

인공 신경망을 이용한 AZ31 Mg 합금의 고온 변형 거동연구

이병호¹·N. S. Reddy¹·이종수[#]

High temperature deformation behaviors of AZ31 Mg alloy by Artificial Neural Network

B. H. Lee, N. S. Reddy, C. S. Lee

Abstract

The high temperature deformation behavior of AZ 31 Mg alloy was investigated by designing a back propagation neural network that uses a gradient descent-learning algorithm. A neural network modeling is an intelligent technique that can solve non-linear and complex problems by learning from the samples. Therefore, some experimental data have been firstly obtained from continuous compression tests performed on a thermo-mechanical simulator over a range of temperatures (250-500°C) with strain rates of 0.0001-100 s⁻¹ and true strains of 0.1 to 0.6. The inputs for neural network model are strain, strain rate, and temperature and the output is flow stress. It was found that the trained model could well predict the flow stress for some experimental data that have not been used in the training. Workability of a material can be evaluated by means of power dissipation map with respect to strain, strain rate and temperature. Power dissipation map was constructed using the flow stress predicted from the neural network model at finer intervals of strain, strain rates and subsequently processing maps were developed for hot working processes for AZ 31 Mg alloy. The safe domains of hot working of AZ 31 Mg alloy were identified and validated through microstructural investigations.

Key Words : AZ31 magnesium alloy, Artificial neural network, Processing map, Workability, Temperature compensation

1. 서 론

최근 대두 되고 있는 에너지 문제로 인해 세계적으로 자동차의 연비 향상에 대한 관심이 지대하다. 특히 이러한 자동차의 연비 향상은 자동차의 CO₂ 방출량까지 줄여 환경 문제도 해결할 수 있는 좋은 방법이다.

이러한 자동차의 연비를 줄이는 방법 중 하나가 바로 경량 구조 재료를 자동차 차체에 사용하여 차체의 무게를 감소시키는 방법으로 최근 자동차 차체용 구조 용 소재로 경량 금속을 이용하려는 많은 움직임이 있어왔다.

특히 사용 가능한 구조용 금속 중 가장 밀도가 낮은 마그네슘 합금은 경량 구조용 재료로서 자동차의 차체 무게 감소를 위한 많은 가능성을 갖고 있는 재료이다[1].

지금까지 대부분의 Mg 합금을 이용한 자동차 부품은 die-casting이나 thixoforming 등을 이용하였으나 이런 방법으로 제조된 부품은 wrought material에 비해 기계적 성질이 떨어진다는 단점이 있다. 일반적으로 Mg 합금은 그 slip system의 제한으로 인해 상온에서 성형성이 좋지 못하지만 성형 온도를 높일수록 작용하는 slip system의 수가 많아져 성형성이 좋아지는 특성을 가진다[2].

1. 포항공과대학교 신소재공학과

포항공과대학교 신소재공학과, E-mail: cslee@postech.ac.kr

따라서, 최근 Mg 합금의 고온 성형성을 향상 시키고 고온에서의 변형 기구를 밝히려는 많은 노력이 있어 왔다[3].

한편, 최근 인간의 신경 최소 단위인 뉴런을 이용하여 인간의 사고를 컴퓨터 시뮬레이션에 적용하려는 움직임이 있어왔다. 이 인공 신경망(Artificial Neural Network) 방법은 통계적인 해석방법으로서 주로 기상학, 경제학, 전자 전기학 등의 여러 분야에서 현재 널리 이용되고 있으며 최근 소성 가공 분야에 이러한 인공 신경망 방법을 적용하는 시도가 계속 이어지고 있는 추세이다[4].

본 연구에서는 최근 활발히 연구되고 있는 AZ31 Mg 합금의 고온 압축 실험 데이터를 이러한 인공 신경망 방법에 이용하여, 최적 성형 공정을 도출하기 위한 Processing map 을 도출할 계획이며 이를 실험을 통해 도출한 AZ31 Mg 합금의 공정지도와 비교 분석할 것이다. 또한 ANN 을 통해 열적 연화현상의 보정을 수행하고자 한다.

2. 인공 신경망 모델링

인공 신경망 모델은 인간의 인식력과 판단력이 단순한 기능을 가진 몇 개의 신경세포의 조합에 의해서 행해진다는 사실에 바탕을 두고 있다. 이후 많은 연구자들은 이러한 신경 세포 조직을 인위적으로 만들기 위한 많은 노력을 해왔고, 이를 통해 인공신경망이라는 개념이 탄생하게 되었다.

인공 신경망은 역전파 학습 알고리즘이 적용 가능한 다계층의 구조를 가진다. 인공 신경망 안에는 입력층, 은닉층, 출력층이 서로 연결된 다계층의 구조를 가지며 각 계층에는 여러 뉴런이 존재하여 이를 뉴런이 서로 연결되어 주어진 문제를 학습하고 추론 기능을 수행하고 있다. 결국 인공 신경망은 뉴런간의 연결 강도와 이에 따른 다계층 구조가 핵심이다. 이때 각각의 뉴런은 주어진 학습자료를 학습하는 학습 기능과 상호 연결된 또 다른 뉴런에 그 처리결과를 보내는 전달 기능이 존재한다. 다음 그림 1은 본 연구에서 사용된 다계층의 인공신경망 구조를 나타내는 것이다. 본 연구에서는 입력층에 온도, 변형율, 변형율 속도의 데이터를 입력하였으며 이를 다단계의 은닉층을 통해 역전파 알고리즘을 적용하여 예측된 응력 값을 바탕으로 응력 값을 모델링하였다. 그리고 도출된 응력 값을 이용하여 AZ31 Mg 합금

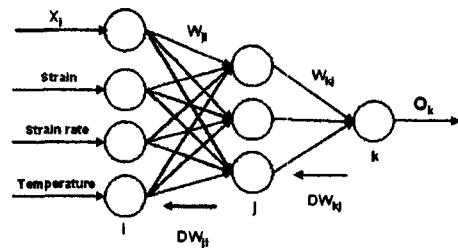


Fig.1. Structural organization of the designed neural network

의 가공성 평가를 위한 processing map 에 적용하였다.

3. 실험 방법

본 연구에 사용된 Mg 합금은 3.8wt%Al-1.0wt%Zn-0.5wt%Mn 의 조성을 가진 상용 AZ31 Mg 합금이다. 이 Mg 합금의 평균 결정립 크기는 12 μm 였다. 이를 이용하여 ANN 에 필요한 database 를 확보하기 위해 다양한 온도구간(250°C ~500°C)과 변형율 속도구간(0.0001/s~100/s)에서 Gleeble3500 고온 압축 시험기를 이용하여 압축실험을 수행하였다. 시편은 직경 10mm, 높이 12mm 의 원통 모양이었으며, 진공 chamber 안에서 전기 저항에 의해 목표 온도까지 가열되고 열적 평형을 위해 1 분 동안 유지한 후 0.6 의 변형율까지 압축실험을 수행하였다. 응력-변형율의 변화는 Gleeble-3500 machine 에 장착된 컴퓨터를 통해 연속적으로 측정되었으며, 실제 시편의 온도도 시편에 장착된 Thermocouple 을 이용하여 실시간으로 측정하였다. 실험 후의 미세조직을 보존하기 위해 실험을 마친 직후 재빨리 수냉 하였다.

4. 결과 및 고찰

2.1 인공 신경망을 통한 압축 응력 도출

인공 신경망 모델링을 이용하여 AZ31 Mg 합금의 다양한 온도와 변형율 속도에서의 압축 응력을 모델링 하였다. 다음의 그림 2 는 각 온도와 변형율 속도 조건에서 0.6 strain 시의 인공 신경망 모델링 결과와 실제 실험 data 를 비교한 것이다. 그 결과 인공 신경망 모델링을 통해 예측된 압축 유동 응력 값은 실험값과 7%의 오차 범위 안에 위치하는 매우 타당한 값이었다.

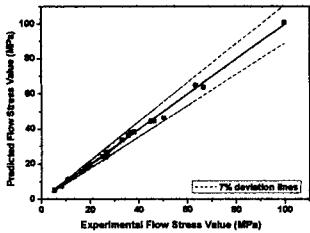


Fig.2 Predicted flow stress by neural network vs. experimental flow stress.

2.2 ANN을 이용한 열적 연화의 보정

재료가 소성 변형을 받으면서 일어나는 가공 연화 현상은 크게 열적 연화와 구조적 연화로 나눌 수 있다. 이때 열적 연화는 유사연화라고도 하며, 온도가 낮고 변형률 속도가 빠른 구간에서 변형 열이 발생하여 실제 재료가 목표보다 높은 온도에서 변형되어 일어나는 현상이다. 이러한 소성 변형 중에 일어나는 변형열은 다음의 식(1)에 의해 얻어진다.

$$\Delta T = \frac{\eta}{\rho c} W = \frac{\eta}{\rho c} \int_0^{\epsilon} \sigma d\epsilon \quad (1)$$

이때 W 는 소성일, η 는 소성일이 변형 열로 바뀌는 비율, ρ 는 재료의 밀도, c 는 재료의 비열을 나타낸다. 즉, 열적 연화의 보정은 소성일이 변형열로 바뀐다는 가정에 의해 소성일을 구하고 이를 변형열로 바꾼 후 다음의 식 (2)에 의해 실제 온도와 그때의 응력을 구하는 방법을 사용한다.

$$\sigma = A \exp \left[\frac{Q}{R(T_0 + \Delta T)} \right]_{\epsilon_s} \quad (2)$$

하지만 변형 열을 소성일로 구하는 것은 소성 가공 도중 시편의 정확한 온도를 알 수 없기 때 문인데, 본 연구에서 압축 실험을 수행한 Gleeble3500은 시편에 장착된 Thermocouple을 이용하여 실시간으로 온도를 측정 가능하며, 가공 열 발생 시 시편의 온도가 비단열적으로 계속 증 가하는 것이 아니라 어느 정도 기계적인 보정이 가능하다. 게다가 식(2)를 이용한 온도 보정은 결국 변형열을 구한 후에 $\log(\sigma)-1/T$ 의 fitting 방법을 사용하여, 구한 응력의 오차가 클 수 밖에 없다는 단점 또한 존재한다. 그리하여 본 연

구에서는 인공 신경망 데이터베이스에 가공시의 변형량에 따른 온도의 증가와 그 때의 응력값을 삽입하여 인공 신경망에 의한 온도 보정을 수행하였다. 다음의 그림 3은 이렇게 얻어진 온도 보정의 결과를 나타낸다.

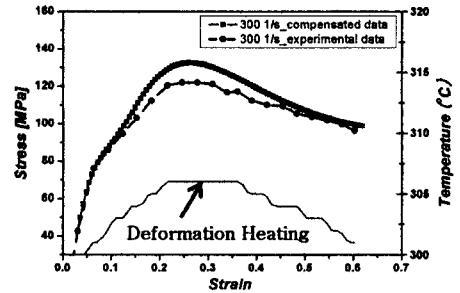


Fig.3. Temperature compensated stress-strain curve by artificial neural network

이 그림을 보면 가공 열에 의해 온도가 올라감에 따라 응력 값이 떨어지며, 그 값은 기계적인 보정에 의해 점점 작아져 수렴하고 있는 것을 알 수 있다. 이렇듯 인공신경망 모델을 이용하면 열적 연화 보정을 효과적으로 수행할 수 있다.

2.3 ANN을 이용한 processing map 도출

Plasad 등은 소성 가공 중의 가공성을 평가하고 최적의 가공 조건을 도출하기 위해 파워 분산 효율지도와 불안정지도의 합으로 나타나는 Processing map이라는 공정 지도를 도출한 바 있다[5]. 본 연구에서는 인공 신경망 모델을 이용하여 도출된 변형율 0.6에서의 stress 값을 이용하여 파워분산효율지도를 도출하였으며, 그 결과는 다음의 그림 4와 같다. 이때 450°C의 온도에서 $10^{-4}/s$ 의 구간에서 가장 분산효율이 높은 지역이 나타나고 있다. 이는 기 연구된 AZ31 Mg 합금의 결과와 같은 것으로 이 지역은 최적의 초소성 현상이 나타나는 지역으로 알려져 있다[6]. 그리고 다음으로 분산 효율이 높은 지역은 250°C, $10^{-1}/s$ 지역이다. 기 연구된 결과에서는 250°C, $1/s$ 지역이 가장 동적 재결정이 활발하게 일어난 지역이라고 보고된 바 있으나[6], $0.1/s$ 지역 역시 활발한 동적 재결정 현상을 보이고 있으며 실제로 동적 재결정의 분율이 상대적으로 $1/s$ 지역에 비해 높은 지역인 것으로 나타났다. 다음의 그림 5는 250°C, $0.1/s$ 지역에서의 미세조직 사진이다.

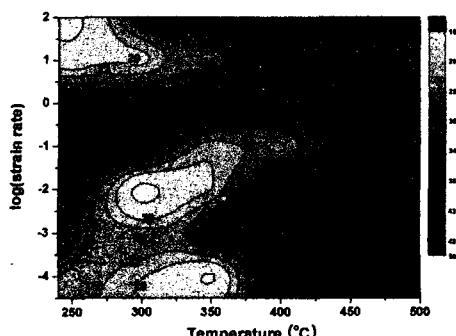


Fig. 4. Power dissipation map of AZ31 Mg alloy by ANN modeling



Fig. 5. Microstructure of specimens compressed at 250°C, $10^{-1}/\text{s}$

이때 실제 실험값과 인공 신경망 모델을 통해 도출된 분산 효율이 높은 지역이 다른 이유는 실제 실험에서는 1/s 이상의 높은 변형률 속도 시에 식(2)의 부정확한 가공 열 보정을 이용하였기 때문으로 생각된다. 인공 신경망을 이용하여 보정된 보다 정확한 열적 연화는 1/s 이상의 빠른 변형률 속도에서의 분산 효율을 보다 정확하게 예측할 수 있게 해준다.

더 나아가 실제 압축 실험으로 수행하기 힘든 높은 변형률의 응력 값을 인공 신경망 방법을 통해 효과적으로 도출할 수 있을 것이다. 이를 통해 대변형량의 경우에도 Processing map 을 도출할 수 있을 것이므로, AZ31 Mg 합금을 실제 변형량이 큰 압연이나 단조의 프로세스에 적용하기 위한 해석에도 효과적으로 사용할 수 있을 것이다.

4. 결 론

인공 신경망 모델을 AZ31 Mg 합금의 고온 압축 데이터에 이용하면, (1)효과적으로 응력 값을 예측할 수 있으며, (2) 고온 압축 실험 시의 열적 연화를 보정할 수 있다. 그리고 (3) 이를 AZ31 Mg 합금의 power dissipation map 에도 효과적으로 적용 가능하다. 이를 이용하여 대변형량의 processing map 을 도출하는데도 인공 신경망 방법이 효과적으로 사용될 수 있을 것이다.

후 기

본 연구는 과학기술부 2003년 국가지정연구사업에 의하여 수행되었으며, 이에 감사 드립니다.

참 고 문 헌

- [1] G. S. Cole, 2003, Issues that Influence Magnesium's Use in the Automotive Industry, Mater. Sci. Forum, Vols. 419~422, pp. 43~50.
- [2] J. Koike, T. Kobayashi, T. Mukai, H. Watanabe, M. Suzuki, K. Karuyama, K. Higashi, 2003, The activity of non-basal slip systems and dynamic recovery at room temperature in fine-grained AZ31B, Acta Mater., Vols. 51, pp. 2055~2065.
- [3] J. C. Tan, M. J. Tan, 2002, Superplasticity and grain boundary sliding characteristics in two stage deformation of Mg-3Al-1Zn alloy sheet, Scripta Mater., Vol.47, pp.101~106.
- [4] P. S. Robi, U. S. Dixit, 2003, Application of neural networks in generating processing map for hot working, Mater. Proc. Tech., Vol.142, pp. 289~294
- [5] Y. V. R. K. Prasad, T. Seshacharyulu, 1998, Processing maps for hot working of titanium alloys, Mater. Sci. Eng., Vol. 243, pp. 82~88.
- [6] B. H. Lee, K. S. Shin, C. S. Lee, High temperature deformation behaviors of AZ31 Mg alloys, Mater. Sci. Forum., Vol. 475~479, pp. 2927~2930.