

유전 알고리즘-BP신경망을 이용한 Al3004 판재 점진성형 공정변수에 대한 최적화 연구

양선, 김영석*
경북대학교 기계공학과

Optimization of Process Parameters of Incremental Sheet Forming of Al3004 Sheet Using Genetic Algorithm-BP Neural Network

Sen Yang, Young-Suk Kim*
Dept. of Mechanical Engineering, Kyungpook Nat'l Univ.

요 약 점진판재성형은 금형을 제작하지 않고 판재를 가공하는 방법으로서 빠른 시제품 제작과 소량 생산에 적합한 성형법이다. 이러한 점진판재성형의 공정 변수로 공구 직경, 매 스텝당 Z-방향 깊이, 공구 이송 속도, 공구 회전 속도 등은 성형품의 품질에 크게 영향을 미친다. 본 연구에서는 두께가 1.0mm인 Al3004판재를 사용하여 원뿔절두체(VWACF: Varying Wall Angle Conical Frustum) 모델의 점진성형을 실시하였으며, 각각의 변수들의 조합에서 성형성을 판단하였다. BP신경망(BPNN: Back Propagation Neural Network)를 기반으로 Minitab 소프트웨어를 사용하여 성형 각도를 예측하는 2 차 수학적 모델을 구축하였다. 또한 이 모델을 유전 알고리즘의 목적함수로 사용하였으며 최대 성형 각도로 얻기 위한 최적의 변수 조합을 찾아내었다. 공구 직경은 6mm, 회전 속도는 180rpm, Z-방향 피치는 0.401mm, 이송 속도는 772.4mm/min일 경우 가장 큰 성형 각도인 87.071°를 갖는 컵을 성형할 수 있었다.

Abstract Incremental Sheet Forming (ISF) is a unique sheet-forming technique. The process is a die-less sheet metal manufacturing process for rapid prototyping and small batch production. In the forming process, the critical parameters affecting the formability of sheet materials are the tool diameter, step depth, feed rate, spindle speed, etc. This study examined the effects of these parameters on the formability in the forming of the varying wall angle conical frustum model for a pure Al3004 sheet with 1mm in thickness. Using Minitab software based on Back Propagation Neural Network (BPNN) and Genetic Algorithm (GA), a second order mathematical prediction model was established to predict and optimize the wall angle. The results showed that the maximum forming angle was 87.071° and the best combination of these parameters to give the best performance of the experiment is as follows: tool diameter of 6mm, spindle speed of 180rpm, step depth of 0.4mm, and feed rate of 772mm/min.

Keywords : Incremental Sheet Forming, BPNN, Genetic Algorithm, Prediction, Optimization

1. 서론

1967년 미국에서 점진판재성형(ISF: Incremental Sheet Forming)[1] 기술에 대한 개념 특허가 처음 제출

된 이후 1990년대 초반, CNC 머신을 이용한 다양한 점진판재성형 기술에 대한 연구와 기술 적용이 시도되었다. 이 기술은 작은 구형의 고체 공구가 판재와 접촉하여 X, Y, Z 3차원 공간에서 컴퓨터 수치제어를 통해 판재를 점

이 논문은 2019년도 경북대학교 연구년 교수 연구비에 의하여 연구되었음.

*Corresponding Author : Young-Suk Kim(Kyungpook National Univ.)

email: caekim@knu.ac.kr

Received September 6, 2019

Accepted January 3, 2020

Revised October 30, 2019

Published January 31, 2019

진적으로 소성변형을 시켜 원하는 제품 형상을 성형하는 방식이다. 점진성형은 점진적으로 소성변형을 확장해가는 방식이기 때문에 프레스 가공과 비교하면 성형 력이 작고 고가의 프레스 및 프레스 금형이 필요하지 않은 장점이 있다. 그에 반해서 점진성형은 성형 속도가 느리고 성형 후 제품형상의 정밀도가 떨어지는 단점이 있지만 시제품 또는 소량 다품종의 판재 성형품을 만드는데 적합하다[2]. 이 점진성형 공정에서 재료변수와 공정변수가 성형성(성형 깊이, 성형 각도)에 영향을 미치는 주요 인자로 알려져 있다. 특히 공정변수로서 공구 형태와 공구 직경, 공구 이송 속도, 공구 회전 속도, Z-방향 공구 이송 피치, 공구와 판재의 마찰, 가공 온도, 성형각도 등이 성형성에 영향을 미치고 있어서 많은 실험적, 해석적 연구들이 이루어지고 있다[3].

점진판재성형 공정에서 성형성에 미치는 변수들의 영향을 규명하고 최적 조건을 찾기 위한 실험계획 기법들이 도입되고 있다. 대표적인 방법으로 다구찌의 직교배열 실험법 (Taguchi Orthogonal Array Method), 표면응답법 (SRM: Surface Response Method), 그레이 관계 분석 (Grey Relation Analysis), BP신경망 등이 있다.

Leon등[4] 과 Kim등[5] 이 공정변수가 점진성형의 기계적 특성에 미치는 영향을 연구하였다. 특히 공구 유형, 공구와 판재 사이의 마찰, 이송 속도, 회전속도, Z-방향 피치 등이 점진성형 공정에서 아주 중요한 변수라고 강조하였다. Xiao등은[6] 다구찌-그레이 관계 분석을 이용하여 각 성형 변수에 대해 평가하고 최적 변수조합을 찾아내었다.

BP신경망은 많은 비선형 처리 장치의 응용을 통해 복잡하고 비선형적인 관계를 모방 할 수 있는 대규모 병렬 처리 아키텍처(Architectures)이다[7]. 일반적으로 BP신경망은 입력변수(Input Data)와 출력변수(Output Data)간의 관계를 입력 층(Input Layer), 은닉 층(Hidden Layer), 그리고 출력 층(Output Layer)에 나타내어, 각 층에 해당하는 뉴런(Neuron)을 역 전파 기법(Back-Propagation Method)으로 학습(Training) 시키는 인공지능 알고리즘 중 하나이며 최근에 유동용력의 예측[8], 점진성형 공정에서 스프링 백 예측 설계[9], 기어 블랭크의 다목적 최적화 설계[10], 재료 구성 방정식 파라미터[11] 등 다양한 소성 가공 영역에 많이 기여하였다. 다양한 소성분야에서 활발하게 응용되고 있다.

유전 알고리즘(GA: Genetic Algorithm)은 기본적으로 자연계의 생물 유전학에 이론적 바탕에 두고 있다. 이는 병렬적이고 전역적인 탐색 알고리즘으로서 다윈의 적

자생존 이론을 기본 개념으로 한다[12]. 유전 알고리즘은 효율적인 포괄 검색 방법으로, 검색 과정 중 검색 공간에 대한 지식을 자동으로 획득하고 축적하며, 최상의 해결책을 찾기 위해 검색 과정을 적절하게 제어하는 특징이 있다. 이 방법은 가공 공차의 설계[13], 트러스 구조물의 최적화 설계[14]의 연구에 적용되고 있다.

본 연구의 대상 소재인 Al3004 판재는 Al-Mn 합금으로 Al3003소재에 비하여 성형성이 좋고 내식성이 우수하다는 특징을 갖고 있다. Al3004 판재는 미래 화학 장치 산업, 해양구조물, 판금 가공 부품 및 건축자재분야 등에서 널리 사용되고 있는 만큼 Al3004에 대한 판재 성능 연구는 필수적이며 중요한 사안이라 할 수 있다.

본 연구에서는 VWACF[15]의 성형에서 성형 각도를 목적함수로 하여 공정변수를 공구 직경, 공구 회전 속도, Z-방향 피치, 공구 이송 속도로 설정하고, BP신경망을 사용하여 성형각도에 대한 공정 변수의 영향 모델을 구축하고 성형 중에 판재가 파단될 때까지의 성형 각도를 예측하였다. 또한 Minitab를 사용하여 BP신경망에 의해 수립된 수학적 모델을 유전 알고리즘의 목적함수로 사용하였으며 유전 알고리즘의 전역 최적화 기능을 통해서 최대 성형각도로 얻기 위한 최적의 변수 조합을 찾는 것을 목적으로 한다.

2. 본론

2.1 실험 및 성형성 평가

본 연구에서 사용한 재료는 두께가 1.0mm인 Al3004 판재이며 점진판재성형 실험에서의 성형 변수(Parameter)와 수준(Level)을 Table 1.에 나타내었다.

Table 1. Level of selected parameters

	Level-1	Level 0	Level 1
a: Tool diameter(mm)	6	8	10
b: Spindle speed(rpm)	60	120	180
c: Step depth(mm)	0.2	0.4	0.6
d: Feed rate(mm/min)	400	800	1200

변수들의 영향을 파악하기 위해서 Minitab를 이용하여 Table 2.와 같이 실험계획법의 일종인 Box-Behnken 설계 법에 따라 다양한 변수와 수준의 조합에 대해서 27개의 실험계획을 설계하고 VWACF에 대한 점진판재성형 실험을 수행하였다.

Table 2. Design of experiment

Exp. no	a	b	c	d
1	0	-1	-1	0
2	0	1	0	-1
3	1	0	1	0
4	0	0	0	0
5	0	1	0	1
6	-1	0	0	1
7	0	-1	0	1
8	0	1	1	0
9	1	-1	1	0
10	1	0	0	-1
11	-1	0	-1	0
12	1	0	-1	0
13	0	0	1	-1
14	1	0	0	1
15	1	1	0	-1
16	0	1	-1	0
17	0	0	-1	1
18	-1	1	1	1
19	-1	0	1	0
20	-1	-1	0	0
21	0	-1	1	0
22	0	-1	0	-1
23	0	0	-1	-1
24	-1	-1	-1	-1
25	1	0	-1	1
26	-1	0	0	0
27	0	0	1	1

2.2 점진성형 성형성 평가

점진성형 성형성을 평가하기 위해서 여러 가지 기준을 적용할 수 있는데 본 연구에서는 최대 성형각도 및 최대 성형 깊이를 사용하였다.

이 VWACF 모델에서 성형 깊이가 깊어질수록 성형각도가 40°부터 90°까지 점차적으로 증가하기 때문에 파단할 때까지 성형하여 식 (1)과 식 (2)를 통해 최대 성형각도 ϕ 를 도출할 수 있다. 각각의 실험 조건에 따라 VWACF 모델에 대한 점진판재성형을 수행하였으며, Fig. 1. 와 같이 각 실험 중에 모델의 밑면에서 시편에 파단이 발생하였을 때까지 성형을 진행하였다.

$$H = L - D + r \tag{1}$$

$$\phi = \frac{\pi}{2} - \arcsin\left(\frac{H}{r+R}\right) \tag{2}$$

여기서 D는 파단이 발생한 최종 성형 깊이이고 R은 50mm이다. L은 38.3mm 이며 r는 공구 직경이다. H는 바닥에서부터 공구 중심까지의 수직 높이이고 ϕ 은 파단이 발생할 때의 최대 성형 각도이다.

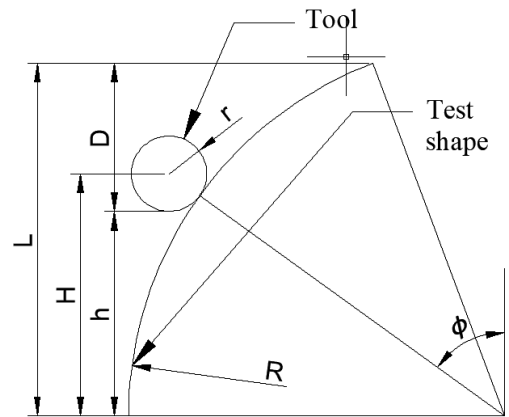


Fig. 1. Geometry used to determine the wall angle ϕ for a given tool position

실험 계획에 따라 수행한 실험의 성형 결과를 Fig. 2. 와 Table 3.에 나타내었다.




Fig. 2. Result of 27 experiments for incremental sheet forming

Table 3. Experiment result with angle

Exp. no	Max angle (ϕ°)	Formability(mm)
1	85.233	31.200
2	85.693	31.600
3	84.543	30.600
4	85.233	31.200
5	85.693	31.600
6	84.733	30.800
7	85.693	31.600
8	84.543	30.600
9	84.773	30.800
10	84.543	30.600
11	85.463	31.400
12	85.003	31.000

13	83.851	30.000
14	84.312	30.400
15	84.773	30.800
16	84.312	30.400
17	84.312	30.400
18	84.543	30.600
19	84.543	30.600
20	86.152	32.000
21	83.159	29.400
22	85.693	31.600
23	85.233	31.200
24	84.543	30.600
25	85.003	31.000
26	86.152	32.000
27	83.159	29.400

2.3 BP신경망 법

Fig. 3.와 같이 BP신경망은 크게 입력 층, 은닉 층, 출력 층으로 구성되어 있다. 이에 모델의 비선형성, 복잡성에 따라 여러 개의 은닉 층과 뉴런을 가질 수 있다. 각 층의 뉴런은 이전 층에서 전달받은 값을 합산하고 정해진 가중치를 인가하여 다음 층의 뉴런에 전달한다. 최종적으로 출력 층으로부터 도출한 유효 값은 시험으로부터 얻어진 표본 데이터와 비교되며, 이에 대한 오차를 분석하여 역 전파 기법으로 각 뉴런들의 가중치를 조절하는 학습 과정을 거치게 된다[16].

입력 층에서 은닉 층까지의 가중합(Weighted Sum) 식 (3)은 아래와 같다.

$$net_k = b + w^T x = b_k + \sum w_{kj} + x_j \quad (3)$$

k와 j는 각각 은닉 층과 입력 변수의 개수이며, b는 편향 벡터(Bias Vector), w는 각 뉴런 간의 가중치, x는 입력 벡터를 의미한다. 위 과정에서 도출한 값은 활성화 함수(Activation Function)에 인가되어 모델의 비선형성(Nonlinearity)을 부여하고 이로써 VWACF 모델의 성형실험에서 최대 성형각도를 예측할 수 있다. 본 연구에서 입력 층은 Sigmoid 함수와 은닉 층은 Identity 함수를 활성화 함수로써 사용하였으며 최대 성형 각도 ϕ 은 아래와 같은 식으로 도출할 수 있다.




Fig. 3. Schematic of artificial neural network

$$Sigmoid: f(net_k) = \left[\frac{2}{1 + \exp(-2 * net_k)} \right] - 1 \quad (4)$$

$$Identity: \bar{\phi}_{angle} = f(net_k) = net_k \quad (5)$$

본 연구에서는 예측된 성형 각도와 성형 깊이를 실제 실험을 통해서 측정된 성형 각도와 성형 깊이의 차이를 비교하기 위해 평균제곱오차(MSE: Mean Square Error)를 식 (6)과 같이 정의하였다.

$$E = \frac{1}{Q} \sum [\phi_{actual}(m) - \phi_{predicted}(m)]^2 \quad (6)$$

여기서는 Q, ϕ_{actual} , $\phi_{predicted}$ 각각 데이터의 개수, 실험을 통해서 얻어진 성형 각도, 그리고 인공신경망기법을 통해 예측된 성형 각도를 의미한다.

본 연구에서는 BP신경망에 대한 학습을 수행하기 위해 역전파기법 중 하나인 Levenberg-Marquardt 기법 [17]을 사용하였다. Levenberg-Marquardt 기법은 아래의 식 (7)과 같다.

$$w_{i+1} = w_i - [J^T J + \mu_i \text{diag}(J^T J)]^{-1} J^T n \quad (7)$$

w은 각 뉴런의 가중치이며, i은 반복 횟수, J는 Jacobian 행렬, μ 은 감쇠지수(Damping Factor)를 의미하며, n은 실제 각도와 인공신경망을 통해 예측된 각도 간의 잔차(Residual)를 의미한다. 이 때, Jacobian 행렬은 후방 차분법(Backward Difference Method)을 사용하여 아래와 같이 정의하였다.

$$J = \frac{\partial r(w)}{\partial w} = \frac{r_i - r_{i-1}}{\Delta w} \quad (8)$$

한편 식 (7)에서 $\mu_i \text{diag}(J^T J)$ 은 Hessian 행렬의 대각행렬로 Hessian 행렬의 고유 값 즉, 곡률을 의미하여 감쇠지수는 임의의 상수를 갖게 되며 반복 구간마다 수렴여부를 확인하여 갱신된다. 이 Levenberg-Marquardt 기법은 뉴턴 방법(Newton Method)을 개선한 Levenberg 방법에서 스텝 크기(Step Size) 문제를 해결하기 위해 제안된 방법이다. 결과적으로 위의 반복 과정을 통해 인공신경망의 뉴런은 오차가 최소화되는 쪽으로 학습하게 된다.

본 연구에서는 공구 직경, 공구 회전 속도, Z-방향 피치 및 공구 이송 속도를 입력 변수로 적용하였으며, 성형 각도와 성형 깊이를 출력 변수로 적용하였다. 많은 학습을 거쳐 은닉 층의 뉴런 수가 6개인 경우가 가장 적합한 것으로 판단하였다. Fig. 4.에 본 연구에서 사용한 BP 신경망의 구조를 나타내었다.




Fig. 4. Architecture of BPNN for wall angle and forming depth prediction

2.4 예측 결과 및 분석

Fig. 5.은 인공신경망 모델의 성능을 보여준다. 본 연구에서는 무작위로 전체 27개의 자료 중에서 학습 자료(Training Set)는 70%인 19개, 검증 자료(Validation Set)와 시험 자료(Test Set)는 각각 15%인 4개를 설정하였다. 그림에서 보듯이 학습에 사용된 자료는 예측 결과와 잘 일치하고 있는데 이는 자기 자신을 학습에 사용했기 때문이다(Fig. 5a). 학습 중단을 결정하는 검증 자료의 상관계수는 1로 상당히 양호하게 분석되었다(Fig. 5b). 학습에 전혀 개입하지 않는 테스트 자료의 상관계수는 0.99996으로 나타내었다(Fig. 5c). 모든 자료에 대한 상관계수는 0.99989로 초기 목표치인 1과 유사한 결과이다.

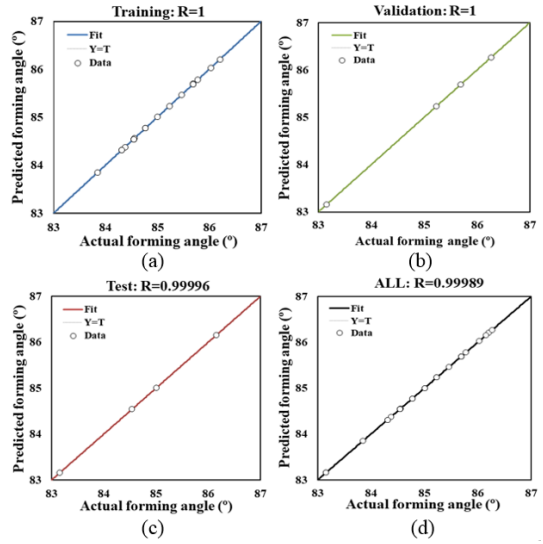


Fig. 5. (a) Correlation coefficients of training sets (19 cases), (b) validating sets (4 cases), (c) testing sets (4 cases), (d) total (27 cases)

인공신경망을 이용하여 예측한 성형 각도를 구하여 Table 4.에 정리하였다. 예측 성형 각도와 실제 성형 각도를 비교할 때 평균 오차가 0.17%정도를 가지며 이 모델을 이용해서 성형 각도를 정확하게 예측할 수 있다는 것을 확인하였다.

Table 4. Results of BP neural network

Exp. no	Forming angle (φ°)	Prediction forming angle(φ°)	Error
1	85.233	85.23289	0.00011
2	85.693	85.69397	-0.00097
3	84.543	84.54293	0.00007
4	85.233	86.03057	-0.79757
5	85.693	85.69480	-0.00180
6	84.733	86.20723	-1.43423
7	85.693	85.69314	-0.00014
8	84.543	84.54309	-0.00009
9	84.773	84.77290	-0.00009
10	84.543	84.55911	-0.01611
11	85.463	85.46340	-0.00040
12	85.003	85.00400	-0.00100
13	83.851	83.85141	-0.00041
14	84.312	84.31231	-0.00031
15	84.773	84.77472	-0.00172
16	84.312	84.37656	-0.06456
17	84.312	84.31281	-0.00081
18	84.543	85.77784	-1.23484

19	84.543	84.54271	0.00028
20	86.152	86.26898	-0.11698
21	83.159	83.15896	0.00004
22	85.693	85.69393	-0.00093
23	85.233	85.23296	0.00004
24	84.543	84.54299	0.00001
25	85.003	85.00308	-0.00008
26	86.152	86.15287	-0.00087
27	83.159	83.15899	0.00001

2.5 유전 알고리즘을 이용한 최적화

다양한 조합의 매개 변수에 대한 실험 결과에서 얻은 성형각도는 개발된 BPNN 입력으로 얻어지며 결과는 Minitab 소프트웨어에 입력하면 공급된다. 또한 성형 각도를 예측하기 위한 2차 코딩식이(9) 아래와 같다.

$$\begin{aligned}
 \text{Angle} = & 85.696 - 0.390 \times a + 0.009 \times b - 0.480 \times c \\
 & - 0.070 \times d + 0.316 \times a^2 + 0.213 \times b^2 - \\
 & 1.240 \times c^2 - 0.394 \times d^2 - 0.893 \times a \times b - \\
 & 0.033 \times a \times c - 0.069 \times a \times d + 0.449 \times b \times c \\
 & - 0.053 \times b \times d - 0.121 \times c \times d \quad (9)
 \end{aligned}$$

유전 알고리즘은 자연세계의 진화과정을 기초로 개발한 계산 모델로서 전역 최적화 기법이다. 생물의 진화를 모방한 진화 연산의 대표적인 기법으로, 실제 진화의 과정에서 상당 부분을 차용하여 문제를 해결하였기에 ‘세대, 인구, 교차, 변이’ 등의 용어를 많이 사용한다. 본 연구에서는 유전 알고리즘의 전역 최적화 기능을 통해서 최대 성형각도로 얻기 위한 최적의 변수 조합을 찾아내었다.

성형각도에 대한 2차 방정식은 유전 알고리즘에 적용도 함수로 사용하여 각각 변수의 제약 조건 식 (10), (11), (12), (13) 과 같이 정의하였다.

$$6\text{mm} \leq a \leq 10\text{mm} \quad (10)$$

$$60\text{rpm} \leq b \leq 180\text{rpm} \quad (11)$$

$$0.2\text{mm} \leq c \leq 0.6\text{mm} \quad (12)$$

$$400\text{mm/min} \leq d \leq 1200\text{mm/min} \quad (13)$$

한편, 유전 알고리즘에서 매개 변수의 선택은 알고리즘의 성능에 직접적인 영향을 미친다. 따라서 본 연구에서 변수인 모집단(Population Size), 교배율(Crossover Rate), 돌연변이 확률(Mutation Rate), 선택 (Selection), 세대(Generations)에 대해 Table 5.와 같이 설계하였다.

Table 5. Critical parameters in GA

Parameters	
Population size	100
Crossover rate	0.8
Mutation rate	0.007
Selection	Stochastic uniform
Generations	400

Matlab에서 유전 알고리즘 법을 사용하여 반복한 후 최대 성형 각도를 얻기 위한 최적 값에 대해 적합도 값의 수렴을 Fig. 6.과 같이 나타내었다.

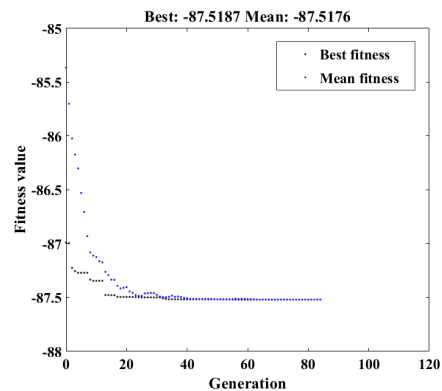


Fig. 6. Convergence of fitness values to optimum level

Table 6. Best combination of parameters and max angle

Parameter	
a: Tool diameter(mm)	6
b: Spindle speed(rpm)	180
c: Step depth(mm)	0.4008
d: Feed rate(mm/min)	772.4
Max angle (°)	87.518

Table 6.과 같이 최적의 변수 조합은 공구 직경 6mm, 회전 속도 180rpm, Z-방향 피치 0.4008 mm, 이송 속도 772.4mm/min이고 이들 최적 변수조합을 입력하여 최대 성형 각도는 87.518°을 얻을 수 있었다.




Fig. 7. Result of verification experiment

유전 알고리즘-BP신경망을 이용하여 최적의 변수 조합 및 최대 성형 각도를 구하고 검증하기 위해서는 확인 실험을 해야 한다. 실제 제조 공정에서 사용한 CNC 머신의 가공 정밀도에 대한 소숫점 이하 셋째자리 정밀도이다. 그래서 공구 직경 6mm, 회전 속도 180rpm, Z-방향 피치 0.401mm, 이송 속도 772.4mm/min로 설정하여 실험한 결과를 도출하고 그 값을 계산한 결과, Fig. 7.와 같이 최대 성형 각도는 87.071°이었다. 이는 최적화된 예측 값과 비교하여 1% 미만의 오차를 갖는 것으로 본 연구에서 제안한 방법이 타당하다는 것을 보여준 것이다.

3. 결론

본 연구에서는 두께가 1mm인 Al3004 판재를 이용하여 가변 벽 각도 원뿔절두체의 점진판재성형을 수행하였다. 공구 직경, 공구 회전 속도, Z-방향 피치 및 공구 이송 속도를 입력 변수로 적용하였으며 성형 각도를 목적함수로 설정하여 BP신경망을 사용해서 성형각도에 대한 예측모델을 구축하였다. 또한 Minitab를 사용하여 BP신경망에 의해 수립된 수학적 모델을 유전 알고리즘의 목적함수로 사용하였으며 유전 알고리즘을 통해서 최대성형 각도를 얻기 위해 최적의 변수 조합을 찾아내었다. 얻어진 결론은 아래와 같다.

- (1) BP신경망 기법을 통해 가변 벽 각도 원뿔절두체의 점진판재성형에서 최대 성형 각도를 효과적으로 예측할 수 있다. 이로부터 점진판재성형 공정에서 사용자의 목적에 따라 BP신경망을 설계하여 다양한 조건에서의 결과를 예측할 수 있다.
- (2) 유전 알고리즘을 통해서 최대성형 각도를 목적함수로 하여 최적의 변수 조합을 찾아내었으며 공구 직경은 6mm, 회전 속도는 180rpm, Z-방향 피치는 0.401mm, 이송 속도는 772.4mm/min일 경우 가장 큰 성형각도인 87.071°를 갖는 컵을 성형할 수 있었다.

Reference

[1] E. Leszak, "Apparatus and Process for Incremental Die Less Forming," Patent US3342051 A1, 1967.
 [2] E. Appleton, B. Mason, "Sheet metal forming for small

batches using sacrificial tooling," *Production Engineer*, Vol. 63, No. 9, pp. 58-61, 1984.
 DOI: <https://doi.org/10.1049/tpe:19840213>

- [3] J. Jeswiet, F. Micari, G. Hirt, A. Bramley, J. Duflou, J. Allwood, "Asymmetric Single Point Incremental Forming of Sheet Metal," *CIRP Annals*, Vol. 54, No. 2, pp. 88-114, 2005.
 DOI: [https://doi.org/10.1016/S0007-8506\(07\)60021-3](https://doi.org/10.1016/S0007-8506(07)60021-3)
- [4] J. Leon, D. Salcedo, C. Ciurriz, C. J. Luis, J. P. Fuentas, I. Puertas, R. Luri, "Analysis of the Influence of Geometrical Parameters on the Mechanical Properties of Incremental Sheet Forming Parts," *Procedia Engineering*, Vol.63, pp. 445~453, 2013.
 DOI: <https://doi.org/10.1016/j.proeng.2013.08.206>
- [5] Y. H. Kim, J. J. Park, "Effect of Process Parameters on Formability in Incremental Forming of Sheet Metal," *Journal of Materials Processing Technology*, Vol. 130~131, pp. 42~46, 2002.
 DOI: [https://doi.org/10.1016/S0924-0136\(02\)00788-4](https://doi.org/10.1016/S0924-0136(02)00788-4)
- [6] C. I. Kim, V. C. Do, X. Xiao, Y. S. Kim, "Optimization of Single Point Incremental Forming of Al5052-O Sheet," *Transactions of the Korean Society of Mechanical Engineers*, Vol. 41, No. 3, pp. 181~186, 2017.
 DOI: <https://doi.org/10.3795/KSME-A.2017.41.3.181>
- [7] R. Varthini, R. Gandhinathan, C. Pandivelan, A. K. Jeevanantham, "Modelling and Optimization of Parameters of the Single Point Incremental Forming of Aluminium5052 Alloy Sheet Using Genetic Algorithm-Back Propagation Neural Network," *International Journal of Mechanical And Production Engineering*, Vol. 2, No. 6, pp. 55~62, 2014.
- [8] E. T. Park, Y. H. Lee, J. Kim, W. J. Song, "Numerical Prediction of Temperature-Dependent Flow Stress on Fiber Metal Laminate Using Artificial Neural Network," *Transactions of Materials Processing*, Vol.27, No.4, pp. 331~338, 2018.
 DOI: <https://doi.org/10.5228/KSTP.2018.27.4.227>
- [9] F. Han, J. H. Mo, H. W. Qi, R. F. Long, X. H. Cui, Z. W. Li, "Springback prediction for incremental sheet forming based on FEM-PSONN technology," *Transactions of Nonferrous Metals Society of China*, Vol. 23, No. 4, pp. 1061-107, 2013.
 DOI: [https://doi.org/10.1016/S1003-6326\(13\)62567-4](https://doi.org/10.1016/S1003-6326(13)62567-4)
- [10] M. Y. Zhang, X. Y. Wang, J. C. Xia, J. Gang, "Multiple-Target Optimization Design of Pre-forging for Gear Blank Using Back Propagation Neural Network and Genetic Algorithm," *Forging Stamping Technology*, Vol.35, No.6, 2010.
- [11] M. A. Woo, S. M. Lee, K. H. Lee, W. J. Song, J. Kim, "Application of an Artificial Neural Network Model to Obtain Constitutive Equation Parameters of Materials in High Speed Forming Process," *Transactions of Materials Processing*, Vol.27, No.6, pp. 331~338, 2018.
 DOI: <https://doi.org/10.5228/KSTP.2018.27.6.331>

[12] K. F. Man, K. S. Tang, and S. Kwong, "Genetic Algorithms: Concepts and Applications," *IEEE Transactions on industrial electronics*, Vol. 43, No. 5, 1996.

[13] I. M. Deiab, "Concurrent Optimization of Design and Machining Tolerances Using the Genetic Algorithms Method," *Int. J. Mach. Tools Manufact.* Vol. 37, No. 12, pp. 1721-1731, 1997.
DOI: [https://doi.org/10.1016/S0890-6955\(97\)00033-3](https://doi.org/10.1016/S0890-6955(97)00033-3)

[14] T. Tugrul, "A New Genetic Algorithm Methodology for Design Optimization of Truss Structures: Bipopulation-Based Genetic Algorithm with Enhanced Interval Search," *Modelling and Simulation in Engineering*, Vol. 2009, Article ID 615162, 28 pages, 2009.
DOI: <http://dx.doi.org/10.1155/2009/615162>

[15] J. Jeswiet, D. Adams, M. Doolan, T. McAnulty, P. Gupta, "Single point and asymmetric incremental forming," *Advances in Manufacturing*, Vol. 3, No.4, pp. 253-262, 2015.
DOI: <https://doi.org/10.1007/s40436-015-0126-1>

[16] J. I. Choi, J. M. Lee, S. H. Baek, B. M. Kim, D. H. Kim, "The Shoe Mold Design for Korea Standard Using Artificial Neural Network," *Transactions of Materials Processing*, Vol.24, No.3, pp. 167~175, 2015.
DOI: <https://doi.org/10.5228/KSTP.24.3.167>

[17] J. M. Jorge, "The Levenberg-Marquardt algorithm: Implementation and theory," *Numerical Analysis*, Vol. 630, pp. 105-116, 2006.

김 영 석(Young-Suk Kim)

[정회원]



- 1981년 2월 : 서울대학교 대학원 기계설계학과 (석사, 졸업)
- 1986년 3월 : KOBE대학 대학원 기계공학과 (박사, 졸업)
- 1986년 10월 ~ 1994년 2월 : 포항제철소 기술연구소, RIST 주임 연구원, 책임연구원, 실장
- 1994년 3월 ~ 현재 : 경북대학교 기계공학부 조교수, 부교수, 교수
- 1999년 7월 ~ 2000년 11월 : 경북대학교 기계BK21사업단장
- 2000년 12월 ~ 2002년 2월 : Brown Univ. 방문교수
- 2010년 12월 ~ 2013년 2월 : (재)대구기계부품연구원 (DMI) 원장
- 2016년 3월 ~ 현재 : 한국소성가공학회 부회장

<관심분야>

소성가공, 유한요소해석, 나노역학, 바이오역학, 기술경영

양 센(Sen Yang)

[준(학생)회원]



- 2016년 6월 : ning샤대학교 기계공학과 (학부, 졸업)
- 2018년 3월 : 경북대학교 대학원 기계공학과 (생산공학연구실 석사)

<관심분야>

유전 알고리즘, BP 신경망, 점진성형