

인공 신경망 모델을 활용한 조미니 곡선 예측

이운재*** · 이석재*†

*전북대학교 신소재공학부, **세아베스틸 기술연구소

Prediction of Jominy Curve using Artificial Neural Network

Woonjae Lee***, Seok-Jae Lee*†

*Division of Advanced Materials Engineering, Chonbuk National University, Jeonju 54896, Korea

**R&D Center, SeAH Besteel, Soryong-dong, Gunsan 54007, Korea

Abstract This work demonstrated the application of an artificial neural network model for predicting the Jominy hardness curve by considering 13 alloying elements in low alloy steels. End-quench Jominy tests were carried out according to ASTM A255 standard method for 1197 samples. The hardness values of Jominy sample were measured at different points from the quenched end. The developed artificial neural network model predicted the Jominy curve with high accuracy ($R^2 = 0.9969$ for training and $R^2 = 0.9956$ for verification). In addition, the model was used to investigate the average sensitivity of input variables to hardness change.

(Received December 8, 2017; Revised December 15, 2017; Accepted December 22, 2017)

Key words : Artificial neural network, Jominy curve, Hardness, Alloying element effect, Low alloy steels

1. 서 론

조미니 경도 시험은 강의 경화능을 평가하는 가장 대표적인 방법이다. 경화능은 강의 쿨링시 마르텐사이트 조직을 형성하는 능력을 대표하는 것으로 강의 쿨링-템퍼링 열처리시의 강의 경도와 강도를 예상하는데 매우 중요한 변수이다. 그러나 조미니 시험을 하기 위해서는 ASTM A255의 규격화된 방법에 따라 준비된 시편과 규격화된 방법에 따라 제작된 조미니 평가 설비가 필요하다[1]. 만약 ASTM A255에 규격화된 방법에 따른 조미니 평가 설비를 사용하지 못할 경우에는 다른 대체 방법들이 사용된다. 가장 대표적인 방법으로는 ASTM A255에 명시된 Carbon 함량과 기타 합금성분을 이용하여 계산한 DI를 이용한 조미니 계산법과 SEP(STAHL EISEN Prüfblatter)1664에 따른 회귀식을 이용한 계산법이 있고[2], 유한요소법을 이용한 시뮬레이션이나 Quenching Factor 계산을 이용한 예측이 있다[3, 4]. 하지만 ASTM A255의 계산법은 탄소 함량이 유사하고 합금성분이 상이하더라도 DI계산에 의하여 DI값

이 유사한 강종은 유사한 조미니 경도 예측이 나온다는 문제가 있다. SEP1664 방법에서는 화학성분계별로 계산 가능한 조미니 경도 위치가 상이하고 조미니 실측 시 평가가 되는 1.5~50 mm 지점보다 낮은 깊이까지 밖에 계산이 되지 않는 단점이 있다. 유한요소법이나 Quenching Factor 계산법의 경우에도 해당 계산에 사용된 강종 및 데이터는 잘 일치하나, 계산에 사용되지 않은 강종, 데이터의 예측에는 사용될 수 없는 단점이 있다. 이와 같은 이유는 대부분 조미니 경도 실측 데이터에 의거한 예측이 아닌 열역학 계산이나 상변태 거동을 사용한 간접적인 방법에 근거하기 때문이며, 이렇게 예측된 결과들은 실제 현장에서 사용하기 위한 데이터의 정확도나 신뢰성이 다소 부족하다[5, 6].

최근 개인 컴퓨터, 스마트폰, 각종 소셜미디어 등의 다양한 정보 채널의 등장과 정보의 생산, 유통, 보유량이 지속적으로 증가함으로써 방대한 데이터를 이용한 빅데이터 처리기술과 이러한 빅데이터를 분석하기 위한 여러 가지 기법의 활용이 대두되고 있다. 그 중에서도 인공지능을 활용한 데이터 분석이 주목 받고

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

있으며, 특히 알파고와 같은 인공 신경망(artificial neural network, ANN) 모델을 이용한 예측 인공지능을 이용한 방법이 높은 신뢰도를 바탕으로 다양한 분야에서 활용되고 있다[7, 8]. 이러한 신경망 모델을 이용한 강의 조미니 경도를 예측하려는 몇몇 연구들이 보고되고 있지만 조미니 경도에 영향을 주는 합금원소 중 일부의 합금원소 효과만 고려했거나[9, 10], 실험 강종이 매우 제한적이거나[11], 혹은 비교적 많은 합금원소가 첨가된 소재에 대해서도 특정 원소의 영향만을 보고하고 있다[12].

본 연구에서는 실제 특수강 업체에서 생산되는 다양한 합금강들에서 측정된 조미니 경도 데이터를 바탕으로 실제 조미니 경도에 영향을 미칠 수 있는 모든 합금원소를 고려하여 부위별 경도 예측을 위한 인공 신경망 모델을 구축하였다. 예측 모델의 높은 신뢰성을 위해 1,200개에 가까운 실험 시편으로부터 얻은 실측 데이터를 사용하였으며, 이를 바탕으로 조미니 경도에 영향을 주는 합금성분의 영향에 대해 살펴보았다.

2. 실험방법

이번 연구에 사용된 조미니 경도 데이터는 ASTM A255과 SEP1664에 의거하여 강의 조미니 경도에 영향을 주는 합금원소인 C, Si, Mn, Ni, Cr, Mo, V, B, Al, N, Ti를 모두 포함하고 추가로 오스테나이트 결정립도, 강도, 미세조직에 영향을 미치는 Nb 까지 고려된 저합금강들로부터 수집되었다. P와 S는 실제 조미니 경도에 크게 영향을 미치지 못하는 것으로 보고되고 있으며[13], P 첨가는 충격 특성을 저하시키고 S 첨가의 경우 내부식성과 피로강도에 악영향을 미치기 때문에 [14] 실제 첨가량이 낮게 관리되고 있다. 따라서 본 연구에서 P와 S의 효과는

고려하지 않았다. 조미니 실험은 ASTM A255 규격을 따라 세아베스틸에서 실시하였다. 가공된 조미니 시편은 조미니 실험 장비에서 퀴칭 후 표면 연마를 실시하고 경도를 측정하였다. 경도 측정 위치는 퀴칭부 1.5 mm 위치에서부터 50 mm까지 총 15 포인트를 자동으로 측정하였다. 실험에 사용된 저합금강들의 조성 범위는 Table 1에 정리하였다. 실험에 사용된 전체 시편의 개수는 1,197개이고 측정된 데이터는 17,955개이다.

3. 결과 및 고찰

본 연구에서는 역전파 학습알고리즘(Back Propagation Algorithm)의 다층 퍼셉트론 신경망 모델을 구축하였다. ANN 모델의 기본 구조는 Fig. 1과 같이 입력층, 은닉층, 출력층으로 구분되며 각 층의 뉴런들은 sigmoidal 함수등의 비선형 함수를 통해 연결 강도를 전달한다. 각 연결 강도는 출력 결과와 목표 결과 사이의 오류를 최소화하는 방향으로 조절되며 이를 학습이라고 한다. 이번 연구에서는 실험 시편 1197개 중 임의로 추출된 80%에 해당하는 데이터는 모델 학습에 사용하고 모델에 만드는 데 사용




Fig. 1. Schematic of ANN structure.

Table 1. Chemical composition range of specimens used for model development (in wt.%)

	C	Si	Mn	Cu	Ni	Cr	Mo	N	Al	B	V	Ti	Nb
Min.	0.1974	0.2151	0.6724	0.0366	0.0279	0.1276	0.0075	0.0030	0.0167	0.0001	0.0004	0.0016	0.0001
Max.	0.4427	0.3038	0.9405	0.1925	1.8741	1.2542	0.287	0.0180	0.0335	0.0030	0.015	0.0446	0.0268
Average	0.2969	0.2571	0.8405	0.0867	0.1753	0.8912	0.1107	0.0109	0.0233	0.0010	0.0060	0.0137	0.0043
Standard deviation	0.0208	0.0027	0.0139	0.0041	0.0538	0.0842	0.0194	0.0007	0.0006	0.0002	0.0004	0.0011	0.0033

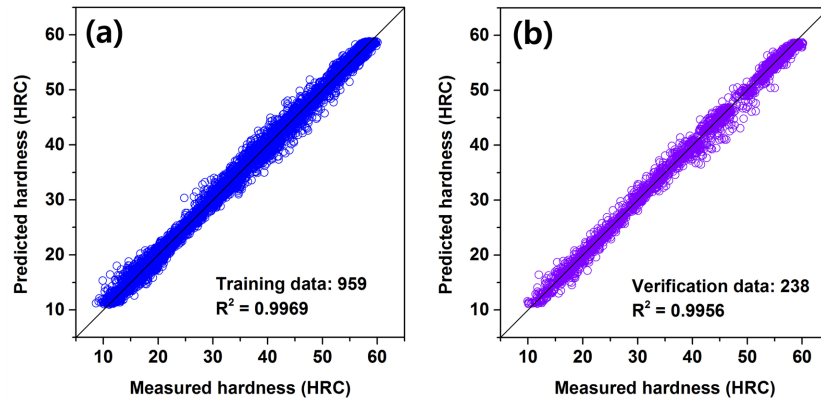


Fig. 2. Comparison of the hardness value predicted by the ANN model with the measured hardness data: (a) training data and (b) verification data.

하지 않은 나머지 20%는 구축된 모델의 정확도를 검증하는데 사용하였다. 최종적으로 사용된 ANN 모델은 1개의 은닉층에 16개의 뉴런을 갖는 구조이다. ANN 모델의 구체적인 계산 과정은 기존의 여러 문헌들에서 쉽게 참고할 수 있다[15, 16].

Fig. 2는 ANN 모델을 사용한 예측 경도와 실험 데이터를 비교한 결과이다. Fig. 2(a)는 ANN 모델을 만드는데 사용한 959개 시편, 총 14,385개 데이터에 대해 학습된 예측 결과이다. 평균제곱오차(R^2) 값이 0.9969로 이는 구축된 ANN 모델이 학습에 사용된 데이터들을 매우 정확하게 예측할 수 있고 신뢰성 있는 모델이 만들어졌음을 의미하기도 한다. Fig. 2(b)는 ANN 모델 개발에 사용하지 않은 238개 시편, 총 3,570개 데이터에 대한 예측 결과를 보여주고 있다. ANN 모델을 만드는데 사용하지 않은 데이터를 예측함에도 불구하고 평균제곱오차 값이 0.9956로 매우 우수한 예측 정확도를 의미한다. 따라서 본 연구에서 구축된 ANN 모델이 Table 1에 해당하는 화학조성의 저합금강들에 대해 신뢰성 높은 조미니 경도 예측이 가능한 것으로 생각된다.

Fig. 3은 ANN 모델을 이용하여 예측한 거리에 따른 경도 변화를 실험 값과 비교한 결과이다. 사용된 실험 시편들 중 Cr강, Cr-Mo강, Ni-Cr-Mo강 1개씩을 임의로 선정하여 비교하였다. 구축된 ANN 모델이 위치별 경도값을 매우 정확하게 예측하고 있다. 각 강종별 평균 예측 오차는 0.026~0.764 HRC이며 모두 1.0 HRC 이하의 오차에서 예측되고 있다. 이는 실제 현장에서도 충분히 사용 가능한 예측 정

확도이다.

조미니 시험에서 위치별 경도의 변화는 시편 내부의 열전달에 의한 냉각 중 상변태 거동에 의한 최종 미세조직에 직접적인 영향을 받는다. 특히 합금 원소의 변화는 상변태 거동 뿐만 아니라 각 미세조직의 경도와 열전달 물성에도 복합적으로 영향을 준다. 따라서 본 연구에서 구축된 ANN 모델을 이용하여 조미니 경도에 미치는 합금 원소들의 민감도를 분석해 보았다. 민감도 분석에 사용된 합금 조성은 Table 1의 평균 조성을 기준 성분으로 하여 각 합금 원소의 표준편차 범위 내에서 성분을 변화시킨 총 130개 성분 조합에 대해 경도 예측을 실시하였다. 계산된 경도값을 다음 식을 이용하여 평균 민감도를 구하였다[17].

$$S(\%) = \frac{1}{n} \sum_{i=1}^{n-1} \frac{(O_{i+1} - O_i) \cdot I_{range}}{(I_{i+1} - I_i) \cdot O_{range}} \times 100 \quad (1)$$

I_i 는 i 번째 입력값, O_i 는 i 번째 출력값, I_{range} 는 입력값의 범위, O_{range} 는 출력값의 범위, n 은 사용된 데이터 수이다. Fig. 4는 표면에서 1.5 mm 위치에 대해 계산된 화학조성 민감도이다. 식 (1)은 특정 합금 원소의 함량 변화에 따른 경도값의 변화 정도를 나타낸다. 즉, 평균 민감도가 양수이면 경도 증가에 기여하는 것을 의미하며 반대로 음수인 경우 경도 감소에 기여하는 것을 의미한다. Fig. 4에서 보는 바와 같이 C의 경우 다른 원소에 비해 월등하게 경도 증가에 기여하고 있으며 그 정도 역시 다른 합금원소들의 영향보다 매우 높다. 이는 잘 알려진 바




Fig. 3. Case simulations for verifying the accuracy of the proposed ANN model: (a) Cr steel, (b) Cr-Mo steel, and (c) Ni-Cr-Mo steel.

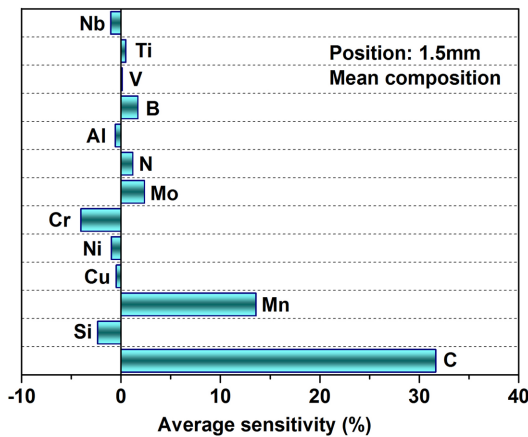


Fig. 4. Prediction of ANN model for average sensitivity of input variables to hardness change.

와 같이 C 첨가가 냉각 중 확산변태 속도를 지연시키고 미세조직의 경도값을 높이는 효과를 잘 반영하고 있다[18]. 다음으로 Mn도 C과 유사한 효과를 보이고 있으나 그 정도는 C보다 낮음을 확인할 수 있다. 반면에 Cr의 경우 표면 경도를 가장 저하시키는 것으로 나타나고 있는데, 이는 단순히 Cr 첨가에 따른 효과라기 보다는 Cr 탄화물의 형성과 그에 따른 기지내 C 농도 변화 등의 복합적인 원인으로 생각된다. 뿐만 아니라 강력한 고온 석출물 형성 원소인 V, Ti, Nb 역시 탄화물 형성에 따른 결정립계 크기에 영향을 미치며 이 역시 냉각 중 상변태 거동과 경화능에 영향이 있는 것으로 알려져 있다 [19, 20]. 하지만 본 연구에서는 합금원소만을 고려한 ANN 모델을 구축하였고 이를 바탕으로 결정립 크기 효과, 석출물 영향 등에 대한 추가적인 연구를 수행할 계획이다.

4. 결 론

본 연구에서는 조미니 경도에 영향을 주는 13개의 합금원소를 고려한 ANN 모델을 구축하였다. 세이베스틸에서 생산된 총 1,197개 시편으로부터 측정된 17,955개의 데이터를 사용하였다. 구축된 ANN 모델은 평균제곱오차 0.9969의 높은 정확도를 보이며 이를 이용한 예측 결과 역시 평균제곱오차 0.9956의 신뢰성 높은 값을 확인하였다. 구축된 모델을 이용하여 화학조성 변화에 따른 부위별 경도 변화를 정확하게 계산할 수 있으며, 화학조성에 대한 민감도 계산을 통해 향후 합금설계에 활용될 것으로 기대한다.

후 기

본 연구는 세이베스틸의 지원에 의해 수행되었으며 이에 감사 드립니다.

References

1. A255/99, Standard test method for determining hardenability of steels, ASTM International, 1999.
2. SEP 1664 - Derivation of equations by multiple regression for the calculation of hardenability in the Jominey end quench test on the basis of the chemical composition of steels, Düsseldorf: Verlag Stahleisen GmbH, 2004.
3. A. Zehtab Yazdi, S. A. Sajjadi, S. M. Zebajrad, and S. M. Moosavi Nezhad : Journal of Materials Processing Technology, **199** (2008) 124
4. D. S. MacKenzie and J. W. Newkirk : Proceedings of the 8th Seminar of the International Federation for Heat Treatment and Surface Engineering, Dubrovnik, Croatia (2001) 139.

5. J. S. Kirkaldy : Metallurgical Transactions A, **4** (1973) 2327.
6. A. Sugianto, M. Narazaki, M. Kogawara, and A. Shirayori : Proceedings of the 8th Asia-Pacific Conference on Materials Processing, Guilin-Guangzhou, China (2008) 883.
7. H. K. D. H. Bhadeshia : ISIJ International, **39** (1999) 966.
8. W. Sha and K. L. Edwards : Materials & Design, **28** (2007) 1747.
9. W. G. Vermeulen, P. J. van der Wolk, A. P. de Weijer, and S. van der Zwaag : Journal of Materials Engineering and Performance, **5** (1996) 57.
10. L. A. Dobrzański and W. Sitek : Journal of Materials Processing Technology, **78** (1998) 59.
11. X. Gao, K. Qi, T. Deng, C. Qiu, P. Zhou, and X. Du : Journal of Iron and Steel Research, International, **13** (2006) 71.
12. T. K. Ho : Ph.D. dissertation, Iowa State University (1978).
13. A. Jacobs and G. Krauss : Journal of Heat Treating, **2** (1981) 139.
14. J. Sojka, P. Betakova, L. Hyspecka, L. Cizek, M. Sozańska, and A. Hernas : Proceedings of the 12th International Scientific Conference on Achievements in Mechanical and Materials Engineering, Gliwice-Cracow-Zakopane, Poland (2003) 821.
15. H. K. D. H. Bhadeshia : ISIJ International, **39** (1999) 966.
16. W. Sha and K. L. Edwards : Materials & Design, **28** (2007) 1747.
17. D. Dunne, H. Tsuei, and Z. Sterjovski : ISIJ International, **44** (2004) 1599.
18. S. J. Lee and Y. K. Lee : Acta Materialia, **56** (2008) 1482.
19. S. J. Lee : ISIJ International, **53** (2013) 1902.
20. B. Hwang, D. W. Suh, and S. J. Kim : Scripta Materialia, **64** (2011) 1118.