

〈논 문〉

신경망을 이용한 HSLA 강의 고온 유동응력 예측 및 통계방법과의 비교

천명식* · 이준정* · B. Jalal** · J. G. Lenard**

(1996년 11월 12일 접수)

A Comparative Study of Material Flow Stress Modeling by Artificial Neural Networks and Statistical Methods

Myung Sik Chun, Joon Jeong Yi, Biglou Jalal and John Gustav Lenard

Key Words : Feed Forward Back-propagation(전향단계 역전파법), Neural Network(신경망), Hyperbolic-sine Function(쌍곡선사인 함수), Training Data(교사데이터), Testing Data(실험데이터), Zener-Hollomon Parameter(온도보상 변형속도계수), Learning Factor(학습계수), Momentum Factor(모멘텀계수)

Abstract

The knowledge of material stress-strain behavior is an essential requirement for design and analysis of deformation processes. Empirical stress-strain relationship and constitutive equations describing material behavior during deformation are being widely used, despite suffering some drawbacks in terms of ease of development, accuracy and speed. In the present study, back-propagation neural networks are used to model and predict the flow stresses of a HSLA steel under conditions of constant strain, strain rate and temperature. The performance of this network model is compared to those of statistical models on rate equations. Well-trained network model provides fast and accurate results, making it superior to statistical models.

기호설명

- i : 입력층의 뉴런수
 h_j : 은닉층의 뉴런벡터
 W_{ij} : 입력층과 출력층간의 가중값
 θ_j : 입력층과 은닉층간의 임계값
 O_k : 출력층의 뉴런벡터
 W_{kj} : 은닉층과 출력층간의 가중값
 θ_k : 은닉층과 출력층간의 임계값

- δ_k : 각 출력뉴런에 대한 에러벡터
 Y_k : 출력층의 목표값
 β : 학습계수(learning factor)
 η : 모멘텀계수(momentum factor)
 X : 정규화 전의 값
 Y : 정규화 후의 값
 A, α : 상수
 n : 변형속도 민감도(strain rate sensitivity)
 Q : 활성화에너지(activation energy)
 R : 가스상수(8.31×10^{-3} KJ/mol.K)
 ϵ : 변형속도
 T : 절대온도

*회원, 포항산업과학연구원 철강프로세스부문

**Department of Mechanical Engineering, University of Waterloo, Canada

I. 서 론

압연, 단조, 압축 등 소성가공공정의 변형거동을 해석할 때 변형률, 변형속도, 온도와 응력간의 구성방정식에 대한 표현은 중요하다. 유한요소법과 같은 수치해석법의 증가와 더불어 고온가공시 응력과 변형률의 관계식은 재료의 변형형상에 중요한 영향을 미치게 된다. 고온변형조건에서 변형속도와 온도의 영향을 고려한 응력과 변형률간의 관계식을 표현하는 방법들이 많이 발표되어 왔다.^(1~8) 최근까지의 연구는 주로 압축, 인장, 비틀림 등의 실험데이터로부터 경험적인 모델 또는 통계적인 모델식의 구성이었다. 그러나, 고온조건에서는 변형경화(strain hardening), 동적회복(dynamic recovery), 정적 및 동적재결정(static and dynamic recrystallization)을 포함하는 미시적인 거동의 표현은 단순한 통계해석법으로는 처리하기가 어려우며, 무엇보다도 예측정도의 정확성을 보장할 수 없다. 특히, 3개의 공정변수(변형률, 변형속도, 온도)를 모두 포함한 유동응력곡선의 표현은 변형경화와 동적연화(dynamic softening) 현상을 수반하는 강종의 경우에 주식화처리의 어려움이 있다.

Lenard 등⁽⁶⁾은 주어진 변형률, 변형속도, 온도 조건에서 유동응력을 표현하기 위하여 다차원 데이터뱅크(multi-dimensional data bank) 시스템을 이용하여 내삽과 외삽에 의해 응력을 예측하였다. Wang 등⁽⁷⁾은 Nb-V 철가 저합금강에 대한 변형저항을 표현하기 위해 Zener-Hollomon 변수를 사용하여 동적재결정에 의한 동적연화 현상이 존재하는 변형영역에 대해서 유동응력을 예측하였다. 또한, Rao와 Hawbolt⁽⁸⁾는 중탄소강에 대한 고온변형거동을 쌍곡선사인 함수를 사용하여 표현하였다. 그러나, 이와같은 경험적이거나 통계적인 모델은 수식화 처리의 어려움 및 시간적인 손실뿐만 아니라 모든 강종에 대하여 적용하기가 곤란하다.

반면에 신경망은 입력값과 출력값간의 관계식이 없어도 학습절차에 따라 입력데이터로부터 출력데이터로 직접 대응(mapping) 할 수 있는 능력이 있어, 다른 공정변수가 추가되더라도 입력변수를 쉽게 처리하여 학습할 수 있는 장점을 갖고 있다. 신경망을 이용한 재료의 유동응력을 예측한 예는 드물다. Rao와 Prasad⁽⁹⁾는 상업화된 신경망 소프트

웨어를 사용하여 저탄소강에 대한 고온조건에서의 변형저항을 예측하였는데 기존의 변형률, 변형속도, 온도등 3개의 입력변수에 이들을 선형화한 변수를 포함시킨 6개의 입력변수를 사용하여 학습함으로써, 기존의 3개의 입력변수의 경우보다 우수함을 입증하였다. Hwe 등⁽¹⁰⁾은 3개의 입력변수에 탄소당량을 추가하여 고온상태의 유동응력을 예측하였는데, 적응학습(adaptability learning)법을 도입하여 예측정도가 향상됨을 보였다. 본 연구에서는 공학분야에 광범위하게 사용되고 있는 전향단계 역전파법(feed-forward error back propagation)을 이용하여 HSLA강의 고온 유동응력을 예측하였으며, Zener-Hollomon 변수를 이용한 통계해석결과와 비교하였다.

2. 역전파 신경망

Fig. 1에 보인 바와 같이 다층 역전파 모델(multi-layered back propagation model)은 크게 3개의 뉴런층으로 입력층(input layer), 은닉층(hidden layer), 출력층(output later)으로 구성된다. 역전파 학습 알고리듬은 출력값과 목표값과의 평균오차(mean square error)를 최소로 하기위하여 고안된 반복구배 알고리듬(iterative gradient algorithm)으로 연속이고, 미분가능한 비선형조건을 요구한다. Fig. 2는 역전파법의 흐름도이며, 학습 알고리듬을 설명하면 다음과 같다.

(a) 입력층과 은닉층 및 은닉층과 출력층간의 가중값과 임계값을 작은 값으로 초기화 한다.

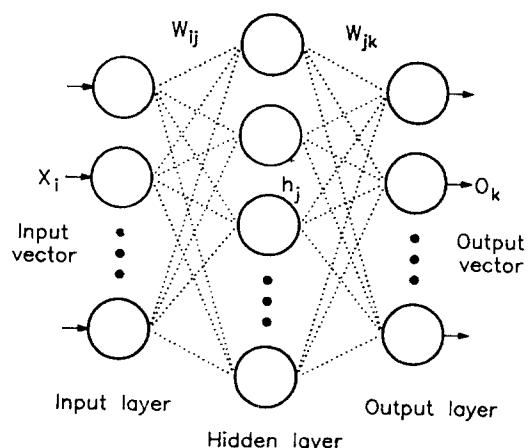


Fig. 1 A three layer feedforward neural network

(b) 모든 입력값과 출력값을 0.1~0.9 범위로 정규화(normalizing) 한다.

(c) 은닉층의 각 절점에서의 출력값을 계산한다.

$$h_j = f\left(\sum_{i=1}^n W_{ij}X_{ij} - \theta_j\right) \quad (1)$$

(d) 출력층의 각 절점에 대한 출력값들을 계산한다.

$$O_k = f\left(\sum_{j=1}^m W_{kj}h_j - \theta_k\right) \quad (2)$$

여기서, $f(\cdot)$ 는 시그모이드 활성화함수(sigmoid activation energy)이다. 활성화함수로는 여러 함수가 있으나, 다음의 논리함수(logistic function)를 사용하였다.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

(e) 목표값과 출력값과의 출력층의 오차를 계산한다.

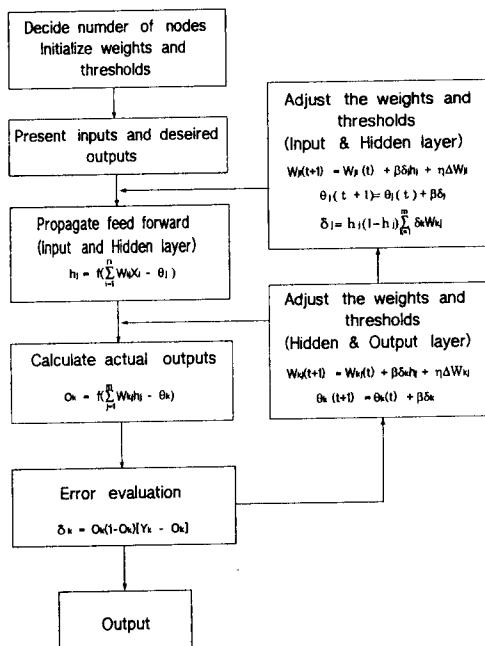


Fig. 2 Flow chart of the back-propagation learning algorithm

$$\delta_k = O_k(1 - O_k)(Y_k - O_k) \quad (4)$$

(f) 은닉층의 오차를 계산한다.

$$\delta_j = h_j(1 - h_j) \sum_{k=1}^n \delta_k W_{kj} \quad (5)$$

(g) 출력층에서의 가중값과 임계값을 조정한다.

$$W_{ji}(t+1) = W_{ji}(t) + \alpha \delta_k h_j + \eta (W_{kj}(t) - W_{kj}(t-1)) \quad (6)$$

$$\theta_k(t+1) = \theta_k(t) + \beta \delta_k \quad (7)$$

여기서, η 는 수렴성을 좋게하기 위하여 전 단계의 가중값의 영향을 고려한 모멘텀계수로 0~1 사이의 값이다.

(h) 은닉층에서의 가중값과 임계값을 조정한다.

$$W_{ji}(t+1) = W_{ji}(t) + \alpha \delta_i X_i + \eta (W_{ji}(t) - W_{ji}(t-1)) \quad (8)$$

$$\theta_j(t+1) = \theta_j(t) + \beta \delta_j \quad (9)$$

(i) 출력층의 오차가 각 뉴런에 대한 허용값내 도달할 때까지 (a)~(h)를 반복 계산한다.

3. 변형저항 예측 모델링

본 연구에 사용된 응력-변형률 데이터는 Lenard 등⁽¹¹⁾에 의해 수행된 고온 압축실험 결과를 이용하였다. 실험은 일정 변형속도를 부여할 수 있는 밀폐형 유압서보 인스트론 압축실험기(closed-loop servo-hydraulic Instron machine)를 사용하였으며, 시편가열은 분리가능한 3-zone 가열로 분위기 내에서 수행되었다. 시편은 Nb-V를 첨가한 HSLA 강으로 화학적성분은 Table 1과 같다. 압축시편은 직경 10 mm, 길이 15 mm의 원통형으로 실험시 그라스운활제의 이탈을 방지하기 위하여 양단면은 0.1 mm깊이로 기계가공되었다. 또한 시편의 온도는 원통형 시편의 길이방향 중심부에 K형 열전대를 삽입하여 온도를 측정하였으며, 875, 900, 950°C의 3가지 온도조건과 0.01, 0.1, 1, 2 sec⁻¹의 4가지 변형속도조건에서 실험이 실시되었다.

Table 1 The chemical composition of the material (wt %)

C	Mn	Nb	V	Si	Cu	Ni	P	Ti	Ca	S	N
0.1	1.093	0.0877	0.0795	0.3645	0.0152	0.0138	0.0076	0.0042	0.0032	0.0023	0.0092

Table 2 Experimental matrix used in flow stress evaluation tests

Temperature (°C)	Strain rate (sec ⁻¹)			
	0.01	0.1	1	2
875	A1	A2	A3	—
900	B1	B2	B3	B4
950	C1	C2	C3	C4

2절에서 언급한 역전파 신경회로망 학습 알고리듬이 유동응력을 예측하는데 사용되었다. Table 2 와 같이 학습에 사용된 조건은 모두 11조건이며, B_2 의 실험데이터(testing data)를 제외한 나머지 10조건들을 교사데이터(training data)로 하여 학습하였다. 11조건에 대한 고온 압축실험 결과로부터 변형률을 0.1 간격으로 하여 각 실험조건에 10 개의 데이터를 선정하여 그 중 100개의 교사데이터를 학습시켰으며 모든 데이터는 다음식과 같이 정규화하여 사용하였다.

$$Y = Y_{\min} + \frac{Y_{\max} - Y_{\min}}{X_{\max} - X_{\min}} \cdot (X - X_{\min}) \quad (10)$$

여기서, Y_{\min} , Y_{\max} 는 0.1~0.9 범위의 값 그리고 X_{\min} , X_{\max} 는 정규화시키기 전의 최소, 최대값을 각각 나타낸다. 학습 후에는 (11)식과 같이 정규화시킨 데이터를 처음값으로 다시 환산하였다.

$$X = X_{\min} + \frac{X_{\max} - X_{\min}}{Y_{\max} - Y_{\min}} (Y - Y_{\min}) \quad (11)$$

학습제수는 초기에 0.5부터 시작하여 점차 0.9까지 증가시켰으며, 모멘텀제수(momentum factor)는 0.7~0.9 범위에서 목표값과의 오차가 최소인 조건을 구하였는데 적절한 학습제수와 모멘텀제수로는 각각 0.7과 0.9이었다. 은닉층의 수는 1개를 사용하였을 경우와 2개를 사용하였을 경우를 비교하였으나 거의 차이가 없어 1개의 은닉층만을 사용하였다. 따라서 본 연구에서 유동응력을 예측하기 위한 신경회로망은 3개의 입력뉴런, 16개의 은닉뉴런 그리고 1개의 출력뉴런으로 구성하여 교사데이터를 학습시켰다.

4. 통계적인 해석방법

열간압연공정에서 응력과 온도의 의존성을 수식

으로 표현하기 위한 여러 방법들이 제시되어 왔다. 그 중에서도 Sellars 등⁽¹²⁾이 제시한 쌍곡선사인 관계식(hyperbolic-sine relationship)이 넓은 범위의 조건에서 만족하는 것으로 알려져 있으며, 유동응력의 항을 지수(exponential), 힘(power) 및 쌍곡선사인 함수꼴로 구성하며, 식 (12)으로 나타내어진다.

$$\dot{\epsilon} = A \sinh(\alpha\sigma)^n \exp\left(-\frac{Q}{RT}\right) \quad (12)$$

식 (12)에 대수를 취하면

$$\ln(\dot{\epsilon}) = \ln(A) + n \ln(\sinh(\alpha\sigma)) - \frac{Q}{RT} \quad (13)$$

으로 된다. 식 (13)에 변형속도 민감도계수는 일정온도와 변형률조건에서 $\ln(\sinh(\alpha\sigma))$ 와 $\ln(\dot{\epsilon})$ 와의 관계도로부터 얻는다. Fig. 3은 변형률이 0.4인 경우, 변형속도 민감도를 나타낸 결과로써 $\ln(\sinh(\alpha\sigma))$ 와 $\ln(\dot{\epsilon})$ 와의 선형적인 관계로부터 기울기가 구해진다. 이 때 사용한 재료상수 a 는 탄소함유량에 따라 변화하는 값으로 Hatta 등⁽⁴⁾이 제시한 문헌을 이용하였으며, HSLA강의 탄소함유량을 고려하여 0.012 Mpa⁻¹으로 가정하였다. 한편, 활성화에너지(Q)를 구하기 위하여 식 (13)을 정리하고 $1/T$ 로 미분하면 다음 식으로 표현된다.

$$Q = Rn \frac{d \ln(\sinh(\alpha\sigma))}{d(1/T)} \quad (14)$$

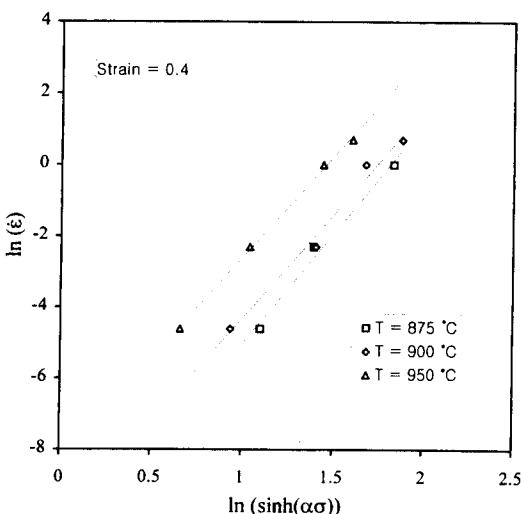
Fig. 13의 $\ln(\sinh(\alpha\sigma))$ 와 $1/T$ 와의 관계도로 부

Fig. 3 Plot for determination of strain rate sensitivity parameter

터 구한 기울기를 구하고 식 (14)에 대입하면, 활성화에너지가 계산된다. Fig. 4는 변형률이 0.4인 경우, $\ln(\sinh(\alpha\sigma))$ 와 $1/T$ 사이의 관계를 나타낸 것이다. 식 (12)을 온도보상 변형속도계수(temperature compensated strain rate parameter)인 Zener-Hollomon Parameter, Z 로 표현하면 식 (15)로 나타낼 수 있다.

$$Z = A \sinh(\alpha\sigma)^n \quad (15)$$

식 (15)에 대수를 취하면

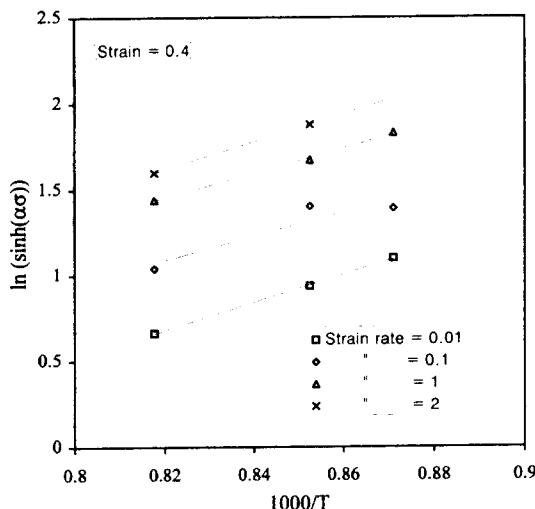


Fig. 4 Plot for calculation activation energy

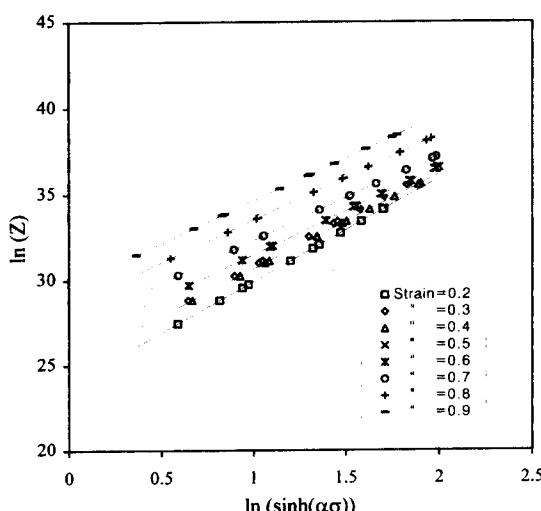


Fig. 5 Zener-Hollomon plot using hyperbolic-sine relationship

Table 3 Values of Q , n and $\ln(A)$ obtained at different strain levels

Strain	Q	n	$\ln(A)$
0.1	320.8	7.13	24.43
0.2	322.1	5.99	23.93
0.3	336.2	5.68	25.17
0.4	357.3	5.5	25.17
0.5	346.7	5.1	26.41
0.6	351.8	5.06	26.44
0.7	341.9	4.94	27.39
0.8	351.9	4.94	28.58
0.9	352.6	4.93	29.70

$$\ln(Z) = \ln(A) + n \cdot \ln(\sinh(\alpha\sigma)) \quad (16)$$

으로 된다. Fig. 5는 측정된 응력, 온도 및 변형속도를 쌍곡선사인 함수의 표현이 가능한지 여부를 알아 보기 위한 주어진 변형률조건에서의 $\ln(Z)$ 와 $\ln(\sinh(\alpha\sigma))$ 의 관계도이다. 이 결과에서 알 수 있듯이 선형적인 관계를 보이므로 쌍곡선사인 함수로의 표현이 가능하다. 따라서 $\ln(A)$ 와 n 값은 Fig. 5의 그래프로부터 절점과 기울기로부터 구할 수 있다. Table 3은 이와 같은 방법으로 다른 변형률조건에 대해서 구한 Q , n , 및 $\ln(A)$ 의 값을 나타낸 표이다.

5. 결과 및 고찰

본 연구에서 HSLA 강의 열간 변형저항을 예측하기 위한 방법으로써 역전과 신경망에 의한 학습방법이 사용되었으며, 예측결과의 성능을 평가하기 위하여 통계해석결과와 비교되었다. Fig. 6은 875°C의 온도조건에서 변형률에 대한 유동응력을 나타낸 것이다. 점선은 통계적인 해석방법 의한 결과이고, 실선은 신경망에 의한 예측결과이다. 변형률이 작은 범위에서는 신경망 모델이 약간의 오차를 보이나 변형률이 증가할수록 실험값과 거의 일치함을 알 수 있다. 이러한 현상은 변곡점부근의 변형률이 작은 범위에서 변형률 증분을 세분화하여 교사데이터를 추출하지 않았기 때문으로 추정된다. 한편, 통계모델은 변형률이 작은 범위에서 오차가

작으나 변형률이 증가할수록 실험값과의 오차가 커짐을 알 수 있다.

Fig. 7은 950°C의 온도조건에서 실험결과와의 비교를 나타낸 것으로 Fig. 6의 경우와 마찬가지로 신경망을 이용한 경우가 통계적인 방법보다 예측정도가 더 우수함을 보인다.

Fig. 8은 900°C의 온도조건에서 실험데이터(test-

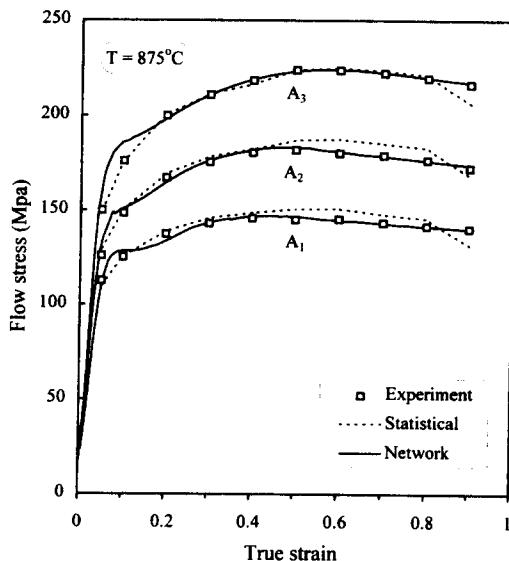


Fig. 6 Comparison of the predicted and the experimental flow stress at the temperature of 875°C.

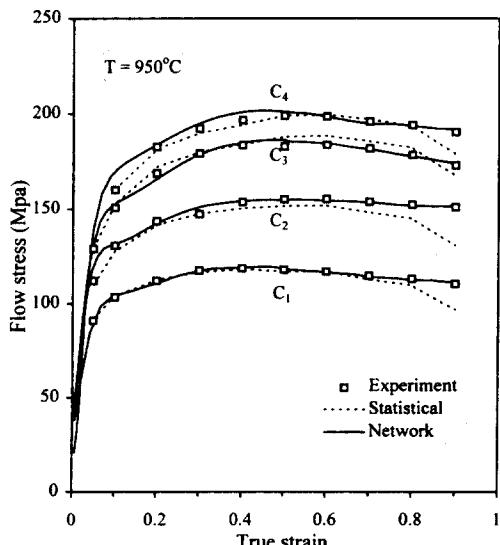


Fig. 7 Comparison of the predicted and the experimental flow stress at the temperature of 950°C.

ing data, B_2)의 신뢰도를 알아보기 위하여 교사된 학습계수로부터 계산한 결과이다. 위의 B_2 조건은 교사학습에 포함하지 않은 데이터로 교사된 신경망모델의 내삽(interpolation)의 가능여부를 평가하기 위하여 수행된 결과이다. 결과에서 알 수 있듯이 교사학습에 포함시킨 조건(B_1 , B_2 , B_3)보다는 예측정도가 다소 떨어지나 기존의 통계적인 방법보다는 우수하다. 따라서 신경망모델을 사용하는 경우 교사학습에 포함되지 않은 조건에도 예측이 가능함을 알 수 있다.

Table 4는 통계모델과 신경망모델의 결과에 대한 평균 상대오차(mean relative error)를 온도별로 나타낸 것이다. 여기서, 평균 상대오차는 실험값과 예측값과의 차이를 실험값으로 나눈 값이다.

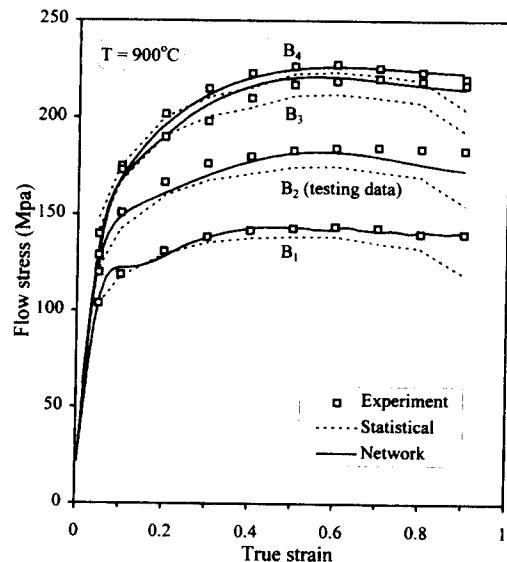


Fig. 8 Comparison of the neural network predicted and the experimental flow stress of B_2 unseen test condition

Table 4 Comparison of mean relative errors of neural network model with that of statistical model

Temperature (°C)	Mean relative error(%)	
	Statistical model	Network model
875	2.01	1.37
900	4.81	1.69
950	2.13	1.38

신경망의 결과는 모든 온도조건에서 1.7% 이내의 평균오차를 보이나 통계모델은 2% 이상의 오차를 갖는다.

6. 결 론

Nb-V을 첨가한 HSLA 강의 고온 압축실험 결과로부터 열간변형저항을 예측하기 위하여 전향단계 역전파 신경망 모델이 사용되었으며, 성능평가를 위해서 기존의 통계해석방법의 경우와 비교한 결과 다음과 같은 결론을 얻었다.

(1) 적절하게 교사된 신경망모델은 교사학습에 포함된 변형률조건에서 유동응력을 예측한 결과 실험값과 잘 일치한다.

(2) 교사학습에 포함하지 않은 실험데이터를 적절하게 교사된 신경망모델에 적용한 결과 측정값과 잘 일치하므로 교사학습범위내의 다른 변형률조건에 대해서도 내삽(interpolation)이 가능함을 보였다.

(3) 신경망모델의 성능평가를 위해서 통계해석결과와 비교한 결과 신경망의 예측정도가 더 우수 하다.

후 기

본 연구는 Waterloo 대학과 공동으로 수행한 연구중의 일부 내용이며, 저자에게 1년간 Visiting Researcher로서 허락해 주신 포항산업과학연구원(RIST)에 감사드립니다.

참고문헌

- (1) Shida, S., 1974, "Effect of Carbon Content, Temperature and Strain Rate on Compression Flow Stress of Carbon Steels," Hitachi Res. Lab. Report, pp. 1~9.
- (2) Yada, H. and Sebum, T., 1986, "Resistance to Hot Deformation of Steels," *J. of Plasticity of Institute*, Japan, No. 27, pp. 34~44.
- (3) Bargar, D. L., 1987, "The High Temperature and High Strain Rate Behaviour of a Plain Carbon and an HSLA Steel," *J. of Mech. Working Tech.*, No. 14, pp. 295~307.
- (4) Hatta, N., Kokado, J. I., Kikuchi, S. and Takada, H., 1985, "Modelling on Flow Stress of Plain Carbon Steel at Elevated Temperatures," *Steel Research*, No. 56, pp. 575~582.
- (5) Laasraoui, A. and Jonas, J. J., 1991, "Prediction of Steel Flow Stresses at High Temperatures and Strain Rates," *Metall. Trans.*, 22A, pp. 1545~1558.
- (6) Lenard, J. G., Wang, F. and Nadkarni, G., 1987, "The Role of Constitutive Formulation in the Analysis of Hot Rolling," *J. of Eng. Mat. Techn.* ASME 109, pp. 343~349.
- (7) Wang, F. and Lenard, J. G., 1991, "The Constitutive Behaviour of a Nb-V HSLA Steel in the Temperature Range of 900 to 975°C," *Steel Research*, No. 2, pp. 66~71.
- (8) Rao, K. P. and Hawbolt, E. B., 1992, "Development of Constitutive Relationships Using Compression Testing of a Medium Carbon Steel," *Transactions of the ASME*, Vol. 114, pp. 116~123.
- (9) Rao, K. P. and Prasad, Y. K. D. V., 1995, "Neural Network Approach to Flow Stress Evaluation in Hot Deformation," *J. of Materials Processing Technology*, 53, pp. 552~566.
- (10) Hwe, Y. J., Pan, Y. T. and Lenard, J. G., 1996, "A Comparative Study of Artificial Neural Networks for the Prediction of Constitutive Behaviour of HSLA and Carbon Steels," *Steel Research*, 67, No. 2, pp. 59~65.
- (11) Lenard, J. G. and Tajima, M., 1995, "Thermo-Mechanical Treatment of a High Nb-High V Bearing Microalloyed Steel," *ISIJ International*, Vol. 35, No. 12, pp. 1509~1517.
- (12) Sellars, C. M. and McG. Targat, J., 1972, "Hot Workability," *Int. Metall. Rev.*, 17, pp. 1~24.