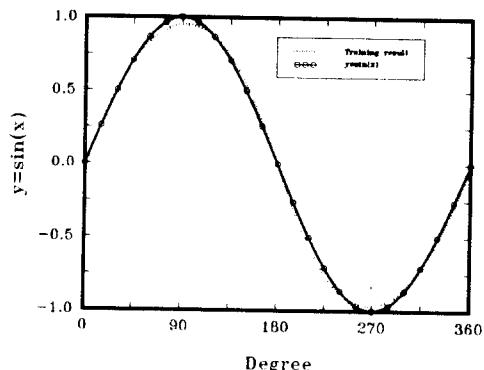
$$\begin{aligned} \delta_{pj} &= f'(net_{pj}) \sum_k \delta_{pk} w_{kj} \\ &= O_{pj} (1 - O_{pj}) \sum_k \delta_{pk} w_{kj} \end{aligned} \quad (9)$$

가 된다. 또한 수렴 속도를 향상시키기 위하여 과거의 연결 강도 변화를 반영하는 모멘텀 항을 도입한다.

$$\Delta_p w_{kj}(n) = \eta \delta_{pk} O_{pj} + \alpha \delta_p w_{kj}(n-1) \quad (10)$$

여기서,  $\alpha$ 는 모멘텀 상수로  $0 \leq \alpha \leq 1$ 의 범위를 가지며  $n$ 은 반복회수이다.

위의 식들로부터 함수 근사 프로그램을 개발하였다. Fig. 2는  $y=\sin(x)$  함수의 근사결과를 보여준다  $0^\circ$ 에서  $360^\circ$ 까지 등간격

Fig. 2 Function  $\sin(x)$  and its training results

으로 25개의 데이터를 선택하여 학습을 시켰다. 입력값은 각도이고 출력값은 그때의  $\sin$ 값이다. 학습시간은 IBM PC 486DX-66에서 5분 정도 걸렸고, 이 때의 유효값 (root mean square) 오차는 0.001이었다. 개발된 프로그램을 이용하여 금형 내의 재료 충만성을 좋게하는 여러 가지 초기 소재 형상을 결정하는 방법에 적용하였다.

### 3. 유한 요소 해석 및 결과 고찰

해석에 사용된 재료는 상용 알루미늄으로 이 재료의 응력-변형률 관계식은 다음과 같다.<sup>(13)</sup>

$$\bar{\sigma} = 346.49 \bar{\epsilon}^{0.173} [\text{N/mm}^2] \quad (11)$$

우선 소재 형상비(소재 높이/폭) 0.3, 0.35, 0.4, 0.45인 4가지 경우에 대하여 유한요소해석을 하였다. 실제 신경망 함수 근사에는 3점의 데이터만 있으면 가능하나, 신경망의 학습과정을 단계별로 나타내기 위하여 4가지 소재 형상비에 대하여 유한요소해석을 하였다. 시뮬레이션 도중 격자가 심하게 변형되어 4~5번의 격자 재구성을 하였다. 일반적으로 격자 재구성과 유한요소 해석 도중 체적의 손실이 발생한다. 본 연구에서는 금형내를 완전히 충만시키는 소재 형상비를 찾는 것이 목적이므로 격자 재구성과 유한요소 해석 자체의 체적 손실을 최

소화하여 유한요소 해석을 수행하였다.

소재 형상비가 0.3인 경우, 소재 체적에 대한 금형 내의 미충만 부분의 체적비( $\Delta V/V$ )는 0.183%이었고, 형상비 0.35인 경우에는 금형 내를 완전히 충만시켰다. 소재 형상비가 0.4일 때는 0.019%이었고, 소재 형상비가 0.45일 때는 0.092%이었다. (Fig. 3) 신경망의 학습특성을 보여 주기 위하여 3가지 방법으로 신경망을 학습시켰다. 함수 근사에 사용된 신경망은 1개의 입력층과 10개의 은닉층, 1개의 출력층을 가지는 3층의 다층 퍼셉트론 신경망을 사용하였다. 소재의 형상비를 입력데이터로 사용하였고, 그 때의 금형 내 미충만 부분의 체적을 교사데이터로 하여 신경망을 학습시켰다.

먼저 소재 형상비가 0.3, 0.4, 0.45인 형상비와 금형 내 미충만 부분의 값을 신경망으로 학습시켰다. (Fig. 4 점선) 학습 결과, 소재 형상비 0.3725인 곳에서 금형 내를 다채우지는 않았지만, 미충만 부분의 양이 최소로 나왔다. 그래서 형상비가 0.3725인 소재에 대하여 한 번 더 유한요소해석을 수행하였다. 해석결과 형상비가 0.3725인 소재는 금형 내를 완전히 채웠다. 위의 3가지 데이터와 소재 형상비 0.3725인 4가지 데이터로 신경망을 재학습시켰다. (Fig. 4 실선) 신경망 학습 결과 소재 형상비가 0.3575~0.3725인데서 금형 내를 완전히 채움을 알 수 있었다. 이 결과를 확인하기 위하여 금형 내 충만을 만족하는 0.3575, 0.365인 2가지 형상비에 대하여 유한요소해석한 결과, 금형 내를 완전히 채웠다. 위와 같은 결과로 알 수 있듯이 3가지 데이터로는 금형 내 충만을 만족하는 소재 형상비를 찾을 수 없으나, 금형 내 충만되는 양이 최소로 되는 소재 형상비는 찾을 수 있다. 이 소재 형상비에 대해 유한요소해석을 한 번 더 수행하여, 신경망을 재학습시키므로서 금형 내 충만을 만족시키는 소재 형상비의 범위를 찾을 수 있었다.

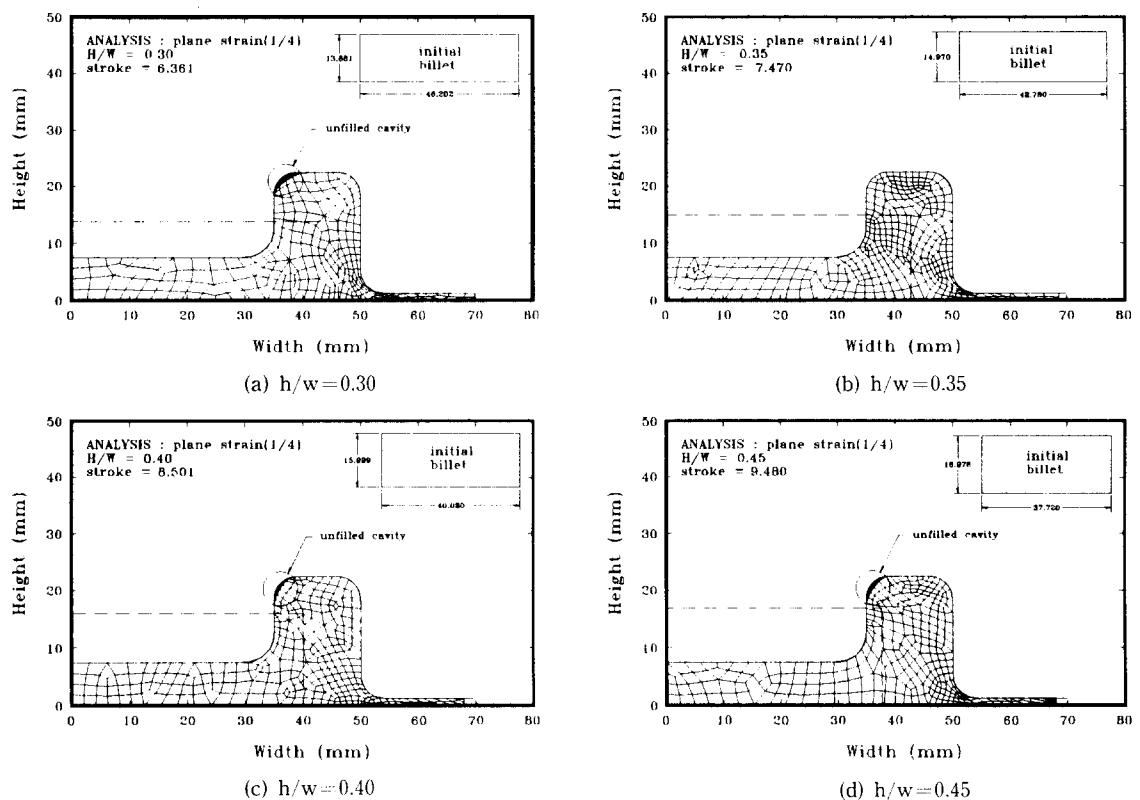


Fig. 3 The simulation of forging process using various aspect ratios  
(the hatched region refers to the unfilled cavity)

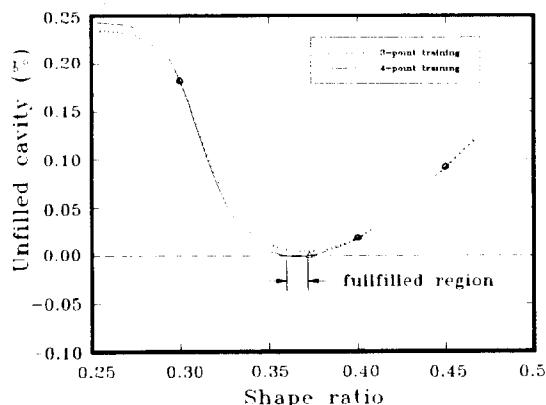


Fig. 4 The results of the training by method 1 through the three layer neural network

다음으로 소재 형상비가 0.3, 0.35, 0.45인 형상비와 금형 내 미충만 부분의 값을 신경망으로 학습시켜 그 결과를 Fig. 5에

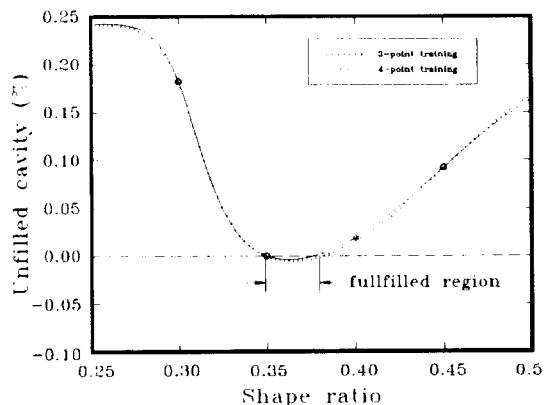


Fig. 5 The results of the training by method 2 through the three layer neural network

점선으로 나타내었다. 위의 신경망 학습 결과와는 달리 소재 형상비 0.35~0.38인 곳에서 금형 내를 다 채우는 것으로 나타났

다. 앞의 결과보다 금형 내를 채우는 소재 형상비의 범위가 넓어졌다. 학습 결과를 확인하기 위하여 소재 형상비 0.38인 경우에 대해서 유한요소해석을 수행하였다. 이 결과 형상비가 0.38인 소재는 금형 내를 완전히 채웠고, 형상비가 0.4인 소재에 대한 신경망 학습 결과는 0.017%로서 실재 유한요소해석 결과와 거의 일치했다. Table 1에 위의 8가지 소재 형상비에 대한 유한요소해석 결과를 나타내었다.

마지막으로 소재 형상비 0.3, 0.35, 0.4, 0.45인 4가지 경우에 대하여 신경망 학습을 시켰다. Fig. 5에 실선으로 나와 있듯이, 소재 형상비 0.35~0.38인 범위내에서 금형 내를 완전히 충만시켰다. 위의 결과들과 비교해 보면 첫번째 방법으로 학습시킨 경우에는 3점으로 학습시킨 결과와 상당한 차이가 있고, 4점으로 학습시킨 결과와 약간의 차이가 있다. 두 번째 방법으로 학습시킨 경우에는 3점으로 학습시킨 결과와 거의 일치하였다. 위의 결과들로부터 신경망을 학

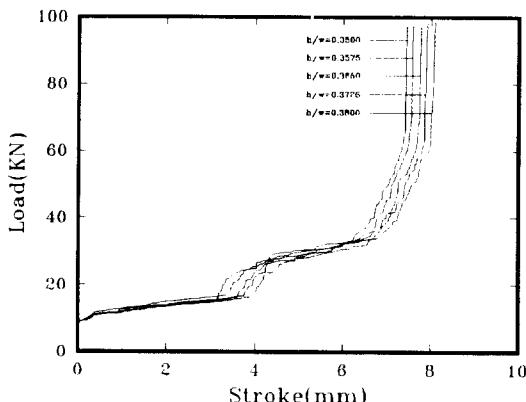
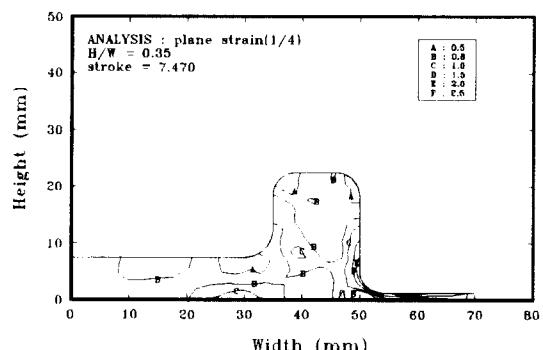
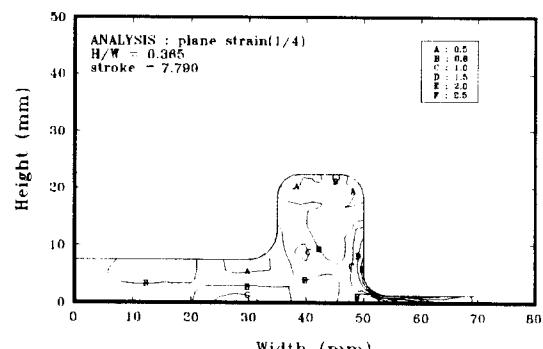


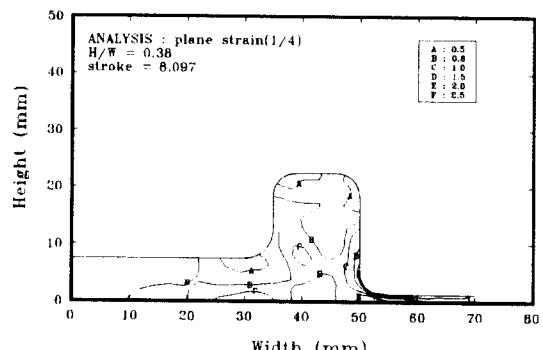
Fig. 6 The comparison of forming load with various aspect ratios



(a)  $h/w = 0.35$



(b)  $h/w = 0.365$



(c)  $h/w = 0.38$

Fig. 7 The distribution of effective strain of finished forming

Table 1 The results of finite element simulation for various aspect ratios

Shape ratio	0.3000	0.3500	0.3575	0.3650	0.3725	0.3800	0.4000	0.4500
Billet height(mm)	13.8610	14.9700	15.1320	15.2890	15.4450	15.6000	15.9990	16.9780
Billet width(mm)	46.2020	42.7800	42.3220	41.8870	41.4640	41.0520	40.0300	37.7200
Cavity(%)	0.1830	0.0000	0.0000	0.0000	0.0000	0.0000	0.0190	0.0920

**Table 2** Final load, forming energy, and average effective strain( $\bar{\varepsilon}_{avg}$ ), for full-filling aspect ratios

Shape ratio	0.3500	0.3575	0.3650	0.3725	0.3800
Final load(KN/unit length)	97.745	97.886	97.526	98.516	98.801
Forming E.(J/unit length)	18.447	18.967	19.249	19.606	19.676
( $\bar{\varepsilon}_{avg}$ )	0.7306	0.7367	0.7460	0.7485	0.7557

습시킬 때 학습 데이터가 많고, 학습 데이터 간격이 일정하며, 교사 데이터의 변화가 급격한 곳을 중점적으로 학습시키면 좀 더 정확한 함수 근사가 가능함을 알 수 있었다.

금형 내 충만을 만족하는 5가지 소재에 대하여 최종하중, 성형에너지, 평균유효변형률( $\bar{\varepsilon}_{avg}$ )을 비교해 보았다. Fig. 6에 변위에 따른 하중선도를 나타내었는데, 최종 성형 하중은 거의 비슷하였다. 성형에너지는 형상비가 0.350인 소재가 18.447(J/unit length)로 다른 4가지 소재보다 낮았다. Fig. 7에 형상비가 0.350, 0.365, 0.380인 소재의 유효변형률 분포를 나타내었다. 전체적인 분포는 비슷하나 평균 유효변형률은 형상비 0.350인 소재가 0.7306으로 제일 작았다. 5가지 소재의 최종 하중, 성형에너지, 평균 유효변형률을 Table 2에 정리하였다. 성형에너지와 평균 유효변형률은 소재의 형상비가 증가함에 따라 이 값들이 증가함을 알 수 있었다. 제품 형상이 비교적 단순하여 최종하중, 성형에너지, 평균유효변형률 값들의 차이가 크지 않았지만, 소재 형상비가 0.35인 소재의 최종하중, 성형에너지, 평균유효변형률 값들이 다른 소재에 비하여 낮았다. 이러한 결과들로부터 유한요소해석을 한 소재중에서 형상비가 0.35인 소재가 최종하중, 성형에너지, 평균유효변형률면에서 가장 적절한 소재임을 알 수 있었다.

#### 4. 결 론

본 연구에서는 유한요소법으로 얻어진 결

과로부터 신경망의 함수 근사 능력을 이용하여 금형 내 충만성을 만족하는 초기 소재를 결정하는 새로운 방법을 제안하였고, 이를 평면변형 형태의 리브-웨브형 제품에 적용하였다. 유한요소해석 결과인 최종 제품 형상의 미충만 체적을 계산하고, 이에 해당하는 소재 형상비(높이/폭)를 신경망의 학습 데이터로 사용하여 다음과 같은 결론을 얻었다.

(1) 임의 3가지 형상에 대한 유한요소해석 결과로부터, 신경망 학습을 이용하면 금형 내 충만을 만족하는 형상비를 찾을 수 있으므로, 유한요소해석 수를 줄일 수 있었다.

(2) 유한요소해석을 하지 않은 형상비에 대한 금형 내 미충만 부분의 체적을 예측할 수 있었다.

(3) 임의 제품의 유한요소해석 결과를 이용하여 금형 내 충만 여부, 성형하중, 결합여부 등 여러 가지 조건에 대한 신경망 학습으로 미해석부분의 값을 예측할 수 있으므로, 다단계 금속성형공정에 요구되는 예비성형체 설계에 유용하게 적용될 수 있다.

#### 후 기

본 연구는 정밀정형 및 금형가공 연구센터의 지원하에 연구되었으며 이에 감사드립니다.

#### 참고문헌

- Altan, T., Oh, S. I. and Gegel, H. L., Metal Forming-Fundamentals and Ap-

- plicaiton, American Society of Metals.
- (2) Alberti, N., Cannizzaro, L., Micari, F. and Riccobono, R., 1990, "Formability inClosed-Die Processes-Computer Aided Design of the Preformed Shape," Ann. ICTP, Vol. 1, pp. 185~189.
- (3) Lanka, S. S., Srinivasan, R. and Gandhi, Rov., 1991, "A Design Approach of Intermediate Die Shapes in Plane Strain Forgings," J. Mat. Shaping Tech. Vol. 9, pp. 193~206.
- (4) Kozo Osakada and Guobin Yang, 1991, "Application of Neural Networks to an Expert System for Cold Forging," Int. J. Mach. Tools Manufact., Vol. 41, No. 4, pp. 577~587.
- (5) Barcellona, A., 1993, "Neural Network Technique for Metal Forming Design," 30th MATDOR conference, pp. 361~365.
- (6) 정낙면, 이낙규, 양동열, 1992, "축대칭 냉간단조의 유한요소해석에서 퍼지로직을 이용한 전방투사법," 대한기계학회 논문집, Vol. 16, No. 8, pp. 1468~1483.
- (7) Nielsen, R. H., 1987, "Kolmogorov's Mapping Neural Network Existence Theorem," IJCNN'87, Vol. 3, pp. 11~13.
- (8) Irie, B. and Miyake, S., 1988, "Capabilities of Three-Layered Perceptrons," IJCNN'88, Vol. 1, pp. 641~648.
- (9) Funahashi, K. C., 1989, "On the Approximate Realization of Continuous Mappings by Neural Networks," Neural Networks, Vol. 2, pp. 183~192.
- (10) Hornik, K., 1989, "Multilayer Feedforward Networks are Universal Approximators," Neural Networks, Vol. 2, pp. 359~366.
- (11) Rumelhart, D. E., Hinton, G. E. and Williams, R. J., 1986, "Learning Internal Representations by Error Propagation," Parallel Distributed Processing Cambridge MA : MIT Press, pp. 318~362.
- (12) Lippmann, R. P., 1987, "An Introduction to Computing with Neural Nets," IEEE ASSP Magazine, April, Vol. 2, pp. 4~22.
- (13) 고대철, 이진희, 김병민, 최재찬, 1994, "금속 성형 공정에서 연성파괴 예측," 한국소성가공학회지, Vol. 3, No. 2, pp. 167~177.