

신경망과 유한요소법을 이용한 단조품의 초기 소재 결정

김동진*, 고대철*, 김병민**, 강범수**, 최재찬**

* 부산대학교 대학원, ** 부산대학교 정밀정형 및 금형가공 연구 센터

Determination of Initial Billet using The Artificial Neural Networks and The Finite Element Method for The Forged Products

D. J. Kim*, D. C. Ko*, B. M. Kim**, B. S. Kang**, J. C. Choi**

* Graduate School, Pusan National University

** ERC for Net Shape and Die Manufacturing, Pusan National University

Abstract

In this paper, we have proposed a new method to determine the initial billet for the forged products using a function approximation in neural networks. 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 neural network, an optimal billet is determined by applying nonlinear mathematical relationship between shape ratio in the initial billet and the final products. A volume of incomplete filling in the die is measured by the rigid-plastic finite element method. The neural network is trained with the initial billet shape ratio and that of the un-filled volume. After learning, the system is able to predict the filling region which are exactly the same or slightly different to results of finite element method. It is found that the prediction of the filling shape ratio region can be made successfully and the finite element method results are represented better by the neural network.

1. 서론

최근 기계 부품의 경량화, 고강도화, 그리고 다품종 소량 생산에 대응하기 위하여 금형의 설계 및 가공에 대한 연구가 필수적이지만 주로 실험이나 전문가의 경험에 의해 이루어 졌다. 이러한 방법들은 새로운 재료나 제품을 생산하는데 많은 비용과 시간이 소모되었으나, 최근에는 대형 컴퓨터의 보급 및 수치 해석 프로그램의 개발로 이러한 작업을 컴퓨터를 통하여 금형의 형상을 임의로 바꿔 가면서 실제 제품 공정을 시뮬레이션할 수 있게 되었다.

소성가공의 큰 장점중의 하나는 재료의 손실없이 좋은 기계적 성질을 얻을 수 있다는 것이다. 이러한 조건을 만족시키기 위해서는 초기 소재 및 예비 성형체 형상, 금형 설계, 가공 공정수 등과 랩속도, 마찰 상수 등의 많은 공정변수를 고려해야 한다. 그러나 위와 같은 공정변수들을 고려해서 최적의 공정변수를 찾기란 매우 어렵다. 이러한 문제점들을 해결하기 위하여 K. Osakada[1]등은 유한요소 시뮬레이션과 전문가 시스템을 연계하여 유한요소해석으로 얻은 결과들을 전문가시스템의 지식베이스로 사용하였고, N. Alberti[2]등은 지식베이스 시스템에 의해 실행된 몇 가지 가능한 성형 절차를 예비 선택하여, 그 공정을 유한요소해석을 통하여 최적 성형 절차를 결정하는 통합된 방법을 제안하였다. 그러나 위와 같은 방법들은 많은 유한요소해석을 필요로 하기 때문에 K.Osakada[3] 등은 신경망의 형상 분류 능력을 이용하여 유한요소해석으로 얻어진 데이터를 학습시켜, 다른 공정조건에 대한 제품 결함 및

금형의 파손 여부를 예측하였고, A. Barcellona[4] 는 2 가지 공정조건에 대한 유한요소해석 결과를 신경망으로 학습시켜, 해석하지 않은 공정조건에 대하여 재료 내부결함(Central Burst) 발생 여부를 판단하였다. D. Y. Yang[5] 등은 퍼지 로직을 이용한 전방 투사법을 이용하여 금형내의 재료 충만성을 만족 하는 초기 소재의 형상을 제안하여 유한요소해석의 횟수를 줄이고자 하였다.

실제 공정에서는 금형내 충만을 만족하는 여러 형상이 존재할 수 있으므로, 본 연구에서는 신경망의 함수 보간(Function Approximation) 능력을 이용하여[6~9] 금속 유동 측면에서 금형내의 재료 충만성을 좋게 하는 여러 가지 초기 소재 형상을 결정하는 방법을 제안하고자 한다. 현재까지 초기 형상을 결정하는 많은 연구가 진행되어져 왔으나 주로 설계자의 경험이나 실험에 의해 결정되었고 다양한 문제에 적용가능한 체계적인 방법이 개발되어 있지 않다. 본 연구에서는 유한 요소법으로 얻어진 결과로부터 신경망의 함수 보간 능력을 이용해서 초기 소재를 결정하는 새로운 방법을 제안하고자 한다. 유한요소해석 결과인 최종 제품형상의 미충만 체적을 계산하고, 이에 해당하는 소재 형상비(소재 높이/폭)를 신경망의 학습 데이터로 사용하였다. 이 데이터로부터 신경망을 학습시켜 유한요소해석을 하지 않은, 소재 형상비에 대하여 미충만 부분의 양을 예상하였다. 예상된 양은 유한요소해석으로 확인하여, 그 오차가 한계치보다 크면 이 데이터로 신경망을 재학습시켜 금형내를 다 채우는 초기 소재 형상을 찾아 내었고, 한계치보다 작으면 이 때의 결과가 금형내를 다 채우는 초기 소재 형상이다. 이러한 방법을 리브-웹브형 제품의 평면 변형 단조에 적용하였다.

2. 이 론

2.1 변형 해석

본 연구에서는 강소성 유한요소법을 이용하여 변형해석을 수행하였다. 이의 수식화 과정은 이미 많은 문헌에[10,11] 잘 알려져 있으므로 여기서는 간략하게 언급하겠다.

강소성 재료에 대한 범함수(Functional), Π 는 다음과 같다.

$$\Pi = \int_V \bar{\sigma} \bar{\epsilon} dV - \int_{S_r} \bar{t}_i v_i dS \quad (1)$$

여기서, $\bar{\sigma} = \sqrt{3/2} \sigma_{ij} \sigma_{ij}$ 로 정의되는 유효응력

$\bar{\epsilon} = \sqrt{2/3} \epsilon_{ij} \epsilon_{ij}$ 로 정의되는 유효변형률속도

σ_{ij} = 편차응력

\bar{t}_i = 표면력

v_i = 절점속도

ϵ_{ij} = 변형률속도이다.

비압축성 조건을 고려하기 위하여 벌칙함수(Penalty Function), K 를 도입하면, 위의 식(1)에 대한 일차 변분 범함수는 다음과 같이 표현할 수 있다.

$$\delta \Pi = \int_V \bar{\sigma} \delta \bar{\epsilon} dV + K \int_V \dot{\epsilon}_v \delta \dot{\epsilon}_v dV - \int_{S_r} \bar{t}_i \delta v_i dS = 0 \quad (2)$$

여기서, $\dot{\epsilon}_v$ 는 체적변형률속도이다.

위의 식(2)는 일반적인 유한요소 분할화과정을 거치면 절점속도가 미지수인 비선형 방정

식이 되므로 뉴우톤-랩슨법(Newton-Raphson Method)을 이용하여 해를 구하며, 초기 속도장은 직접 반복법(Direct Iteration Method)을 이용하여 구한다.

2.2 신경망

신경망은 강도치(Weight)로 연결된 비선형이고 독특한 아날로그(Analog) 계산 요소들로 구성된 고도의 병렬 시스템이다[12]. 신경망은 뉴우런(Neuron)과 뉴우런간의 연결 강도를 조절하여 정보를 저장하는 분산 저장의 형태로 이루어져 있다. 분산 저장은 인간의 기억 방식과 유사한 것으로 데이터의 부분적 손실이나 왜곡 등에 관계없이 데이터를 저장하고 찾을 수 있는 장점이 있다.

Rumelhart[13]가 제안한 다층 퍼셉트론(Multilayer-Perceptron) 신경망은 비선형 문제, 형상 분류, 인식, 제어 등의 분야를 해결하는 데 우수한 특성을 가지고 있고, 최근에는 함수 보간에까지 그 응용범위가 확대되었다. Kolmogorov[6]는 $[0, 1]^m$ 에서 R^m 으로 사상하는 어떠한 다변수 연속함수도 일변수 연속함수의 선형 조합에 의해 근사화될 수 있다는 것을 증명하였고, Irie 와 Miyake[7], Funahashi[8], Hornik[9] 등도 다층 퍼셉트론 신경망의 함수 근사화에 관한 이론적 연구를 하였다.

다층 퍼셉트론 신경망은 크게 입력층, 은닉층과 출력층으로 구성되어 있으며(그림 1), 다층 퍼셉트론 신경망의 학습 알고리즘인 역전파 학습 규칙은 일반화된 델타 법칙(Generalized Delta Rule)에 따라 가중치에 대한 오차함수의 최급하강법(Gradient Descent Method)을 사용하여 반복적 계산으로 오차를 최소화하는 것이다. 역전파 학습 알고리즘은 두가지 단계로 분리할 수 있다. 첫번째는 입력값으로 부터 출력값을 계산하는 전향 단계(Feed-Forward)이고 두번째는 위에서의 계산 출력값과 실제 원하는 출력값(교사 데이터)의 오차를 계산하여 강도치를 계산하는 후향 단계(Feed-Backward)이다[12].

전향 단계에서는 입력층에서 입력값을 받아 은닉층을 통해 출력값을 계산하는 과정이다. 은닉층의 출력은 입력값을 은닉층 뉴런에 연결된 입력층 뉴런들의 강도치에 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.

$$\text{net}_{pj} = \sum_i w_{ji} o_{pi} + \theta_j \quad (3)$$

$$o_{pj} = f_j(\text{net}_{pj}) \quad (4)$$

여기서 $f_j(\text{net}_{pj})$ 는 활성화 함수로 다음과 같이 정의된다.

$$f(x) = \frac{1}{1 + e^{-NET}} \quad (5)$$

여기서 o_{pj} 는 은닉층에서 출력되는 값이고, w_{ji} 는 입력층과 은닉층 사이의 연결강도, θ_j 는 은닉층의 임계치를 나타낸다. 은닉층에서 출력층의 출력값도 위와 같은 방법으로 계산된다.

후향 단계는 전향 단계에서 계산된 실제 출력과 원하는 출력과의 차이를 이용하여 연결 강도치를 계산한다. 이때 전체 오차 함수 E는 다음과 같이 정의된다.

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_k (T_{pk} - O_{pk})^2 \quad (6)$$

여기서 E_p 는 p번째 입력치의 오차이고, T_{pk} 는 p번째 입력치에 대한 k번째 출력 뉴우

린의 원하는 출력치이고 O_{pk} 는 실제 출력이다. 이 오차에 대한 최급하강법에 의하여 가중치의 증분량을 계산하면 다음과 같다.

$$\Delta_p w_k = -\eta \frac{\partial E}{\partial w_k} \quad (7)$$

$$= \eta \delta_{pk} O_{pj} \quad (8)$$

여기서 η 는 학습계수(learning rate)이며 $0 < \eta < 1$ 의 범위를 가진다. 일반적으로 큰 η 의 경우 빠른 수렴 속도를 얻을 수 있으나 진동(oscillation)할 수도 있고, 지나치게 작은 η 를 선택할 경우 매우 느린 수렴 속도를 가진다. 그리고 δ_{pk} 의 값을 계산하면

$$\begin{aligned} \delta_{pk} &= (T_{pk} - O_{pk}) f'(\text{net}_{pk}) \\ &= (T_{pk} - O_{pk}) O_{pk} (1 - O_{pk}) \end{aligned} \quad (9)$$

그리고 은닉층에 대한 결과는 위와 같은 방법에 의하여

$$\Delta_p w_{ji} = \eta \delta_{pj} O_{pi} \quad (10)$$

가 되고 δ_{pj} 의 값은

$$\begin{aligned} \delta_{pj} &= f'(\text{net}_{pj}) \sum_k \delta_{pk} w_{kj} \\ &= O_{pj} (1 - O_{pj}) \sum_k \delta_{pk} w_{kj} \end{aligned} \quad (11)$$

가 된다. 그리고 수렴 속도를 향상시키기 위하여 과거의 연결 강도 변화를 반영하는 모멘텀항을 도입한다.

$$\Delta_p w_{kj}(n) = \eta \delta_{pk} O_{pj} + \alpha \delta_p w_{kj}(n-1) \quad (12)$$

여기서 α 는 모멘텀 상수이고 n 은 반복횟수이다.

3. 유한 요소 해석 및 결과 고찰

해석에 사용된 재료는 상용 알루미늄으로 이 재료의 응력-변형을 관계식은 다음과 같다.

$$\bar{\sigma} = 346.49 \bar{\epsilon}^{0.173} \quad [\text{N/mm}^2] \quad (13)$$

우선 소재 형상비(소재 높이/폭) 0.3, 0.35, 0.4, 0.45인 4가지 경우에 대하여 유한요소해석을 하였다. 실제 신경망 함수 보간에는 3점의 데이터만 있으면 가능하나, 신경망의 학습과정을 단계별로 나타내기 위하여 4가지 소재 형상비에 대하여 유한요소해석을 하였다. 시뮬레이션 도중 격자가 심하게 변형되어 3~4번의 격자 재구성을 하였다 소재 형상비가 0.3인 경우 소재 체적에 대한 금형내의 미충만 부분의 양 ($\Delta V / V$)은 0.183%이었고, 형상비 0.35인 경우에는 금형내를 완전히 충만시켰다. 소재 형상비가 0.4일때는 0.019%이었고, 소재 형상비가 0.45일때는 0.092%이었다(그림 2). 신경망의 학습특성을 보여 주기 위하여 3가지 방법으로 신경망을 학습시켰다. 함수 보간에 사용된 신경망은 1개의 입력층과 10개의 은닉층, 1개의 출력층을 가지는 3층의 다층 퍼셉트론 신경망을 사용하였다. 소재의 형상비를 입력데이터로 사용하였고, 그때의 금형내 미충만 부분의 양을 교사 데이터로 하여 신경망을 학습시켰다.

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

다음으로 소재 형상비가 0.3, 0.35, 0.45인 형상비와 금형내 미충만 부분의 값을 신경망으로 학습시켜 그 결과를 그림 4에 점선으로 나타내었다. 위의 신경망 학습 결과와는 달리 소재 형상비 0.35~0.38인 곳에서 금형내를 다 채우는 것으로 나타났다. 앞의 결과보다 금형내를 채우는 소재 형상비의 범위가 넓어졌다. 학습 결과를 확인하기 위하여 소재 형상비 0.38인 경우에 대해서 유한요소해석을 수행하였다. 이결과 형상비가 0.38인 소재는 금형내를 완전히 채웠고, 형상비가 0.4인 소재에 대한 신경망 학습 결과는 0.017%로서 실제 유한요소해석 결과와 거의 일치했다. 표1에 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. 그림 4에 실선으로 나와 있듯이 소재 형상비 0.35~0.38인 범위내에서 금형내를 완전히 충만시켰다. 위의 결과들과 비교해 보면 첫번째 방법으로 학습시킨 경우에는 3점으로 학습시킨 결과와 상당한 차이가 있고, 4점으로 학습시킨 결과와 약간의 차이가 있다. 두번째 방법으로 학습시킨 경우에는 3점으로 학습시킨 결과와 거의 일치하였다. 위의 결과들로 신경망을 학습시킬때 학습 데이터가 많고, 학습 데이터 간격이 일정하며, 교사 데이터의 변화가 급격한 곳을 중점적으로 학습시키면 좀 더 정확한 함수 보간이 가능함을 알 수 있었다.

금형내 충만을 만족하는 5가지 소재에 대하여 최종 하중, 성형에너지, 평균 유효변형율 ($\bar{\epsilon}_{avg}$)을 비교해 보았다. 그림 5에 변위에 따른 하중선도를 나타내었는데, 최종 성형 하중은 거의 비슷하였다. 성형에너지는 형상비가 0.350인 소재가 18.447 (J/unitlength)로 다른 4가지 소재보다 낮았다. 그림 6에 형상비가 0.350, 0.365, 0.380인 소재의 유효변형율 분포를 나타내었다. 전체적인 분포는 비슷하나 평균 유효변형율은 형상비 0.350인 소재가 0.7306으로 제일 작았다. 5가지 소재의 최종 하중, 성형에너지, 평균 유효변형율을 표2에 정리하였다. 성형에너지와 평균 유효변형율은 소재의 형상비가 증가함에 따라 이 값들이 증가함을 알 수 있었다. 최종 하중, 성형에너지, 평균 유효변형율 값들도 신경망 학습을 통하여 유한요소해석을 하지 않은 소재 형상비에 대해서 예측할 수 있으나 본연구에서는 하지 않았다. 제품형상이 비교적 단순하여 최종 하중, 성형에너지, 평균 유효변형율 값들의 차이가 크지 않았지만, 소재 형상비가 0.35인 소재의 최종 하중, 성형 에너지, 평균 유효변형율 값들이 다른 소재에 비하여 낮았다. 이러한 결과들로부터 유한요소해석을 한 소재중에서 형상비가 0.35인 소재가 최종 하중, 성형 에너지, 평균 유효변형율면에서 가장 적절한 소재임을 알 수 있었다.

4. 결 론

본 연구에서는 유한요소법으로 얻어진 결과로부터 신경망의 함수 보간 능력을 이용해서 금형내 충만성을 만족하는 초기 소재를 결정하는 새로운 방법을 제안하였다. 이를 평면-변형 형태의 리브-웹형 제품에 적용하였다. 유한요소해석 결과인 최종 제품형상의 미충만 체적을 계산하고, 이에 해당하는 소재 형상비(높이/폭)를 신경망의 학습 데이터로 사용하여 다음과 같은 결론을 얻었다.

- (1) 임의 3가지 형상에 대한 유한요소해석 결과를로부터, 신경망 학습을 이용하여 금형내 충만을 만족하는 형상비를 찾을 수 있기 때문에, 유한요소해석 수를 줄일 수 있었다.
- (2) 유한요소해석을 하지 않은 형상비에 대한 금형내 미충만 부분의 양을 예측할 수 있었다.
- (3) 임의 제품의 유한요소해석 결과를 이용하여 금형내 충만 여부, 성형 하중, 결합 여부 등 여러가지 조건에 대한 신경망 학습으로 미해석부분의 값을 예측할 수 있어, 단단 계 금속성형공정에 요구되는 예비성형체 설계에 유용하게 적용될 수 있다.

5. 참 고 문 헌

- [1] K.Osakada, G.B.Yang, T.Nakamura and K.Mori, "Expert System for Cold-Forging Process Based on FEM Simulation," Annals of the CIRP, Vol. 39, No. 1, pp 249 - 252, 1990.
- [2] N.Alberti, L.Cannizzaro and F.Micari, "Knowledge-Based Systems and F.E.Simulation in Metal-Forming Processes Design," Annals of the CIRP, Vol. 40, No. 1, pp 295 - 298, 1991.
- [3] Kozo Osakada and Guobin Yang, "Application of Neural Networks to an Expert System for Cold Forging," Int. J. Mach. Tools Manufact., Vol. 41, No. 4, pp 577 - 587, 1991.
- [4] A.Barcellona, "Neural Network Technique for Metal Forming Design," 30th MATDOR conference, pp 361 - 365, 1993.
- [5] 정낙면, 이낙규, 양동열, "축대칭 냉간단조의 유한요소해석에서 퍼지로직을 이용한 전방투사법," 대한 기계학회논문집, Vol. 16, No. 8, pp 1468 - 1483, 1992.
- [6] R.H.Nielsen, "Kolmogorov's Mapping Neural Network Existence Theorem," IJCNN'87, Vol. 3, pp 11 - 13, 1987.
- [7] B.Irie and S.Miyake, "Capabilities of Three-Layered Perceptrons," IJCNN'88, Vol. 1, pp 641 - 648, 1988.
- [8] K.C.Funahashi, "On the Approximate Realization of Continuous Mappings by Neural Networks," Neural Networks, Vol. 2, pp 183 - 192, 1989.
- [9] K. Hornik, "Multilayer Feedforward Networks are Universal Approximators," Neural Networks, Vol. 2, pp 359 - 366, 1989.
- [10] O.C.Zienkiewicz, "The Finite Element Method," McGraw-Hill, New York, 3rd ed.1977.
- [11] S. Kobayashi, S.I. Oh and T. Altan, "Metal Forming and the Finite Element Method," Oxford University Press, 1989.
- [12] R.P. Lippmann, "An Introduction to Computing with Neural Nets," IEEE ASSP Magazine, Vol. 2, pp 4 - 22, April 1987.
- [13] D.E.Rumelhart, G.E.Hinton and R.J.Williams, "Learning Internal Representations by Error Propagation," in D.E.Rumelhart and J.L. McClelland(Eds), Parallel Distributed Processing :Explorations in the Microstructure of Cognition, Vol. 1, pp 318 - 362, 1986.

Table 1 The results of finite element method for various shape ratio

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 The comparison of final load, forming energy, ($\bar{\epsilon}_{avg}$), for full-filling shape ratio

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
($\bar{\epsilon}_{avg}$)	0.7306	0.7367	0.7460	0.7485	0.7557

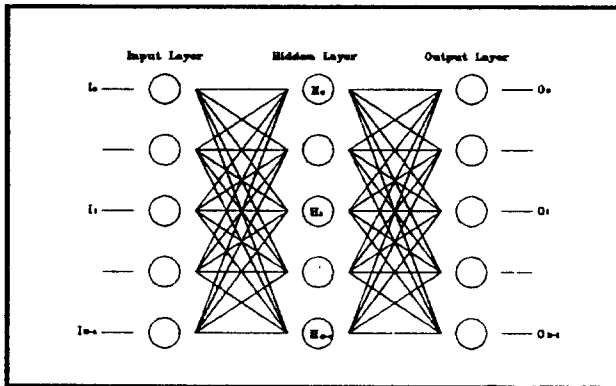

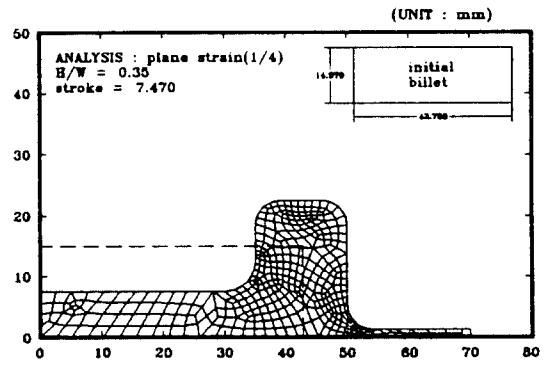


Fig. 1 A three-layer neural network


$$H_i = f \left(\sum_j w_{ji} I_{pj} + \theta_j \right)$$




(a) H/W=0.30



(b) H/W=0.35



(c) H/W=0.40



(d) H/W=0.45

Fig. 2 Simulation of forging process using various shape ratio
(Hatched region refers to the unfilled cavity)




Fig. 3 The results of the training by method 1 through 3-layer neural network




Fig. 4 The results of the training by method 2 through 3-layer neural network







Fig. 5 Comparison of forming load with various shape ratio



(b) H/W=0.365



(c) H/W=0.38

Fig. 6 Distribution of effective strain of finished forging