



인공신경망을 이용한 인콜로이 825 합금의 고온 변형 거동 연구

송신형^{a*}, 김용배^b, 이승용^c

Study on the High Temperature Deformation of Incoloy 825 Alloy using an Artificial Neural Network

Shin-Hyung Song^{a*}, Yongbae Kim^b, Seoung-Yong Lee^c^a Department of Mechanical Engineering, Wonkwang University, 460, Iksan-daero, Iksan, Jeonbuk-do, 54538, Korea^b Korea Institute of Industrial Technology, 156, Gaetbeol-ro, Yeonsu-gu, Incheon 21999, Korea^c Automobile Engineering, Seojeong College, 1049-56, Hwahap-ro, Yangju, Gyeonggi-do, 11429, Korea

ARTICLE INFO

Article history:

Received	16	October	2017
Revised	7	December	2017
Accepted	29	December	2017

Keywords:

Incoloy 825
High temperature
Compression test
Artificial neural network

ABSTRACT

In this research, a constitutive study of the high-temperature deformation behavior of Incoloy 825 alloy was performed using an artificial neural network (ANN). For the study, a high-temperature compression test on Incoloy 825 was carried out on a Gleeble 3500 system at temperatures ranging from 950-1,150°C and strain rates of 0.2/s and 2/s. After the compression test, the study of the flow stress was conducted for various temperatures and strain rates. The flow stress variation during the deformation of Incoloy 825 was dependent on the deformation temperature and strain rate. The flow stress at various deformation temperatures and strain rates was modeled using the Hollomon-type equation. The constitutive behavior of Incoloy 825 during hot temperature deformation was modeled using an ANN.

1. 서론

Ni-Fe-Cr계 합금인 인콜로이 825(Incoloy 825)는 내부식성이 강한 합금이며 화학처리설비, 공해처리설비, 기름환원설비, 가스 환원설비, 산제조설비 그리고 핵연료재처리 및 방사능폐기물설비 등에 사용되고 있다^[1]. 한편으로 역시 이러한 인콜로이 825가 사용되고 있는 정유산업 및 해양플랜트 등의 분야에서는 최근 대형화된 설비 등이 제조되고 있으며 이러한 대형설비 부품의 제조를 위하여 부품의 제조공법도 형단조에서 자유단조의 공법으로 바뀌고 있다^[2]. 따라서 이러한 추세에 맞게 인콜로이 825의 고온단조 등과 같은 고온성형에 관한 많은 연구가 필요한 실정이다.

이 연구에서는 인콜로이 825의 고온에서의 성형하중을 예측하기 위한 기초연구로서 인콜로이 825의 동적재결정 온도에 해당하는 950°C에서 1,050°C의 온도범위와 0.2 /s 그리고 2 /s의 변형률 속도(strain rate) 하에서의 변형에 대한 실험을 수행하고 인콜로이 825의 응력변화를 분석 하였다. 특히, 이 연구에서는 딥러닝 알고리즘의 일종인 인공신경망을 사용하여 고온변형의 응력변화를 예측하는 방법을 사용하였다. 많은 딥러닝 기법 중 하나인 인공신경망은 입력변수들과 출력변수들의 복잡한 인과관계를 빅데이터의 학습을 통하여 추정하는 인공지능 알고리즘의 하나이며 최근 다양한 분야에 활발하게 적용이 되고 있다.

금속재료의 고온변형거동 과정에서 일어나는 대표적 현상 중 한

* Corresponding author. Tel.: +82-63-850-6969

Fax: +82-63-850-6666

E-mail address: 57nsongsh@daum.net (Shin-Hyung Song).

가지는 동적재결정(dynamic recrystallization) 현상이다. 이러한 동적재결정을 포함한 금속의 고온에서의 변형거동 및 응력변화를 묘사하는데는 전통적으로 Zener-Hollomon 상수를 계산하거나 Arrhenius type 구성방정식을 도출하는 방식이 널리 쓰이고 있으며 이러한 Arrhenius type 방정식은 고온변형을 모델링하는데 매우 효과적인 것으로 알려져 있다.

최근에는 딥러닝 기법의 하나인 인공신경망을 재료시험의 구성식 개발에 적용하는 시도가 증가하고 있는데 이는 온도 및 변형률 속도 등의 조건에 해당하는 변형시의 유동응력을 효과적으로 예측할 수 있는 인공신경망 알고리즘의 특성 때문이다. 이에 따라서 금속재료의 고온실험에서도 인공신경망을 사용한 응력거동 예측에 관한 실험연구들이 이루어졌다³⁻⁸⁾.

예를 들어, Quan³⁾ 등은 20MnNiMo 합금의 고온변형시의 유동응력을 인공신경망 모델로 예측하고 이를 개선된 형태의 Arrhenius 형태의 구성방정식을 사용한 예측결과와 비교하였으며 인공신경망 모델을 사용한 예측이 더 뛰어난 결과를 보고하였다. Zhao⁴⁾ 등은 또한 Ti600 합금의 고온변형실험을 수행하고 인공신경망 모델을 사용한 유동응력의 예측연구를 수행하였으며 Arrhenius 형태의 구성방정식으로 예측한 결과와 비교하여 인공신경망을 사용한 결과가 더 양호하다는 결과를 도출하였다. Guo⁵⁾ 등 또한 TC21합금의 고온변형실험을 수행한 후 응력변화의 예측에 인공신경망을 사용하였으며 역시 Zener-Hollomon 등의 전통적 방식을 사용한 예측보다 더 뛰어난 효과를 보임을 보고하였다. 상기의 연구들은 공통적으로 금속재료의 고온변형 시험에서 시편의 변형거동에 영향을 미치는 변수가 변형률, 온도 그리고 변형률속도 등으로 다양하였으며 이들 변수와 유동응력의 관계는 복잡한 비선형의 관계로서 이러한 복잡한 관계를 기존의 구성방정식 등을 사용한 방법보다 인공신경망을 사용한 방법으로 더 정확하게 예측한 것이 특징이다.

이 연구에서는 인콜로이 825에 대한 특정 조건에서의 고온 변형 실험을 수행하였는데 실험의 분석 결과 재료변형의 유동응력이 변형률, 온도 및 변형률속도에 상당한 의존성을 보였고 이들 변수와 유동응력은 상당한 비선형적 관계를 가질 것으로 예측이 되었다. 따라서 이 연구에서도 인공신경망의 기법 중 가장 널리 쓰이는 방식 중 하나인 역전파신경망을 사용하여 응력의 변화를 예측하는 시도가 이루어졌으며 이러한 연구에 대한 토의가 이루어졌다.

2. 시험 준비

2.1 고온압축시험

시험 시편의 재료인 인콜로이 825는 Sanyo Special steel Co. Ltd.에서 제조하였으며 생산 시 분석된 화학조성을 Table 1에 나타내었다.

본 연구에서는 Fig. 1의 Gleeble-3500 장비를 이용하여 고온압축시험을 수행하였으며 시험에 사용된 시편은 지름 10 mm 및 길이 15 mm의 원통형으로 제작 하였다.

이 연구에서 수행한 고온압축시험에서는 압축온도를 각각 950°C, 1050°C 그리고 1,150°C로 하고 변형률속도를 0.2 /s 그리고 2 /s로 하였으며 각각의 온도와 변형률속도 하에서의 압축응력의 변화를 측정하였다. 시험 시 온도는 목표온도까지 초당 20°C의 비율로 증가시켰으며 목표한 온도는 도달 후에 5분 동안 유지되었다. 또한 총 압축 변형률은 0.6으로 하였다. 압축하중은 시험의 조건에 따라 약 12 kN에서 42 kN으로 하였으며 ram speed 역시 시험조건에 따라 약 3 mm/s와 30 mm/s로 하였다.

2.2 인공신경망에 의한 유동응력 예측

Fig. 2는 인공신경망 알고리즘의 개념도를 나타낸 것이다. 인공신경망은 딥러닝 알고리즘의 일종으로 기 존재하는 빅데이터의 학습을 통하여 데이터의 입력값과 출력값의 상관관계를 추정하는 딥러닝 기법의 한 종류이다. 인공신경망 알고리즘은 일종의 블랙박스 추정기법으로 구성식 등의 단순한 수식으로 그 정확한 관계를 나타내기 어려운 입력과 출력의 비선형적이며 복잡한 관계도 매우 효과

Table 1 Chemical composition of specimen (wt%)

C	Si	Mn	S	Ni	Cr	Mo	Cu	Ti	Al	Fe
0.01	0.3	0.7	0.001	38.51	20.46	2.62	1.82	0.89	0.12	33.93



Fig. 1 Test equipment (Gleeble-3500)

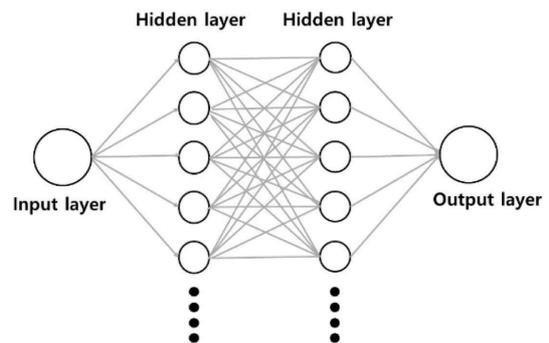


Fig. 2 Artificial neural network

적으로 추정하는 것으로 알려져 다양한 분야에서 널리 이용되고 있으며 이 알고리즘의 추정 및 예측의 정확도는 학습하는 표본 데이터가 많고 적음에 따라 그리고 표본 데이터의 정확도에 따라 좌우된다.

인공신경망의 개념적 구조는 Fig. 2에 나타난 것과 같이 입력층(input layer), 은닉층(hidden layer) 그리고 출력층(output layer)으로 나뉜다. 인공신경망은 여러 개의 은닉층을 가질 수 있다. 각 층에는 신경세포를 모사한 뉴런이라는 부분이 있으며 Fig. 2에서는 원형으로 묘사된 뉴런이 입력층에 1개, 2개의 은닉층에 각 5개(이상) 그리고 출력층에 1개가 표시되어 있다. 각 층의 뉴런들은 이전 층의 모든 뉴런에서 전달받은 값들을 합산하고 일정한 가중치를 곱하여 앞 층의 모든 뉴런에 전달하며 뉴런마다 이루어지는 이러한 계산을 통해 최종적으로 출력층에 도달한 값과 표본이 되는 학습데이터를 비교하여 인공신경망 학습의 정확도를 높이게 된다. 이 때 계산된 결과값과 표본데이터를 비교했을 때의 오차를 이전 층들에 되먹이는 방법을 통해 각각의 뉴런이 보유한 가중치를 매 순간마다 조절하면서 인공신경망의 정확도를 높여나가는 방식을 특히 역전파(back propagation) 인공신경망이라고 한다.

인공신경망에서는 신경망을 이용하여 유추하고자 하는 관계가 비선형이고 복잡할 수록 은닉층을 여러 개 층으로 하거나 각 은닉층의 뉴런의 개수를 증가시키는 것이 인공신경망 학습의 정확도를 높일 수 있는데 이는 많은 뉴런이 가진 더 다양한 가중치값들이 최종값의 계산에 반영되기 때문이다.

이 연구에서는 역전파 인공신경망 알고리즘을 사용하였는데 입력층의 뉴런의 개수는 3개로 하였으며 이는 각각 온도, 변형률속도, 변형률을 의미한다. 은닉층은 1개 층으로 하였으며 은닉층의 뉴런의 개수는 300개로 하였다. 출력층의 뉴런은 한 개로 하였으며 이는 유동응력을 나타낸다. 이 연구에서 수행된 다양한 온도 및 변형률속도에서의 압축시험을 통해 얻은 6개의 응력곡선에서 각각의 곡선마다 15개 지점의 학습데이터를 표본으로 추출하였으며 이렇게 해서 3개의 입력값과 한 개의 출력값을 관계 짓는 총 90개의 학습데이터를 인공신경망이 학습하도록 하였다. 그리고 이렇게 학습된 인공신경망으로 다시 90개의 응력값을 추정해 보도록 하였으며 이 추정값들을 인공신경망의 학습에 사용된 표본데이터와 비교하였다.

3. 결과 및 토의

3.1 인콜로이 825의 고온 변형 거동

Fig. 3은 변형률속도가 2 /s 이고 온도가 1,150°C 인 경우의 시편의 내부를 50 μm의 배율에서 SEM (scanning electron

microscope)으로 촬영한 사진이다. 미세한 결정입자가 생성된 모습에서 열간변형 과정의 동적재결정이 일어난 것을 확인할 수 있다.

Fig. 4-Fig. 5는 변형률속도가 각각 0.2 /s 이고 2 /s일 때의 진응력-진변형률 곡선을 온도 별로 표시한 것이다. 각각의 진응력-진변형률 곡선에서 온도가 증가함에 따라 연화현상으로 인하여 유동응력이 감소함을 확인할 수 있다.

압축시험에서는 원통형 시편의 초기지름과 초기높이를 각각 D_0 , L_0 그리고 순간지름과 순간높이를 각각 D , L 이라고 하고 F 를 압축하중이라고 할 때 진변형률과 진응력은 각각 아래와 같다.

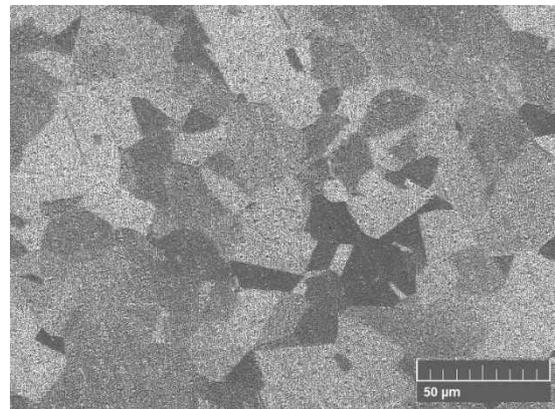


Fig. 3 Microstructure of deformed specimen (1,150°C and 2 /s)

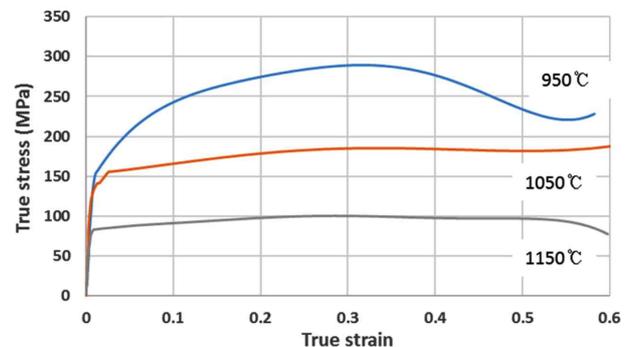


Fig. 4 True stress-true strain curves (strain rate 0.2 /s)

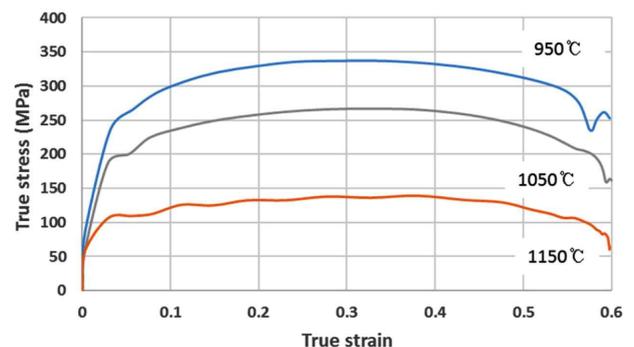


Fig. 5 True stress-true strain curves (strain rate 2 /s)

$$\varepsilon = \ln \frac{L_0}{L} \quad (1)$$

$$\sigma = \frac{4FL}{\pi D_0^2 L_0} \quad (2)$$

Fig. 6-Fig. 8는 온도가 각각 950°C, 1,050°C 그리고 1,150°C 일 때의 진응력-진변형률 곡선을 변형률속도 별로 표시한 것이다. 각각의 진응력-진변형률 곡선에서 변형률속도가 증가함에 따라 유동응력이 증가함을 확인할 수 있다. 인콜로이 825는 이 연구에서

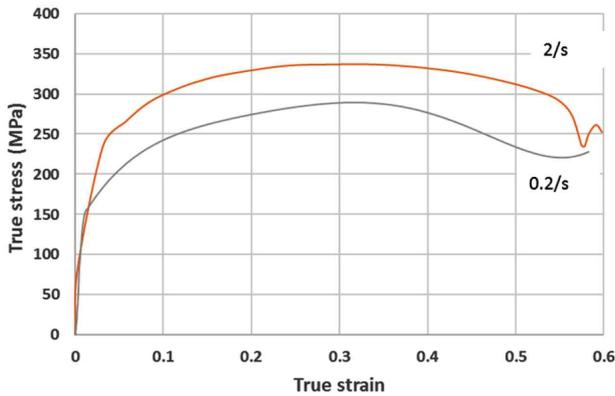


Fig. 6 True stress-true strain curves (temperature 950°C)

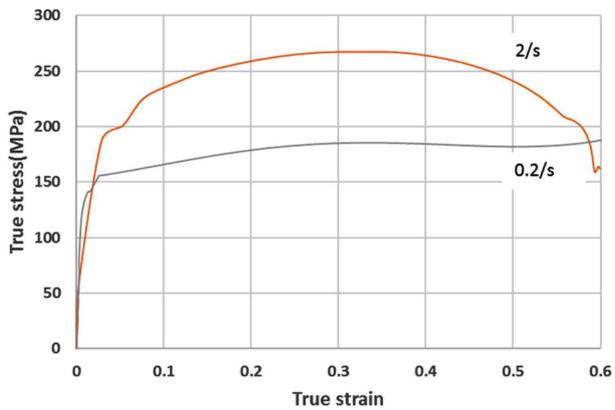


Fig. 7 True stress-true strain curves (temperature 1,050°C)

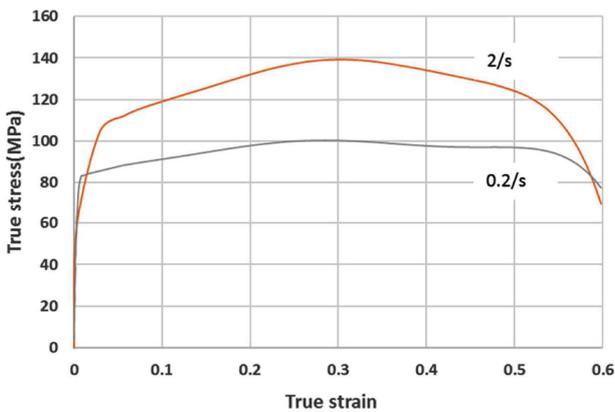


Fig. 8 True stress-true strain curves (temperature 1,150°C)

수행된 고온변형시험의 범위에서 고온변형시 응력거동이 상당한 변형률의존성을 나타내고 있다.

이 연구에서는 압축시험의 결과를 이용하여 각각의 온도 및 변형률속도에서의 인콜로이 825의 유동응력을 Hollomon 식으로 분석하였다. Hollomon식은 다음과 같다.

$$\sigma = \sigma_1 \varepsilon^n \quad (3)$$

여기서 σ 는 유동응력, ε 는 변형률, σ_1 는 $\varepsilon=1$ 일 때의 응력, 그리고 n 는 경화지수를 나타낸다.

Table 2에서는 각각의 온도 및 변형률속도에서의 σ_1 와 n 이 나타나 있다.

3.2 인공신경망의 적용을 통한 유동응력 예측

Figs. 9-11은 온도가 950°C, 1,050°C 그리고 1,150°C이며 변형률속도가 0.2 /s 그리고 2 /s일 때의 진응력-진변형률곡선과 인공신경망 알고리즘으로 예측한 변형시의 응력을 표시한 것이다. 그림에서 점으로 표시된 지점의 변형률에 해당하는 응력곡선 상의 값들은 인공신경망의 학습을 위한 표본데이터로 사용되었으며 학습된 인공신경망으로 예측한 응력값들이 실험을 통해 측정된 응력곡선 위에 점으로 표시되어 있다. 인공신경망의 학습결과로 예측한 응력이 실험값에 근접하며 뛰어난 예측결과를 보임을 알 수 있다.

인공신경망에서 오차를 되먹이며 각 뉴런의 가중치를 개선하는 학습의 횟수는 5,000으로 하였으며 인공신경망에 의한 학습의 과정에서는 보통 무작위로 생성되는 뉴런의 초기 가중치, 학습횟수,

Table 2 K and n for various temperatures and strain rates

	950°C		1050°C		1150°C	
	0.2/s	2/s	0.2/s	2/s	0.2/s	2/s
σ_1 (MPa)	409.49	478.57	186.65	337.32	99.71	256.47
n	0.228	0.205	0.053	0.157	0.04	0.325

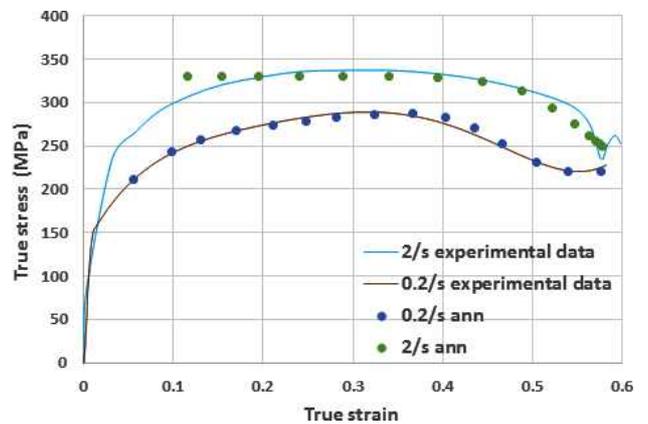


Fig. 9 True stress-true strain curves (temperature 950°C)

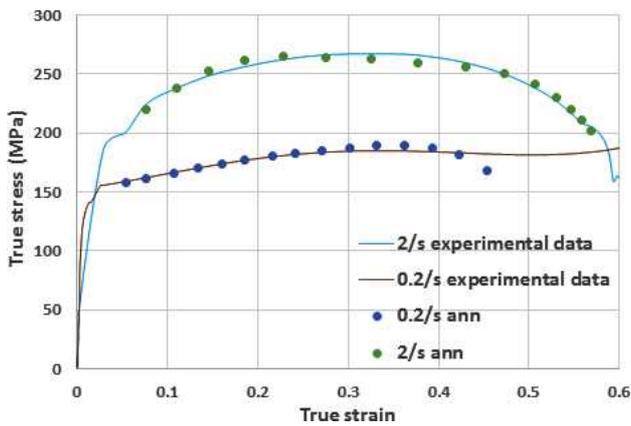


Fig. 10 True stress-true strain curves (temperature 1050°C)

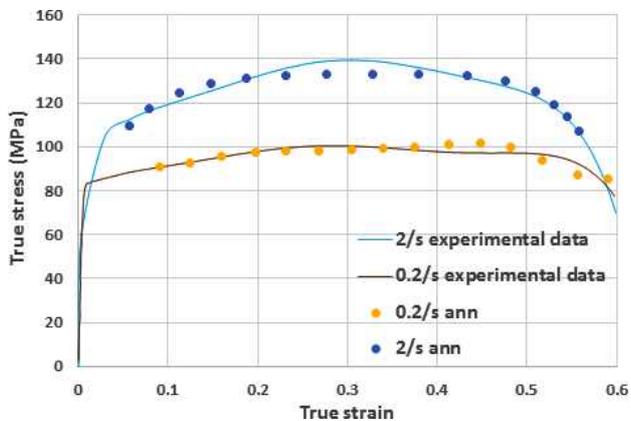


Fig. 11 True stress-true strain curves (temperature 1150°C)

은닉층의 개수 및 은닉층의 뉴런의 개수 등이 학습결과에 중요한 영향을 미치는 것으로 나타났다.

이 실험연구에서는 인콜로이 825의 고온변형 시 동적재결정 및 응력거동 상의 변형률속도 의존성 등이 관찰되었다. 하지만 이러한 재료역학적 특성에 관한 내용은 인공신경망 알고리즘에 의한 응력 변화의 학습에는 직접적으로 입력되지 않았다. 재료변형의 구성식 개발에서 전통적으로 사용되어온 방식은 그 구성식의 종류에 따라 구성식의 내용에 시편의 재료역학적 특성에 관한 내용이 반영될 수 있지만 인공신경망 알고리즘에 의한 응력거동의 예측은 측정된 곡선들의 형상 특성만을 학습하여 예측이 이루어진다. 이러한 특성에 더하여 주어진 학습데이터만을 기반으로 예측값을 도출하는 인공신경망의 고유의 특성을 고려할 때 인공신경망 알고리즘을 사용한 고온변형 상의 응력의 예측은 양질의 풍부한 초기 학습데이터를 확보하는 것이 관건이라고 사료된다.

4. 결론

이 연구에서는 다양한 분야에 사용되는 내부식성 재료인 인콜로

이 825의 고온성형을 위한 기초연구로서 950°C, 1,050°C 그리고 1,150°C의 온도와 0.2 /s 그리고 2 /s의 변형률속도 영역에서 고온 압축시험이 수행되었다. 실험 결과 유동응력은 온도가 증가함에 따라 감소하였으며 변형률속도가 증가함에 따라 증가하였다. 또한 이 연구에서 수행된 실험의 온도 및 변형률속도 범위에서는 유동응력의 변화가 강한 온도 및 변형률속도 의존성을 보였다. 이 연구에서는 이러한 인콜로이 825의 변형과 관련된 다양한 변수와 유동응력의 복잡한 관계를 추정하기 위하여 실험값들에 대한 역전파 인공신경망 알고리즘을 통한 학습이 이루어졌으며 이렇게 학습된 인공신경망으로 유동응력을 효과적으로 예측하였다.

References

- [1] Park, Y. T., Jeong, Y. H., 2016, Effect of Hot Forging Ratio on the Mechanical Properties in Incoloy 825 Alloy, Journal of the Korean Society for Heat Treatment. 29:6 259-263.
- [2] Kim, H. B., Lee, C. H., 1997, A Study of Dissimilar Weldability of Incoloy 825 With Mild Steel, Korean Journal of Materials Research 7:2 162-170.
- [3] Quan, G., Yu, C., 2014, A Comparative Study on Improved Arrhenius-Type and Artificial Neural Network Models to Predict High-Temperature Flow Behaviors in 20MnNiMo Alloy, The Scientific World Journal 2014 108492.
- [4] Zhao, J., Ding, H., 2014, Modelling of the Hot Deformation Behaviour of a Titanium Alloy Using Constitutive Equations and Artificial Neural Network, Computational Materials Science 92 47-56.
- [5] Guo, L., Li, B., 2013, Constitutive Relationship Model of TC21 Alloy Based on Artificial Neural Network, Transactions of Nonferrous Metals Society of China 23:6 1761-1765.
- [6] Duan, Y., Ma, L., 2017, Developed Constitutive Models, Processing Maps and Microstructural Evolution of Pb-Mg-10Al-0.5B Alloy, Materials Characterization 129 353-366.
- [7] YAN, J., Pan, Q., 2017, Flow Behavior of Al-6.2Zn-0.70Mg-0.30Mn-0.17Zr Alloy During Hot Compressive Deformation Based on Arrhenius and ANN Models, Transactions of Nonferrous Metals Society of China 27:3 638-647.
- [8] Babu, A., Mandal, S., 2017, Regression Based Novel Constitutive Analyses to Predict High Temperature Flow Behavior in Super Austenitic Stainless Steel, Materials Science and Engineering: A 703 187-195.