

인공신경망을 이용한 다단 인발 공정 설계

김동환* · 김동진* · 김병민**

(1997년 10월 15일 접수)

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

D.H.Kim, D.J.Kim and B.M.Kim

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 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 the 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 application of new technique using ANN and Orthogonal array table to the process design of metal forming process is useful method.

Key Words : ANN(인공신경망), Orthogonal Array Table(직교배열표), Multi-Step Wire Drawing (다단 인발), Forming 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⁾

일반적으로 인발공정은 연속적으로 수행되는 연속인발(Tandem Drawing)공정을 거쳐 원하는 최종직경을 얻어내는 마무리 공정이며, 인발된 제품은 그대로 사용되거나 굽힘 또는 기계가공 등의 후속공정을 통하여 다른 형상으로 가공되기도 한다. 이러한 인발공정에서 인발력은 인발가공의 조건이 바뀌면 광범위하게 변화된다. 인발력에 영향을 미치는 요소로서는 인발속도, 다이스의 형상, 단면감소율, 윤활제, 다이스 및 인발재의 표면 상태, 인발재의 기계적 성질, 인발시의 열 등을 생각할 수 있다.

인발공정설계에서 Avitzur⁽²⁾는 인발가공중 나타나는 내부결함(Central Bursting)을 다이반각, 마찰조건, 단면

* 부산대학교 대학원

** 부산대학교 정밀정형 및 금형가공 연구센터

감소를 등의 공정변수로 조사하여 내부결함이 발생하지 않는 공정변수 범위를 제안하였고, Tisza⁽³⁾는 전문가 시스템을 이용하여 최적의 소재 이용율, 최소 성형에너지, 최소의 제품단가 등을 목적함수로 하여 선제 인발 공정설계와 그에 따른 필요한 장비를 선정하였으며, 최근에 Stok⁽⁴⁾ 등은 유한요소해석으로 성형에너지를 최소로 하는 다이반각과 단면감소율을 찾는 최적공정기법을 제시하였다. 그러나 위와 같은 방법들은 제품 성형공정에 미치는 많은 공정변수의 영향을 조사해야 하고, 실제와 똑같은 재료거동을 묘사하기 위해서 사용되는 수학적 모델의 복잡성으로 인해 비용과 시간이 많이 든다. 다만 인발공정의 경우 거의 전문가의 경험이나 실험결과 그리고 시행착오에 의해서 결정되어왔다.

최근에는 인공신경망이나 통계학적 실험계획법(Design of Experiments)을 금속성형의 공정설계에 적용하여 설계자의 설계목적에 맞는 공정변수들의 영향을 조사하는 새로운 기법이 제안되고 있다. 공정변수들이 제품 성형공정에 미치는 영향을 조사하는 기법에 관한 연구를 보면, Carbaugh⁽⁵⁾ 등은 요인배치법(Factorial Design)을 이용하여 제트엔진 디스크단조를 시뮬레이션하였고, 각 공정변수의 영향을 Yates's 알고리즘으로 정량적으로 표현하였다. Osakada⁽⁶⁾ 등은 인공신경망의 형상인식 시스템을 이용하여 제품결함 및 금형의 파손여부를 예측하였고, Kim⁽⁷⁾ 등은 인공신경망의 함수근사능력을 이용하여 금형내 충만성을 만족하는 소재형상비를 예측하였다. Peng⁽⁸⁾ 등은 유한요소법과 인공신경망을 이용하여 측방압출공정에서 접합결함을 예측하였다. 인공신경망은 다차원 함수의 학습이 가능하며, 학습으로 인해 다차원 함수의 변수관계를 찾는 능력을 가진다.⁽⁹⁾ 그러나 인공신경망을 학습시키기 위한 데이터의 선택은 주의를 요하며 찾고자하는 데이터보다 넓은 범위의 학습이 선행되어야 좋은 결과를 얻을 수 있다.⁽¹⁰⁾

본 연구에서는 최소 성형에너지 측면에서 초기 직경과 최종 직경이 주어진 선제 인발공정설계를 하기위해 직교배열표(Orthogonal Array Table)⁽¹¹⁾를 이용한 인공신경망 프로그램을 적용하였다. 직교배열표에 따라 상용 강소성 유한 요소 코드인 DEFORM⁽¹²⁾을 이용하여 각각의 설계변수조합을 시뮬레이션하였다. 먼저 통계학적 해석만으로 최소성형하중을 갖는 설계변수조합과 그 때의 성형하중값을 예측하였고, 인공신경망을 이용하여 직교배열표의 설계변수조합을 입력데이터로 하고 그 조합의 성형하중을 목적값(Target Value)으로 하여 학습한 후 최소성형하중

을 갖는 설계변수조합을 찾아내었다. 통계학적 해석과 인공신경망으로 찾아낸 최소성형하중을 비교하여 최적의 설계변수조건을 선정하였다.

2. 실험계획법 및 신경망 이론

2.1 실험계획법

통계학적 실험계획법은 최소의 실험이나 시뮬레이션으로 고려한 설계변수 범위에서 설계변수만의 주효과(Main Effect) 및 설계변수 사이의 교호작용효과(Interaction Effect)를 알아 보고, 설계목적에 미치는 각 설계변수의 효과를 고려하여 최적의 설계변수조합을 얻고자 하는데에 그 목적이 있다. 실험을 계획하는데 사용되는 직교배열표는 설계목적에 맞게 고려한 설계변수의 수준에서, 설계변수가 목적함수에 미치는 영향을 독립적으로 측정되게 하여 설계자가 원하는 설계변수 및 설계변수간의 교호작용 효과를 알 수 있도록 만들어진 표이며, 설계변수간에 직교성(Orthogonality)을 갖도록 하여 같은 실험횟수라도 검출력이 더 좋은 검정을 할 수 있다. 직교배열표에 따라 실험 및 시뮬레이션을 수행한 후 데이터를 해석 방법으로 분산분석(Analysis of Variance: ANOVA)을 실시하는데, 분산분석이란 특성치(Characteristics), 즉 측정데이터의 산포를 제곱합(Sum of Squares: 변동)으로 나타내고 이 제곱합을 실험과 관련된 요인마다의 제곱합으로 분해하여 오차에 비해 특히 큰 영향을 주는 요인이 무엇인가를 찾아내는 분석방법이다. 분산분석표에서 F검정결과 유의하지 않은 요인을 오차항에 넣어서 새로운 오차항을 만드는 데, 이것을 오차항에 풀링(Pooling)한다고 한다. F값이란 각 요인의 평균제곱(Mean Square)을 오차의 평균제곱(Mean Square Error)으로 나눈 값을 말하며, 이 값을 표준통계표(Standard Statistical Tables)와 비교하여 보다 큰 값을 가지는 요인이 유의한 인자로 판단된다.⁽¹³⁾

식(1)은 특성치의 총 변동을 나타내며, 식(2)는 설계변수 A의 변동을, 그리고 식(3)은 두 설계변수 A와 B간의 교호작용에 대한 변동을 나타낸다.⁽¹⁴⁾

$$S_T = \sum_{i=1}^N y_i^2 - \frac{T^2}{N}, \quad (T = \sum_{i=1}^N y_i) \quad (1)$$

$$S_A = \sum_{i=1}^{k_A} \frac{A_i^2}{n_{Ai}} - \frac{T^2}{N} \quad (2)$$

$$S_{AXB} = \left[\sum_{i=1}^c \frac{(AxB)_i^2}{n_{(AxB)i}} \right] - \frac{T^2}{N} - S_A - S_B \quad (3)$$

where, $(AxB)_1 = A_1B_1, (AxB)_2 = A_1B_2, \dots$

여기서, N 은 실험횟수, y 는 특성치, T 는 특성치의 합을 나타내고, n_{Ai} 는 설계변수 A 의 i 수준에서의 실험횟수, k_A 는 설계변수 A 의 수준수를 나타낸다. 식(3)에서 c 는 두 설계변수준에서 가질 수 있는 수준조합수를 나타내고, $(AxB)_i$ 는 두 변수간의 수준조합에서 특성치의 합을, $n_{(AxB)i}$ 는 $(AxB)_i$ 의 수준조합수를 나타낸다.

통계학적 해석으로 최적의 설계변수조합이 결정되면 이 설계변수조합이 가지는 특성치, 즉 공정평균을 추정하게 되는데 아래에 그 식을 나타내었다

$$\mu = \bar{T} + \sum_i^n (\bar{P}_i - \bar{T}) \pm C.I. \quad (4)$$

여기서, \bar{T} 는 실험전체 특성치의 평균이며, n 은 유의한 설계변수갯수, \bar{P} 는 선정된 설계변수수준에서의 평균값, $C.I.$ 는 신뢰구간(Confidence Interval)을 나타낸다.⁽¹⁴⁾

2.2 신경망 이론

Rumelhart⁽¹⁵⁾가 제안한 다층 퍼셉트론(Multilayer Perceptron)신경망은 비선형 문제, 형상 분류, 인식, 제어 등의 분야뿐만 아니라 근래에 와서는 함수 근사까지 그 응용범위가 확대되었고, 그 능력 또한 우수하다. 다층 퍼셉트론 신경망은 크게 입력층, 은닉층, 그리고 출력층으로 구성되어 있으며, 감독학습의 역전파 학습 알고리즘에 의해 학습된다.

Fig. 1는 L 개의 입력뉴런과 M 개의 은닉뉴런, 그리고 N 개의 출력뉴런을 가진 신경망의 기본 구조를 간략히 나타낸 그림이다. 역전파 학습 알고리즘의 학습단계는 크게 입력값(Input Value)으로부터 실제 출력값(Output Value)을 계산하는 전향단계(Feed Forward)와 실제 출력값과 목적값(Target Value)의 오차를 계산하여 가중치(Weight Connections)와 임계치를 조절하는 후향단계(Feed Backward)로 이루어져 있다.

전향단계에서 은닉층의 출력은 입력값을 은닉층의 뉴런에 연결된 입력층 뉴런들의 가중치를 곱하여 모두 합한 후 활성화 함수를 거쳐 다음식에 의해 계산된다.⁽¹⁶⁾

$$net_{pj} = \sum_i w_{ji} o_{pi} + \theta_i \quad (5)$$

$$o_{pj} = f_i(net_{pj}) \quad (6)$$

여기서, o_{pi} 는 은닉층의 출력값이고, w_{ji} 는 은닉층과




Fig. 1 A Schematic representation of ANN

입력층의 연결강도이며, θ_i 는 은닉층의 임계값을 나타낸다. 은닉층에서 출력층의 출력값도 위와 같은 과정을 통하여 계산된다.

본 연구에서 사용된 활성화 함수, $f(x)$,는 다음과 같은 수정된 시그모이드 함수(Sigmoid Function)를 사용하였다.

$$f(x) = \frac{1}{1 + e^{-(x/t)}} \quad (7)$$

여기서, t 는 시그모이드 함수의 기울기를 크게하여 수렴속도를 향상시키기 위해 고안되었다.⁽¹⁷⁾

후향단계는 전향단계에서 계산된 실제 출력과 목적값과의 오차를 계산하여 연결가중치를 조절한다. 전체 오차 함수는 다음과 같이 정의 된다.

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_k (T_{pk} - O_{pk})^2 \quad (8)$$

여기서, 아래 첨자 p 는 학습패턴을 나타내며 T_{pk} 는 p 학습패턴의 k 번째 목적값이고 O_{pk} 는 그때의 계산되어진 실제 출력값을 나타낸다. 이 오차에 대한 최급하강법(Steepest Descent Method)에 의하여 가중치의 증분량을 계산하면 다음과 같다.

$$\Delta_p w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} \quad (9)$$

$$= \eta \delta_{pk} O_{pj} \quad (10)$$

여기서, η 는 학습률(Learning Rate)이고 0과 1사이의 값을 가진다.

δ_{pk} 은 아래의 식으로 계산된다.

$$\begin{aligned} \delta_{pk} &= (T_{pk} - O_{pk})f'(net_{pk}) \\ &= (T_{pk} - O_{pk})O_{pk}(1 - O_{pk}) \end{aligned} \quad (11)$$

은닉층과 입력층의 가중치 증분량도 위와 같은 방법으로 계산되며, 그때의 δ_{pj} 의 계산식은 다음과 같다.

$$\begin{aligned} \delta_{pj} &= f'(net_{pi}) \sum_k \delta_{pk} w_{kj} \\ &= O_{pj}(1 - O_{pj}) \sum_k \delta_{pk} w_{kj} \end{aligned} \quad (12)$$

수렴속도의 향상과 이전의 연결 강도 변화를 반영하기 위해 모멘텀항을 도입하여 아래와 같은 가중치 증분량식 도입하였다.

$$\Delta_p w_{kj}(n) = \eta \delta_{pk} O_{pj} + \alpha \Delta_p w_{kj}(n-1) \quad (13)$$

여기서, α 는 모멘텀의 크기를 제어하는 상수로 0과 1사이의 값을 가지며, n 은 신경망의 학습 반복 횟수를 나타낸다.⁽¹⁶⁾

3. 선재 인발 공정 설계

인발공정에서 사용된 소재는 AISI 1010이며 소재에 대한 압축실험을 하여 다음과 같은 응력-변형을 관계식을 얻었다.⁽¹⁸⁾

$$\bar{\sigma} = 715.93\epsilon^{0.22} (MPa) \quad (14)$$

초기 직경과 최종 직경이 주어진 두 개의 다이스를 이용한 선재 인발공정을 Fig. 2에 간략히 나타내었고, 시뮬레이션에 사용된 공정변수 조건을 Table 1에 나타내었다. 단면 감소율은 각 다이스에서 단면 감소율 변화에 따른 성형하중의 변화를 살펴보기 위하여, 두 번째 다이스의 단면

감소율에 대한 첫 번째 다이스의 단면감소율 비(Ratio)로 정의된 단면 감소율 상수 R 을 두어 하나의 설계변수로써 고려하였다.

$$R = \frac{D_i^2(D_m^2 - D_f^2)}{D_m^2(D_i^2 - D_m^2)}, \quad (R = \frac{R2}{R1}) \quad (15)$$

여기서 $R1$ 은 첫 번째 다이스의 단면감소율이며, $R2$ 는 두 번째 다이스의 단면감소율을 나타낸다. 다이스 사이의 간격과 랜드부의 길이는 일정하게 두어 그 영향은 고려하지 않았다. Table 2에는 설계변수로 고려한 단면 감소율 상수 R , 첫 번째 다이반각 α_1 , 두 번째 다이반각 α_2 그리고 마찰계수의 각 수준(Level)에 해당하는 변수값을 나타내었다. 실제 선재 인발공정에 사용되는 설계변수 범위⁽²⁾에서 첫 번째 다이스의 단면감소율에 대한 두 번째 다이스의 단면감소율을 2배에서 0.5배까지 고려하였고, 다이반각은 각각 $6^\circ \sim 10^\circ$, 마찰 계수는 0.1~0.2의 범위에서 고려하였다. 실험계획법은 고려한 설계변수 수준에서만 최적의 설계변수조합을 선정하게 되므로, 설계목적에 보다 적합한 설계변수조합을 신속히 선정하기 위해서는 설계변수 수준간의 간격은 좁아야 하며 수준수도 작아야 한다. 그러나 설계변수의 수준은 그 수가 증가할수록 시뮬레이션의 횟수도 증가하는 단점을 가진다. 본 연구에서는 신경망의 학습능력으로 보다 신속히 그리고 보다 넓은 설계변수범위에서 성형하중을 최소화하는 최적의 설계변수조합을 얻기 위하여 각각의 설계변수를 고려한 변수 값 범위내에서 등 간격의 3수준으로 선정하였다.

4. 시뮬레이션 결과 및 고찰

4.1 통계학적 해석

본 연구에서 사용한 직교배열표는 라틴방격법⁽¹⁴⁾에 따른 $L_{27}(3^{13})$ 이다. 여기서 하첨자 27은 시뮬레이션의 횟수를,




Fig. 2 A schematic sketch of wire drawing process

Table 1 Condition of process parameters

Condition	Process	1 Pass	2 Pass
Half die angle(°)		6~10	6~10
Initial workpiece diameter (Di : mm)		4.7	D _m
Final workpiece diameter (Df : 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≤m≤1)		0.1~0.2	
Die distance(L : mm)		30	

Table 2 Levels of design parameters

Parameters	Constant of percent reduction in area(R)	Half die angle($\alpha 1$)	Half die angle($\alpha 2$)	Friction (m)
Levels				
1	2	6	6	0.1
2	1	8	8	0.15
3	0.5	10	10	0.2

팔호안의 3은 설계변수의 수준수를, 삼첨자 13은 직교배열표상의 열(Column)수를 나타낸다. 직교배열표와 이에 따라 시뮬레이션을 수행한 후 각각의 성형하중값을 Table 3에 나타내었다.

분산분석표를 작성하여 Table 4에 나타내었다. 비교적

적은 효과를 가지는 변수간의 교호작용은 에리항에 포함시켰다. 그 결과 모든 설계변수의 검정값(F)은 1보다 큰 수치를 가지므로 유의한 인자로 생각할 수 있다. 설계변수 및 설계변수의 교호작용 그리고 오차에 대한 분산값을 Fig. 3에 나타내었고, 설계변수 수준에서의 평균하중값을

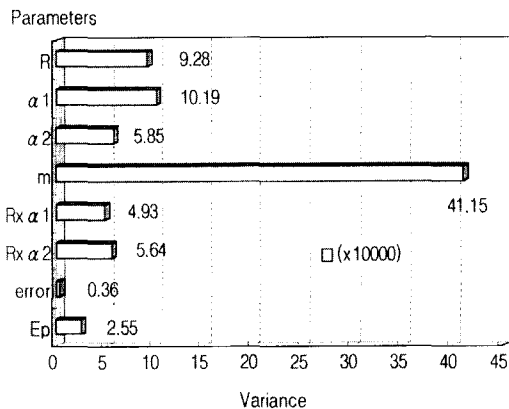


Fig. 3 Analysis of variance




Fig. 4 Average load by level

Table 3 $L_{27}(3^{13})$ Orthogonal array table and load data

Trial no.	Design parameters				FE-simulation
	R	$\alpha 1$	$\alpha 2$	m	
	Column no.				
	1	2	5	10	Load data(N)
1	1	1	1	1	3587.298
2	1	1	2	2	3832.535
3	1	1	3	3	3928.423
4	1	2	1	2	4130.364
5	1	2	2	3	4295.264
6	1	2	3	1	3785.400
7	1	3	1	3	4515.704
8	1	3	2	1	3891.978
9	1	3	3	2	4064.863
10	2	1	1	3	3831.373
11	2	1	2	1	3477.267
12	2	1	3	2	3817.351
13	2	2	1	1	3413.667
14	2	2	2	2	3830.880
15	2	2	3	3	4069.429
16	2	3	1	2	3841.176
17	2	3	2	3	4202.655
18	2	3	3	1	4018.306
19	3	1	1	2	3710.237
20	3	1	2	3	4060.996
21	3	1	3	1	3810.271
22	3	2	1	3	3777.071
23	3	2	2	1	3617.939
24	3	2	3	2	3990.661
25	3	3	1	1	3410.586
26	3	3	2	2	3844.547
27	3	3	3	3	4178.150

Fig. 4에 나타내었다. 여기서 성형하중에 가장 큰 영향을 미치는 설계변수는 마찰이었고, $\alpha 1$, R, $\alpha 2$ 순으로 나타났다. 성형하중을 최소로 하는 각 설계변수수준의 값은

$R=0.5$, $\alpha 1=6^\circ$, $\alpha 2=6^\circ$, $m=0.1$ 이었다. 그리고 95%의 신뢰구간을 잡아 공정평균 예측치를 구하면 3.422 ± 0.194 (kN)이었다.

Table 4 ANOVA Table

Effects	Parameters	Average load by level(N)			Sum of squares	Degree of freedom	Mean square	F ratio
		1	2	3				
Main effects	R	4003.5	3833.6	3822.3	185621.3	2	92810.6	3.6 †
	$\alpha 1$	3783.9	3878.9	3996.4	203901.1	2	101950.5	4.0 †
	$\alpha 2$	3801.9	3894.9	3962.5	117023.1	2	58511.5	2.3
	m	3668.1	3895.8	4095.5	823103.3	2	411511.6	16.1 †
Interaction effects	*Rx $\alpha 1$				197302.5	4	49325.6	
	*Rx $\alpha 1$				225717.2	4	56429.3	
Error	error				36437.1	10	3643.7	
	Ep				459456.8	18	25525.4	
Total					1789105.5	26		

Note : Ep indicate pooled error
 * indicate pooling
 † At least 95% confidence
 ‡ At least 99% confidence

통계학적 해석을 통해 찾아낸 최소성형하중을 갖는 설계변수조합으로 유한 요소 시뮬레이션을 수행한 결과, 그 조합이 가지는 성형하중은 3.450(kN)이었으며, 이것은 시뮬레이션한 결과 중에서 가장 낮은 성형하중이었고, 공정평균 예측치와 거의 일치하였다.

4.2 인공신경망 해석

인공신경망의 학습 데이터를 선정하는 데에는 세심한 주의가 요구된다. 어떠한 데이터로 인공신경망을 학습시키느냐에 따라 학습되지 않은 임의의 데이터에 대한 목적값과 신경망의 학습으로 얻어진 실제 출력값이 차이를 보일 수 있기 때문이다. 본 연구에서는 인공신경망의 학습데이터를 선정하기 위해 통계학적 해석에서 사용한 동일한 직교배열표를 이용하였다. 사용된 인공신경망은 감독학습의 역전파 학습 알고리즘으로써, 4개의 뉴런을 갖는 하나의 입력층과 1개 뉴런을 갖는 출력층, 그리고 각각 20, 20, 10, 5개의 뉴런을 갖는 4개의 은닉층 구조로 수행하였다.

Fig. 5에 인공신경망을 이용한 해석과정을 나타내었다. 여기서 특성치, 즉 목적함수는 성형하중이다. 먼저 직교배열표의 설계변수조합으로 유한요소해석을 한다. 그런 다음 직교배열표상의 설계변수조합을 입력층 뉴런값으로 하고, 유한요소해석으로 얻은 성형하중값을 출력층 뉴런값으로하여 인공신경망 프로그램을 학습한다. 만약 수렴하지 않을 경우 은닉층의 수나 은닉층의 뉴런의 수를 달리하

는 방식으로 프로그램의 구조를 수정하였고, 학습후 유한 요소해석을 수행하여 결과를 검증한다. 수렴 조건은 실제 출력값과 목적값의 차이(Root Mean Square Error)가 10^{-7} 에 도달할 때 까지로 하였고, 그 때의 학습 반복횟수는 40850회였다. 그 수렴과정을 Fig. 6에 나타내었다. 신경망의 학습속도를 개선하기 위하여 식(13)의 학습률 η 와 모멘텀계수 α 를 달리하여 수행해 보았으며, η 는 0.1, α 는 0.9로 하고, 식(17)의 t 는 0.9로 하였을 때 한계오차에 보다 빨리 수렴하는 것으로 나타났다.

Table 5에 직교배열표를 이용한 인공신경망의 학습데이터와 그 출력값을 나타내었다. Table 5에서 알 수 있듯이, 인공신경망의 학습으로 얻은 실제 출력값은 유한요소 해석으로 얻은 성형하중, 즉 목적값과 거의 일치하였으며, 이로써 인공신경망의 학습이 잘 되었음을 알 수 있었다.

학습된 인공신경망의 가중치값과 임계치를 이용하여 1200개의 설계변수조합에 대한 인공신경망의 출력값을 Fig. 7에 나타내었다. 이 1200개의 데이터는 단면감소율 상수 R을 2와 0.5 범위에서 등간격으로 열 여섯 수준, 다이아각 $\alpha 1$ 과 $\alpha 2$ 를 각각 6° 와 10° 범위에서 다섯 수준 그리고 마찰은 그대로 세 수준으로 하였을 때 만들 수 있는 설계변수조합이다. 이러한 설계변수조합들 중에서 최소 성형하중을 가지는 조합은 $R=1, \alpha 1=6^\circ, \alpha 2=6^\circ, m=0.1$ 이며 이 조합으로 예측한 성형하중은 3.384(kN) 이었고 통계학적 해석으로 찾아낸 최소성형하중보다 더 적은 값이었다.

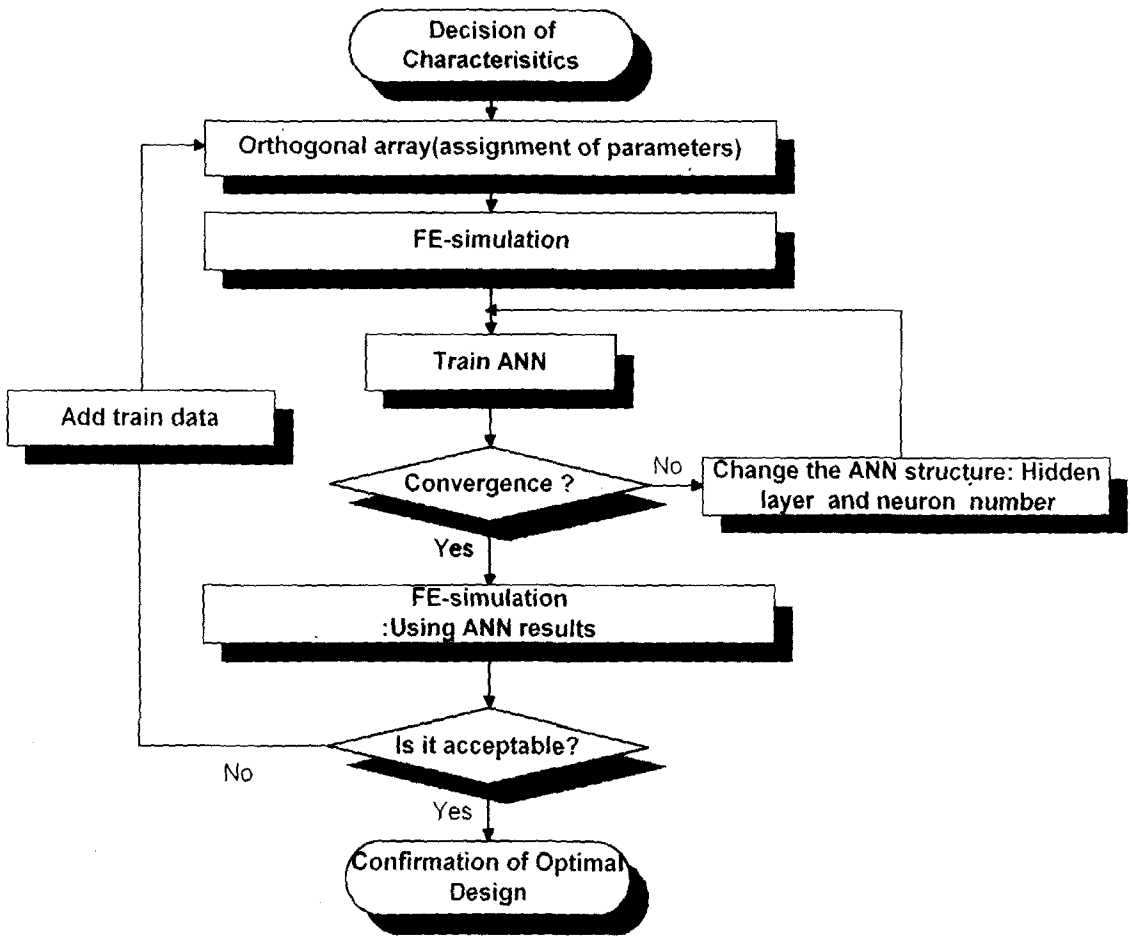


Fig. 5 Flow chart of the process design using ANN




Fig. 6 Root mean square error of ANN

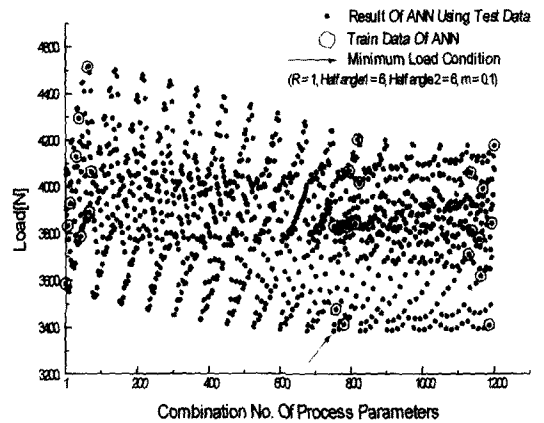


Fig. 7 Outputs of ANN using test data

Table 5 Orthogonal array table and results of ANN

No.	ANN input data					ANN output data
	Input layer				Output layer	After train
	R	$\alpha 1$	$\alpha 2$	m	FEM(load:N)	ANN(load:N)
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
4	2	8	6	0.15	4130.364	4130.121
5	2	8	8	0.2	4295.264	4294.949
6	2	8	10	0.1	3785.400	3785.197
7	2	10	6	0.2	4515.704	4515.520
8	2	10	8	0.1	3891.978	3891.718
9	2	10	10	0.15	4064.863	4064.604
10	1	6	6	0.2	3831.373	3831.187
11	1	6	8	0.1	3477.267	3476.936
12	1	6	10	0.15	3817.351	3817.115
13	1	8	6	0.1	3413.667	3413.629
14	1	8	8	0.15	3830.880	3830.938
15	1	8	10	0.2	4069.429	4069.126
16	1	10	6	0.15	3841.176	3840.611
17	1	10	8	0.2	4202.655	4202.313
18	1	10	10	0.1	4018.306	4018.011
19	0.5	6	6	0.15	3710.237	3710.031
20	0.5	6	8	0.2	4060.996	4060.803
21	0.5	6	10	0.1	3810.271	3810.066
22	0.5	8	6	0.2	3777.071	3776.859
23	0.5	8	8	0.1	3617.939	3617.798
24	0.5	8	10	0.15	3990.661	3990.469
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

4.3 비교 및 고찰

Table 6에는 통계학적 해석 및 인공신경망으로 찾아낸 최소성형하중을 갖는 설계변수 조합으로 유한요소해석하

여 각 경우의 인공신경망 예측치와 비교하였다. 그 결과 인공신경망으로 예측한 성형하중이 유한요소해석 결과와 아주 잘 일치함을 확인하였다. 마찬가지로 학습되지 않은

임의의 설계변수조합에 대해서도 인공신경망의 예측치와 유한요소해석 결과는 1%미만의 에러를 가지며 잘 일치하였다. 따라서 인공신경망의 학습으로 통계학적 해석보다 더 적은 성형하중을 갖는 설계변수조건을 찾을 수 있었다. 이것은 신경망이 가지는 능력으로 통계학적 해석에서 무

시되기 쉬운 교호작용의 영향까지도 고려되었다고 생각된다. 또한 신경망의 학습을 통해 임의의 설계변수조합의 성형하중도 예측할 수 있었다.

Fig. 8은 인공신경망을 적용하여 찾아낸 최소성형하중 조건으로 유한요소 시뮬레이션하여 그때의 유효 응력과

Table 6 Comparison between ANN and FEM results

Condition	Design parameters				Load FEM(N)	Load ANN(N)	error (%)
	R	$\alpha 1(^\circ)$	$\alpha 2(^\circ)$	m			
Test condition	2	9	6	0.2	4430.245	4446.734	0.37
Test condition	0.8	7	9	0.1	3669.527	3672.119	0.07
Statistical Opt. Condition	0.5	6	6	0.1	3450.347	3424.140	0.75
ANN Opt. Condition	1	6	6	0.1	3367.227	3384.429	0.51




Fig. 8 Stress and strain distribution in two-step wire drawing




Fig. 9 The effects of process parameters on the load

변형률을 나타내었다. 이 그림에서 나타나 있듯이 소재가 두 번째 다이스의 랜드부에서 가장 큰 변형과 응력값을 가짐을 볼 수 있다.

본 연구에서 고려한 각각의 설계변수가 성형하중에 미치는 영향을 살펴보면, 마찰 값이 변할 때 성형하중 차이가 가장 심하였다. 그래서 마찰값을 일정하게 두어 각 설계변수의 영향을 살펴보았다. 마찰을 0.1로 두고 가로축을 단면감소율 상수 R , 세로축을 성형하중으로 하여 Fig. 9에 나타내었다.

여기서 알 수 있는 것은 두 번째 다이스의 다이반각이 6° 이고 첫 번째 다이스의 단면 감소율이 두 번째 다이스의 단면 감소율 보다 클 때 비교적 낮은 성형하중이 분포한다는 사실이었다. 또한 첫 번째 다이스의 다이반각이 두 번째 다이스의 다이반각 보다 클 경우에는 첫 번째 다이스의 단면 감소율이 두 번째 다이스의 단면 감소율 보다 클 수록, 반대의 경우인 첫 번째 다이스의 다이반각이 두 번째 다이스의 다이반각 보다 작을 경우에는 첫 번째 다이스의 단면 감소율이 두 번째 다이스의 단면 감소율 보다 작을 수록 낮은 성형하중을 가진다는 것을 알 수 있었다.

5. 결 론

본 연구에서는 직교배열표와 인공신경망을 이용한 새로운 공정설계기법을 제시하였다. 그리고 이러한 방법을 초기 직경과 최종 직경이 주어진 선재 인발공정에 적용하여 다음과 같은 결론을 얻었다.

(1) 통계학적 실험계획법을 통하여 설계변수간의 주요

과 및 교호작용효과를 알 수 있었고, 고려한 설계변수에서 성형하중에 영향을 미치는 것은 마찰, 첫 번째 다이반각, 단면감소율 상수, 두 번째 다이반각 순으로 나타났다.

(2) 직교배열표와 인공신경망을 이용하여 최소의 성형하중을 갖는 설계변수조건을 찾을 수 있었고 고려한 설계변수 범위에서 임의의 설계변수조합에 대한 성형하중도 예측할 수 있었다. 이로써 보다 넓은 범위의 학습이 가능하였음을 알 수 있었으며, 학습 후 만족할 만한 결과를 얻을 수 있었다.

(3) 직교배열표를 이용함으로써 많은 수의 유한요소해석을 줄일 수 있고, 인공신경망을 도입함으로써 미해석 부분의 값까지도 예측할 수 있으므로 다단계 금속성형공정의 공정설계에 유용하게 적용될 수 있으며, 그 응용 범위 또한 넓을 것으로 생각된다.

후 기

본 연구는 부산대학교 정밀정형 및 금형가공 연구센터를 통한 한국과학재단 우수연구센터 지원금에 의한 것입니다.

참고문헌

- (1) J.J.Park, N.Rebello 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) B.Avitur, "Analysis of Central Bursting Defects in Extrusion and Wire Drawing", Transactions of the ASME, Series B, 1970.
- (3) Tisza, "A Knowledge Based Expert System for Wire-Drawing Processes", Advanced Technology of Plasticity, 1990.
- (4) B.stok and A.Mihelic, "Optimal Design of Multi-Step Extrusion/Drawing Processes", Advanced Technology of Plasticity, 1996.
- (5) D.F.Carbaugh and J.L.Frater, "A Factorial Analysis of Input Parameters Using Finite Element Techniques", J. Mater. Shaping Technology, 1991.
- (6) K.Osakada and G.Yang, "Applocation of Neural Networks and Expert System for Cold Forging"

- Int. J. Mach. Tools. Manu., Vol. 41, No. 4, pp. 577~587, 1991.
- (7) 김동진, 김병민, 최재찬, "신경망을 이용한 열간단조품의 초기소재 설계", 한국정밀공학회 논문집, Vol. 12, No. 11, p. 118, 1995.
- (8) Y.Peng, X.Ruan, F.Zhou and Z.Wang, "Defects Prediction During Metal Forming Process by FEM", Advanced Technology of Plasticity, 1996.
- (9) R.P.Lippmann, "An Introduction to Computation with Neural Nets" IEEE ASSP Magazine, Vol. 2, pp. 4~22, 1987.
- (10) H.T.Fan, "Case Studies on Modeling Manufacturing Processes Using Artificial Neural Networks", Transactions of the ASME, Vol. 117, AUGUST, 1995.
- (11) G.E.P.Box, W.G.Hunter and J.S.Hunter, Statistics for Experimenters, New York, John Wiley. 1978.
- (12) J.P.Tang and W.T.Wu, DEFORM 2D User Manual Ver. 4.0, SFTC, USA, 1994.
- (13) K.Hinkelmann and O.Kempthorne, Design and Analysis of Experiments, New York, John Wiley, 1994.
- (14) 박성현, 현대실험계획법, 민영사, 1995.
- (15) 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.
- (16) 김대수, 신경망 이론과 응용(I), 하이테크정보, 1993.
- (17) A.S.Pandya and R.B.Macy, Pattern Recognition with Neural Networks in C++, CRC Press, 1996.
- (18) 김태형, "냉간 금속성형제품의 정밀도 향상을 위한 유한 요소법의 활용", 부산대학교 대학원 박사학위논문, 1997.