

Predicting Coercivity in NdFeB Sintered Magnets via Dual-Tower Neural Networks: Impact of Data Distribution and Latent Space Coverage

Chunghye Nam*

Department of Electrical and Electronic Engineering, Hannam University, Daejeon 34430, Republic of Korea

(Received 7 May 2026, Received in final form 19 June 2026, Accepted 22 June 2026)

In this study, a Dual-Tower Artificial Neural Network was constructed to predict the coercivity of NdFeB sintered permanent magnets based on experimental data of composition and process variables, while investigating the dependency of regression performance on data distribution. It was observed that the regression performance fluctuated sensitively depending on the specific split between the training and test datasets. To identify the cause of these performance variations, dimensionality reduction techniques were employed to visualize the geometric distribution of the training and test data for each split condition. The visualization revealed a clear distinction between the best and worst performance cases: the results depended on how effectively the training data spanned the distribution of the test data within the latent space of the feature factors. Furthermore, by tracking the attention weights derived during the training process for different data splits, it was confirmed that the weights for composition variables generally remained higher than those for process variables. This indicates that composition exerts a dominant influence on the prediction of coercivity.

Keywords : NdFeB sintered magnet, hard magnet, machine learning, deep learning

듀얼 타워 신경망을 이용한 NdFeB 소결 자석의 보자력 예측: 데이터 분포 및 잠재 공간 포괄 범위의 영향

남충희*

한남대학교 전기전자공학과, 대전광역시 대덕구 한남로 70, 34430

(2026년 5월 7일 받음, 2026년 6월 19일 최종수정본 받음, 2026년 6월 22일 게재확정)

본 연구에서는 NdFeB 소결 영구자석의 조성과 공정변수 실험 데이터를 바탕으로 보자력을 예측하는 듀얼 타워 인공신경망을 구축하고 회귀성능의 데이터 의존성을 확인하였다. 학습데이터와 테스트 데이터 분할 조건에 따라 회귀 성능이 민감하게 변동하는 현상이 관찰되었다. 이러한 성능 변동의 원인을 규명하기 위해 차원 축소 기법을 활용하여 각 분할조건에 따른 학습데이터와 테스트 데이터의 잠재공간 분포를 시각화 하였다. 시각화 결과, 최적 성능과 최저 성능사례 사이에서 학습 데이터가 테스트 데이터의 특성인자의 잠재공간의 분포가 얼마나 효과적으로 포괄하고 있는지에 따른 명확한 차이가 확인되었다. 또한, 학습데이터와 테스트 데이터의 서로 다른 분할의 경우 각 모델의 학습 과정에서 도출된 어텐션 가중치 변화를 추적한 결과, 보자력 예측에 있어 조성 변수의 가중치가 공정 변수의 가중치보다 전반적으로 높은 수준을 유지하며 지배적인 영향력을 행사하고 있음을 확인하였다.

주제어 : NdFeB 소결자석, 경자성, 기계학습, 딥러닝

I. 서 론

소결 NdFeB 영구자석은 우수한 자기적 성능으로 인해서 에너지 변환 전기 장치에서 매우 큰 잠재력을 가진 소재이다. 현재 널리 사용되고 있고 향후 크게 응용성이 높은 분야로는

전기 구동모터가 필요한 모빌리티, 의료기기, 풍력 발전, 로봇 등 다양한 분야가 있다[1-3]. 특히 NdFeB 자석은 높은 보자력(coercivity), 우수한 최대 에너지 곱(BH_{max}), 그리고 전락 금속인 코발트를 사용하지 않아 비교적 낮은 비용이라는 장점을 지니고 있어 학계와 산업계 모두에서 큰 관심을 받고

있다. $\text{Nd}_2\text{Fe}_{14}\text{B}$ 자석은 일본의 Masato Sagawa 등에 의해 소개된 이후 지속적인 연구를 통해 자기적 특성이 꾸준히 향상되어 왔다[4-6]. 특정 응용 분야에 적합한 성능을 얻기 위해 다양한 합금 원소를 첨가하는 방식이 널리 사용된다. 예를 들어 Dy나 Tb와 같은 중희토류(heavy rare earth: HRE) 원소는 Nd를 일부 대체하여 HRE-Fe-B 상을 형성함으로써 보자력을 높이고 고온에서도 안정한 특성을 유지한다. 그러나 Dy와 Tb는 원소 자체의 희소성이 높을 뿐 아니라 전략 소재이기 때문에 고보자력 자석의 상용화에는 한계가 존재한다[7,8].

이러한 문제를 해결하기 위해 Al, Cu, Zr 등의 첨가 원소를 이용한 미세조직 제어 연구도 활발히 진행되고 있다. 예를 들어 Al은 입계의 젖음성(wetability)을 향상시켜 입계 구조를 최적화하고 결과적으로 보자력을 높이는 데 도움을 준다[9]. 하지만 비자성 원소를 첨가할 경우 잔류자속밀도(remanence)가 감소하는 문제도 함께 발생하는 단점이 있다. 최근에는 자원 균형과 비용 절감을 위해 Pr/Nd 일부를 La, Ce, Y와 같은 풍부한 희토류 원소로 대체하는 연구 역시 주목받고 있지만, 이 경우에도 보자력과 잔류자속밀도의 저하 문제가 여전히 존재한다[5,7,8].

NdFeB 자석의 성능은 조성뿐만 아니라 제조 공정에도 크게 영향을 받는다. 소결 공정은 여러 단계로 이루어져 있으며, 조성·미세조직·공정 변수들이 서로 복잡하게 상호작용하여 최종 자기 특성을 결정한다. 기존의 최적화 전략 방식은 한 가지 원소를 변경하고 나머지 조건은 고정하는 시행착오(trial-and-error) 방식이 주를 이루었는데, 이는 시간과 자원이 많이 소모될 뿐 아니라 복잡한 변수 간 관계를 파악하기 어렵다는 한계가 있었다. 이러한 한계를 극복하기 위해 최근에는 기계학습(machine learning) 기반 데이터 주도형 연구가 활발히 도입되고 있다. 기계학습은 대량의 데이터를 학습하여

조성·공정 변수와 소재의 특성 사이의 관계를 찾아낼 수 있다는 장점이 있다. 예를 들어, NdFeB 소결자석의 조성데이터와 공정변수 데이터를 바탕으로 자석의 물성을 예측한 연구의 경우 그래디언트 부스팅 회귀모델이 우수한 성능을 보인 반면, 데이터가 추가된 경우 랜덤포레스트 앙상블 모델이 우수한 예측 성능을 나타내었다[10,11]. 중희토류를 배제하기 위한 접근 방법으로 경희토류 데이터를 수집하여 최적의 (PrNdLaCe)-Fe-B 계 영구자석의 조성을 유전알고리즘으로 탐색하였다. 이 경우에는, 영구자석의 성능을 유지하며 소재의 가격을 낮추는 설계전략을 택하여 최적의 조성에 대하여 실험으로 검증하였다[12].

그러나 기존 연구에는 몇 가지 한계가 존재했다. 첫째, 데이터 수가 적어 모델의 일반화 성능이 낮았다. 둘째, 조성 정보만 사용하는 경우가 많아 실제 성능에 큰 영향을 주는 공정 변수들이 충분히 반영되지 않았다. 본 연구에서는 조성과 공정변수를 모두 포함하는 데이터를 사용하되 목적함수는 보자력을 택하여 인공신경망을 통하여 회귀 예측 모델을 구축하였다. 소재 데이터의 특성상 데이터 수가 적기 때문에 데이터의 의존성을 확인하기 위해서 학습데이터와 테스트 데이터를 8:2로 나누고 50가지 다른 방법으로 나누어, 회귀 예측 성능의 데이터의 의존성을 확인함으로써, 데이터의 정량적 양뿐 아니라 조성과 공정의 다양한 정보를 포함해야지 일반화 성능이 높아지는 것을 확인하였다.

II. 실험 방법

본 연구에서는 최근 문헌에서 보고된 NdFeB 소결자석의 데이터셋을 사용하였으며[11], 데이터는 조성 성분과 공정변수를 포함하고 있고 포함된 화학 조성 성분을 주기율표상에 히트맵 형식으로 Fig. 1에 시각화 하였으며 공정변수는 Table




Fig. 1. (Color online) Periodic-table visualization of the average elemental concentration (wt%) in the NdFeB permanent magnet dataset. The color intensity represents the logarithmic scale of the average concentration of each element.

Table I. Processing parameters and Units Used in Artificial Neural Networks [11].

Processing parameters	Units
Magnetic field intensity	[T]/Tesla
Sintering temperature	[°C]/Celsius
Sintering time	[h]/hours
Primary tempering temperature	[°C]/Celsius
Secondary tempering time	[h]/hours
Secondary tempering temperature	[°C]/Celsius

1에서 확인할 수 있다. 분석 결과, 소결 NdFeB 자석의 주상 ($\text{Nd}_2\text{Fe}_{14}\text{B}$)을 구성하는 핵심 원소인 Fe(평균 64.19 wt%)와 Nd(평균 29.40 wt%)가 가장 높은 농도로 분포하고 있음을 확인할 수 있으며, 이는 전형적인 상용 소결자석의 조성 범위를 충실히 반영하고 있다. 특히, 자기적 특성, 그중에서도 보자력(H_{cj})의 극대화 및 고온 안정성 확보를 위해 다양한 합금 원소가 전략적으로 첨가되었음을 알 수 있다. 중희토류 원소(HRE)인 Dy(1.16 wt%)와 Tb(0.02 wt%)는 주상의 자기 이방성을 높여 보자력을 직접적으로 향상시키는 역할을 수행하며, 데이터셋 내에서의 폭넓은 분포는 고보자력 자석 설계를 위한 핵심 변수로 작용한다. 또한, Pr(1.46 wt%), Gd(0.34 wt%), Ce(0.31 wt%) 등 다양한 희토류 원소의 혼합 사용은 자원의 효율적 활용과 자기적 성능 사이의 최적화된 설계가 반영되었음을 시사한다[7,8]. 전이금속 및 첨가 원소인 Co(1.03 wt%), Ga(0.23 wt%), Al(0.21 wt%), Cu(0.11 wt%) 등은 주상과 입계상 사이의 젖음성(wettability)을 개선하고, 비자성 입계상

을 매끄럽게 형성함으로써 결정립 간의 자기적 교환 결합을 차단하는 역할을 한다. 특히 Ga과 Cu의 미량 첨가는 입계상의 용점을 낮추고 미세조직을 균일하게 제어하여 유효 보자력을 높이는 데 기여하는 것으로 알려져 있다[9].

Fig. 2는 본 연구에서 제안하는 인공지능망(Two-Tower Attention Fusion Network)의 구조와 이를 활용한 NdFeB 자석의 H_{cj} 예측 및 데이터 의존성 분석을 위한 전체 연구 워크플로우(workflow)를 보여준다. 먼저, 수집된 NdFeB 데이터셋은 화학 조성(wt%) 정보와 공정 변수로 구분되어 입력층을 구성한다. 제안된 모델 아키텍처는 조성 영역(composition tower)과 공정변수 영역(processing tower)으로 정의된 두 개의 독립적인 신경망 블록을 통해 각각의 입력으로부터 추상화된 특성 벡터를 병렬적으로 추출한다. 이후 두 타워에서 도출된 특징은 결합(concatenation) 및 어텐션 기반 융합 메커니즘을 거치게 된다. 이 과정에서 모델은 보자력 예측에 기여하는 조성과 공정 변수의 상대적 가중치인 α (조성)과 β (공정)를 동적으로 산출한다. 최종적으로, 산출된 가중치가 적용된 두 특징 벡터의 가중합(weighted sum)은 다층 퍼셉트론(MLP) 기반의 출력층을 거쳐 최종 목적 변수인 보자력을 정량적으로 예측하게 된다. 본 연구에서는 데이터셋 규모(262개)가 제한적이라는 점에 주목하여, 데이터 분할 방식이 모델 성능에 미치는 영향을 체계적으로 검증하였다. 이를 위해 학습 데이터와 테스트 데이터를 8:2 비율로 분할하되, 서로 다른 50개의 랜덤 시드(random Seed)를 적용하여 총 50가지의 학습/테스트(train/test) 데이터 조합을 생성하고 각각 독립적인




Fig. 2. (Color online) Schematic overview of the machine-learning framework for predicting the intrinsic coercivity (H_{cj}) of NdFeB permanent magnets. The workflow consists of: (1) construction of the NdFeB dataset, (2) repeated train/test splitting with 50 different random seeds, (3) development of a two-tower neural network model, (4) evaluation of feature importance and regression performance, (5) visualization of t-SNE distributions.

회귀 예측을 수행하여 비교하였다.

III. 결과 및 토의

Fig. 3은 서로 다른 50개의 무작위 조건(random seed)을 적용하여 학습데이터와 테스트 데이터를 나누는 후의 각 모델의 보자력 예측 결과이다. 50개 서로 다른 학습 데이터에 대해서 학습을 완료한 후 테스트 데이터에 대한 회귀 예측 성능을 R^2 score와 평균제곱근오차(root-mean-squared-error: RMSE) 수치로 나타낸 결과이다. 분석 결과, 전체 50회 실험의 평균 R^2 score는 0.784, 평균 RMSE는 152.774 kA/m로 나타났으나, 각 분할 조건에 따른 성능 편차는 상당히 뚜렷하게 관찰되었다. 특히, 그래프상에 표시된 최적 성능 사례(best case)와 최저 성능 사례(worst case)간의 통계적 성능 차이는 매우 현격한 수준을 보여준다. 일부 최적화된 데이터 분할 조건에서는 0.9에 근접하는 높은 R^2 score를 달성하며 우수한 예측 정확도를 기록한 반면, 특정 분할 조건에서는 R^2 score가 0.4 수준으로 급격히 하락하며 모델의 예측 신뢰성이 크게 저하되는 현상이 확인되었다. 이러한 결과는 NdFeB 소결 자석 데이터셋과 같이 샘플의 개수가 제한적인 환경(small data)에서 학습 데이터와 테스트 데이터 간의 불균형이 회귀 모델의 일반화 성능에 결정적인 영향을 미칠 수 있음을 시사한다. 즉, 특정 분할 조건에서 테스트 데이터는 학습 데이터가 포괄하지 못하는 물리적 영역(extrapolation zone)에 집중적으로 배치될 경우, 모델의 예측 오차가 심화될 수 있음을 정량적으로 보여준다.

Fig. 4는 Fig. 3의 반복 실험을 통해 확인된 최적 성능 사례와 최저 성능 사례에 대한 실측치(measured)와 예측치(predicted) 간의 상관관계를 나타낸 패리티 플롯 결과이다. 먼저 특정 분할 조건(seed 19)인 최적 성능 사례의 경우, 학습 데이터(R^2 score = 0.956)와 테스트 데이터(R^2 score = 0.907) 모두에서 데이터 포인트들이 대각선 기준선에 조밀하




Fig. 3. (Color online) Prediction performance variation of the two-tower neural network model across 50 different random train/test splits. Distribution of (a) test R^2 scores and (b) test RMSE values for each random seed.

게 분포하며 매우 높은 선형 상관관계를 보여주는 것을 Fig. 4(a, b)를 통해서 알 수 있다. 이는 해당 데이터 분할 조건에서 모델이 NdFeB 자석의 조성 및 공정 변수와 보자력 사이의 복잡한 비선형 관계를 성공적으로 학습하였으며, 테스트 데이터에 대해서도 탁월한 보간(Interpolation) 성능을 발휘하고 있음을 입증한다.

반면, 또다른 특정 분할(seed 25) 조건인 최저 성능 사례에서는 학습 데이터에 대해 R^2 score = 0.963이라는 매우 높은 예측 성능을 유지하고 있음에도 불구하고, 테스트 데이터에서의 성능은 R^2 score = 0.407로 급격히 하락하는 양상을 보이는 것을 Fig. 4(c, d)를 통해서 알 수 있다. 특히 특정 보자력 구간에서 예측값이 실측값으로부터 크게 벗어나는 데이터 포인트들이 다수 관찰된다.

이러한 결과는 학습된 모델의 예측 성능이 단순한 인공 신경망 아키텍처의 역량보다는 학습 데이터와 테스트 데이터 간의 변수 잠재 공간(feature latent space)의 유사성에 크게 의존하고 있음을 시사한다. 즉, 최저 성능 사례의 경우 모델이




Fig. 4. (Color online) Parity plots comparing measured and predicted intrinsic coercivity (H_{cj}) values for different random train/test splits. (a, b) Results for Seed 19 representing the best-performing split. (c, d) Results for Seed 25 representing the worst-performing split. The red dashed lines indicate perfect agreement between measured and predicted values.




Fig. 5. (Color online) t-SNE visualization of the NdFeB dataset colored by intrinsic coercivity (H_{ci}) values, illustrating the distribution of training and test samples for different random data splits. Open circles represent test samples, while filled circles indicate training samples, for (a) Seed 19 (best-performing split) and (b) seed 25 (worst-performing split).

학습 데이터에 과도하게 최적화되었으나, 테스트 데이터가 학습 데이터에서 포함하지 못한 물리적 불연속점이나 희소 영역에 위치함에 따라 일반화(generalization) 능력이 상실되는 전형적인 외삽(extrapolation) 오류가 발생한 것으로 해석된다. 따라서 본 연구는 소량의 데이터셋을 활용한 영구자석 물성 예측 시, 학습데이터와 테스트 데이터의 일화성 분할에 의한 성능 지표가 모델의 실제 역량을 왜곡할 수 있음을 확인하였으며, 모델의 신뢰성 확보를 위해 데이터 분포의 기하학적 유사성을 고려한 검증 체계가 필수적임을 확인하였다.

Fig. 5는 최적 성능 사례와 최저 성능 사례에 대해 전체 데이터의 특성인자 분포(feature distribution)를 t-SNE(t-distributed Stochastic Neighbor Embedding) 기법으로 2차원 투영하여 시각화한 결과이다. 각 데이터 포인트의 색상은 각 데이터의 보자력값을 나타내며, 학습 데이터는 채워진 원(closed circle)으로, 테스트 데이터는 열린 원(open circle)으로 표시하여 데이터 분할에 따른 데이터 특성의 잠재 공간적 배치를 비교 분석하였다. 분석 결과, Fig. 5(a)의 최적 성능 사례에서는 테스트 데이터들이 학습 데이터가 형성하고 있는 특성인자 공간(feature space) 내부에 고르게 분포하고 있음을 확인할 수 있다. 이는 테스트 데이터의 대부분이 학습 데이터의 거동을 통해 예측 가능한 내삽(Interpolation) 영역에 위치함을 의미하며, 앞서 확인한 높은 예측 성능을 이해할 수 있는 근거가 될 수 있다.

반면, Fig. 5(b)의 최저 성능 사례에서는 일부 테스트 데이터 포인트들이 학습 데이터가 존재하지 않는 희소 영역, 즉 외삽(extrapolation)이 요구되는 영역에 고립되어 분포하는 양상이 뚜렷하게 관찰된다. 특히, 학습 데이터의 범위를 벗어난 영역에 위치한 테스트 샘플들은 주로 1,000~1,400 kA/m 범위의 보자력 값을 나타내고 있으며, 이는 앞선 Fig. 4(d)의 패리티 플롯에서 해당 구간의 예측 오차가 두드러지게 나타

났던 결과와 정확히 일치한다.

이러한 결과는 데이터셋의 규모가 제한적인 경우, 모델이 충분히 학습하지 못한 영역(out-of-distribution region)에 대한 예측 성능이 급격히 저하될 수 있음을 시사한다. 결론적으로, NdFeB 소결자석과 같이 복잡한 다변수 시스템을 다루는 회귀 모델의 신뢰성을 확보하기 위해서는 단순한 데이터 수의 양적 확보뿐만 아니라, 특성인자 공간 내에서 데이터의 균일한 분포를 확보하여 모델의 외삽 성능 한계를 최소화하는 전략이 필수적임을 나타낸다. 이를 위해서는 다양한 조성과 공정변수를 가지는 데이터가 필요한 것을 알 수 있다.

Fig. 6은 제안된 듀얼타워(dual-tower) 인공지능망 모델에서 50개의 서로 다른 랜덤시드(random seed)를 사용하여 학습/테스트 데이터를 8:2로 분할한 조건에서 얻어진 조성(composition) 및 공정변수(processing parameters)의 어텐션 가중치(attention weight)를 나타낸다. 각 랜덤시드에 대해 모델은 어텐션 기반 융합 메커니즘을 통해 조성 특징의 기여도(α)와 공정 변수의 기여도(β)를 학습과정에서 얻을 수 있었다.




Fig. 6. (Color online) Variation of attention weights assigned to the composition tower (α) and processing tower (β) across 50 different random train/test splits.

모든 랜덤시드에 의해서 서로 다르게 분할된 조건임에도 불구하고 조성 가중치는 공정변수 가중치보다 일관되게 높은 값을 나타냈으며, 평균 어텐션 가중치는 각각 $\alpha \approx 0.78$, $\beta \approx 0.22$ 수준으로 확인되었다. 이러한 결과는 현재 데이터셋에서 보자력 예측 시 공정 변수보다 조성 정보가 상대적으로 더 지배적인 영향을 미친다는 것을 의미한다. 이것은 중희토류 사용을 통하여 자기이방성을 높이고 전이금속을 이용하여 균일한 계면 형성등을 통한 보자력을 높이는 방법 등이 그 예가 된다. 또한, 특정 데이터 분할조건에서 공정변수 가중치가 0.4에 도달할 만큼 큰 값을 보이는 것을 확인할 수 있다. 이것은 소결자석의 보자력 특성은 공정변수에도 큰 영향을 받는 것을 나타낸다. 한편, 랜덤시드 및 이에 따른 학습/테스트 데이터 분포 변화에 따라 어텐션 가중치의 일부 변동이 관찰되었으나, 전체적인 경향성은 50개의 모든 분할 조건에서 유사하게 유지되었다. 이는 제안된 어텐션 기반 듀얼타워 프레임워크가 서로 다른 데이터 분할 조건에서도 조성 및 공정 변수의 상대적 중요도를 안정적으로 정량화할 수 있음을 보여준다. 또한 데이터 분할 조건에 따른 어텐션 가중치의 변동성은 전체 데이터 수가 262개로 제한적이기 때문에 학습 데이터와 테스트 데이터의 통계적 분포 차이가 특징 중요도 학습 및 회귀 예측 거동에 영향을 미칠 수 있음을 시사한다.

IV. 결 론

본 연구에서는 NdFeB 소결 영구자석의 조성과 공정변수 데이터를 바탕으로 보자력을 예측하는 인공신경망을 구축하고 데이터의 의존성을 확인하였다. 학습데이터와 테스트 데이터 분할 조건에 따라 회귀 성능(R^2 score, RMSE)이 민감하게 변동하는 현상이 관찰되었다. 이러한 성능 변동의 원인을 규명하기 위해 t-SNE(t-distributed Stochastic Neighbor Embedding) 차원 축소 기법을 활용하여 각 분할조건에 따른 학습데이터와 테스트 데이터의 기하학적 분포를 시각화 하였다. 시각화 결과, 최적 성능과 최저 성능사례 사이에서 학습 데이터가 테스트 데이터의 공간적 분포를 얼마나 효과적으로 포괄하고 있는지에 따른 명확한 차이가 확인되었다. 또한, 학습데이터와 테스트 데이터의 50회 다른 분할 조건하에서 각 모델의 학습 과정에서 도출된 어텐션 가중치(Attention weight) 변화를 추

적한 결과, 보자력 예측에 있어 조성 변수의 가중치가 공정 변수의 가중치보다 전반적으로 높은 수준을 유지하며 지배적인 영향력을 행사하고 있음을 확인하였다. 이는 본 연구 모델이 단순한 수치 예측을 넘어, 복잡한 합금 시스템에서 물질 결정 인자의 상대적 중요도를 물리적으로 타당하게 해석하고 있음을 시사한다.

감사의 글

이 논문은 2025 학년도 한남대학교 학술연구비 지원에 의하여 연구되었음.

References

- [1] T.-H. Kim and J.-G. Lee, J. Korean Magn. Soc. **32**, 59 (2022).
- [2] D. Brown, B.-M. Ma, and Z. Chen, J. Magn. Magn. Mater. **248**, 432 (2002).
- [3] Q. Lu, Y. Shao, Y. Yin, H. Chen, H. Xu, W. Liu, M. Liu, C. Zhong, X. Yu, J. Chen, Y. Liu, X. Yi, and M. Yue, Sustain. Mater. Technol. **36**, e00615 (2023).
- [4] C. Zhao, Q. Jiang, S. Ur Rehman, X. Li, Y. Chen, J. Song, and Z. Zhong, J. Rare Earth. **40**, 1894 (2022).
- [5] S.-M. Lee, G. Kim, K.-S. Lee, S. Kim, T.-H. Kim, S.-H. Lee, D.-H. Kim, W. Lee, and J.-G. Lee, Acta Mater. **285**, 120660 (2025).
- [6] T.-H. Kim, T.T. Sasaki, T. Ohkubo, Y. Takada, A. Kato, Y. Kaneko, and K. Hono, Acta Mater. **172**, 139 (2019).
- [7] J. Yan, Q. Wu, H. Ge, Z. Xi, and J. Liang, Mater. Chem. Phys. **315**, 128901 (2024).
- [8] M. Ji, Z. Wang, W. Liu, Y. Li, H. Chen, H. Wu, R. Du, D. Zhang, M. Yue, X. Yi, Y. Liu, and S. Zha, J. Alloys Compd. **970**, 172598 (2024).
- [9] R. Yang, Q. Li, M. Bu, M. Zhao, W. Chen, K. Lv, S. Ren, J. Jin, and M. Yan, J. Alloys Compd. **1036**, 181691 (2025).
- [10] Z. Qiao, S. Dong, Q. Li, X. Lu, R. Chen, S. Guo, A. Yan, and W. Li, J. Alloys Compd. **963**, 171250 (2023).
- [11] Q. Zhou, X. Bai, X. Ma, Z. Zhou, P. Lin, X. Xing, Y. Zhang, S. Jiang, and Y. Zhang, J. Alloys Compd. **1022**, 179810 (2025).
- [12] Z. Wang, S. Zhang, J. Wang, M. Zhang, Y. Chen, B. Li, T. Zhao, M. Zhu, F. Hu, B. Shen, and W. Li, Acta Mater. **292**, 121031 (2025).