
論 文

大韓造船學會論文集
 第34卷第1號 1997年2月
 Journal of the Society of
 Naval Architects of Korea
 Vol. 34, No. 1, February 1997

인공신경망을 이용한 선상가열 공정의 역학정보모델

박성건*, 김원돈**, 신종계***

A Mechanical Information Model of Line Heating Process
 using Artificial Neural Network

by

Sung-Gun Park*, Won-Don Kim** and Jong-Gye Shin***

요 약

외판곡가공 과정의 역학적해석에 사용되는 열탄소성 해석은 계산시간이 많이 소요된다. 선상가열작업의 최적공정을 구하기 위하여 시뮬레이션과 유한요소해석 사이에 상당수의 반복계산이 필요하다. 그러므로 요구되는 천문학적인 계산시간으로 인하여 선상가열의 수치시뮬레이션은 많은 제약을 받고 있다. 따라서 선상가열의 시뮬레이션에 소요되는 역학해석 계산시간을 크게 줄이는 방안이 필요하다.

외판곡가공에서의 역학적 정보를 효율적으로 구하기 위하여, 본 논문에서는 먼저 선상 가열 작업에 영향을 끼치는 요소들을 살펴보았으며, 역전파 방식의 인공 신경망을 이용하여 일종의 추론기구를 구현하였다. 신경망은 은닉층의 갯수와 은닉층에 있는 뉴런의 갯수를 바꿔 주며 수치해석 결과들을 학습시켰다. 그 결과 두개의 은닉층을 가진 인공 신경망의 경우 각 은닉층에 뉴런의 갯수가 충분하다면 학습 예제들을 쉽게 학습하였고, 또 학습된 결과로부터 새로운 해를 도출해 낼 때 그 값은 실제 값과 비교해 볼 때 비교적 작은 오차를 보였다. 결과적으로 구하고자 하는 문제 영역 근처에 충분한 학습 예제가 마련된다면 비교적 실제 값에 근사하는 결과를 보인다는 것을 알 수 있었다.

본 연구를 통하여, 수치해석결과의 학습방법을 기초로한 인공신경망은 곡면가공의 시뮬레이션 단계에서 필요한 역학적 해석정보의 경제적인 산출에 적용가능함이 확인되었다.

발 표 : 1996년도 대한조선학회 춘계연구발표회('96. 4. 18)

접수일자 : 1996년 6월 3일, 재접수일자 : 1997년 1월 14일

* 대우중공업(주) 선박해양기술연구소

** 정회원, 서울대학교 대학원 조선해양공학과

*** 정회원, 서울대학교 조선해양공학과

Abstract

Thermo-elastic-plastic analyses used in solving plate forming process are often computationally expensive. To obtain an optimal process of line heating typically requires numerous iterations between the simulation and a finite element analysis. This process often becomes prohibitive due to the amount of computer time required for numerical simulation of line heating process. Therefore, a new techniques that could significantly reduce the computer time required to solve a complex analysis problem would be beneficial.

In this paper, we considered factors that influence the bending effect by line heating and developed inference engine by using the concept of artificial neural network. To verify the validity of the neural network, we used results obtained from numerical analysis. We trained the neural network with the data made from numerical analysis and experiments varying the structure of neural network, in other words varying the number of hidden layers and the number of neurons in each hidden layers. From that we concluded that if the number of neurons in each hidden layers is large enough neural network having two hidden layers can be trained easily and errors between exact value and results obtained from trained network are not so large.

Consequently, if there are enough number of training pairs, artificial neural network can infer similar results. Based on the numerical results, we applied the artificial neural network technique to deal with mechanical behavior of line heating at simulation stage effectively.

1. 서 론

선체외판의 곡면가공방법은 프레스, 로울러 등을 이용하는 기계적 냉간가공법과 가열에 의한 잔류 열소성 변형을 이용하는 선상가열법이 주로 사용되고 있다. 일반적으로 한방향으로만 일정한 곡률을 갖는 완만하고 단순한 외판의 곡면가공과 이중곡외판의 1차곡 가공에는 제어의 편의성 때문에 프레스에의한 냉간가공법을 이용하고, 마무리작업 및 이중곡외판의 2차곡가공, 용접변형제거 등은 선상가열로 작업한다. 선상가열의 과정은 판두께 방향으로 불균일한 온도분포를 가함으로써 잔류응력과 잔류변형이 생기는 것으로 이 과정 중에 재료의 특성치인 항복응력, 탄성계수, 선팽창계수 등의 값이 온도 의존성을 가진다. 따라서 이러한 선상가열의 과정의 해석은 복잡하고 해석시간이 많이 소요되는 3차원 과도 열탄소성 구조해석이 요구된다[1,2,3].

그러나, 선상가열에 대한 역학적인 정보분석에

있어서 매번 구조해석을 수행할 경우 상당수의 반복계산이 필요하며 구조해석 시스템에서의 천문학적인 계산시간이 소모된다. 따라서 열탄소성해석을 직접 수행하지 않고 실험자료로부터 가열토오치의 입열량과 굽힘변형량의 관계를 간단한 식으로 표현하는 방법이 연구되었으며[4], 간이모델을 이용하는 방법으로 초기의 보모델로 부터 2차원 스트립모델, 3차원 판이론, 수정된 스트립 모델로 발전하고 있으나[5] 실용적으로 시뮬레이션에 활용하기에는 역학적 거동의 정도와 계산시간상 문제가 있다.

본 연구에서는 선체외판 곡면가공 시뮬레이션 시스템 구축에 있어서 필요한 열탄소성 구조해석의 정보도출을 경제적인 방법으로 처리하는 기법 연구를 수행하였다. 먼저 곡면가공의 작업공간에서의 역학적 거동을 관심있는 매개변수에 따라 구조해석을 수행하여 그 결과를 인공신경망에 학습시킨 뒤 각 작업공정에서 필요한 매개변수에 대한 최적의 구조해석 정보를 도출하는 것이다. 따라서

선상가열의 시뮬레이션개발에 있어서 열탄소성의 역학적 정보를 효율적으로 활용하는 방안을 마련하였다.

2. 선상가열의 역학적 거동

2.1. 열전달 해석

선상가열을 받는 판은 복잡한 열탄소성 특성을 보인다. 열탄소성 해석을 하기 위해서는 먼저 판의 시간의존성 온도분포를 구하여야 한다. 본 연구에서는 가열토치를 일정한 속도로 판 위를 이동하는 분포열원으로 가정한다. 분포열원이 움직이면서 생긴 편미분방정식 형태의 열전도 문제를 수치적으로 풀어서 온도분포를 구한다. 이 방정식의 해는 범용 유한 요소 프로그램인 ANSYS를 이용하여 transient mode에서 구한다. 열전달 현상은 일반적으로 전도, 대류, 복사의 3 가지 전달 기구로 분류한다. 선상가열 문제에 있어서 복사에 의한 열전달 현상은 열전도에 비해 중요성이 적으므로 냉각 과정을 제외한 가열 과정만을 정식화하면 다음의 식과 같은 열전도 방정식이 지배 방정식이 된다.

$$\frac{\partial}{\partial x} \left(k \frac{\partial T}{\partial x} \right) + \frac{\partial}{\partial y} \left(k \frac{\partial T}{\partial y} \right) + \frac{\partial}{\partial z} \left(k \frac{\partial T}{\partial z} \right) = \rho c \frac{\partial T}{\partial t} \quad (1)$$

k = thermal conductivity [cal/mm · sec°C]

ρ = density [g/mm³]

c = specific heat [cal/g · °C]

이 때 열전달 계수와 비열은 온도에 따라 값이 변하는 온도의존성 함수이다.

2.2. 열탄소성 재료구성방정식

전체변형을 증분은 elastic strain, plastic strain, thermal strain의 증분으로 구성된다. 전체변형을의 증분형태로 정리하면 아래의 식과 같다.

$$d\varepsilon_{ij} = \frac{1+\nu}{E} d\sigma_{ij} + \frac{\nu}{E} \delta_{ij} d\sigma_{mm} - \frac{1}{E} dE \cdot \varepsilon_{ij} \quad (2)$$

$$+ \frac{1}{E} (\alpha T \cdot dE + ET \cdot da + E\alpha \cdot dT) \delta_{ij} + \sigma'_{ij} d\lambda$$

$$d\sigma_{ij} = \frac{\nu}{(1+\nu)(1-2\nu)} (dE\varepsilon_{mm}\delta_{ij} + Ed\varepsilon_{mm}\delta_{ij}) \\ + \frac{1}{1+\nu} (\varepsilon_{ij} dE + Ed\varepsilon_{ij}) - \frac{1}{1-2\nu} (\alpha T \cdot dE \\ + ET \cdot da + E\alpha \cdot dT) \delta_{ij} - \frac{E}{1+\nu} \sigma'_{ij} d\lambda \quad (3)$$

여기서, ν =Poisson's ratio, E =Young's modulus
 δ =Kronecker's delta function, T =temperature
 λ =Heat conductivity, α =Expansion coefficient

즉, 탄소성 유한요소 정식화 과정에 열변형에 의한 용력성분이 더해진 형태의 강성행렬이 증분 형식으로 정식화된다.

2.3. 선상가열의 열탄소성 해석

선상가열 과정은 가열과 냉각 과정을 통해 강판의 두께 방향에 생기는 온도 분포로 인해 생기는 열변형과 항복응력, 선팽창 계수 등의 온도 의존성 재료 특성치의 변화에 따른 복잡한 3차원 과도 열탄소성 문제이다.

가열과 냉각에 따른 재료의 열변형이 그리 크지 않으므로 가열 및 냉각에 따른 열전달 문제와 그에 따른 열변형 문제를 비연성으로 해석하여 문제를 보다 간단히 할 수 있다. 여기서는 해석 과정의 편의를 위해 평판에 1개의 가열선이 주어지는 경우만을 생각하였다.

수치해석 과정은 크게 3가지 단계로 나누어질 수 있다.

첫번째 단계로 강판의 크기와 초기곡률과 같은 형상정보와 변형량에 영향을 줄 수 있는 여러 정보 즉 토치의 속도, 냉각조건 등을 입력하고 수치해석의 정확성에 영향을 줄 수 있는 유한 요소의 갯수등을 결정하는 단계이다.

두번째 단계는 열전달 문제를 해석하는 과정이다. 여기서 토치는 가우스 분포를 가지는 열속(heat flux)으로 가정하였다. 가열과정에서는 열전도에 의해 강판이 두께 및 폭 방향의 온도분포를 가지며, 냉각과정에 있어서는 복사에 의한 냉각량을 무시하고 열대류 현상에 의해서 냉각되는 것으로 이상화하였다.

세번째 단계는 두번째 단계로부터 구해진 온도 분포로부터 열탄소성 해석을 수행하는 과정이다.

가열작업에 의해 강판의 온도가 올라감에 따라 항복응력이 낮아진다. 가열면이 열팽창함에 따라 가열면은 압축응력을 가지게 되는데 이 압축응력이 항복응력보다 더 낮아져 부분적으로 재료의 항복이 생기고 이에 의해 냉각과정 동안 굽힘 효과를 가지게 된다.

수치해석은 범용유한요소구조해석 프로그램을 이용하여 수행하였다. 전체적인 과정은 Fig. 1과 같다[2].

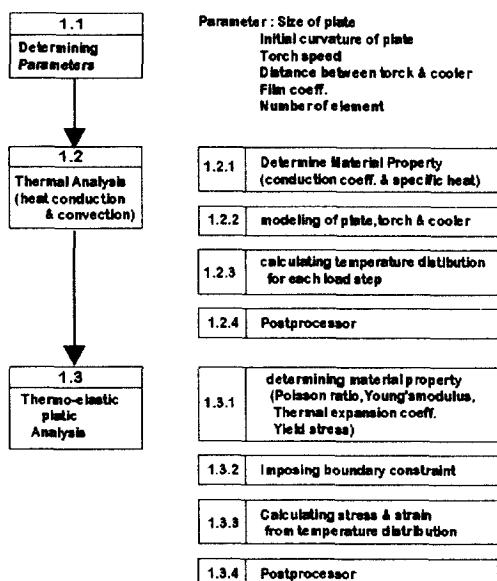


Fig. 1 Procedure of numerical analysis

2.4. 해석 모델

유한요소모델은 가열선을 중심으로 대칭이므로 한쪽면에 대해서만 모델링되었다. 판의 끝부분에서 단순지지된 상태의 경계조건이라고 가정하였으며, 유한요소는 소성, 가공경화, 대변형 해석이 가능한 8 절점 입체 요소를 사용하였다.

수치 해석은 강판의 두께와 강판이 가지는 초기 곡률 그리고 토치의 이동 속도를 변화시키며 행하였다. 첫번째로 두께는 일정하고 초기 곡률을 갖지 않는 평판에 대해 토치의 이동 속도만이 바뀌는 경우를 해석해 보았고 두번째 경우로 강판의 두께와 초기 곡률 그리고 토치의 이동 속도가 모두 바뀌는 경우를 해석해 보았다.

수치 해석 과정에서 모델링한 강판의 형상은 Fig.2 와 같다.

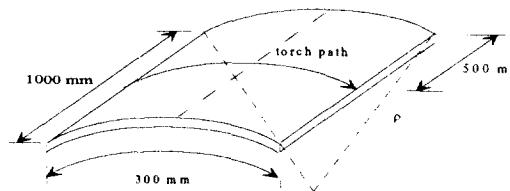
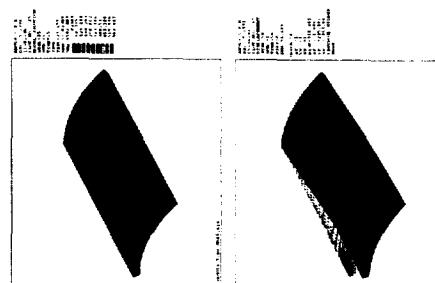


Fig. 2 Geometric shape of plate modeled in numerical analysis

Fig. 3 는 saddle shape의 곡외판을 구하기 위하여 냉간가공에 의하여 초기곡률이 있는 판에 선상가열작업을 할 경우의 역학적 거동을 보여주고 있다.



(a)Temperature distribution (b)deformed shape

Fig. 3 Simulation of line heating process for the initially curved shell

3. 인공 신경망 이론

3.1. 디층 인공 신경망

인공 신경망은 Fig. 4 에 나타난 것과 같은 인공 신경 세포들로 구성된다[6]. 이 인공 세포들은 인간의 뉴런들이 수상돌기를 통해 다른 뉴런들로부터 입력을 받아들이듯이 이전 층의 다른 신경세포들의 출력(O_1, O_2, \dots, O_n)에 연결 강도(W_1, W_2, \dots, W_n)들을 곱해 받아 들인다. 즉 여기서

연결 강도(weight)는 인간의 신경 세포계에서 시냅스와 같은 역할을 한다. 연결 강도를 통해 받아들여진 다른 뉴런들의 출력값은 식(4)에 보이는 것처럼 모두 더해져서(NET) 내부의 활성함수(F)로 보내어져 식(5)처럼 그 뉴런의 출력을 결정하게 된다.

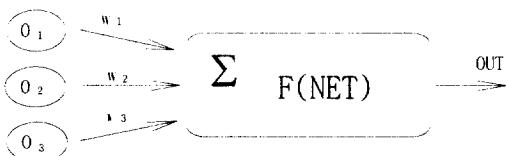


Fig. 4 Artificial neuron

$$NET = \sum_{i=0}^n O_i W_i \quad (4)$$

$$Out = F(NET) \quad (5)$$

신경망의 학습은 신경망의 경우 역전파 방식(back propagation)의 학습 방법이 많이 쓰인다. 일반적으로 역전파 방식의 신경망에서는 계단 함수(threshold function), 시그모이드 함수(Sigmoid function), hyperbolic tangent 함수 등이 활성함수로 쓰이는데 주로 식(6)과 같은 시그모이드 함수가 편의상 많이 쓰인다. 이 함수는 Fig. 5에 나타난 것처럼 입력(NET)값을 받아 0에서 1 사이의 값을 출력하는 비선형 함수이다.

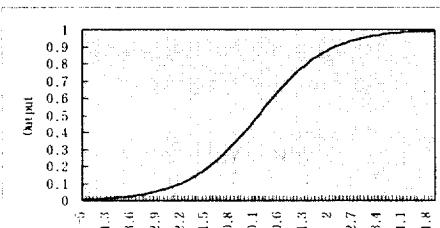


Fig. 5 Sigmoid function

$$F(NET) = 1/(1 + e^{-NET}) \quad (6)$$

Fig. 6은 다층 인공 신경망의 구조이다. 여기서 옆으로 늘어선 한 무리의 인공 세포들을 층(layer)이라고 한다. 같은 층 내의 신경 세포들은 기능적

으로 같은 작업을 수행한다. 신경망의 여러 층들은 외부로부터 입력을 받아들이는 입력층, 신경망의 외부로 출력을 보내는 출력층, 그리고 입력층과 출력층 사이에 은닉층을 가진다. 다층 신경망의 경우 하나 이상의 은닉층을 가지고 있다. 여기서 은닉층의 갯수가 많아 질수록 인공 신경망이 형성하는 결정 구역의 특성은 더욱 다양한 형태의 학습을 할 수 있다. 이론적으로 2개의 은닉층을 가진다면 모든 형태의 학습 예제를 학습할 수 있다고 한다.

다층 신경망의 경우 상위층에 있는 인공 세포는 하위층에 있는 신경세포들의 출력에 연결 강도를 곱한 것을 받아들여 작동한다. 즉 입력층의 각 뉴런에 입력 데이터를 제시하면 이 신호는 각 뉴런에서 변환되어 중간층 즉 은닉층으로 전달되고 최종적으로 출력층으로 전달되게 된다.

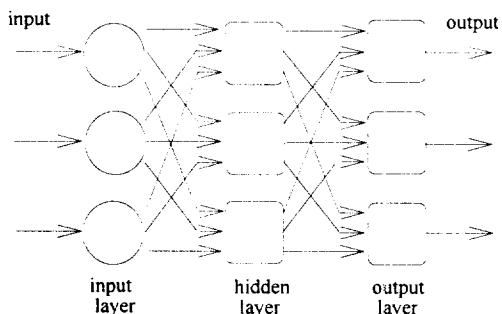


Fig. 6 Structure of neural network

3.2. 다층 인공 신경망의 학습

신경망의 학습이라는 것은 적절한 입력이 주어졌을 때 원하는 출력값이 나오도록 각 뉴런 사이의 연결 강도를 적절히 조절하는 것이다. 연결 강도는 임의의 값으로 초기화를 하되 서로 다른 값으로, 또 0 근처의 작은 값으로 초기화를 한다. 그 후 역전파 방식의 신경망의 학습 방법은 그 이름이 뜻하는데로 어떤 입력값을 주었을 때 나오는 출력값과 기대되는 출력값을 비교하면서 그 차이가 줄어들도록 상위층으로부터 입력층의 방향으로 연결강도를 조절하는 것이다.

신경망은 학습 예제(training pair)를 통해 학습 한다. 즉 A라는 입력이 주어질 때 0.5라는 값을 출력하도록 학습하는 과정을 생각해 보자. 학습

되지 않은 신경망에 A라는 패턴을 입력으로 줄 경우 0.5와는 관계없는 값을 출력할 것이다. 신경망의 학습이라는 것은 이 출력값과 원하는 출력값(target value) 0.5와의 차이를 비교하여 그 차이를 감소시키는 방향으로 연결 강도를 조절하는 것이다. 그러나 중간층이 있으면 학습은 어려워 진다. 왜냐하면 어떤 연결 강도가 오차를 유발시키는지 알 수 없게 되기 때문이다. 역전파 방식의 학습이란 것은 그 이름이 뜻하는 데로 어떤 입력 패턴이 주었을 때 나오는 출력값과 기대되는 출력값(target)을 비교하면서 그 차이가 줄어들도록 상위 층으로부터 입력층의 방향으로 연결 강도를 조절하여 학습 예제를 학습한다.

처음 학습 하기 전의 연결 강도는 임의의 값으로 초기화를 하되 서로 다른 값으로, 또 0이 아닌 0 근처의 값으로 초기화를 한다.

은닉층에서 출력층으로의 연결 강도 조절은 식 (7), (8)와 같은 방법으로 한다.

$$W(\text{new}) = W(\text{old}) + \eta \times \text{delta} \times \text{out} \quad (7)$$

$$\text{delta} = F \times (\text{target} - \text{out}) \quad (8)$$

out : 그 뉴런이 가지는 출력값

η : 학습률

F : 활성함수 F 의 미분 값

target : 목표로 하는 출력값

학습률은 보통 0.01에서 1.0 사이의 값으로 결정되는 상수이다.

F 의 경우 시그모이드 함수를 사용한다면 $F = \text{out}/(1-\text{out})$ 로 간단히 구할 수 있는 이점이 있다.

이렇게 은닉층에서 출력층으로의 연결 강도를 조절한 후에는 보다 복잡하지만 이와 비슷한 방식으로 은닉층에서 입력층 방향으로 오차를 전파하여 연결 강도를 조절하도록 한다. 그 후 새롭게 바뀐 연결 강도로써 다시 신경망의 출력값을 계산하고 그 값이 허용 오차 이하의 오차를 가진다면 학습을 중단하고 그렇지 않은 경우는 출력값과 target value 사이의 오차가 허용오차 이하로 될 때 까지 학습을 계속한다.

4. 인공신경망을 이용한 수치해석 시뮬레이션

인공 신경망을 이용하여 일종의 추론기구를 구현하기 위하여, 학습하는 예제의 형태를 신경망이 학습하기 쉬운 형태로 바꿔주는 고려가 필요하다. 복잡한 예제를 학습시킬 경우 입력 변수가 더 많아지고, 변수가 많아지면 학습의 어려움이 따르기 때문에 되도록 많은 수의 뉴런을 사용하는 것이 유리하다. 또한 각각의 경우에 대해 얼마만큼의 은닉층의 뉴런 수가 필요한지도 연구되어져야 한다.

실제 곡가공을 위한 추론기구는 필요한 처짐량이 입력으로 주어졌을 경우, 그 양으로부터 가열선의 간격 또는 토치의 이동속도 등이 결정되어야 한다. 하지만 수치해석을 통한 검증작업에서는 단순히 검증을 위한 과정이므로 토치의 이동속도가 입력으로 주어지고 가열작업을 통해 얻어지는 처짐량을 출력하였다.

수치해석은 강판의 두께와 강판이 가지는 초기곡률 그리고 토치의 이동속도를 변화시키며 행하였다. 첫번째로 두께는 일정하고 초기곡률을 갖지 않는 강판에 대해 토치의 이동속도만이 바뀌는 경우를 해석해 보았고 두번째 경우로 강판의 두께와 초기곡률 그리고 토치의 이동속도가 모두 바뀌는 경우를 해석해 보았다. 그리고 각각의 경우에 대해 해석된 예제들로부터 새로운 입력변수(강판의 초기곡률과 두께, 토치의 이동속도)에 대해 최대처짐량을 예측하는 기구로써 신경망을 이용하였다.

1) 토치의 이동속도만 변화 시켰을 때.

강판의 두께와 토치의 이동속도를 신경망의 입력으로 하였고 가열에 따른 처짐량을 출력량으로 하였다. 신경망을 학습시킨 예제는 Table 1 과 같다.

Table 1 Training pair 1

thickness (t:mm)	torch speed (s:mm/sec)	max deflection (δ:mm)
20	7.0	2.84
20	9.0	2.53
20	12.0	0.94
20	13.0	0.54

두께를 20 mm로 두고 토치의 이동속도를 10 mm/sec으로 바꾼 경우에 대해 학습된 신경망을 이용해 처짐량을 예측해 보았다.

Table 2 Result from training pair 1

t	s	δ(exact)	δ1	δ2
20	10	2.000	2.1175(+5.9%)	2.12(+6.0%)
20	11	1.517	1.5335(+1.1%)	1.54(+1.2%)

Table 2에서 보는 바와 같이 2개의 은의총을 가진 경우, 학습시간은 단축되었으나 오차는 조금 크게 나타났다.

2) 초기곡률, 두께 그리고 토치의 이동속도를 변화 시켰을 때.

강판의 초기곡률과 두께 그리고 토치의 이동속도를 신경망의 입력으로 하였고 가열에 따른 처짐량을 출력으로 하였다. 신경망을 학습시킨 예제는 아래의 Table 3과 같다.

Table 3 Training pair 2

curvature (ρ:mm)	thickness (t:mm)	speed (s:mm/sec)	deflection (δ:mm)
1000.	20.	10.0	2.413
1000.	25.	10.0	1.197
2000.	20.	7.5	3.328
2000.	25.	7.5	2.169
3000.	20.	7.5	3.219

초기 곡률반경을 1000 mm, 두께를 20 mm 그리고 토치의 이동 속도를 7.5 mm/sec로 바꾼 경우에 대해 처짐량을 신경망을 통해 예측해 보았다.

Table 4 Verification of trained network

analysis result	3.681
result from 1 hidden layer	2.024
result from 2 hidden layer	3.925

첫번째 예제는 토치의 이동 속도만이 변화한 경우였다. 따라서 학습에 사용된 예제의 수가 적어도 비교적 근사한 해를 얻을 수 있었다. 그러나 두번째 예제에서는 강판의 초기 곡률과 두께, 그리고 토치의 이동 속도가 모두 바뀌었기 때문에 학습에 의해 근사해를 구하기 위해서는 충분히 많은 개수의 예제가 필요함을 알 수 있다. 따라서 첫번째의 경우에 비해 오차가 크게 나오는 것을 짐작할 수 있다.

3) 초기곡률, 두께, 토치속도의 학습예제를 증가시킨 경우.

두번째 예제에서 오차를 줄이기 위하여 Table 5와 같이 예제를 증가시켜 학습시켜 보았다.

Table 5 Training pair 3

curvature	thickness	speed	deflection
1000	20	7.5	3.654
1000	20	10.0	2.413
1000	20	12.0	1.917
1000	25	10.0	1.958
1000	25	12.0	1.710
2000	20	7.5	3.328
2000	20	10.0	2.465
2000	20	12.0	2.040
2000	25	7.5	2.169
2000	25	10.0	1.981
3000	20	7.5	3.219
3000	20	10.0	2.471

초기 곡률반경과 두께 그리고 토치의 이동 속도를 Table 6과 같이 두가지 경우에 대해 신경망을 통하여 처짐량을 추론예측해 보았다.

Table 6 Result from training pair 3

ρ	t	s	δ_{exact}	δ_1	δ_2
1000	25	7.5	2.406	2.56(+6.4%)	2.87(+19%)
2000	25	11	1.89	1.90(+0.3%)	1.84(-2.7%)

1. Network with two hidden layers. 4 neurons for each hidden neurons
Number of training is 162900.
2. Network with two hidden layers. 6neurons for each hidden layers.
Number of training is 227700.

Table 6에서 보는 바와 같이 학습량의 증가로 오차는 상당히 줄일수 있었다. 그러나, 은닉층의 뉴런 수를 증가시킬 경우 학습시간이 증가 하였으며 오차도 오히려 크게 나타났다. 따라서 인공신경망을 적용시킬 경우 은의층과 뉴런의 수의 적절한 선택이 요구된다.

5. 결 론

본 논문에서는 선체외판 곡면가공 시뮬레이션 시스템구축에 있어서 필요한 열탄소성구조해석의 정보도출을 경제적인 방법으로 처리하는 기법연구를 수행하였으며, 최적해의 도출을 위하여 인공신경망중 역전파 방법이 이용되었다.

인공 신경망을 이용하여 추론기구를 구현하기 위하여, 신경망의 은닉층의 갯수와 은의층에 있는 뉴런의 갯수를 바꿔 주며 학습을 시켰다. 그 결과 두개의 은의층을 가진 인공 신경망의 경우 각 은의층에 뉴런의 갯수가 충분하다면 학습 예제들을 쉽게 학습하였고, 또 학습된 결과로부터 새로운 해를 도출해 낼 때 그 값은 실제 값과 비교해 볼 때 비교적 작은 오차를 보였다. 결과적으로 구하고자 하는 문제 영역 근처에 충분한 학습 예제가 마련된다면 비교적 실제 값에 근사하는 결과를 보인다는 것을 알 수 있었으며, 수치해석결과를 토대로 인공신경망은 곡면가공에 필요한 구조해석정보를 효율적으로 활용할 수 있음을 확인하였다.

참 고 문 헌

- [1] 신종계, "선상가열에 의한 평판가공 Simulator 연구", 대한조선학회 논문집, 제29권, 제1호, 191-200, 1992.
- [2] Shin, J.G., Lee, J.H and Kim, W.D., "A Numerical Simulation of a Line Heating Process for Plate Forming", PRADS95, pp.2.1447-2.1458, 1995.
- [3] 노인식, 신종계, 이광한, "유한요소해석에 의한 선상가열 변형의 시뮬레이션", 대한조선학회 논문집, 제32권, 제2호, 75-83, 1995
- [4] Nomoto, T., Takechi, S., Shouki, K., "Development of Simulator for Plate by Line Heating Considering In-Plane Shrinkage", Journal of the Society of Naval Architects of Japan, Vol. 130, pp. 577-586, 1971.
- [5] Shin, J.G. and Moshaiov, A., 'Modified Strip Model for Analyzing the Line Heating Method - Part1 : Elastic Plates", Journal of Ship Research, Vol. 35, No. 2, pp. 172-182, 1991.
- [6] P.D.Wasserman, "Neural computing -theory and practice-", ANZA Rearch, Inc., 1989.