

신경망을 이용한 열간단조품의 초기 소재 설계

김동진*, 김병민**, 최재찬**

* 부산대학교 대학원, ** 부산대학교 정밀 정형 및 금형 가공연구 센터

Design of Initial Billet using the Artificial Neural Network for a Hot Forged Product

D. J. Kim*, B. M. Kim**, J. C. Choi**

* Graduate school, Pusan National University

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

Abstract

In the paper, we have proposed a new technique to determine the initial billet for the forged products using a function approximation in neural network. A three-layer neural network is used and a back propagation algorithm is employed to train the network. An optimal billet which satisfied the forming limitation, minimum of incomplete filling in the die cavity, load and energy as well as more uniform distribution of effective strain, is determined by applying the ability of function approximation of the neural network. The amount of incomplete filling in the die, load and forming energy as well as effective strain are measured by the rigid-plastic finite element method. This new technique is applied to find the optimal billet size for the axisymmetric rib-web product in hot forging. This would reduce the number of finite element simulation for determining the optimal billet of forging products, further it is usefully adapted to physical modeling for the forging design

1. 서 론

소성가공의 큰 장점중의 하나는 재료의 손실없이 좋은 기계적 성질을 얻을 수 있다는 것이다. 이러한 조건을 만족시키기 위해서는 초기소재 및 예비성형체 형상, 금형설계, 가공 공정수 등과 램속도, 마찰 상수등의 많은 공정변수를 고려해야 한다. 특히 소재의 초기형상은 대부분 금속 유동의 영향을 받는다. 따라서 어떤 특정한 기하학적 형상은 재료의 유동결합, 금형의 조기파손 등을 일으킨다. 결국 재료 유동은 공정중에 제어하기가 곤란하므로 소재의 초기형상으로 재료 유동을 가장 적절하게 제어해야 한다.

초기소재의 결정에 있어서는 Altan[1]등이 금속유동을 압출형과 압축형으로 분류하고 금속유동면과 유동방향에 따라서 초기형상을 결정하였다. N. Alberti[2]등은 밀폐단조에서 금형 내를 충만시키고 금속유동결합 및 연성파괴를 일으키지 않는 최적의 예비성형체 형상을 결정하기 위해 성형 경로를 역추적하여 예비성형체 형상을 바꿔가면서 반복적으로 유한요소해석을 수행하였다. Lanka[3]등은 평면변형 리브-웹 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 조사해야하고, 재료거동을 실제와 똑같이 묘사하기 위해서 사용되는 수학적 모델의 복잡성으로 인해 야기되는 어려움때문에 비용과 시간이 너무 많이 든다. 또 초기소재 형상의 결정에 있어서는 거의 전문가의 경험이나 실험결과 혹은 시행착오에 의해서 결정하였다. 최근에는 이러한 단점들을 보완하기 위하여 인공지능이나 신경망과 같은 새로운 기법을 이용한 방법들이 제안되고 있다.

K.Osakada[4] 등은 신경망의 형상 분류 능력을 이용하여 유한요소해석으로 얻어진 데이터를 학습시켜, 다른 공정조건에 대한 제품 결함 및 금형의 파손 여부를 예측하였고, Roy[5] 등도 신경망의 형상보간 기능을 이용하여 각 부품군으로부터 예비성형체형상을 예측하였고 예비성형체 설계의 지식과 유한요소해석결과, 실험결과로 신경망을 학습시켜 학습되지 않은 부품군에 대한 그 값들을 예측하였다. A. Barcellona[6] 는 2 가지 공정조건에 대한 유한요소해석 결과를 신경망으로 학습시켜, 해석하지 않은 공정조건에 대하여 재료의 내부결함(Central Burst) 발생 여부를 판단하였고, Kim [7] 등은 신경망의 함수 근사능력을 이용하여 금형내 충만성을 만족하는

소재 형상비를 예측하였다. D. Y. Yang[8] 등은 퍼지 로직을 이용한 전방 투사법으로 금형 내의 재료 충만성을 만족하는 초기 소재의 형상을 제안하여 유한요소해석의 회수를 줄이고자 하였다.

본 연구에서는 신경망의 함수 근사(Function Approximation) 능력을 이용하여[9~12] 급속 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 찾아 내었고, 한계치보다 작으면 이 때의 결과가 금형 내를 완전히 충만시키는 초기 소재 형상이다. 그리고 금형내를 완전히 충만시키는 소재 중에서 성형하중, 성형에너지가 최소가 되거나, 유효변형률분포 등이 균일한 소재를 찾아내었다. 이러한 방법을 리브-웨이브형 측대칭 열간 단조품에 적용하였다.

2. 다층 퍼셉트론 신경망

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 근사에까지 그 응용범위가 확대되었다. Kolmogorov[9]는 $[0, 1]$ 에서 R^m 으로 사상하는 어떠한 다변수 연속함수도 일변수 연속함수의 선형 조합에 의해 근사화될 수 있다는 것을 증명하였고, Irie 와 Miyake[10], Funahashi[11], Hornik[12] 등도 다층 퍼셉트론 신경망의 함수 근사화에 관한 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 전방 단계(Feed-Forward)와 출력값과 실제 원하는 값(교사 데이터)의 오차를 계산하여 가중치를 계산하는 후방 단계(Feed-Backward)로 이루어져 있다[14].

전방 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.

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

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

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

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

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.

후방 단계는 전방 단계에서 계산된 실제 출력과 원하는 출력과의 오차를 계산하여 연결 가중치를 조절한다. 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 뉴런의 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.

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. 또한 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 상수로 $0 \leq \alpha \leq 1$ 의 범위를 가지며

n은 반복횟수이다.

위의 식들로부터 함수 근사 프로그램을 개발하였다. Fig. 2는 $y=\sin(x)$ 함수의 근사결과를 보여준다. 0°에서 360°까지 등간격으로 25개의 데이터를 선택하여 학습을 시켰다. 입력값은 각도이고 출력값은 그때의 sine 값이며, 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

유한요소 해석에 사용된 재료는 AISI-1045로 용력-변형률속도의 관계는 표 1과 같고[15] 소재 및 금형의 열특성 및 열전달 계수는 표 2에 나타내었고, 램속도는 80mm/sec, 마찰상수는 0.3으로 하여 유한요소 해석을 하였다[16]. 일반적으로 열간단조에서는 플래시량을 소재 체적의 10%로 한다[16]. 이 소재 체적으로 유한요소해석을 수행한 결과 소재형상비(소재높이/소재반경)가 0.60~1.24까지의 소재가 금형내를 완전히 채움을 알 수 있었다(Fig. 3 A영역). 그래서 플래시량을 7% 줄여서 유한요소해석을 수행하여 금형내를 충만시키는 소재 형상비를 예측하기로 하였다. 플래시량을 7% 고려한 이유는 10%의 플래시를 준 초기 소재로 재품(h/r=0.90)을 해석했을 경우 원하는 펀치 행정에 도달하기 전에 이미 금형내를 충만시켰기 때문에 그 때의 플래시 체적과 펀치 행정이 완전히 다 내려 갔을 때의 플래시량을 계산하여 플래시량을 7%로 고려하였다.

앞의 유한요소 결과로부터 형상비가 0.40, 0.80, 1.20, 1.60인 4가지 소재형상비에 대하여 유한요소 해석을 수행하였다. 실제 신경망 함수 근사에는 3점의 데이터만 있으면 가능하나, 좀 더 정확한 함수 근사를 위하여 4가지 경우의 결과로 신경망을 학습시켰다. 시뮬레이션 도중 격자가 심하게 변형되어 8~9번의 격자 재구성을 하였다. 일반적으로 격자 재구성과 유한요소 해석 도중 체적의 손실이 발생한다. 본 연구에서는 금형내를 완전히 충만시키는 소재 형상비를 찾는 것이 목적이기 때문에 격자 재구성과 유한요소 해석 자체의 체적 손실을 최소화하여 유한요소 해석을 수행하였다.

소재 형상비가 0.40인 소재로 유한요소 해석을 수행한 결과 금형내 미충만 부분의 체적이 24,274.90mm³이었고(Fig. 4(a)), 형상비가 0.80인 경우는 금형내를 완전히 충만시켰다(Fig. 4(b)). 그리고 형상비 1.20인 경우는 금형내 미충만 부분의 체적이 6,006.40mm³이었고(Fig. 4(c)), 형상비가 1.60인 소재는 금형내 미충만부분의 체적이 22,542.90mm³이었고(Fig. 4(d)). 소재 형상비와 유한요소

해석 결과인 금형내 미충만 체적을 신경망으로 학습시켰다. 학습에 사용된 신경망은 1개의 입력층과 10개의 은닉층, 1개의 출력층을 가지는 3층의 다중퍼셉트론 신경망을 사용하였다. 소재의 형상비를 입력데이터로 사용하였고, 그 때의 금형내 미충만 부분의 체적을 교사 데이터로 하여 신경망을 학습시켰다.

신경망으로 위의 데이터들을 학습시킨 결과 형상비가 0.80~0.94 사이의 형상비를 가지는 초기 소재가 금형내를 완전히 충만시킴을 알 수 있었다(Fig. 3 B영역). 플래시량을 10%로 하였을 경우보다 금형내를 충만시키는 형상비의 범위는 줄었는데, 함수근사 결과는 10%의 함수근사 결과를 y축으로 평행이동한 것과 비슷하였다. 이 결과를 확인하기 위하여 형상비 0.85, 0.90, 0.95인 3가지 초기 소재로 추가 해석을 하였다. 형상비가 0.85, 0.90인 소재는 신경망의 예측결과대로 금형내를 완전히 충만시켰고 형상비 0.95인 소재는 신경망 예측대로 금형내를 완전히 채우지 못했고, 신경망에서 예측한 것 보다 10%정도의 차이가 났다. 신경망의 학습 데이터가 충분히 많으면 위의 량을 좀 더 정확하게 예측할 수 있을 것으로 생각된다.

금형내를 완전히 충만시키는 3가지 소재에 대하여 최종하중, 성형에너지, 평균 유효변형률, 유효변형률의 편차량을 비교해 보았다(Table 3). 그림 5에 편치행정에 따른 하중선도를 나타내었다. 최종 편치행정에서의 하중이 거의 일정할 것으로 생각되었으나 형상비가 0.90인 소재가 나머지 2가지 소재보다 각각 19.69%(h/r=0.80), 11.29%(h/r=0.85) 정도가 작게 걸렸다. 이 것으로 보아 형상비가 0.80, 0.85인 소재는 편치행정이 최종상태에 도달하기 전에 이미 금형내를 완전히 채워 편치행정이 진행됨에 따라 플래시부로의 소재 압축이 이루어져 하중의 차이가 생기는 것으로 생각된다. 최종하중 측면에서는 형상비가 0.90인 소재가 가장 낮은 값을 가짐을 알 수 있었다. 성형에너지는 형상비가 0.80인 소재가 나머지 2가지 소재보다 각각 1.56%(h/r=0.85), 3.77%(h/r=0.90) 정도가 작게 걸림을 알 수 있었다. 형상비가 작을수록 소재 높이가 낮아져 성형에너지는 작게 걸린 것으로 생각되며, 성형에너지 측면에서는 형상비가 0.8인 소재가 작은 값을 가짐을 알 수 있었다.

다음으로 소재의 평균 유효변형률과 유효변형률의 편차량을 비교해 보았다(Table 3). 평균 유효변형률은 형상비가 0.80인 소재가 다른 2가지 소재에 비해 각각 3.08%(h/r=0.85), 5.52%(h/r=0.90) 만큼 작았다. 유효변형률의 편차값을 비교해 보면 형상비가 0.80인 소재가 다른 2가지 소재에 비해 각각 2.51%(h/r=0.85), 3.06%(h/r=0.90) 만큼 작았다. 편차값이 작은 소재가 다른 소재에 비해

균일한 유효변형률분포를 가짐을 알 수 있다. 피로 (Fatiguc)측면에서는 균일한 유효변형률 분포를 가지는 것이 좋기 때문에[17] 형상비 0.80인 소재가 다른 2가지 소재에 비해 피로에 강인하다는 것을 알 수 있다.

금형내를 완전히 채우는 소재 중에서 최종 성형하중으로 보아서는 형상비 0.90인 소재가 낮지만, 성형에너지, 평균 유효변형률값, 피로측면에서는 형상비 0.80인 소재가 가장 알맞은 소재임을 알 수 있었다.

4. 결 론

본 연구에서는 유한요소법과 다층퍼셉트론 신경망을 이용하여 열간 단조품의 초기소재를 설계하였다. 예비선택된 초기소재들로 유한요소 해석을 수행하여 금형내의 미충만 체적과 금형내를 완전히 충만시키는 소재의 형상비를 알아내었다. 이 결과들을 신경망으로 학습시켜 다음과 같은 결론을 얻었다.

(1) 일반적인 초기소재 설계에서는 플래시량을 10%로 하여 초기소재의 체적을 계산한다. 기존에 설계된 초기소재로 유한요소 해석과 신경망 학습을 통해 플래시량을 7%로 줄여서 금형내 충만을 만족하는 소재 형상비를 찾을 수 있어 소재의 손실을 막을 수 있었다.

(2) 4가지 소재 형상비에 대한 유한요소 해석 결과를 신경망의 학습을 통해 금형내부를 충만시키는 형상비를 예측할 수 있으므로 유한요소 해석 수를 줄일 수 있었다.

(3) 임의 제품의 유한요소 해석결과를 이용하여 금형내 충만 여부와 성형하중, 균일한 유효변형률분포 등 여러 가지 조건에 대한 신경망 학습으로 미해석부분의 값을 예측할 수 있어 다단계 금속성형공정에 요구되는 예비성형체 설계에 유용하게 적용될 수 있을 것이다.

5. 참고 문헌

- 1 T.Altan, S.I.Oh and H.L.Gegel, Metal Forming-Fundamentals and Appliaiotn, American Society of Metals
- 2 N.Alberti, L.Cannizzaro and F.Micari and R.Riccobono, "Formability in Closed -Die Processes-Computer Aided Design of the Preformed Shape", Ann. ICTP, Vol. 1, pp. 185-189, 1990
- 3 S.S.Lanka, R.Srinivasan and Rov. Gandhi, "A Design

- Approach of Intermediate Die Shapes in Plane Strain Forgings", J.Mat. Shaping Tchh. Vol. 9, pp. 193-206, 1991
- 4 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.
- 5 R. Roy, K. Chodnikiewicz and R. Balendra, "Interpolation of Forging Preform Shapes using Neural Network", J. Mat. Proc. Tchh., Vol.45, pp. 695-702, 1994
- 6 A.Barcellona, "Neural Network Technique for Metal Forming Design," 30th MATDOR conference, pp 361-365, 1993.
- 7 김동진, 고대철, 김병민, 최재찬, "신경망과 유한요소법을 이용한 단조품의 초기소재 결정", 한국소성가공학회 추계학술대회논문집, pp. 133-140, 1994
- 8 정낙면, 이낙규, 양동열, "축대칭 냉간단조의 유한요소해석에서 퍼지로직을 이용한 전방투사법," 대한기계학회논문집, Vol. 16, No. 8, pp 1468-1483, 1992.
- 9 R.H.Nielsen, "Kolmogorov's Mapping Neural Network Existence Theorem," IJCNN'87, Vol. 3, pp 11-13, 1987.
- 10 B.Irie and S.Miyake, "Capabilities of Three-Layered Perceptrons," IJCNN'88, Vol. 1, pp 641-648, 1988.
- 11 K.C Funahashi, "On the Approximate Realization of Continuous Mappings by Neural Networks," Neural Networks, Vol. 2, pp 183-192, 1989.
- 12 K. Hornik, "Multilayer Feedforward Networks are Universal Approximators", Neural Networks, Vol. 2, pp 359-366, 1989.
- 13 D.E.Rumelhart, G.E.Hinton and R.J.Wiliams, "Learning Internal Representations by Error Propagation", Parallel Distributed Processing Cambridge MA:MIT press, pp 318-362, 1986.
- 14 R.P. Lippmann, "An Introduction to Computing with Neural Nets," IEEE ASSP Magazine, Vol. 2, pp 4-22, April 1987.
- 15 Taylan Altan, Soo-Ik Oh, and Harold L. Gegel, "Metal Forming Fundamentals and Application", American Society for Metals, 1983
- 16 김성원, "열간단조 공정설계 및 금형설계의 자동화시스템에 관한 연구", 부산대학교, 박사학위논문, 1994
- 17 N. Kanamaru, O. Tsusa, T. Matsushita, H. Takigawa and S. Furuta, "Effects of Preform Design on Mechanical Properties of P/M Superalloy Turbine Disk", Ann. ICTP, Vol.2, pp. 921-926, 1990

Table 1. Stress strain-rate properties of AISI-1045 given with respect to the temperature and strain

temperature \ strain	900(°C)		1000(°C)		1100(°C)		1200(°C)	
	C (N/mm ²)	m	C (N/mm ²)	m	C (N/mm ²)	m	C (N/mm ²)	m
0.05	175.05	0.080	104.07	0.089	77.19	0.100	55.13	0.175
0.10	199.17	0.082	129.57	0.103	93.04	0.125	64.78	0.168
0.20	229.50	0.086	157.13	0.108	106.13	0.128	72.36	0.167
0.30	243.97	0.083	169.54	0.110	108.89	0.162	74.43	0.180

Table 2. Thermal properties and heat transfer coefficients

Coeff.	conductivity (N/sec°C)	heat capacity (N/mm°C)	convection coeff. (N/sec mm°C)	lubricant heat transfer coeff. (N/sec mm°C)	emissivity
workpiece (AISI 1045)	74.93	3.602	0.005	30	0.3
die (SKD61)	28.6	3.574			0.3

Table 3. Final load, forming energy, average strain and deviation strain for full-filling aspect ratios

aspect ratios	final load(KN)	forming energy (KN · m)	average strain	deviation strain
h/r=0.80	28,950.00	1.563x10 ⁸	1.19074	0.44766
h/r=0.85	26,209.97	1.588x10 ⁸	1.22740	0.45888
h/r=0.90	23,249.99	1.622x10 ⁸	1.26028	0.46134




Fig. 1 The architecture of three layer neural network




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







Fig. 3 The results of the training by the neural network



(c) $h/r=1.20$




(a) $h/r=0.40$



(d) $h/r=1.60$

Fig. 4 The simulation of forging process using various aspect ratios (The hatched region refers to the unfilled cavity)



(b) $h/r=0.80$




Fig. 5 The comparison of forming load with various aspect ratios