

# 레이저 분말 베드 용융법으로 제조된 AlSi10Mg 합금의 경도 예측을 위한 설명 가능한 인공지능 활용

전준협<sup>a,b</sup> · 서남혁<sup>a,b</sup> · 김민수<sup>b</sup> · 손승배<sup>a</sup> · 정재길<sup>a</sup> · 이석재<sup>a\*</sup>  
<sup>a</sup>전북대학교 신소재공학부, <sup>b</sup>한국생산기술연구원 탄소경량소재융합그룹

## Application of Explainable Artificial Intelligence for Predicting Hardness of AlSi10Mg Alloy Manufactured by Laser Powder Bed Fusion

Junhyub Jeon<sup>a,b</sup>, Namhyuk Seo<sup>a,b</sup>, Min-Su Kim<sup>b</sup>, Seung Bae Son<sup>a</sup>, Jae-Gil Jung<sup>a</sup> and Seok-Jae Lee<sup>a\*</sup>

<sup>a</sup>Department of Metallurgical Engineering, Jeonbuk National University, Jeonju 54896, Republic of Korea

<sup>b</sup>Jeonbuk Regional Division, Korea Institute of Industrial Technology, Gimje 54325, Republic of Korea

(Received June 8, 2023; Revised June 21, 2023; Accepted June 24, 2023)

**Abstract** In this study, machine learning models are proposed to predict the Vickers hardness of AlSi10Mg alloys fabricated by laser powder bed fusion (LPBF). A total of 113 utilizable datasets were collected from the literature. The hyperparameters of the machine-learning models were adjusted to select an accurate predictive model. The random forest regression (RFR) model showed the best performance compared to support vector regression, artificial neural networks, and k-nearest neighbors. The variable importance and prediction mechanisms of the RFR were discussed by Shapley additive explanation (SHAP). Aging time had the greatest influence on the Vickers hardness, followed by solution time, solution temperature, layer thickness, scan speed, power, aging temperature, average particle size, and hatching distance. Detailed prediction mechanisms for RFR are analyzed using SHAP dependence plots.

**Keywords:** Laser powder bed fusion, AlSi10Mg, Vickers hardness, explainable artificial intelligence (XAI), Machine learning

### 1. 서 론

레이저 분말 베드 용융(laser powder bed fusion, LPBF) 방식은 최근 각광받고 있는 적층제조 방법 중 하나로 복잡한 형상을 직접 만들 수 있으며 제조 공정의 특성상 빠른 냉각 속도를 갖고 추가적인 가공을 하지 않아도 되는 장점을 가지고 있다. 이로 인해 철, 티타늄, 니켈, 알루미늄과 같은 다양한 소재의 부품에 적용되고 있다[1]. 알루미늄 합금 중에서는 AlSi10Mg 합금이 Al-Si 공정 조성으로 인해 우수한 용접성을 갖고 낮은 밀도, 높은 열전도도, 재활용 비용, 우수한 기계적 특성을 갖기 때문에 LPBF 공정에 적용하기 위해 많은 연구가 이루어져 왔다 [2-11]. 예를 들어 Wei 등[2]은 LPBF 공정으로 만들어진

AlSi10Mg 합금의 열처리에 따른 상과 물리적 특성의 변화를 보고 하였으며, Grielli 등[3]은 LPBF 공정으로 만들어진 AlSi10Mg 합금과 주물체의 열처리 전후의 미세조직과 물성을 비교 분석하였다. LPBF 방식으로 만들어진 AlSi10Mg 합금은 제조 공정과 열처리 조건에 따라 물성이 변하게 되며, 기존의 연구에서는 특정 제조 공정과 제한된 열처리 조건에서 실험을 진행했기 때문에 전체적인 제조 공정과 열처리 조건에 따른 영향을 확인하기 쉽지 않으며, 변수들이 물리적 특성에 어떻게 정량적으로 영향을 미치는지 알 수 없다. 전체적인 변수의 거동과 물성의 예측을 위해서는 모든 변수 조합의 실험이 필요하며, 이를 하기 위해서는 무수한 시간과 비용이 필요하다.

추가적인 시간과 비용 없이, 제조 공정과 열처리 조건과

- 전준협·서남혁: 학생, 김민수: 수석연구원, 손승배·정재길·이석재: 교수

\*Corresponding Author: Seok-Jae Lee, TEL: +82-63-270-2298, FAX: +82-63-270-2305, E-mail: seokjaelee@jbnu.ac.kr

같은 변수들이 재료의 특성에 미치는 정량적인 영향과 물성의 예측을 위해 최근에는 기계 학습 모델이 많이 적용되고 있다. 기계 학습 법은 기존의 데이터를 통해 원하는 특성을 예측하는 모델을 제시하는 방법으로, 재료 과학 분야에서는 새로운 신 합금의 설계나 합금 조성, 열처리 조건, 제조 공정 등을 이용해 원하는 합금의 물리적 특성과 열역학적 특성을 예측하는데 사용되고 있다[12-19]. 우리의 이전 논문[12]에서는 합금강에서의 재가열시 오스테나이트 결정립의 성장에 대한 예측을 랜덤 포레스트 회귀 모델을 통해 예측하였고, Hong 등[13]은 랜덤 포레스트 회귀, 인공신경망, 서포트벡터 머신, 가우시안 프로세스를 통해 주철의 고온 연성을 예측하였다. 이러한 기계학습 방법은 기존의 데이터를 통해 원하는 재료의 특성을 충분히 잘 예측하지만, 모델이 복잡하거나 해석이 불가능하기 때문에 예측 거동을 확인할 수 없다는 단점이 있다. 이를 해결하기 위해 기존의 연구자들은 설명 가능한 인공지능 기법 중 하나인 Shapley additive explanation(SHAP) 분석 기법을 적용해 모델의 예측 거동과 변수의 중요도를 분석했다[12, 13, 20-23].

본 연구에서는 기계 학습법과 SHAP 분석을 통해 LPBF 방식의 제조 공정과 열처리 조건에 따른 AlSi10Mg 합금의 경도를 예측하는 모델을 제시하고, 예측 거동을 분석했다. 이를 통해 LPBF 방식으로 만들어진 AlSi10Mg 합금의 설계에 대한 방향성을 제시했다.

## 2. 해석 모델 구축

본 연구에서는 LPBF 공정을 통해 만들어진 AlSi10Mg 합금의 제조 공정과 열처리에 따른 경도의 변화를 예측하고 각각의 특성들이 미치는 영향을 확인하기 위해 기존 문헌을 통해 분말의 평균 크기, 레이저의 세기, 스캔 속도, 분말 층의 두께, 해치 거리, 용체화 온도, 용체화 시간, 인공시효 온도, 인공시효 시간을 포함하는 113개의 실험 데

이터를 수집했다[2-11]. 데이터 수집 시 결측치를 포함하는 데이터를 제외하고 수집하였으며, 데이터의 정규화는 진행하지 않았다. 데이터의 최소값, 최대값, 평균값 및 분산은 표 1에 정리하였다. 데이터는 랜덤 포레스트 회귀(Random forest regression, RFR)와 서포트 벡터 회귀(Support vector regression, SVR), 최근접 이웃(k-nearest neighbors, kNN) 모델을 학습시키기 위해 데이터의 70%를 학습 데이터로 30%를 테스트 데이터로 분리했다. 또한 인공신경망(Artificial neural network, ANN)을 학습시키기 위해 데이터의 70%는 학습 데이터, 15%는 검증 데이터 나머지 15%는 테스트 데이터로 분리했다.

최적의 기계학습 모델을 제안하기 위해 각 모델의 하이퍼파라미터(hyperparameter)를 조정하였다. 랜덤 포레스트 회귀의 경우 여러 개의 결정 트리(decision tree)로 이루어진 모델로 결정 트리의 수와 각 트리의 최대 깊이에 따라 모델의 성능이 달라진다[24, 25]. 그렇기 때문에 결정 트리의 수와 트리의 최대 깊이가 하이퍼파라미터이며, 본 연구에서는 결정 트리의 수와 최대 깊이를 1에서 100으로 변경시켜 가며 학습을 진행했다. 서포트 벡터 회귀의 하이퍼파라미터는 커널의 종류, 커널(kernel) 계수와 규칙화 매개변수(regularization parameter)이며[26], 커널은 radial basis function을 사용하였고, 커널의 계수는 0.1에서 10000으로, 규칙화 매개변수는 0.0000001에서 0.01로 변경시켜 가며 학습을 진행했다. 인공신경망의 하이퍼파라미터는 optimizer의 종류, 학습률(learning rate), 활성화 함수(activation function)의 종류, 히든 레이어(hidden layer)의 수와 노드(node) 수이며[16], optimizer는 adaptive moment estimation을 사용했으며, 학습률의 경우 0.00001에서 0.1로 변경시켜가며 학습을 진행했다. 히든 레이어의 수는 과적합(over fitting)을 피하기 위해 1~2개의 레이어(layer)를 사용하였으며, 활성화 함수는 linear, sigmoid와 ReLU를 각 레이어에 적용시켜 학습시켰다. 첫 번째와 두 번째 히든 레이어의 노드 수를 각각 1에서 100까지 변경

**Table 1. The ranges, averages, and deviations of LPBF process variables and heat treatment variables**

| Variant                                     | Minimum | Maximum | Average | Deviation |
|---|---------|---------|---------|-----------|
| APS ( $\mu\text{m}$ )                       | 24.00   | 50.00   | 38.87   | 10.25     |
| Power (W)                                   | 200.0   | 400.0   | 378.2   | 27.14     |
| Scan speed (mm/s)                           | 500.0   | 7000    | 2989    | 2635      |
| Layer thickness ( $\mu\text{m}$ )           | 25.00   | 60.00   | 32.35   | 6.720     |
| Hatching distance ( $\mu\text{m}$ )         | 130.0   | 200.0   | 190.0   | 10.98     |
| Solution temperature ( $^{\circ}\text{C}$ ) | 0.000   | 560.0   | 480.6   | 151.2     |
| Solution time (min)                         | 0.000   | 540.0   | 216.9   | 151.4     |
| Aging temperature ( $^{\circ}\text{C}$ )    | 0.000   | 180.0   | 117.4   | 71.32     |
| Aging time (min)                            | 0.000   | 1440    | 319.6   | 319.3     |
| Hardness (HV)                               | 52.50   | 140.0   | 93.06   | 17.31     |

시켜 가며 학습을 진행했으며, 이때 두 번째 히든 레이어의 노드 수는 첫 번째 히든 레이어의 노드 수를 넘지 않게 했다. 최근접 이웃의 경우 인접하는 데이터의 수를 통해 예측을 진행함으로, 고려하는 데이터의 수가 하이퍼파라미터이며[27], 이를 1에서 90으로 변경시켜가며 학습시켰다. 하이퍼파라미터 조정 후 각 기계학습 모델에서 가장 높은 성능을 보이는 모델을 선택했다. 그 결과, 랜덤 포레스트 회귀의 경우 결정 트리의 수가 14개 최대 깊이가 93개인 모델이 선택됐고, 서포트 벡터 회귀의 경우 커널의 계수가 1000, 규격화 매개변수가 0.00001인 모델을 선택했으며, 인공신경망의 경우 학습률이 0.001, 첫 번째 레이어의 노드 수가 83개, 두 번째 레이어의 노드 수가 21개, 첫 번째와 두 번째 레이어의 활성화 함수가 각각 linear와 ReLU인 모델을 선택했다. 마지막으로 최근접 이웃의 경우 2개의 데이터를 고려한 모델을 선택했다. 하이퍼파라미터가 조정된 모델들의 성능을 평가하기 위해 식 (1)을 이용하여 결정 계수( $R^2$ )를 구했다.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

이때  $\hat{y}$ 는 모델의 경도 예측 값,  $y$ 는 문헌에서 수집된 실험값,  $\bar{y}$ 는 실험값의 산술 평균이다. 학습된 3개의 모델 중 예측 정확도가 가장 높은 모델을 선택하여 설명 가능한 인공지능 기법 중 하나인 SHAP을 이용하여 변수의 중요도와 변수에 따른 예측 거동을 분석했다. 기계 학습과 SHAP 분석은 TensorFlow version 2.7.0, scikit-learn version 0.23.1과 Python version 3.7을 이용하여 진행했다.

### 3. 결과 및 고찰

그림 1은 하이퍼파라미터 조정 후 선택된 기계학습 모델을 비교한 것이다. 랜덤 포레스트 회귀는 학습 데이터와 테스트 데이터 각각 0.91과 0.86의 정확도를 보였으며, 서포트 벡터 회귀의 경우 학습 데이터와 테스트 데이터에서 각각 0.94와 0.82의 정확도를 보였고, 인공 신경망의 경우 학습 데이터, 검증 데이터, 테스트 데이터에서 각각 0.55, 0.59, 0.59의 정확도를 보였으며, 최근접 이웃 모델의 경우 학습 데이터와 검증 데이터에서 각각 0.87과 0.11의 정확도를 보였다. 학습 데이터에서는 서포트 벡터 회귀 모델이 가장 높은 정확도를 보였지만, 테스트 데이터의 경우 랜덤 포레스트 회귀가 가장 높은 정확도를 보였다. 학습 데이터의 경우 모델의 학습에 사용되는 데이터이므로, 테스트 데이터 세트에서의 정확도의 중요도가 높다. 따라서 이후

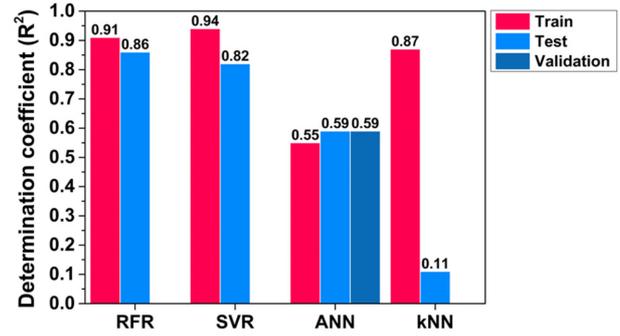


Fig. 1. Performance of machine learning models for the training and testing datasets (add performance for validation dataset in the case of ANN).

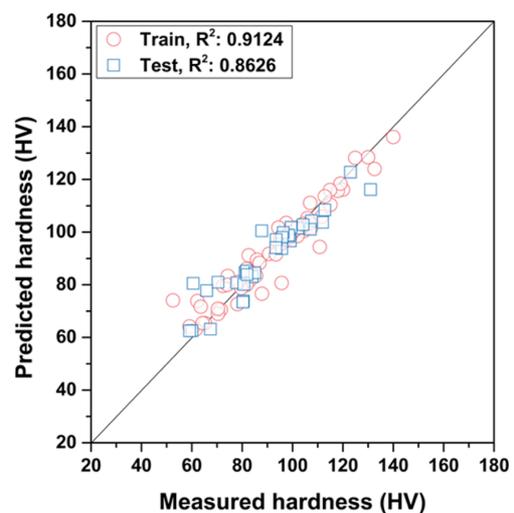


Fig. 2. Performance of RFR model. (red circle) prediction accuracy of train dataset. (blue square) prediction accuracy of test dataset.

의 데이터 분석의 경우 랜덤 포레스트 회귀를 선택하여 진행했다.

그림 2는 랜덤 포레스트 회귀의 학습 데이터와 테스트 데이터의 정확도와 분포를 보여주는 그림이다. 그림에서 보는 것과 같이 전체적인 데이터 범위에서 데이터가 나뉜 것을 확인할 수 있으며, 랜덤 포레스트 회귀 모델이 LPBF로 만들어진 AISi10Mg 합금의 경도를 학습 데이터뿐만 아니라 학습에서 사용되지 않았던 테스트 데이터에서도 정확하게 예측하는 것을 알 수 있다. 따라서 랜덤 포레스트 모델을 이용하여 SHAP 분석을 통해 변수들의 정량적인 영향과 예측 거동을 분석했다.

SHAP 분석은 데이터 범위 내의 변수의 전체적인 조합으로 분석이 진행되며, 각 변수들의 기여도를 분석하는 것이기 때문에 전체적인 모델의 예측 메커니즘을 알려줄 수 있다. SHAP의 기준 값은 SHAP 분석 시 사용된 데이터 경도의 평균값인 88.973이었으며, SHAP 값이 양수이면, 기준 값에서 증가를 음수이면, 기준 값에서 감소함을 뜻한

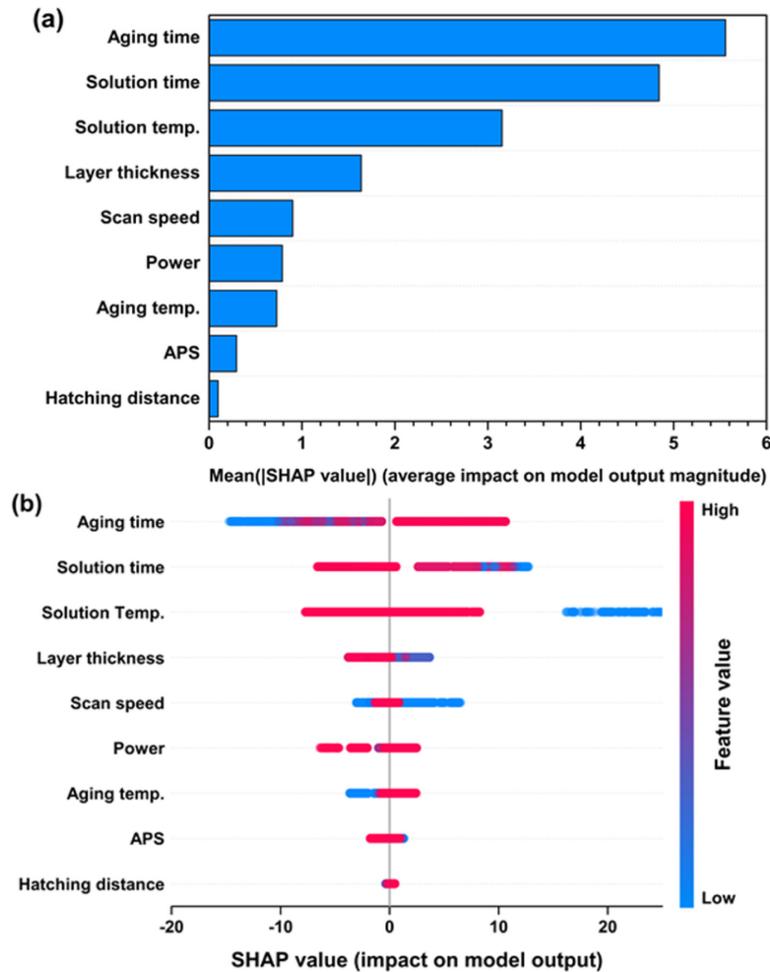


Fig. 3. (a) Feature importance of each variable and (b) prediction mechanisms of each variable on HV of AISi10Mg.

다. 그림 3(a)는 공정 변수와 열처리가 AISi10Mg 합금의 경도에 미치는 정량적인 평균 영향도를 보여주는 그래프이다. 그림에서 보는 것과 같이 인공시효 시간이 경도에 가장 높은 영향을 미쳤고 용체화 시간, 용체화 온도, 분말 층의 두께, 스캔 속도, 레이저의 세기, 인공 시효 온도, 평균 분말 크기, 해치 거리가 뒤따랐다. 각 변수의 값의 변화에 따른 경도의 변화를 확인하기 위해 그림 3(b)와 같이 산점도로 SHAP 분석 결과를 나타냈다. 그림에서 색이 붉은색에 가까우면 각 변수의 값이 크고, 파란색에 가까우면 변수의 값이 작으며, SHAP 값이 클수록 경도 증가에 영향을 미친다는 뜻이다. 인공시효 시간과 인공시효 온도, 해치 거리가 증가함에 따라, 경도가 증가함을 확인했으며, 용체화 시간, 용체화 온도, 분말 층의 두께, 평균 분말 크기가 증가함에 따라 합금의 경도가 감소함을 확인했다.

각 변수의 변화에 따른 자세한 예측 메커니즘을 분석하기 위해 그림 4와 같이 각 변수의 값에 따른 SHAP 값을 산점도로 나타냈다. 그림 4 (a)는 인공시효 시간의 변화에 따른 경도(SHAP 값)의 변화를 나타내고 있으며, 산점도의

색은 용체화 온도를 나타내며, 붉은색에 가까울수록 값이 증가함을 나타낸다. 인공시효 시간이 증가함에 따라 경도가 증가함을 알 수 있으며, 약 700분 근처에서 최대 경도를 보이는 것을 알 수 있다. 또한 30분간 인공시효 시 용체화 온도가 증가할수록 경도가 감소하며, 700분 이상 인공시효 시 용체화 온도가 증가할수록 경도가 증가하는 경향을 보였다. As-built 상태의 AISi10Mg 시편의 공정 Si 상은 섬유질 형태의 형태로 존재하며, 용체화 처리 시 공정 Si 상이 구상화되고 용체화 온도가 올라갈수록 섬유질은 희미해지고 사라지며, 구상화된 Si 상만이 존재하게 된다[2, 5]. 이러한 섬유질 형태의 Si 상은 경도와 강도에 큰 기여를 하지만, 연성에 악영향을 미친다. 인공시효 시간이 30분에서 용체화 처리 온도가 증가함에 따라 경도가 감소하는 이유는 높은 용체화 처리 온도에서 구상화된 공정 Si 상만이 존재하게 되었기 때문으로 생각된다. 700분 이상에서 용체화 온도가 증가함에 따라 경도가 증가하는 이유는 높은 용체화 온도로 인해 합금 원소들이 알루미늄 모재에 고용되었으며, 충분한 인공시효 시간 동안 합

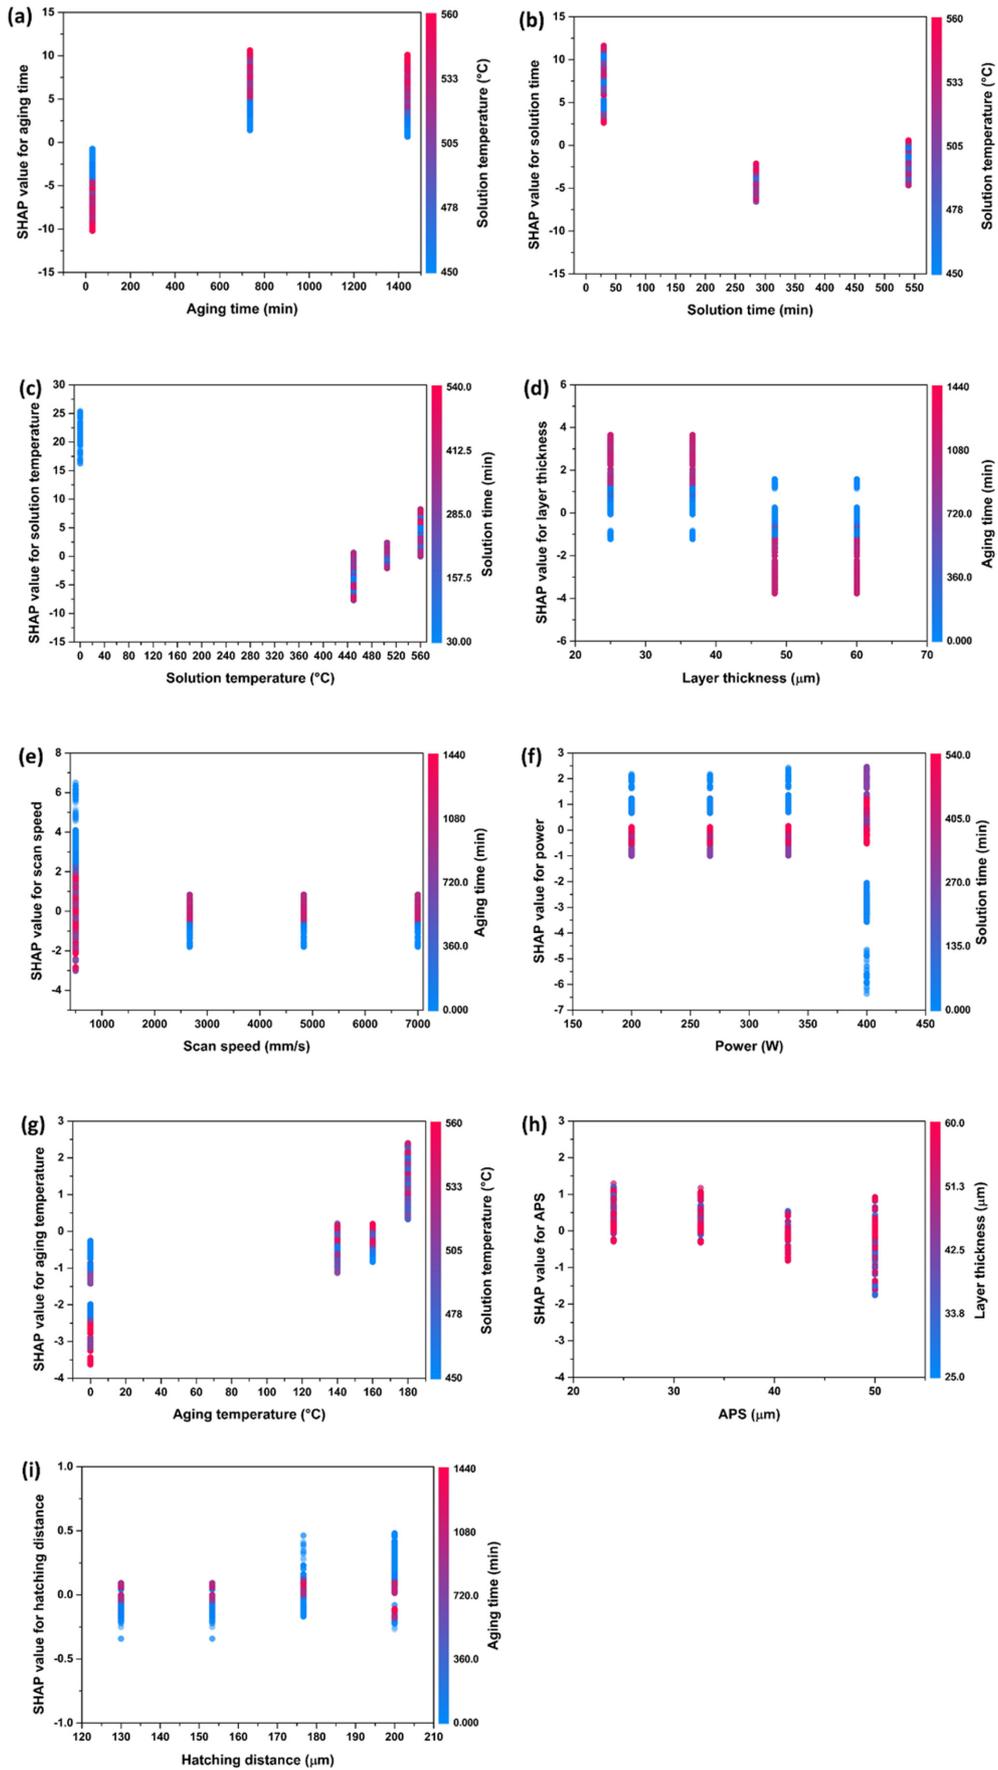


Fig. 4. The detailed prediction mechanisms of each variable on HV of AlSi10Mg.

금의 주요 석출 강화 상인  $\beta$ 상 계열의 석출물들이 석출되었기 때문으로 생각된다. 그림 4 (b)는 용체화 시간의 변화에 따른 경도의 변화를 나타내고 있다. 용체화 시간이 증가함에 따라 경도가 감소하는 것을 알 수 있으며, 용체화 시간이 30분으로 짧은 경우 섬유질 형태의 공정 Si 상이 충분히 구상화되지 않아 경도의 감소가 작은 것을 알 수 있으며, 용체화 시간이 증가할수록 경도가 감소하는 것을 알 수 있다. 용체화를 285분 이상 진행함에 따라 합금의 경도는 미세하게 증가하는 경향을 보인다. 이를 통해 용체화 시간이 285분 일 때 이미 섬유질 형태의 공정 Si 상이 모두 구상화되었고, 285분 이상에서는 합금원소가 모재로 용체화 되면서 고용강화 효과를 보이는 것을 유추할 수 있다. 그림 4 (c)는 용체화 온도에 따른 경도의 변화를 나타낸다. As-built 시편에서 용체화를 진행하게 되면, 경도가 크게 감소하는 것을 알 수 있다. 이는 앞서 설명한 것과 같이 공정 Si 상의 구상화가 가장 큰 영향을 미친 것으로 생각된다. 용체화 온도가 증가함에 따라 경도가 증가하는 이유는 용체화 온도 증가에 따른 이차상들의 모상으로의 용해 때문이다[3]. 그림 4 (g)의 경우 인공 시효 온도에 따른 경도의 변화를 보여준다. 그림에서 보는 것과 같이 시효 온도가 증가할수록 경도가 증가하는 것을 알 수 있으며, 이는 시효 온도 증가에 따른 이차 상의 석출이 가속화되었기 때문으로 생각된다. 그림 4 (d), (e), (f), (h), (i)는 LPBF의 공정 변수의 변화에 따른 경도 변화를 나타내고 있다. 분말 층의 두께의 경우 두께가 얇을수록 경도가 증가하는 경향을 보였고, 스캔 속도의 경우 속도가 높아질수록 경도가 감소하는 경향을 보였다. 레이저의 세기의 경우에는 약 350 W까지 일정하다가 400 W에서 경도가 감소하는 것을 알 수 있다. 레이저의 세기가 커지면 이전에 소결되었던 층에 레이저 열에 의한 영향이 증가하게 되고, 용융지가 커지게 되므로 레이저 세기가 커짐에 따라 이전 층이 재용융 되므로 이에 대한 효과로 경도가 감소한 것으로 생각된다. 분말의 평균 크기와 헤치 거리의 경우 경도 변화에 큰 영향을 미치지 않은 것을 확인하였다.

#### 4. 결 론

본 연구는 LPBF 방식으로 만들어진 AlSi10Mg 합금의 경도를 예측하고 제조 공정 변수와 열처리 변수에 따른 경도의 예측 메커니즘과 변수들의 중요도를 제시하기 위해 기계 학습 모델과 SHAP 분석을 진행했다. 랜덤 포레스트 회귀, 서포트 벡터 회귀, 인공 신경망, 최근접 이웃 모델 총 4개의 경도를 예측하는 모델을 학습시켜 비교 분석을 진행했으며, 랜덤 포레스트 회귀 모델이 학습 데이터와 테스트 데이터에서 각각 91.24%와 86.26%의 정확도를

보였다. 이를 기반으로 예측 거동 분석을 위해 랜덤 포레스트 회귀 모델을 선택하여 변수의 중요도와 예측 메커니즘을 분석하였다. AlSi10Mg 합금의 경도에 가장 큰 영향을 미친 변수는 인공시효 시간이었으며, 그 뒤를 용체화 시간, 용체화 온도, 분말 층의 두께, 스캔 속도, 레이저의 세기, 인공 시효 온도, 평균 분말 크기, 헤치 거리가 뒤따랐다. 또한 인공시효 시간과 인공시효 온도, 헤치 거리가 증가함에 따라, 경도가 증가함을 확인했으며, 용체화 시간, 용체화 온도, 분말 층의 두께, 평균 분말 크기가 증가함에 따라 합금의 경도가 감소함을 확인했다. 분석 결과를 통해 프린팅 시 공정 변수 보다 열처리 시간과 온도가 경도에 더 큰 영향을 미치는 것을 확인했으며, 용체화 처리 시에 합금의 그물 형태의 공정 Si 상이 구상화되며 경도 감소에 가장 큰 기여를 한다는 것을 확인했다. 용체화 후 인공시효 시  $\beta$ 상 계열의 석출 강화 상이 석출되며, 경도의 증가에 기여하는 것을 확인했으며, SHAP 분석 결과를 통해 LPBF공정으로 만들어진 AlSi10Mg 합금의 경도 변화에 대한 전체적인 거동을 제시했다.

#### Acknowledgements

This work was supported by a Korea Institute for Advancement of Technology grant, funded by the Korea Government (MOTIE) (P0002019), as part of the Competency Development Program for Industry Specialists. And also this work was supported by the Technology Innovation Program (20010408) funded by the Ministry of Trade, Industry & Energy (MOTIE, Korea).

#### References

- [1] J. Flocchi, A. Tuissi and C. A. Biffi: *Mater. Des.*, **204** (2021) 109651.
- [2] W. Li, S. Li, J. Liu, A. Zhang, Y. Zhou, Q. Wei, C. Yan and Y. Shi: *Mater. Sci. Eng. A*, **663** (2016) 116.
- [3] L. Girelli, M. Tocci, M. Gelfi and A. Pola: *Mater. Sci. Eng. A*, **739** (2019) 317.
- [4] Q. Han and Y. Jiao: *Int. J. Adv. Manuf. Technol.*, **102** (2019) 3315.
- [5] L. Zhou, A. Mehta, E. Schulz, B. McWilliams, K. Cho and Y. Sohn: *Mater. Charact.*, **143** (2018) 5.
- [6] K. Zygula, B. Nosek, H. Pasiowicz and N. Szyslak: *World Sci. News*, **104** (2018) 456.
- [7] E. Padovano, C. Badini, A. Pantarelli, F. Gili and F. D'Aiuto: *J. Alloys Compd.*, **831** (2020) 154822.
- [8] P. Delroisse, P. J. Jacques, E. Maire, O. Rigo and A. Simar: *Scr. Mater.*, **141** (2017) 32.

- [9] W. H. Kan, Y. Nadot, M. Foley, L. Ridosz, G. Proust and J. M. Cairney: *Addit. Manuf.*, **29** (2019) 100805.
- [10] S. Bagherifard, N. Beretta, S. Monti, M. Riccio, M. Bandini and M. Guagliano: *Mater. Des.*, **145** (2018) 28.
- [11] C. D. Clement, J. Masson and A. S. Kabir: *J. Manuf. Mater. Process.*, **6** (2022) 52.
- [12] J. Jeon, N. Seo, J.-G. Jung, H.-S. Kim, S. B. Son and S.-J. Lee: *J. Mater. Res. Technol.*, **21** (2022) 1408.
- [13] C. Yang, C. Ren, Y. Jia, G. Wang, M. Li and W. Lu: *Acta Mater.*, **222** (2022) 117431.
- [14] T. Thankachan, K. S. Prakash, V. Kavimani and S. R. Silambarasan: *Met. Mater. Int.*, **27** (2021) 220.
- [15] D. Hong, S. Kwon and C. Yim: *Met. Mater. Int.*, **27** (2021) 298.
- [16] J. Jeon, G. Kim, N. Seo, H. Choi, H.-J. Kim, M.-H. Lee, H.-K. Lim, S. B. Son and S.-J. Lee: *J. Mater. Res. Technol.*, **16** (2022) 129.
- [17] J. Jeon, D. Kim, J.-H. Hong, H.-J. Kim and S.-J. Lee: *Korean J. Met. Mater.*, **60** (2022) 713.
- [18] Y. Zhang and X. Xu: *Met. Mater. Int.*, **27** (2021) 235.
- [19] C. Capdevila, F. G. Caballero and C. Garcia de Andres: *ISIJ Int.*, **42** (2002) 894.
- [20] J. Jeon, N. Seo, J.-G. Jung, S. B. Son and S.-J. Lee: *Mater. Trans.*, **63** (2022) 1369.
- [21] J. Jeon, N. Seo, S. B. Son, J.-G. Jung and S.-J. Lee: *J. Mater. Sci.*, **57** (2022) 18142.
- [22] J. Jeon, N. Seo, S. B. Son, S.-J. Lee and M. Jung: *Metals*, **11** (2021) 1159.
- [23] J. Jeon, N. Seo, H.-J. Kim, M.-H. Lee, H.-K. Lim, S. B. Son and S.-J. Lee: *Metals*, **11** (2021) 729.
- [24] S. K. Murthy, S. Kasif and S. Salzberg: *J. Artif. Intell. Res.*, **2** (1994) 1.
- [25] Q. R. Wang and C. Y. Suen: *IEEE Trans. Pattern Anal. Mach. Intell.*, **PAMI-6** (1984) 406.
- [26] A. J. Smola and B. Schölkopf: *Stat. Comput.*, **14** (2004) 199.
- [27] T. M. Cover and P. E. Hart: *IEEE Trans. Inf. Theory*, **13** (1967) 21.