

## 신경망을 이용한 다단 인발의 공정설계

김동환\*, 김동진\*, 김병민\*\*, 최재찬\*\*

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

## Process Design of Multi-Step Drawing using Artificial Neural Network

D. H. KIM\*, 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

Process design of multi-step wire drawing process, conducted by means of finite element analysis and ANN(Artificial Neural Network), has been considered. The investigated problem involves the adequate selection of the drawing die angle and the correspondent reduction rate sequence in the condition of desired initial and final diameter. Combinations of the process parameters which are used in finite element simulation are selected by using orthogonal array. Also the orthogonal array and the results of finite element simulation which are related to the process energy are used as train data of ANN. In this study, it is shown that the new technique using ANN is useful method in application to the wide range of metal forming process

**Key words :** ANN(인공신경망), Orthogonal Array Table(직교배열표), Multi-Step Drawing(다단 인발), Load(성형하중)

### 1. 서론

소성가공은 소재의 손실과 생산에 소요되는 시간을 최소로 줄이면서 기계적 성질이 우수한 제품을 생산하는데 그 장점이 있다. 그러나 금속의 소성유동을 이해하는데 사용되는 수학적 모델은 복잡하며 그 완전 해를 구하기란 매우 어렵다. 따라서 실제 해에 근접한 이상화된 수학적 모델의 사용이 불가피하며, 그 중에서도 유한 요소 해석방법은 설계자에게 상세한 정보를 제공할 수 있고 생산과정에서 시행착오를 줄일 수 있어 유용하게 사용되고 있는 방법이다[1]. 그러나 유한요소 해석을 하기 위해서는 먼저 제품의 성형공정에 미치는 많은 공정변수들의 영향을 조사해야 하는데, 최근에는 이러한 점을 보완하기 위해 인공신경망을 이용하여 설계자의 설계목적에 맞는 공정변수들의 영향을 조사하는 새로운 기법이 제안되고 있다[2,3].

인공신경망은 다차원 함수의 학습이 가능하며, 학습으로 인해 다차원 함수의 변수관계를 찾는 능력을 가진다[4]. 그러나 인공신경망을 학습시키기 위한 데이터의 선택은 주의를 요하며 찾고자 하는 데이터보다 넓은 범위의 학습이 선행되어야 좋은 결과를 얻을 수 있다.

본 연구에서는 인공신경망의 함수 근사(Function approximation)능력과 학습데이터를 얻기 위한 방법으로 직교배열표(Orthogonal array)[5]를 이용하여, 최소 성형에너지의 측면에서 초기 직경과 최종 직경이 주어진 두 개의 디아스를 가진 선재 인발의 공정설계를 하기 위해 적용하였다. 상용 강소성 유한 요소 코드인 DEFORM을 이용하여 직교배열표 작성법에 따라 선정된 각각의 공정변수조합을 시뮬레이션하였고, 직교배열표의 공정변수조합을 입력데이터로 하고 각각의 공정변수조합으로 시뮬레이션하여 구한 성형하중을 목적데이터(Target value)로 하여 인공신경망 프로그램을 학습시켜서, 역으로 최소 성형하중을 갖는 공정변수조건을 찾아낸다.

### 2. 신경망 이론

인공신경망은 비선형 문제, 형상 분류, 인식, 제어 등의 분야뿐만 아니라 근래에 와서는 함수 근사까지 그 용용범위가 확대되었고, 그 능력 또한 우수하다[2,3,4]. 감독학습의 역전파 학습 알고리즘은 입력값으로부터 실제 출력값을 계산하는 전향단계(Feed forward)와 실제 출력값과 목적값의 오차를 계산하여 가중치와 임계치를 조절하는 후향단계(Feed backward)로 이루어져 있다.

전향단계에서 은닉층의 출력은 입력값을 은닉층의 뉴런에 연결된 입력층 뉴런들의 가중치를 곱하여 모두 합한 다음, 활성화 함수를 거쳐 계산되며, 본 연구에서 사용된 활성화 함수,  $f_i(n_{\text{net},p})$ ,는 다음과 같은 수정된 시그모이드 함수를 사용하였다.

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

여기서,  $t$ 는 수렴속도를 항상시키기 위해 고안되었다. 은닉층에서 출력층의 출력값도 위와 같은 방법으로 계산된다.

후향단계는 전향단계에서 계산된 실제 출력과 원하는 출력과의 오차를 계산하여 연결가중치를 조절한다. 오차에 대한 최급하강법에 의하여 가중치의 증분량을 계산하면 다음과 같다.

$$\Delta_p w_{kj}(n) = \eta \delta_{pk} o_{pj} + \alpha \delta_p w_{kj}(n-1) \quad (2)$$

여기서,  $\eta$ 는 학습률이고,  $n$ 은 반복횟수를 가리키며,  $\alpha$ 는 모멘텀의 크기를 제어하는 상수이다. 역전파 학습알고리즘을 가진 다층 퍼셉트론의 은닉층 수와 뉴런의 개수에는 그 제한을 두지 않고 있다[4].

### 3. 인발 공정 설계 및 신경망 학습

#### 3.1 선재 인발 공정

초기 직경과 최종 직경이 주어진 두 개의 다이스를 이용한 선재 인발공정을 시뮬레이션하기 위해 사용된 공정변수의 조건은 Table 1과 같고, 그 공정을 Fig.1에 간단히 나타내었다. 인발공정에 사용된 소재는 AISI 1010이며 소재에 대한 압축실험을 하여 다음과 같은 응력-변형율 관계식을 얻었다[6].

$$\bar{\sigma} = 715.93 \bar{\epsilon}^{0.22} (\text{N/mm}^2) \quad (3)$$

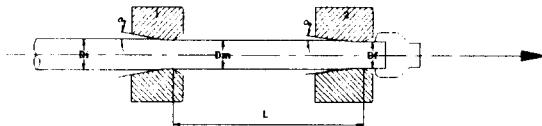


Fig.1 A schematic sketch of drawing process.

여기서, 다이반각은 실제 선재 인발공정에서 주로 사용하는 범위 내에서 고려하였으며, 첫 번째 다이스에서  $\alpha_1$ , 두 번째 다이스에서  $\alpha_2$ 로 하여 각기 다른 변수로 취하였다.

단면 감소율은 식 (4)과 같이 정의된 단면 감소율 상수  $R$ 을 두어 고려하였다.

$$R = \frac{D_i^2(D_m^2 - D_f^2)}{D_m^2(D_i^2 - D_m^2)} , \quad (R = \frac{R_2}{R_1}) \quad (4)$$

Table 1 Condition of process parameters

Process Condition	1 Pass	2 Pass
Half die angle(°)	6~10	6~10
Initial workpiece diameter ( $D_i$ : mm)	4.7	$D_m$
Final workpiece diameter ( $D_f$ : mm)	$D_m$	4.0
Reduction in area(%)	R1	R2
Length of die land(mm)	1.5	1.5
Wire drawing speed(mm/s)	5000	
Constant friction factor( $m$ ; $0 \leq m \leq 1$ )	0.1~0.2	
Die distance( $L$ : mm)	30	

Table 2 Level of design parameters

Level	단면 감소율 상수( $R$ )	Half die angle ( $\alpha_1$ )	Half die angle ( $\alpha_2$ )	Friction ( $m$ )
High level	2	6	6	0.1
Middle level	1	8	8	0.15
Low level	0.5	10	10	0.2

본 연구에서는 다이스 사이의 간격과 랜드부의 길이 그리고 인발속도는 일정하게 두어 그 영향은 고려하지 않았다.

#### 3.2 인공신경망의 학습데이터의 선정

신경망의 학습 데이터를 선정하는 데에는 세심한 주의가 요구된다. 본 연구에서는 인공신경망의 학습데이터를 선정하기 위해 통계학적 실험계획법에서 주로 사용되는 칙교배열표를 이용하였

다. 직교배열표는 설계목적에 맞게 고려한 공정변수의 수준에서 공정변수가 특성치에 미치는 영향을 독립적으로 측정되게 하여, 설계자가 원하는 공정변수와 공정변수의 상호작용의 효과를 얻을 수 있도록 실험계획을 간단히 짤 수 있게 만들어 놓은 표이다. 본 연구에서는  $L_{27}(3^{13})$ 의 직교배열표를 이용하였고, Table 2에는 설계변수로 고려된 공정변수와 공정변수의 수준을 나타내었다[5]. 사용된 인공신경망은 감독학습의 역전파 학습 알고리즘으로, 4개의 뉴런을 갖는 입력층과 1개 뉴런을 갖는 출력층, 그리고 각각 20, 20, 10, 5개의 뉴런을 갖는 4개의 은닉층을 사용하였다.

### 3.3 인공신경망의 학습 및 결과 고찰

직교 배열표상의 공정변수조합을 인공신경망의 입력층 뉴런값으로 하고, 유한 요소 해석으로 얻은 성형하중을 출력층 뉴런값으로 하여 인공신경망 프로그램을 학습시켰다. 수렴 조건은 실제

Table 3 Train and output data of ANN

No.	Train Data				Output Data	
	R[1]*	$\alpha 1[2]$	$\alpha 2[5]$	m[10]	FEM (load:kN)	ANN (load:kN)
1	2	6	6	0.1	3587.298	3587.306
2	2	6	8	0.15	3832.535	3832.229
3	2	6	10	0.2	3928.423	3928.190
:	:	:	:	:	:	:
25	0.5	10	6	0.1	3410.586	3410.268
26	0.5	10	8	0.15	3844.547	3844.039
27	0.5	10	10	0.2	4178.150	4177.932

\*[ ] : Column number of orthogonal array.

Table 4 Comparisons of ANN and FEM results

	R	$\alpha 1$ (*)	$\alpha 2$ (*)	m	Load FEM (kN)	Load ANN (kN)	error (%)
Optimal Condition	1	6	6	0.1	3367.227	3384.429	0.51
Test data	0.5	6	6	0.1	3450.347	3424.140	0.75
Test data	2	9	6	0.2	4430.245	4446.734	0.37
Test data	0.8	7	9	0.1	3669.527	3672.119	0.07

출력값과 목적값의 차이(Root mean square error)가  $10^{-7}$ 에 도달할 때 까지로 하였으며 그 수렴 과정을 Fig.2에 나타내었다. Table 3에는 직교배열표에 따른 인공신경망의 학습데이터와 그 출력값이 나타나있다. Table 3에서 알 수 있듯이, 인공신경망의 학습으로 얻은 실제 출력값과 목적값, 즉 유한 요소 해석으로 얻은 성형하중과는 거의 일치하였으며, 이로써 인공신경망의 학습이 잘 되었음을 알 수 있었다.

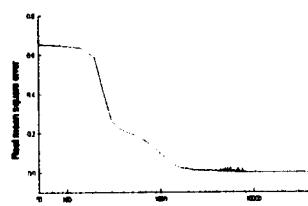


Fig. 2 Mean square errors in network training processes

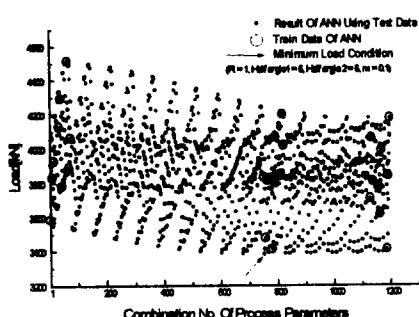


Fig. 3 Output of ANN using test data

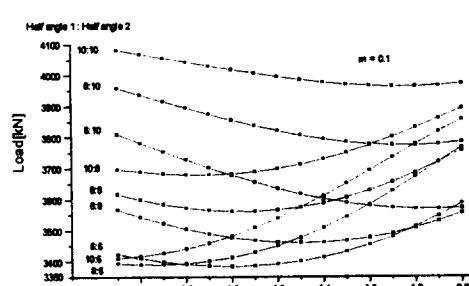


Fig. 4 The effect of process parameters on the load

학습된 인공신경망의 가중치값과 임계치를 이용하여 1200개의 공정변수조합에 대한 인공신경망의 출력값을 Fig.3에 나타내었다. 이 1200개의 데이터는 고려된 공정변수 범위 내에서 단면감소율 상수  $R$ 을 열여섯 수준, 다이반각  $\alpha_1$ 과  $\alpha_2$ 를 각각 나섯 수준 그리고 마찰율 세 수준으로 하였을 때 만들 수 있는 공정변수조합으로 하였다. 이러한 공정변수조합들 중에서 최소 성형하중을 가지는 조합은  $R=1$ ,  $\alpha_1=6$ ,  $\alpha_2=6$ ,  $m=0.1$ 이었으며, 이 조합으로 예측한 성형하중은 3384.429kN 이었다. Table 4에는 인공신경망으로 예측한 최소성형하중을 가지는 공정변수조합의 출력값과 같은 조건으로 유한 요소 해석으로 구한 성형하중을 나타내었고, 그 값들이 거의 일치함을 확인할 수 있었으며 시뮬레이션을 한 결과 중에서 가장 낮은 성형하중값을 갖는 공정변수조합이었다. 또한, 인공신경망의 학습결과를 검증하고자 임의의 공정변수조합을 선정하여 그 공정변수조합으로 구한 인공신경망의 출력값과 유한 요소 해석 결과와도 비교하였다. 그 결과 Table 4에서 알 수 있듯이, 인공신경망의 예측치는 1%이하의 에러를 가지며 임의의 공정변수조합에서도 그 값이 거의 일치하므로 인공신경망으로 찾은 최소성형하중을 가지는 공정변수조건이 성형하중의 측면에서는 최적의 공정변수조합이라고 할 수 있다.

인공신경망의 학습결과를 이용하여 본 연구에서 고려한 각각의 공정변수가 성형하중에 미치는 영향을 살펴보면, 마찰 값이 변할 때 성형하중값의 차이가 가장 심하다는 것을 알 수 있었다. 그래서 이번에는 마찰값을 일정하게 두었을 때 각 공정변수의 영향을 살펴보기로 하였다. 마찰율 0.1로 두고 가로축을 단면감소율 상수  $R$ , 세로축을 성형하중값으로 하여 Fig.4에 나타내었다. 여기서 알 수 있는 것은 두 번째 다이스 반각이  $6^\circ$ 이고 첫 번째 다이스의 단면 감소율이 두 번째 다이스의 단면 감소율 보다 작을 때 비교적 낮은 성형하중이 분포한다는 사실이었다. 또한 첫 번째 다이스 반각이 두 번째 다이스 반각 보다 클 경우에는 첫 번째 다이스의 단면 감소율이 두 번째 다이스의 단면 감소율 보다 작을수록, 반대의 경우에는 첫 번째 다이스의 단면 감소율이 두 번째 다이스의 단면 감소율 보다 클 수록 낮은 성형하중을 가진다는 것을 알 수 있었다.

#### 4. 결론

본 연구에서는 인공신경망의 함수 근사 능력과 직교배열표를 이용한 새로운 공정설계기법을 초기 직경과 최종 직경이 주어진, 두 개의 다이스를 가진 선재 인발공정에 적용하여 다음과 같은 결론을 얻었다.

- (1). 인공신경망을 이용하여 최소의 성형하중을 갖는 공정변수조합을 찾을 수 있었다.
- (2). 인공신경망의 학습은 학습데이터에 따라 그 결과가 달라지므로, 학습데이터의 선정은 상당한 주의를 요한다. 그러나 직교배열표를 이용하여 학습데이터를 선정함으로써 보다 넓은 범위의 학습이 가능하였고, 학습 후 만족할 만한 결과를 얻을 수 있었다.
- (3). 직교배열표를 이용함으로써 많은 수의 유한 요소 해석을 줄일 수 있고, 인공신경망을 도입함으로써 미해석 부분의 값까지도 예측할 수 있으므로 다단계 금속성형공정에 요구되는 공정설계에 유용하게 적용 될 수 있으며, 그 용용 범위 또한 넓을 것으로 생각된다.

#### Reference

1. J.J.Park, N.Rebelo, and S.Kobayashi, "A New Approach to Preform Design in Metal Forming with the Finite Element Method", Int. J.Mach. Tool Des. Res., Vol. 23, No.1, pp.71-79, 1983
2. K.Osakada and G.Yang, "Application of Neural Networks to an Expert System for Cold Forging" Int. J. Mach. Tools. Manu., Vol. 41, No. 4, pp.577-587, 1991.
3. 김동진, 김병민, 최재찬, "신경망을 이용한 열간단조품의 초기소재 설계", 한국정밀공학회논문집, Vol.12, No.11, p.118, 1995
4. 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.
5. Box, G.E.P., Hunter, W.G., and Hunter, J.S., "Statistics for Experimenters", New York: John Wiley
6. 김태형, "냉간 금속성형제품의 정밀도 향상을 위한 유한 요소법의 활용", 부산대학교 대학원 박사학위 논문(1997).