

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

신경망과 실험계획법을 이용한 열간 단조품의 공정설계

김 동 환*, 김 동 진**, 김 호 관***, 김 병 민*, 최 재 찬*

Process Design of a Hot Forged Product Using the Artificial Neural Network and the Statistical Design of Experiments

D.H.KIM*, D.J.KIM**, H.K.KIM***, B.M.KIM*, J.C.CHOI*

ABSTRACT

In this research, we have proposed a new technique to determine the combination of design parameters for the process design of a hot forged product using artificial neural network(ANN) and statistical design of experiments(DOE). The investigated problem involves the adequate selection of the aspect ratio of billet, the ram velocity and the friction factor as design parameters. An optimal billet satisfying the forming limitation, die filling, load and energy as well as more uniform distribution of effective strain, is determined by applying the ability of artificial neural network and considering the analysis of mean and variation on the functional requirement. This methodology will be helpful in designing and controlling parameters on the shop floor which would yield the best design solution.

Key Words : Artificial Neural Network(인공신경망), Design of Experiments(실험계획법), Orthogonal Array Table(직교배열표), Process Design(공정설계), Hot Forging(열간 단조), Die Filling(금형내부채움), Forming Energy(성형 에너지), Deviation Strain(변형률 편차량)

1. 서 론

밀폐형 단조 공정설계에서 가장 중요한 사항은 적절한 금속유동을 얻기 위한 최적의 예비 성형체를 설계하는데 있다. 이러한 밀폐 단조공정에서 금형 내부를 충만 시키고 금속유동결함 및 연성과괴를 일으키지 않는 최적의 예비 성형체를 결정하기 위해 N. Alberti⁽¹⁾ 등은 성형경로를 역추적 하여 예비 성형체를 바꿔가면서 유한요소 해석을 반복 수행하였다. 그리고 Lanka⁽²⁾ 등은 평면변형 리

브-웹브 제품의 공정수와 각 금형 형상의 설계과정을 개발하기 위해 등각 사상(conformal mapping)기법을 이용하여 예비 성형체를 유한요소 해석으로 예측하였다. 그러나 유한요소법을 이용한 공정설계에서도 공정의 최적화를 위해서는 시행착오적인 시뮬레이션 절차는 반드시 필요하며, 이로 인한 시행착오를 줄이기 위해서는 설계 이전에 금속성형 및 설계자의 설계목적에 미치는 공정변수의 영향을 아는 것이 필수적이고 보다 효율적인 설계기법의 연계가 절실히 요구된다.

* 부산대학교 정밀 정형 및 금형가공 연구센터
 ** 부산대학교 기계 기술연구소
 *** 부산지방중소기업청 조선기자재시험연구센터

이러한 요구를 만족시키기 위하여, 최근에 인공지능, 신경망 그리고 유전자 알고리즘과 같은 설계기법을 급속성형의 공정설계에 적용해 오고 있다. Osakada⁽³⁾ 등은 냉간 단조 공정설계를 위하여 유한요소 해석으로 얻어진 데이터를 신경망의 형상 분류 능력을 이용하여, 이것을 전문가 시스템에 적용함으로써 미세석 공정조건에 대한 제품 결함 및 금형의 파손 여부를 예측하였고, 김⁽⁴⁾ 등은 신경망의 함수근사(function approximation) 능력을 이용하여 금형내 충만성을 만족하는 초기소재형상을 예측하였다. 그러나 신경망을 이용하는 방법에 있어서 초기에 학습데이터를 선정하는 뚜렷한 방법을 제시하지 못하였고 학습결과도 학습 데이터의 수에 따라 차이를 보이는 문제가 있다.

양⁽⁵⁾ 등은 임의의 두 가지 초기 형상에 대한 유한요소 해석 결과를 이용하여 퍼지 로직을 이용한 전방 투사법에 적용하여 금형내의 재료 충만성을 만족하는 초기 소재의 형상을 제안함으로써 유한요소 해석의 횟수를 줄이고자 하였다.

Carbaugh⁽⁶⁾ 등은 제트엔진 디스크 단조를 해석하기 위해 속도, 마찰, 변형을 속도 경화지수의 세 가지 설계변수에 대한 두 수준(level)의 요인배치법(factorial analysis)에 따라 유한요소 해석하여 각 설계변수가 성형하중에 미치는 영향을 Yates's 알고리즘으로 정량적으로 표

현하였다. 정⁽⁷⁾ 등은 금형 수명의 연장 측면에서 단조 공정에 사용되는 주요인자들을 최적화하기 위한 방법으로 수정 미세 유전알고리즘을 이용하였으며, Roy⁽⁸⁾ 등은 유전알고리즘을 이용한 다이 형상, 단면감소율, 성형 단계수를 최적화 하는 기법을 다단계 급속성형공정에 적용하였다. 그러나 인공지능 기술은 모든 가능한 경우를 확인하여 옳은 답을 얻는데 효과적이지만 옳은 답을 찾는 데 많은 시간이 걸리며, 실험계획법은 설계자가 미리 정한 변수값에서 변수들의 최적조합만을 선정하므로 보다 나은 설계변수값을 정하는 것은 어렵다. 그리고 유전알고리즘은 목적함수를 구하기 위해 소요되는 시간이 많을 경우 많은 반복계산에 따른 전체적인 컴퓨터 소모시간이 문제가 될 수 있다.

따라서, 보다 신속하게 설계자가 고려하지 못한 변수값에서도 최적의 설계변수 조합을 선정할 수 있는 설계기법이 요구된다. Fig. 1에는 (1)신경망과 F.E-simulation을 이용하는 방법 (2)실험계획법과 F.E-simulation을 이용하는 방법 (3)신경망과 실험계획법 그리고 F.E-simulation을 이용하는 방법에 관해 도시하였다. 신경망과 실험계획법 그리고 F.E-simulation을 이용하면 신경망의 학습 후, 미세석된 설계변수 조합에 대한 목적함수를 예측할 수 있으므로 설계변수의 다 수준(level) 영역에 대한 실험 및 시뮬레이션 효과를 얻는 것이 가능하다.

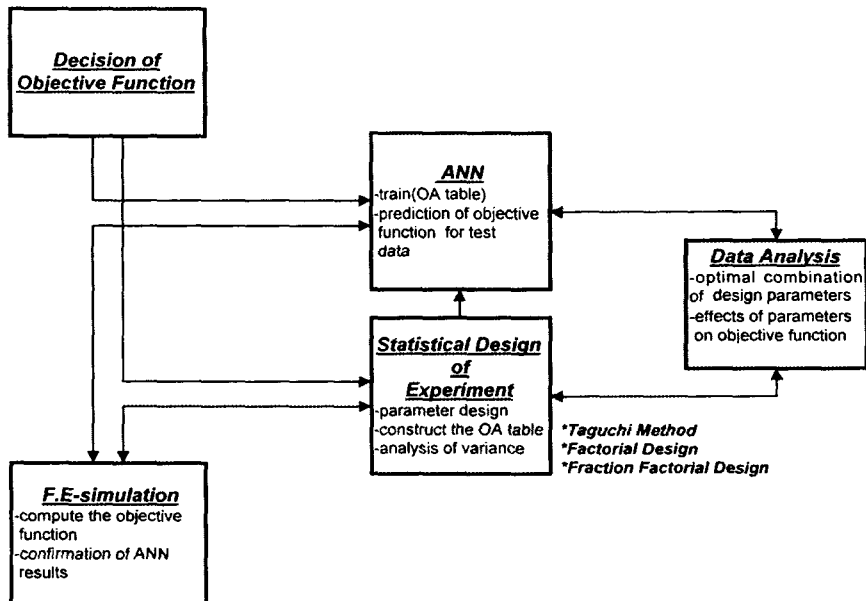


Fig. 1 Schematic arrangement of process design

본 연구의 목적은 신경망, 실험계획법 그리고 유한요소법을 이용한 새로운 금속성형의 공정설계기법을 제시하고, 이러한 설계기법을 리브-웨이브형 열간 단조품의 공정설계에 적용하여 그 유용성을 알아보는 것이다. 목적함수로는 금형 내부의 소재 층만성과 성형 에너지, 변형률 분포로 하였으며, 이러한 세 가지 목적함수에 가장 적합한 최적의 설계변수 조합을 얻고자 하였다. 설계변수는 소재 형상비(소재 높이/반지름), 램 속도, 마찰로 하였고, 해석은 상용 강소성 유한요소 코드인 DEFORM⁽⁹⁾을 이용하였다.

2. 신경망과 실험계획법을 이용한 공정설계

2.1 신경망 이론

Rumelhart⁽¹⁰⁾가 제안한 다층 퍼셉트론(multilayer perceptron)신경망은 비선형 문제, 형상 분류, 인식, 제어 등의 분야뿐만 아니라 근래에 와서는 함수근사까지 그 응용범위가 확대되었고, 그 능력 또한 우수하다⁽¹¹⁾. 다층 퍼셉트론 신경망은 크게 입력층, 은닉층, 그리고 출력층으로 구성되어 있으며, 감독학습의 역전파 학습 알고리즘에 의해 학습된다. 역전파 학습 알고리즘의 학습단계는 크게 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 후 활성화 함수를 거쳐 계산되며, 본 연구에서 사용된 활성화 함수, $f(x)$ 는 다음과 같은 수정된 시그모이드 함수(sigmoid function)를 사용하였다.

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

식(1)에서, t 는 시그모이드 함수의 기울기를 크게 하여 수렴속도를 향상시키기 위해 고안되었다⁽¹²⁾.

후향단계는 전향단계에서 계산된 실제 출력과 목적값과의 오차를 계산하여 연결가중치를 조절한다. 전체 오차함수는 E 는 다음과 같이 정의된다.

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

식(2)에서, 아래 첨자 p 는 학습패턴을 나타내며 T_{pk} 는 p

학습패턴의 k 번째 목적값이고 O_{pk} 는 그때의 계산되어진 실제 출력값을 나타낸다.

수렴속도의 향상과 이전의 연결 강도 변화를 반영하기 위해 모멘텀항을 도입하여 아래와 같은 가중치 증분방식을 이용하였다.

$$\Delta_p w_{kj}(n) = \eta \delta_{pk} O_{pj} + \alpha \Delta_p w_{kj}(n-1) \quad (3)$$

식(3)에서, $\Delta_p w_{kj}(n)$ 는 가중치 증분량이며 $\Delta_p w_{kj}(n-1)$ 는 이전의 가중치를 나타낸다. 하첨자 k 는 출력층 유니트이며 j 는 그 이전층의 유니트를 나타낸다. 그리고 δ_{pk} 는 출력층 유니트 k 의 오차에 대한 오차를 말하며, α 는 모멘텀의 크기를 제어하는 상수로 0과 1사이의 값을 가진다. 그리고 η 는 학습률(learning rate), n 은 신경망의 학습 반복 횟수를 나타낸다.

2.2 실험계획법

기존의 실험 및 시뮬레이션에서는 한번의 실행으로 하나의 설계변수가 측정데이터에 미치는 영향을 평가한다. 그러나 통계학적 실험계획법은 최소의 실험이나 시뮬레이션으로 고려한 설계변수 범위에서 설계변수만의 주효과(main effect) 및 설계변수간의 교호작용(interaction effect)효과를 알아봄으로써, 설계목적에 맞는 최적의 설계변수 조합을 얻는데 그 목적이 있다. 실험계획을 하는데 사용되는 직교배열표는 설계변수간에 직교성(orthogonality)을 갖도록 하여 같은 실험횟수라도 검출력이 더 좋은 검정을 할 수 있으며, 설계목적에 맞게 고려한 설계변수의 수준에서 설계변수가 목적함수에 미치는 영향을 독립적으로 측정되게 하여 설계자가 원하는 설계변수 및 설계변수간의 교호작용효과를 알 수 있도록 만들어진 표이다⁽¹³⁾. 직교배열표를 사용하는 목적은 실험 및 시뮬레이션의 결과로부터 요인 변동의 계산이 편리하고 분산분석표의 작성을 수월하게 하기 위함이며, 실험을 확대시키지 않고도 실험에 많은 인자를 넣을 수 있고 실험 및 시뮬레이션의 수행이 용이하기 때문이다.

2.3 실험계획법을 이용한 신경망의 적용

실험계획법을 이용함에 있어서 설계변수의 수준수(number of level)를 정하는데 제약이 따른다. 설계변수의 수준수를 많이 하면 설계목적에 좀 더 적합한 설계변수 조합을 얻을 수는 있지만, 실험 및 시뮬레이션의 횟수가 증가하므로 설계자는 해석시간을 줄이기 위해서 가끔

적 각 설계변수의 수준수를 작게 하고 공정설계 이전에 전문가적인 경험과 설계지식을 통하여 설계변수의 적절한 값의 범위를 짐작할 수 있어야 하며 또한 변수 수준간의 폭도 좁아야 한다. 이러한 실험계획법이 가지는 단점을 보완하고 장점만을 이용하기 위하여 신경망을 적용하면 고려하지 못한 설계변수 조합이 가지는 목적함수를 예측할 수 있으므로 설계변수의 다 수준 영역에 대한 실험 및 시뮬레이션 효과를 얻는 것이 된다. 따라서 추가적인 데이터 해석 없이 설계목적에 맞는 최적의 설계변수 조합을 선정할 수 있으므로 신뢰성 있는 지식을 설계자에게 신속히 제공하게 된다.

공정설계 절차는 먼저, 여러 가지 성형공정 중에서 해석할 대상의 목적함수를 결정하고, 이러한 목적함수에 영향을 미치리라고 생각되는 설계변수 및 설계변수 수준을 선정하여 직교배열표를 구성한다. 직교배열표상의 설계변수 조합으로 유한요소 해석을 수행한 후, 목적함수를 고려한 최적의 설계변수 조합을 구하기 위하여, 직교배열표상의 설계변수 조합을 신경망의 입력데이터로 이용하고 목적함수를 신경망의 출력데이터로 하여 신경망 프로그램을 학습시킨다. 신경망의 학습으로 얻어진 연결가중치와 임계치를 이용하여 미해석 설계변수 조합이 갖는 목적함수를 예측하고, 이러한 결과를 검토한 후 최적의 설계변수 조합을 결정한다.

3. 리브-웹브형 열간 단조품의 공정 설계

유한요소 해석에 사용된 재료는 AISI-1045이며, 응력-변형을 속도의 관계는 Table 1⁽¹⁴⁾과 같고 소재와 금형의 열전달 계수는 Table 2에 나타내었다. 일반적으로 열간 단조에서는 플래쉬량을 소재 체적의 10%로 하지만⁽¹⁵⁾ 원하는 펀치 행정에 도달하기 전에 이미 금형 내부를 충만 시키며, 최근의 연구⁽⁴⁾에서 형상비만을 설계변수로 고려하였을 경우, 다이 내부를 완전히 채우는 형상비 범위를 기초로 하여 소재 체적의 6.5% 플래쉬량으로 초기 소

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

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

Material	Coeff. (N/sec ²)	Heat capacity (N/mm ²)	Convection coeff. (N/secmm ²)	Lubricant heat transfer coeff. (N/secmm ²)	Emissivity
Workpiece (AISI 1045)	74.93	3.602	0.005	30	0.3
Die (SKD61)	28.6	3.574			0.3

재 체적을 결정하였다.

본 연구에서는 리브-웹브형 열간 단조의 공정설계를 하기 위해 먼저 다이 내부를 완전히 채우면서 성형 에너지와 변형을 펀차가 적은 최적의 설계변수 조합을 찾기 위해 목적함수는 다이 내부의 소재 충만성, 성형 에너지 그리고 변형을 펀차량으로 하였다.

설계변수로는 형상비, 램 속도, 마찰상수로 하였으며 각 설계변수를 세 수준으로 나누어 그 수준의 값을 Table 3에 나타내었다. 형상비는 소재 체적의 7% 플래쉬량으로 하였을 경우⁽⁴⁾, 다이 내부를 채우는 형상비 범위보다 좀 더 넓게 0.6~1.0로 하였고 램 속도는 10mm/s~150mm/s, 마찰은 0.1~0.5내의 범위로 하였다.

본 연구에서 사용된 직교배열표는 L₉3⁴이다⁽¹⁰⁾. 여기서 하첨자 9는 시뮬레이션의 횟수를, 3은 설계변수의 수준수를, 상첨자 4는 직교배열표상의 열(column)수를 나타낸다.

Table 3 Levels of design parameters

Parameters Levels	Aspect ratio(H/R)	Velocity(mm/s)	Friction
1 (Low)	0.6	10	0.1
2 (Middle)	0.8	80	0.3
3 (High)	1.0	150	0.5

4. 유한 요소 해석

직교배열표상의 각 설계변수 조합으로 유한요소 해석을 수행하여 펀치 행정을 완전히 내렸을 때, 각 경우에 대한 미충만 체적량과 성형 에너지 그리고 변형을 펀차량을 계산하였다. 시뮬레이션 도중 격자가 심하게 변형되어 8~9번의 격자 재구성을 하였고, 이 때에 발생하는 체적손실을 감안하여 초기 소재 체적을 정함으로써 유한요소 해석 도중의 체적 손실을 최소화 하고자 하였다. 직교배열표에 따라 9번의 시뮬레이션을 수행한 후, 각 경우에 대한 미충만 체적을 Table 4에 나타내었다. 그 결과 No. 5의 설계변수 조합으로 시뮬레이션을 한 경우에만 다이 내부를

완전히 채우는 것을 알 수 있었다. Table 4에 각 설계변수 조합이 갖는 성형 에너지 및 변형을 편차량도 나타내었다. 여기서 다이 내부를 완전히 채우는 No. 5시물레이션의 경우에 동일한 형상비에서 비교적 성형 에너지가 크며, 이것은 Fig. 2에서 보는 것처럼 다이 내부를 완전히 채울 때 성형하중이 급격히 상승하고, 이로 인해 성형 에너지가 커지기 때문이다.

Table 4 Results of F.E-simulations for the combinations of design parameters and ANN input data

Trial no.	ANN(input values)				ANN(target values)		
	L9 OA inner array/control parameters				Objective functions		
	Aspect ratio	Velocity	Friction	-	(Characteristics)		
	Column no.				Unfilled cavity volume	Forming energy	Deviation strain
	1	2	3	4	(mm ³)	(KJ)	
1	1	1	1	1	11079.3926	96.308	0.366596
2	1	2	2	2	5720.1241	129.156	0.374582
3	1	3	3	3	4591.5403	152.746	0.400163
4	2	1	2	3	3950.3938	127.078	0.444156
5	2	2	3	1	0	156.397	0.461347
6	2	3	1	2	1740.9048	124.018	0.363786
7	3	1	3	2	10770.7621	160.809	0.531092
8	3	2	1	3	4336.1668	126.687	0.407363
9	3	3	2	1	1437.2153	156.511	0.421212

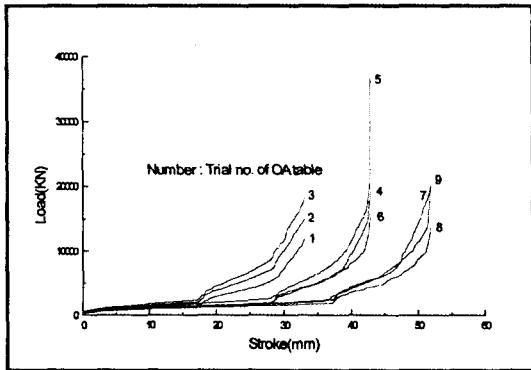


Fig. 2 The comparison of forming load with combinations of design parameter on orthogonal array table

5. 해석 결과 및 고찰

세 가지의 목적함수에 미치는 각 설계변수 영향을 평가하기 위해서 Table 5에 각 인자의 수준변동에 따른 목적함수의 변화를 보여주는 평균분석(analysis of mean: ANOM)결과를 나타내었다. Table 5(a)를 보면 고려한 각 설계변수 값에서 다이 내부 충만에 가장 큰 영향을 미치는 변수는 램 속도(sum of squares=6.424x E7)이고

Table 5 Analysis of mean value in hot forging process


Parameters	(a) Mean unfilled cavity volume variation			Sum of Squares
	Means			
	Level 1	Level 2	Level 3	
Aspect Ratio	7130.352333	1897.066203	5514.714733	4.308 x E7
Velocity	8600.182833	3352.096970	2589.853467	6.424 x E7
Friction	5718.788067	3702.577733	5120.767470	6.434 x E6

Parameters	(b) Mean forming energy variation			Sum of Squares
	Means			
	Level 1	Level 2	Level 3	
Aspect Ratio	126.07000	136.49767	148.00233	722.1
Velocity	128.06500	138.08000	144.42500	408.2
Friction	115.67100	137.58167	157.31733	2604.0


Parameters	(c) Mean deviation strain variation			Sum of Squares
	Means			
	Level 1	Level 2	Level 3	
Aspect Ratio	0.390447	0.422096	0.453222	0.8 xE-2
Velocity	0.447281	0.414431	0.395054	0.4 xE-2
Friction	0.379248	0.413317	0.464201	1.1 xE-2

다음은 형상비, 마찰이었다. Table 5(b),(c)에서 성형 에너지와 변형을 편차량에 가장 큰 영향을 주는 설계변수는 마찰이었고, 다음은 형상비, 램 속도였다. 각 설계변수의 수준에 따른 평균분석값을 점추정(point estimation) 방법으로 Fig. 3에 나타내었다. Fig. 3(a)를 보면, 다이 내부 충만성을 고려할 경우 형상비, 램 속도, 마찰이 각각 2수준, 3수준, 2수준일 때 비교적 미충만 체적량이 적다. 그리고 Fig. 3(b)에서 모든 설계변수가 제 1수준일 경우 성형 에너지가 적고, Fig. 3(c)에서 형상비와 마찰이 제 1수준, 램 속도가 3수준일 경우 변형을 편차량이 적은 것을 알 수 있다. 그러나 설계변수 수준간의 범위가 크므로 이 결과를 토대로 최적의 설계변수 조합을 선정하는 것은 무리이다.

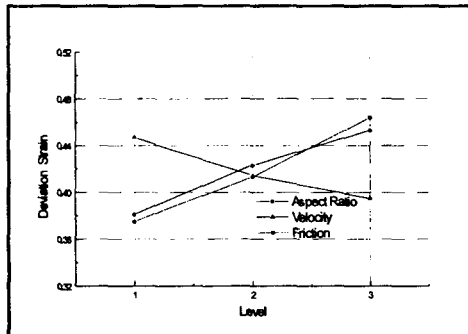
따라서 Table 4의 직교배열표의 데이터를 이용하여 신경망을 적용하였다. 먼저, 직교배열표의 설계변수 조합을 신경망의 입력값으로 하고 그 설계변수 조합이 가지는 목적함수, 즉 다이 내부의 미충만 체적량, 성형 에너지 그리고 변형을 편차량을 목적값으로 하여 각 목적값에 따라 세 개의 신경망 프로그램으로 학습시켰다. 학습 후, 각 신경망 프로그램의 가중치와 임계치를 이용하여 미해석 데이터, 즉 형상비를 0.6~1.0까지 0.1씩 등간격으로 세분화하여 이러한 형상비와 램 속도, 마찰이 가질 수 있는 설계변수 조합의 목적함수를 예측하여 보았다. Fig. 4에 미해석데이터의 다이 내부 미충만 체적량을 예측하여 나타내었다. 마찰이 0.1인 Fig. 4(a)경우는 다이 내부를 완전히 채우는 형상비의 범위가 존재하지 않으며, 마찰이



(a) mean unfilled cavity volume with control factors




(b) mean forming energy response with control factors




(c) mean deviation strain response with control factors


Fig. 3 Mean response of the control factors



(a) $m = 0.1$



(b) $m = 0.3$




(c) $m = 0.5$


Fig. 4 Prediction of unfilled cavity volume for test data using ANN 1

0.3인 Fig. 4(b) 경우는 램 속도가 150mm/s이고 형상비가 0.83~0.91일 경우 다이 내부를 완전히 채울 수 있음을 예측하였다. 그리고 마찰이 0.5인 Fig. 4(c)의 경우에는 램 속도가 80mm/s일 때는 0.74~0.79범위에서, 램 속도가 150mm/s일 때는 0.76~0.92의 형상비 범위에서 다이 내부를 완전히 채울 수 있음을 예측하였다. 여기서 알 수 있는 사실은 마찰이 증가할수록 플래쉬부로의


소재 유동보다 다이 내부 측면으로 소재 유동이 원활하였고, 따라서 다이 내부를 완전히 채우는 형상비의 범위가 증가하였다. 또한 램 속도가 증가할수록 소재에서 다이로의 열 전달량이 적어지고 축 방향의 소재 유동이 원활함을 볼 수 있었으며 다이 내부를 완전히 채우는 형상비의 범위도 증가하였다.




(a) $m = 0.1$




(a) $m = 0.1$




(b) $m = 0.3$



(b) $m = 0.3$



(c) $m = 0.5$



(c) $m = 0.5$

Fig. 5 Prediction of forming energy for test data using ANN 2

Fig. 6 Prediction of deviation strain for test data using ANN 3

Fig. 5와 Fig. 6에는 앞에서 사용한 동일한 미세석데이터를 이용하여 그 때의 설계변수 조합이 가지는 성형 에너지와 변형을 편차량을 각각의 학습된 신경망으로 예측한 결과를 나타내었다. Fig. 5를 보면, 동일한 형상비에서 마찰상수가 작을수록($m = 0.1$), 램 속도가 보다 작은 수준($v = 10$ mm/s)에서 성형 에너지가 적을 것임을 예측하였다. 그리고 Fig. 5(a),(b),(c)에서 마찰과 램 속

도가 동일한 조건일 때 형상비가 작을수록, 즉 소재 높이가 소재 반경보다 작은 값을 가질 때 성형 에너지가 적다. 이것은 소재 높이가 증가할수록 상부 다이에서 하부 다이까지의 행정거리가 길어지므로 같은 하중이라 하더라도 그 에너지는 증가하게 된다.

Fig. 6을 보면, 동일한 형상비에서 마찰상수가 작을수록($m = 0.1$), 램 속도가 비교적 클 때 ($v = 150$ mm/s)

변형을 편차량이 적을 것임을 예측하였다. Fig. 6(a),(b),(c)을 보면 마찰과 램 속도가 동일한 조건일 때 형상비가 작을수록 변형을 편차량도 작다. 이것은 본 연구에서 고려한 리브-웹형 단조품은 축 방향보다는 다이 반경 방향으로 변형이 심하였기 때문이다. 따라서 소재 높이가 증가할수록 변형을 편차량이 증가하게 된다.


Table 5에서 알 수 있듯이 성형 에너지와 변형을 편차량에 영향을 많이 미치는 마찰상수는 그 값이 작을 때 성형 에너지와 변형을 편차량이 적고, 비교적 이 두 목적함수에 미치는 영향이 적은 램 속도는 성형 에너지를 적게 하는 값을 가질 때 변형을 편차량을 크게 하는 요인이라는 것을 알 수 있다. 즉, 램 속도가 150mm/s 일 때 변형을 편차량과 다이 내부의 미충만 채적량은 적고 성형 에너지 값은 크지만, 램 속도가 성형 에너지에 미치는 영향은 Table 5(b)에 나타나 있듯이, 다른 설계변수가 성형 에너지에 미치는 영향보다 작다. 따라서 신경망의 예측결과를 기초로 하여 다이 내부를 완전히 채우면서 성형 에너지와 변형을 편차량이 적은 설계변수 조합을 선정하여 보면, 형상비가 0.83, 마찰상수가 0.3, 램 속도가 150mm/s이다. 본 연구에서 고려한 각 설계변수 범위 내에서 형상비만을 세분화하여 미해석 변수조합으로 나타내고, 이것만을 학습된 신경망으로 예측한 이유는 마찰상수와 램 속도는 각 목적함수에 미치는 영향이 거의 균일한 감소 또는 증가를 나타내었기 때문이다.

Table 6 Verification of ANN result using F.E-simulation


	Condition of Parameters	Unfilled cavity volume (mm ³)	Forming energy (KJ)	Deviation strain
ANN	H/R = 0.83 v = 150 (m/s)	0 (Full)	148,259	0.394
F.E.M simulation	m = 0.3	0 (Full)	153,560	0.386

신경망을 이용하여 찾아낸 최적의 설계변수 조합으로 유한요소 해석을 하여 신경망의 예측 결과를 검증하여 보았다. Table 6에는 신경망으로 찾아낸 설계변수 조합으로 시뮬레이션 하여 금형 내부의 소재 충만 여부 및 성형 에너지 그리고 변형을 편차량을 나타내었고, 신경망으로 예측한 각 목적함수값을 나타내어 유한요소 해석 결과와 비교하여 보았다. 먼저 이 변수조건으로 시뮬레이션 하였을 때 Fig. 7(b)에서 알 수 있듯이 금형 내부를 완전히 채우는 것을 확인하였고, Fig. 8에서 보여지듯이 유효변형률 분포가 비교적 균일하였다. Fig. 8에 알 수 있듯이

플래쉬부에서의 변형이 가장 심하였고 축 방향보다는 반경 방향으로 변형이 심함을 확인 할 수 있었다. Table 6에 나타나 있는 변형을 편차량도 신경망으로 예측한 값과 거의 일치하며 0.386의 비교적 작은 값을 가지고 있음을 알 수 있었다. 그러나 성형 에너지는 약간의 오차를 있었지만, 다이 내부를 채우는 시점에 따라 그 에너지량이 달라지므로 정확하게 예측하기란 어렵다고 생각한다. 이 조건과 직교배열표에서 금형내를 완전히 채우는 조건을 비교하여 보면, 신경망으로 찾아낸 설계변수 조합이 성형 에너지와 변형을 편차량 모두 적다는 것을 확인 할 수 있으며, 따라서 이러한 결과를 종합하여 보면 신경망 해석으로 찾아낸 조건 즉, 형상비가 0.83이고 속도가 150mm/s 그리고 마찰이 0.3인 경우가 본 연구에서 고려한 소재 손



(a) H/R=0.6, v=10mm/s, m=0.1 (No.1 on the orthogonal array table)



(b) H/R=0.830, v=150mm/s, m=0.3 (the condition of a select parameters)

Fig. 7 The FE-simulation of hot forging process at the various combinations of parameters

실이 적고 금형내를 완전히 충만 시키면서 동시에 성형 에너지 및 변형을 편차량을 최소로 하는 가장 적합한 설계변수 조합임을 알 수 있었다.




Fig. 8 The distribution of effective strain using a select condition in hot forging process ($H/R=0.83, v=150\text{mm/s}, m=0.3$)

6. 결론

본 연구에서는 실험계획법의 직교배열표를 신경망의 학습데이터로 이용하는 새로운 방식의 공정설계기법을 리브-웹브형 열간 단조제품의 공정설계에 적용하여 그 유용성 및 응용가능성을 살펴보았다. 리브-웹브형 열간 단조 제품에 대한 공정설계를 하는데 있어, 다이 내부의 소재 충만성, 성형 에너지 그리고 변형을 분포를 고려하여, 이 세 가지 목적함수에 미치는 설계변수 즉, 초기 소재 형상비, 마찰 그리고 램 속도의 영향을 알 수 있었으며, 일반적인 초기 소재량보다 적은 량의 소재로 다이 내부를 완전히 채우면서 성형 에너지 및 변형을 편차량이 적은 설계변수 조합을 찾을 수 있었다. 직교배열표에 따라 유한요소 해석하여, 적은 시뮬레이션 횟수로 목적함수에 대한 변수의 영향을 알 수 있었고, 신경망을 적용하여 설계목적에 적합한 설계변수 조합을 찾을 수 있었다. 이러한 공정설계 기법은 설계자에게 여러 가지 목적함수에 대한 설계변수의 정보를 제공할 수 있으므로, 주어진 설계환경조건에서 최적의 설계변수 조합의 선정이 가능하다.

본 연구에서는 강소성 유한요소 해석을 이용하여 제시한 설계방법으로 찾아낸 설계변수 조합을 검증하였다. 그리고 공정설계의 초기단계에서 세 가지의 설계변수를 선정하여 이 변수들이 제품에 미치는 영향을 살펴보았다.

그러나 실제 제품의 제조과정에서는 많은 공정변수가 제품의 특성에 영향을 미치므로 향후 여러 가지 변수간의 상관관계에 대한 연구가 요구되며, 실제 실험을 통한 정확한 검증을 해야 할 것이다.

참고 문헌

1. N. Alberti, L. Cannizzaro, 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.
2. S. S. Lanka, R. Srinivasan and Rov. Gandhi, "A Design Approach of Intermediate Die Shapes in Plane Strain Forgings," J. Mat. Shaping Tech. Vol. 9, pp. 193~206, 1991.
3. 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.
4. 김동진, 김병민, 최재찬 "신경망을 이용한 열간 단조품의 공정설계," 대한기계학회논문집, Vol. 12, No. 11, p. 118, 1995.
5. 정낙면, 이낙규, 양동렬 "축대칭 냉간단조의 유한요소 해석에서 퍼지로그를 이용한 전방투사법," 대한기계학회논문집, Vol. 16, No. 8, pp. 1468~1483, 1992.
6. D. F. Carbaugh and J. L. Frater, "A Factorial Analysis of Input Parameters Using Finite Element Techniques," J. Mater. Shaping Technol, 1991.
7. 정제숙, 황상무 "유전 알고리즘을 이용한 단조공정 중간 공정 최적설계," 한국소성가공학회 '97 춘계 학술대회 논문집, pp. 155~158, 1997.
8. S. Roy, S. Ghosh and R. Shivipuri, "A New Approach to Optimal Design of Multi-stage Metal Forming Processes with Micro Genetic Algorithms," Int. J. Mach. Tools Manufact. Vol. 37, No. 1, pp. 29~44, 1997.
9. S. I. Oh, Private Communication, SFTC Inc., Columbus, Ohio and DEFORM Manu-al (Version 4.0)

10. D.E.Rumelhart, G.E.Hinton and R.J.Williams, "Learning Internal Representations by Error Propagation," Parallel Distribution Processing Cambridge MA:MIT press, pp. 318~362, 1986.
11. B.Irie and S.Miyake, "Capabilities of Three-Layered Perceptrons," IJCNN'88, Vol. 1, pp. 641-48, 1988.
12. A.S.Pandya and R.B.Macy, Pattern Recognition with Neural Networks in C++, IEEE PRESS, 1996.
13. G.P.Box, W.G.Hunter and J.S.Hunter, Statistics for Experiments, Wiley, New York, 1978.
14. T.Altan, S.I.Oh and H.L.Gegel, Metal Forming Fundamentals and Application, American Society for Metals, 1983.
15. 김성원, 열간 단조 공정설계 및 금형설계의 자동화에 관한 연구, 부산대학교 박사학위논문, 1994.