

## 공구강의 고온 변형 거동 예측을 위한 모델 비교 연구

김근학\* · 박동성\* · 전중환\*\* · 이민하\*\* · 이석재\*<sup>†</sup>

\*전북대학교 신소재공학부, \*\*한국생산기술연구원 융합공정소재그룹

### Comparison Study of Prediction Models for Hot Deformation Behavior of Tool Steel

Keunhak Kim\*, Dongsung Park\*, Joong-Hwan Jun\*\*, Min-Ha Lee\*\*, Seok-Jae Lee\*<sup>†</sup>

\*Division of Advanced Materials Engineering, Chonbuk National University

\*\*Advanced Process and Material R&D Group, Korea Institute of Industrial Technology

**Abstract** High temperature flow behaviors of Fe-Cr-Mo-V-W-C tool steel were investigated using isothermal compression tests on a Gleeble simulator. The compressive test temperature was varied from 850 to 1,150°C with the strain rate ranges of 0.05 and 10 s<sup>-1</sup>. The maximum height reduction was 45%. The dynamic softening related to the dynamic recrystallization was observed during hot deformation. The constitutive model based on Arrhenius-typed equation with the Zener-Hollomon parameter was proposed to simulate the hot deformation behavior of Fe-Cr-Mo-V-W-C steel. An artificial neural network (ANN) model was also developed to compare with the constitutive model. It was concluded that the ANN model showed more accurate prediction compared with the constitutive model for describing the hot compressive behavior of Fe-Cr-Mo-V-W-C steel.

(Received June 18, 2018; Revised June 26, 2018; Accepted July 6, 2018)

**Key words** : Hot deformation behavior, Constitutive model, Zener-Hollomon parameter, Artificial neural network, Tool steel

## 1. 서 론

공구강은 고탄소, 고크롬계 합금으로 추가적으로 Mo, V, W, Nb 등과 같은 강력한 탄화물 형성 원소를 포함하는 고합금강이다. 이들 공구강은 고온에서 냉각 후 템퍼링 처리를 통해 다양한 석출상들을 제어함으로써 높은 경도와 우수한 내마모성을 보인다 [1-3]. 하지만 높은 탄소와 크롬 등의 첨가 원소들로 인해 응고 중 정출 탄화물이 존재하게 되고 고온에서도 상당량의 석출물이 존재하게 되는데 이는 고온에서의 변형성을 저하시켜 열간 단조 시 불량 발생되는 원인이 되기도 한다. 따라서 합금 원소의 첨가량이 높은 합금강일수록 고온에서의 변형 거동을 정확하게 파악하는 것은 소재의 성공적인 열간 가공을 위해 매우 중요하다.

일반적으로 소재의 변형 거동을 수학적으로 표현하기 위해서 구성 방정식(constitutive equation)이 사

용된다. 다양한 변형 속도와 실험 온도에서 소재의 변형 거동을 나타내기 위한 구성 방정식의 종류는 대표적으로 Johnson-Cook 모델[4, 5]과 Zerilli-Armstrong 모델[6, 7] 등이 있다. 하지만 높은 온도와 변형속도 하에서 재료의 고온 거동은 비선형적이고, 유동응력에 대한 많은 상수들 또한 비선형적이다. 이러한 비선형적인 관계들은 구성 방정식의 예측 정확도를 감소시키며, 정확도가 높은 구성 방정식을 만드는 것은 많은 시간이 필요하다.

요즘 다양한 연구 분야에서 인공지능을 활용한 데이터 분석이 주목을 받고 있다. 기존에 널리 사용되던 정해진 수식에 따르는 회귀방법과 달리, 인공 신경망(artificial neural network, ANN) 모델은 수학적 모델 혹은 최적 변수들을 계산할 필요가 없이, 학습 데이터, 입력값과 출력값들로부터 스스로 학습을 통해 모델을 구축한다[8, 9]. 그러므로 인공 신경망 모델은 복잡하고 비선형적인 관계를 가지는 재료

<sup>†</sup>Corresponding author. E-mail : seokjaelee@jbnu.ac.kr  
Copyright © The Korean Society for Heat Treatment

모델링과는 다른 새로운 접근 방법을 제시 할 수 있다.

실제로 지난 몇 년 동안 인공 신경망 모델을 사용하여 금속 소재의 고온 변형 거동을 예측한 여러 연구들이 보고되고 있다[10-15]. Li 등[10]은 개량된 2.25Cr-1Mo 강에 대한 고온 압축 실험을 실시하고 구성 방정식과 인공 신경망 모델의 예측 정확도를 비교하였다. Singh 등[11]은 높은 인(P)이 첨가된 합금강의 고온 변형 거동을 실험으로 측정하였다. 이를 바탕으로 인공 신경망 모델을 만들고 공정맵(process map)을 제시하여 최적의 변형 조건을 찾고자 하였다. Mirzaei와 연구자들[12]은 오스테나이트계 스테인리스강에 대해 동적 회복과 동적 재결정을 고려한 인공 신경망 모델에 대해 연구하였고, Ren 등[13]은 마르텐사이트계 스테인리스강의 고온 거동을 인공 신경망 모델과 구성 방정식을 이용하여 모델링하고 비교하였다. 철강 외 다른 금속에 대한 여러 연구들도 보고되고 있다. Haghdaei와 동료들[14]은 A356 알루미늄 합금의 고온 거동을 예측할 수 있는 인공 신경망 모델에 대해 보고하고 있다. Zhao 등[15]도 티타늄 합금의 고온 변형 거동에 대해 구성 방정식과 인공 신경망 모델의 예측 결과를 실험 데이터와 비교 분석한 연구를 수행하였다.

하지만 합금 원소의 첨가량이 높은 공구강의 고온 변형 거동을 예측하기 위한 구성 방정식이나 인공 신경망 모델에 대한 연구는 현재 미흡한 상태이다. 따라서 본 연구에서는 다양한 고온 조건에서 변형 속도를 변화시켜 가면서 압축실험을 실시하고, 압축 실험 데이터를 이용하여 구성 방정식과 인공 신경망 모델을 제시하고 예측 결과를 비교, 평가해 보았다.

## 2. 실험방법

이번 연구에서는 저자들이 기존에 개발하였던 공구강의 고온 변형 거동에 대해 조사하였다[16]. 사용된 공구강의 화학 조성은 Fe-0.96%C-0.52%Si-0.5%Mn-6.09%Cr-2.87%Mo-0.5%W-0.4%V (in wt.%)이다. 고온 압축 시험은 Gleeble 3500을 이용하여 실시하였다. 시험 시편은 직경 10 mm, 높이 12 mm의 원통형 시편이다. 시험 시편을 10°C/s의 가열 속도로 1,050°C까지 가열한 후 5분간 유지하고 850~

1,150°C 사이 온도에서 압축 시험을 실시하였다. 1,050°C에서 등은 유지한 이유는 고온 압축 전 시편의 전위 밀도를 동일하게 낮추기 위함이다. 고온 압축 시험은 0.05, 1, 10 s<sup>-1</sup>의 변형률 속도로 수행하였으며 압축 시험이 끝난 후 상온까지 공냉하였다.

## 3. 결과 및 고찰

### 3.1 구성 방정식

응력 거동에 대한 변형속도와 온도의 관계는 아래 식과 같이 Zener-Hollomon parameter(Z)로 표현 가능하다 [17].

$$\dot{\epsilon} = \exp(Q/RT) = Af(\sigma) \quad (1)$$

여기서  $Q$ 는 활성화 에너지,  $R$ 은 기체 상수,  $T$ 는 절대온도,  $A$ 는 구조 의존 함수, 그리고  $f(\sigma)$ 는 응력의 함수를 의미한다.  $Z$  값이 낮을 때 동적 회복과 동적 재결정이 발생하고,  $Z$  값이 높을 때 가공경화가 나타난다.

식 (1)은 다음과 같이 응력에 따라 구분하여 나타낼 수 있다[18].

$$\dot{\epsilon} = A_1 \sigma^{n'} \exp(-Q/RT) \quad (2)$$

$$\dot{\epsilon} = A_2 \exp(\beta\sigma) \exp(-Q/RT) \quad (3)$$

$$\dot{\epsilon} = A [\sinh(\alpha\sigma)]^n \exp(-Q/RT) \quad (4)$$

위 식들에서  $A_1$ ,  $A_2$ ,  $A$ ,  $n'$ ,  $n$ ,  $\alpha$ ,  $\beta$ 는 재료 상수이고,  $\sigma$ 는 유동 응력이다. 식 (2)는 응력이 낮을 때( $\alpha\sigma < 0.8$ ), 식 (3)은 응력이 높을 때( $1.2 < \alpha\sigma$ ), 그리고 식 (4)는 응력 크기의 구분 없이 모든 응력 범위에 대해 적용 가능하다. 식 (2)와 식 (3) 양변에 자연 로그를 취하면 식 (5)와 식(6)과 같이 나타낼 수 있다.

$$\ln \dot{\epsilon} = \ln A_1 + n' \ln \sigma - Q/RT \quad (5)$$

$$\ln \dot{\epsilon} = \ln A_2 + \beta\sigma - Q/RT \quad (6)$$

여기서  $n'$ 과  $\beta$ 는 식 (5)와 식 (6)에서  $\ln \dot{\epsilon}$ 를  $\ln \sigma$ 와  $\sigma$ 에 대해 그래프로 나타낼 때 기울기 값이다.

**Table 1.** Material constants at different strains

True strain	alpha	beta	n	n'	Q (kJ/mol)	lnA
0.05	0.008821	0.082575	7.30378	12.01516	453.4633	39.79082
0.15	0.009309	0.101289	10.02235	16.70634	882.0263	77.54866
0.25	0.011422	0.080776	6.19884	13.02719	692.8675	60.17990
0.35	0.011779	0.071013	6.31923	11.30381	682.0909	59.50636
0.45	0.012091	0.079297	9.08041	12.65711	958.9657	84.73384

식 (4)의 양변에 자연 로그를 취하면  $n$ 과  $Q$  값을 구할 수 있다.

$$\frac{1}{n} = \frac{\partial \ln[\sinh(\alpha\sigma)]}{\partial \ln \dot{\epsilon}} \Big|_T \quad (7)$$

$$Q = Rn \frac{\partial \ln[\sinh(\alpha\sigma)]}{\partial (1/T)} \Big|_T \quad (8)$$

식 (8)에서  $Q$  값을 구하면 다음과 같이 식 (1) 양변에 자연 로그를 취해  $Z$  값을 구할 수 있다.

$$\ln Z = n \ln[\sinh(\alpha\sigma)] + \ln A \quad (9)$$

위 계산을 다양한 변형률 데이터에 대해 적용하면 Table 1과 같이 변형률 변화에 따른 여러 재료 상수들을 구할 수 있다. 또한 이 재료 상수들은 식 (10)~(15)와 같이 변형률에 따른 6차 방정식으로도 표현된다.

$$\alpha = 2.83\varepsilon^6 + 0.74\varepsilon^5 - 1.60\varepsilon^4 - 0.14\varepsilon^3 + 0.31\varepsilon^2 - 0.05\varepsilon + 0.01 \quad (10)$$

$$\beta = 1436\varepsilon^6 - 2157\varepsilon^5 + 1260\varepsilon^4 - 356\varepsilon^3 + 49\varepsilon^2 - 2.80\varepsilon + 0.04 \quad (11)$$

$$n = 205726\varepsilon^6 - 311366\varepsilon^5 + 181141\varepsilon^4 - 499221\varepsilon^3 + 6436\varepsilon^2 - 332\varepsilon + 13 \quad (12)$$

$$n' = 212768\varepsilon^6 - 323210\varepsilon^5 + 190068\varepsilon^4 - 53395\varepsilon^3 + 7027\varepsilon^2 - 353\varepsilon + 18 \quad (13)$$

$$Q = 15531152\varepsilon^6 - 23688558\varepsilon^5 + 13987503\varepsilon^4 - 3940600\varepsilon^3 + 519439\varepsilon^2 - 25322\varepsilon + 833 \quad (14)$$

$$\ln A = 1399384\varepsilon^6 - 2136228\varepsilon^5 + 1262304\varepsilon^4 - 355859\varepsilon^3 + 46976\varepsilon^2 - 2307\varepsilon + 75 \quad (15)$$

고온 변형 중 동적 회복이 일어나는 구간에서 유동응력은 다음과 같이 표현 가능하다.

$$\sigma^2 = [\sigma_{DRV}^2 + (\sigma_0^2 - \sigma_{DRV}^2)e^{-\Omega \dot{\epsilon}}] \quad (16)$$

$\sigma$ 은 유동 응력,  $\Omega$ 은 동적회복 계수,  $\sigma_0$ 는 항복 강도,  $\sigma_{DRV}$ 는 동적 회복과 관련된 응력이다.  $\Omega$ 은 다음과 같이  $Z$ 값을 통해 나타낼 수 있다.

$$\Omega = 399Z^{-0.04} \quad (17)$$

따라서 고온 변형시 동적 회복 구간에서의 구성 방정식은 다음 식 (18)을 식 (16)에 대입하면 얻을 수 있다.

$$\sigma_{DRV} = \frac{1}{\alpha} \ln \left[ \left( Z/A \right)^{\frac{1}{n}} + \left( \left( Z/A \right)^{\frac{2}{n}} + 1 \right)^{\frac{1}{2}} \right] \quad (18)$$

고온 변형 중 동적 재결정이 일어나는 구간에서 유동응력은 다음과 같이 표현 가능하다.

$$\sigma = \sigma_{DRX} - (\sigma_p - \sigma_{DRX}) \left( 1 - \exp \left( -K_d \left( \frac{\varepsilon - \varepsilon_c}{\varepsilon_p} \right)^{n_d} \right) \right) \quad (19)$$

$K_d$ 는 화학 조성에 따른 동적 재결정 상수이고  $n_d$ 는 고온 거동 조건에 따른 동적 재결정 상수(=5.8)이다.  $\sigma_{DRX}$ 는 동적 회복과 관련된 응력이다.  $K_d$ 는 식 (20)과 같이  $Z$ 값으로 나타낼 수 있다.

$$K_d = 0.89Z^{-0.14} \quad (20)$$

따라서 고온 변형시 동적 재결정 구간에서의 구성 방정식은 식 (20)과 식 (21)을 식 (19)에 대입하면 된다.

$$\sigma_{DRX} = \frac{1}{\alpha} \ln \left[ \left( Z/A \right)^{\frac{1}{n}} + \left( \left( Z/A \right)^{\frac{2}{n}} + 1 \right)^{\frac{1}{2}} \right] \quad (21)$$

위의 수식들을 이용하여 본 연구에서의 공구강 소재의 변형 속도와 온도에 따른 진응력-진변형률 곡선을 계산할 수 있다.

### 3.2 인공 신경망 모델

일반적으로 ANN 모델은 입력층, 출력층 그리고 은닉층으로 구성된다. 본 연구에서는 역전파 학습 알고리즘(Back Propagation Algorithm)의 다층 퍼셉트론 신경망 모델을 구축하였다[19]. Fig. 1과 같이 본 연구에서는 공구강의 고온 거동을 예측하기 위해서 입력층, 15개의 뉴런으로 구성된 은닉층, 그리고 출력층의 모두 3개의 층으로 구성된 모델을 사용하였다. 각 층의 뉴런들은 sigmoidal 함수 등의 비선형

함수를 통해 연결 강도를 전달한다. 각 연결 강도는 출력 결과와 목표 결과 사이의 오류를 최소화하는 방향으로 조절되며 이를 학습이라고 한다. 구체적인 계산 과정은 기존의 여러 문헌들에서 쉽게 참고할




Fig. 1. Schematic of ANN model structure.

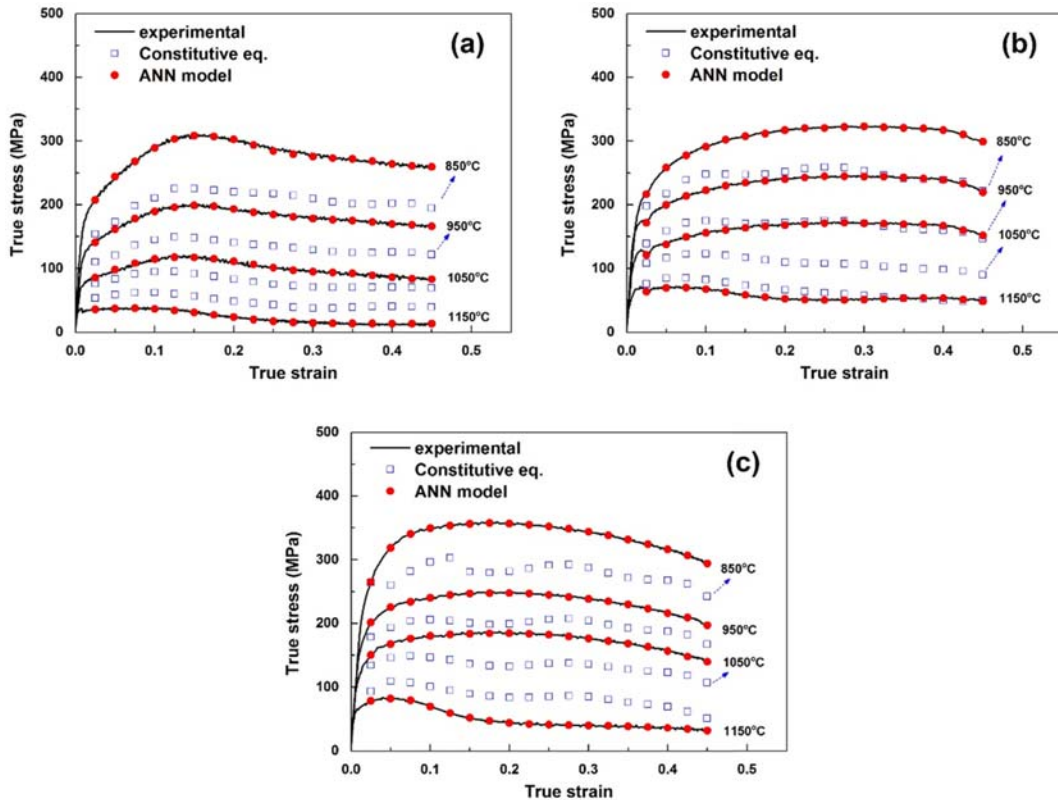


Fig. 2. Comparison of the predicted results with the experimental flow curves of the tool steel sample at different temperatures with various strain rate of (a) 0.05 s<sup>-1</sup>, (b) 1 s<sup>-1</sup>, and (c) 10 s<sup>-1</sup>.

수 있다[8, 20]. 이번 연구에서 고온 압축 실험으로부터 얻은 진응력-진변형률 곡선들로부터 216개의 데이터를 얻었다. 그 중 임의로 선택된 173개의 데이터(전체 데이터의 80%)는 모델 학습에 사용됐고, 나머지 43개 데이터(전체 데이터의 20%)는 구축된 모델의 정확도를 검증하는데 사용하였다.

### 3.3 구성 방정식과 ANN 모델의 비교

Fig. 2는 구성 방정식과 ANN 모델을 이용해 계산된 유동응력을 실험 결과와 함께 비교하고 있다. 고온 압축 실험으로부터 얻은 진응력-진변형률 곡선에서 변형률이 증가할수록 초기의 유동응력은 빠르게 증가한다. 이는 전위의 형성과 증식에 의해 가공경화가 일어났기 때문이다 [21]. 빠르게 증가했던 유동응력은 최대 응력까지 천천히 증가하는데, 이는 동적 회복으로 인해 전위의 양이 감소했기 때문이다. 유동응력은 최고점에 도달한 후 감소하거나 유지하는 경향을 보인다. 이러한 현상은 동적 재결정에 의한 가공 연화 현상 때문이다. 압축이 진행될수록 응력이 일정해 지는데 이는 동적 재결정, 불안정한 가공, 혹은 고온 크랙 등이 원인으로 작용한 결과이다. 또한 온도가 증가하거나 혹은 변형률 속도가 느려질수록 유동 응력은 감소한다. 모든 온도 조건과 변형률 속도에 대해 ANN 모델을 이용한 예측 결과가 구성 방정식을 이용한 예측 결과보다 실험값에 매우 가깝게

일치함을 확인하였다. 구성 방정식으로 예측된 결과 값들은 1,150°C 온도에서의 예측 응력 변화를 제외하고 그보다 낮은 온도에 대해서는 실제 측정된 응력보다 전체적으로 낮은 값들을 나타냈다. 본 연구에서 사용된 구성 방정식은 일반적인 형태의 Zener-Hollomon parameter를 사용하여 최적 계수를 실험 데이터로부터 구하였다. 이와 같이 일반적인 형태의 수식을 사용하여 정확한 예측이 어려울 경우에는 사용된 수식 중 실험 강종의 동적 회복이나 동적 재결정 특성을 표현할 수 있도록 수식을 수정함으로써 예측 정확도를 높일 수는 있다[12, 22]. 하지만 개량된 수식을 사용한다고 해도 예측 정확도를 다소 증가시킬 뿐 전체 예측 경향을 바꾸는 것은 제한이 따른다.

Fig. 3에서 구성 방정식과 ANN 모델을 이용한 예측 정확도를 평균제곱오차( $R^2$ )를 사용하여 비교하였다. 구성 방정식을 사용한 경우에 평균제곱오차 값은 0.944이고 ANN 모델을 사용한 경우에 평균제곱오차 값은 0.999이다. Fig. 4에서는 상대오차를 정량화하여 구성 방정식과 ANN 모델로 예측된 결과의 정확도를 비교해 보았다. 상대오차는 다음 식 (22)를 이용하였다.

$$\text{relative error (\%)} = \left( \frac{E_i - P_i}{E_i} \right) \times 100 \quad (22)$$

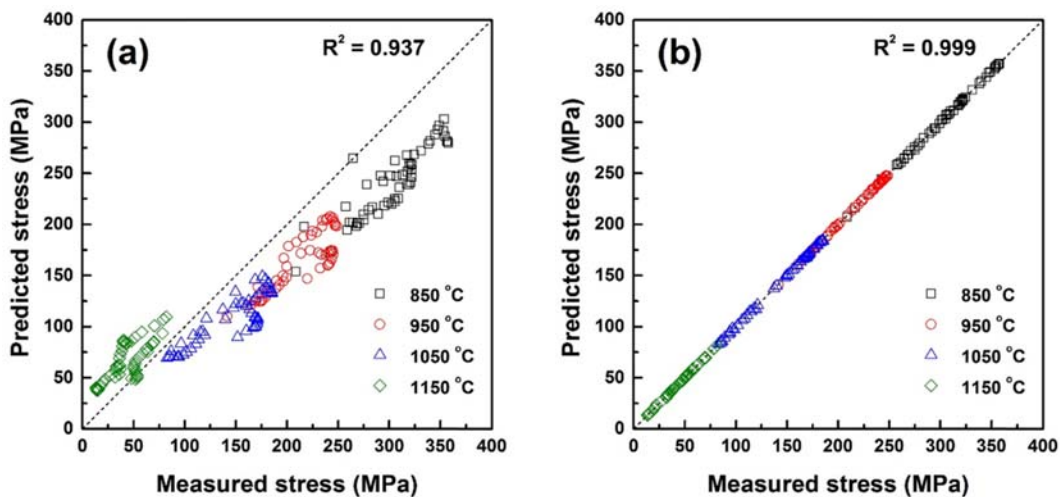


Fig. 3. Correlation between experimental and predicted flow stresses (a) by the constitutive equation and (b) by the ANN model.

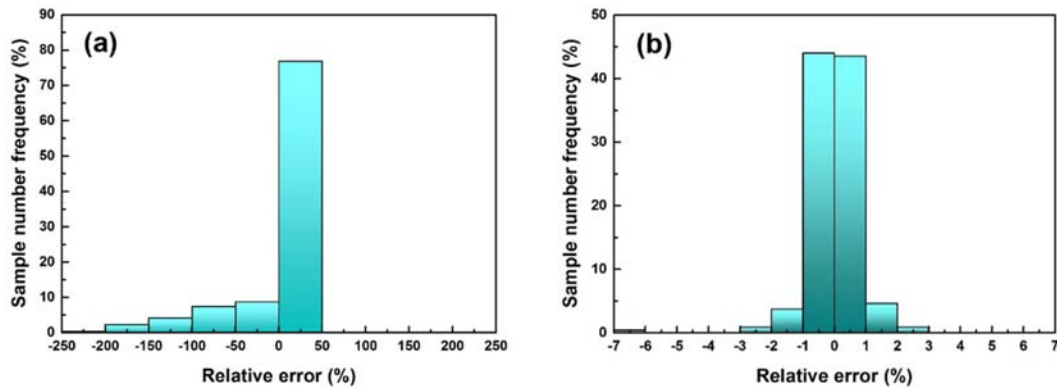


Fig. 4. Statistical analysis of the relative error between experimental and predicted flow stresses by (a) the constitutive equations and by (b) the ANN model.

여기서  $E_i$ 와  $P_i$ 는 각각  $i$ 번째 데이터의 실험값과 계산값이다. 구성 방정식에서 얻은 상대오차 범위는 -202%에서 +41%이고, ANN 모델에서 얻은 상대오차 범위는 -6%에서 +5%이다. 뿐만 아니라 구성 방정식에서는 오차범위 0~41% 구간에서 약 76%의 데이터가 존재하는 반면, ANN 모델에서  $\pm 1\%$  오차범위 구간에 약 87%의 데이터가 존재한다. 즉 상대오차 계산 결과를 통해서도 구성 방정식보다 ANN 모델의 예측 정확도가 매우 높음을 확인할 수 있다.

#### 4. 결 론

이번 연구에서 Fe-Cr-Mo-V-W-C계 공구강의 고온 변형 거동을 예측하기 위한 구성 방정식과 ANN 모델을 구축하였다. 다양한 실험 온도와 변형률 조건에서 압축 실험으로 구한 유동곡선을 이용하여 모델을 개발하였다. 구축된 구성 방정식은 평균제곱오차 0.944 값을 보였고 ANN모델은 0.999의 평균제곱오차를 보였다. 상대오차 비교 결과에서도 구성 방정식은 -202%에서 +41% 오차 범위를 가지며 약 76%의 데이터가 0~+41%의 오차 범위 구간에 존재하였다. 반면에 ANN 모델의 경우 상대오차 범위는 -6%에서 +5%로  $\pm 1\%$  범위에 약 87%의 데이터가 존재하였다. 따라서 유동곡선 비교, 평균제곱오차와 상대오차 비교 결과, 입력 변수와 결과 사이의 복잡한 비선형 관계를 고려할 수 있는 ANN모델이 여러 재료 상수들을 사용하여 계산한 구성 방정식보다 Fe-Cr-Mo-V-W-C계 공구강의 고온 변형 거동을

예측함에 있어 더 높은 예측 정확도를 보였다. 이 ANN 모델은 유한요소해석의 고온 물성 데이터 구축이나 고온단조 조건 최적 조건을 찾기 위한 공정맵 개발 연구들에 활용될 것으로 기대한다.

#### 후 기

본 연구는 산업통상자원부와 한국산업기술진흥원의 “국제공동기술개발사업”의 지원을 받아 수행된 연구 결과임.

#### References

1. G. Roberts, G. Krauss, and R. Kennedy : Tool Steel, 5th edition, ASM International (1998) p. 13.
2. H. Park, D. Park, J. H. Jun, M. H. Lee, and S. J. Lee : Materials Research Express, **4** (2017) 116504.
3. D. Park, J. H. Jun, M. H. Lee, and S. J. Lee : J. of Korean Society for Heat Treatment, **30** (2017) 156.
4. G. R. Johnson, and W. H. Cook : Proceedings of the 7th International Symposium on Ballistics, The Hague, Netherlands (1983), 541.
5. H. Y. Li, X. F. Wang, J. Y. Duan and J.J. Liu : Materials Science & Engineering A, **557** (2013) 138.
6. F. J. Zerilli and R. W. Armstrong : Journal of Applied Physics, **61** (1987) 1816.
7. H. Zhang, W. Wen, H. Cui and Y. Xu : Materials Science and Engineering A, **527** (2009) 328.
8. H. K. D. H. Bhadeshia: ISIJ International, **39** (1999) 966.
9. W. Sha and K. L. Edwards: Materials & Design, **28** (2007) 1747.

10. H. Y. Li, J. D. Hu, D. D. Wei, X. F. Wang, and Y. H. Li : *Materials & Design*, **42** (2012) 192.
11. K. Singh, S. K. Rajput, and Y. Mehta : *Materials Discovery*, **6** (2016) 1.
12. A. Mirzaei, A. Zarei-Hanzaki, M. H. Pishbin, A. Imandoust, and Sh. Khoddam : *Journal of Materials Engineering and Performance*, **24** (2015) 2412.
13. F. Ren, J. Chen, and F. Chen : *Transactions of Nonferrous Metals Society of China*, **24** (2014) 1407.
14. N. Haghdam, A. Zarei-Hanzaki, A. R. Khalesian, and H. R. Abedi : *Materials & Design*, **49** (2013) 386.
15. J. Zhao, H. Ding, W. Zhao, M. Huang, D. Wei, and Z. Jiang : *Computational Materials Science*, **92** (2014) 47.
16. S. Kang, M. Kim, and S. J. Lee : *Metals*, **7** (2017) 12.
17. C. Zener and J. H. Hollomon : *Journal of Applied Physics*, **15** (1994) 22.
18. C. M. Sellars and W. J. McTegart : *Acta Metallurgica*, **14** (1966) 1136.
19. W. Lee and S. J. Lee : *J. of Korean Society for Heat Treatment*, **31** (2017) 1.
20. W. Sha and K. L. Edwards: *Materials & Design*, **28** (2007) 1747.
21. R. Bobbili, B. V. Ramudu, and V. Madhu : *Journal of Alloys and Compounds*, **696** (2017) 295.
22. K. Kim, M. Jung, and S. J. Lee : *J. of Korean Society for Heat Treatment*, **30** (2017) 187.