

인공신경망을 이용한 S31803 듀플렉스 스테인리스강의 환경변수 변화에 따른 동전위 분극 거동 예측

정광후¹ · 김성종^{2,†}

¹국립목포해양대학교 승선실습과정부, 전남 목포시 해양대로 91

²국립목포해양대학교 기관시스템공학부, 전남 목포시 해양대로 91

(2026년 2월 05일 접수, 2026년 2월 13일 수정, 2026년 2월 24일 채택)

Prediction of Potentiodynamic Polarization Behavior of S31803 Duplex Stainless Steel under Various Environmental Conditions Using Artificial Neural Networks

Kwang-Hu Jung¹ and Seong-Jong Kim^{2,†}

¹Division of cadet training, Mokpo national maritime university, 91, Haeryangdaehak-ro, Mokpo-si, Jeollanam-do, 58628, Republic of Korea

²Division of marine system engineering, Mokpo national maritime university,

91, Haeryangdaehak-ro, Mokpo-si, Jeollanam-do, 58628, Republic of Korea

(Received February 05, 2026; Revised February 13, 2026; Accepted February 24, 2026)

This paper presents an artificial neural network (ANN) model designed to predict the potentiodynamic polarization behavior of S31803 duplex stainless steel (DSS) in marine environments. A full factorial experimental design was utilized to gather data on the effects of temperature, salinity, and pH on corrosion behavior. Potentiodynamic polarization (PDP) tests were performed to create a comprehensive database across a wide potential range. The ANN model uses temperature, salinity, pH, and overpotential as input variables, while the output layer predicts the corresponding current density under overpotential. Based on the dataset obtained from the PDP curves, a multilayer ANN model was developed and optimized to forecast polarization curves. The optimized ANN model demonstrated high predictive accuracy, with determination coefficients of 0.993, 0.987, and 0.987 for the training, validation, and test datasets, respectively. These results suggest that the proposed ANN model is an effective tool for predicting corrosion behavior, contributing to corrosion monitoring and condition-based maintenance in marine systems.

Keywords: Artificial neural network, Duplex stainless, Potentiodynamic polarization, Corrosion behavior, Environmental factors

1. 서론

듀플렉스 스테인리스강(duplex stainless steel, DSS)은 페라이트(α)와 오스테나이트(γ)가 공존하는 이중상의 미세조직을 가지고 있다. 이러한 특성은 소재의 우수한 기계적 강도와 내식성을 부여하며, 이러한 장점으로 인해 해양 구조물, 해수 취급 설비, 화학 플랜트 및 담수화 시스템 등 다양한 분야에서 널리 사용되고 있다. 이중상 구조는 오스테나이트계 스테인리스강에 비해 높은 국부 부식 저항성을 제공하며, 응력부식 균열에 대한 저

항성을 향상시킨다 [1,2]. 반면, 해수와 같이 가혹한 부식환경이나 고온 환경에서는 공식 부식(pitting corrosion)에 취약해질 수 있으며 [3], 이는 구조적 건전성과 신뢰성 측면에서 심각한 문제를 야기한다.

일반적으로 습식 환경에서 스테인리스강의 부식 거동은 동전위 분극시험(potentiodynamic polarization test, PDP)을 통해 평가되며, 이로부터 부식전위와 공식 전위 같은 주요 전기화학적 지표가 도출된다 [4,5]. PDP 시험은 재료의 부식 특성을 정량적으로 평가하는 데 유용하며, 분극곡선 자체에는 부동태화, 부동태피막 붕괴, 재부동태화 등 다양한 전기화학적 정보를 포함하고 있다. 그러나 공학적 실험을 통한 연속적인 변수조건에 대한 분극곡선을 실험적으로 확보하는 것은 시간적/인적 비

[†]Corresponding author: ksj@mmu.ac.kr

정광후: 교수, 김성종: 교수

용 측면에서 실질적 제약이 있다. 더욱이, 실험 설계 과정에서 변수는 현실적인 제약으로 인해 제한된 조건 또는 특정 수준으로 설정되며, 이로 인해 변수 간 중간 조건에 대한 전기화학적 거동을 직접 확인하는 데에는 한계가 존재한다. 이는 실험결과에 대한 해석을 불연속적인 조건으로 제한시키며, 연속적인 환경 변화에 따른 부식 거동을 체계적으로 분석하는 데 한계가 있다. 또한, DSS의 부식 거동은 단일상 오스테나이트계 스테인리스강에 비해 복잡한 특성을 가질 수 있다. 이는 페라이트상과 오스테나이트상의 이중구조에서 발생하는 화학 조성, 결정 구조 등에 영향을 받을 수 있기 때문이다 [6,7]. 이로 인해 분극곡선 상의 비선형적인 특성이 관찰될 수 있다. 비선형적 거동은 단순한 경험식이나 선형 회귀 모델로는 정확하게 예측하는데 제한이 있으며, 공식 전위와 같은 단일 지표만으로는 전체 부식 거동을 충분히 설명하기 어렵다.

이와 같은 문제점을 보완하기 위해 통계적 기법과 회귀 분석이 부식 연구에 적용되고 있으며, 이들 방법은 부식 거동에 영향을 미치는 주요 인자를 식별하는 데 매우 효과적인 도구로 활용되고 있다 [8-11]. 그러나 전기화학적 부식 시스템은 변수 간 비선형성과 복잡한 상호작용을 내포하고 있어, 전통적인 통계적 접근만으로는 전체 거동을 충분히 반영하는 데 한계가 있다 [12].

최근 기계학습과 데이터 기반 모델링 기법이 이러한 한계를 극복하기 위한 새로운 접근법으로 주목받고 있다 [13]. 특히 인공신경망(artificial neural network, ANN)은 복잡한 비선형 관계를 효과적으로 학습할 수 있는 장점을 가지며 [14,15], 제한된 실험 데이터로부터 변수 간 중간 조건에 대한 전기화학적 거동을 예측할 수 있다. 이러한 접근법은 실험 결과 해석의 연속성을 확보하고, 추가 실험조건 선정 및 실험 설계의 효율성을 향상시키는 중요한 기준을 제공할 수 있다.

선행연구에서는 오스테나이트계 스테인리스강을 대상으로 ANN을 활용하여 동전위 분극곡선을 예측한 사례가 있으며 [16,17], 이를 통해 데이터 기반 모델이 평균적인 전기화학 거동에 대한 재현성이 확인되었다. 그러나 대부분의 사전연구들이 단일상 재료에 국한되어 있으며, 이중상 미세조직을 갖는 DSS의 복합적이고 국부적인 부식 거동을 대상으로 한 연구는 상대적으로 제한적이다. 특히 환경변수에 따른 DSS의 분극곡선 예측에 관한 연구는 아직 충분히 이루어지지 않았다.

본 연구에서는 S31803 DSS를 대상으로 해양환경에

서의 다변수 조합에서 동전위 분극 거동을 예측하기 위해 인공신경망 기반의 데이터 구동형 모델을 제안한다. 온도, 염도 그리고 pH를 변수로 하는 완전 요인 설계(full factorial design)를 통해 체계적인 실험 데이터를 확보하였으며, 이를 기반으로 분극곡선 전체를 예측할 수 있는 ANN 모델을 구축하였다.

본 연구의 목적은 첫째, 환경변수 변화에 따른 S31803 DSS의 분극 거동과 공식 저항성을 실험적으로 분석하고, 둘째, 인공신경망 모델을 통해 복잡한 분극곡선을 정량적으로 예측하며, 마지막으로 제안된 모델의 예측 성능과 적용 가능성을 평가하는 데 있다. 본 연구결과는 DSS의 부식 거동을 보다 효율적으로 예측할 수 있는 도구를 제공하고, 데이터 기반 접근법의 활용 가능성을 확장하는 데 기여할 것으로 기대된다.

2. 연구방법

2.1 시편 및 전처리

본 연구에서 사용된 S31803 DSS의 화학조성은 Table 1에 제시하였다. 전기화학시험용 금속 시편(20 mm × 20 mm × 5 mm)은 SiC 연마지 #600번까지 순차적으로 표면을 연마하였다. 연마된 시편은 무수 에탄올로 세척 후 열풍 건조하여 데시케이터에 보관하였다.

미세조직관찰용 시편은 순차적으로 SiC 연마지 #2000까지 순차적으로 연마한 후, 0.5 μm 산화알루미늄 페이스트를 이용하여 최종 연마를 수행하였다. 이후 30 wt% KOH 용액에서 전기화학적 에칭을 수행하였으며, 미세조직은 주사전자현미경(scanning electron microscope, SEM)을 이용하여 관찰하였다. X선 회절분석(X-ray diffraction, XRD) 분석은 Cu-Kα 방사선($\lambda = 0.15418$ nm)을 사용하여 $2\theta = 20\text{--}80^\circ$ 범위에서 $2^\circ/\text{min}$ 조건으로 수행하였다.

2.2 실험조건 선정

ANN 모델에 대한 학습(training), 검증(validation), 시험(test) 데이터 획득을 위해, 3 인자(온도, 염도, pH) 3 수준의 전 요인 실험계획을 설정하였다. 전 요인 실험계획(full factorial design)은 모든 인자와 수준의 변수조합이 포함되는 방법이다. 이는 각 인자와 수준 간의 작용 효과를 분석할 수 있어, 높은 신뢰도의 회귀 모델을 도출할 수 있다. 본 연구에서 적용된 전 요인 실험의 상세 조건은 Table 2와 3에 제시하였다. 본 연구에서 설정한 온도, 염도 및 pH 범위는 선박과 해양플랜트의 해

Table 1. Chemical composition of S31803

C	Si	Mn	P	S	Cr	Ni	Mo	N	Cu
0.02	0.27	1.8	0.04	0.001	22.54	5.54	3.25	0.15	0.15

Table 2. Experimental factor and their levels

Factors		Unit	Level (Normalized Value)		
Input	temperature	°C	30(0)	60(0.5)	90(1)
Input	salinity	g/L	20(0)	30(0.5)	40(1)
Input	pH		2(0)	4(0.5)	6(1)
Input	overpotential, η	V	from -0.25 V vs. OCP to 1.2 V		
Output	current under overpotential, I_η	A/cm ²	range of $10^{-10} \sim 10^{-1}$		

Table 3. Full factorial design matrix and experiment results

No.	Temp.	Salinity	pH
1	30	20	2
2	30	20	4
3	30	20	6
4	30	30	2
5	30	30	4
6	30	30	6
7	30	40	2
8	30	40	4
9	30	40	6
10	60	20	2
11	60	20	4
12	60	20	6
13	60	30	2
14	60	30	4
15	60	30	6
16	60	40	2
17	60	40	4
18	60	40	6
19	90	20	2
20	90	20	4
21	90	20	6
22	90	30	2
23	90	30	4
24	90	30	6
25	90	40	2
26	90	40	4
27	90	40	6

수 냉각계통에서 진단 가능한 전 범위의 모델을 도출하고자, 정상 운전 범위와 비정상 상황에서 국부적으로 발생할 수 있는 환경을 포괄하도록 설정하였다.

2.2.1 온도(temperature)

일반적인 해수 온도는 약 10 ~ 35 °C 범위이다 [18], 선박 주기관 및 보조기관 해수 냉각계통에서 온도가 상승하여 30 ~ 50 °C 범위가 관찰되며, 고부하 운전, 해수 유량 저하, 비정상 상황에서 국부적으로 그 이상 상승할 수 있다. 극단적으로 해양플랜트와 배기가스 후처리 장치의 일부 고온 공정에서 국부적으로 90 °C 수준까지 상승할 수 있다.

2.2.2 염도(salinity)

염도는 해수 내 염소이온(Cl⁻) 농도를 대표하는 인자이며, 금속의 전기화학적 거동에 중요한 영향을 미친다 [19]. 일반적인 해수의 평균 염도는 약 3.5 wt%이다. 연안 및 하구역에서 담수 유입으로 인해 감소되거나 폐쇄형 해수 계통에서 농축에 의해 4 wt%까지 상승할 수 있다 [20].

2.2.3 pH

pH는 금속 표면의 반응 특성 및 부식에 영향을 미치는 인자이다. 일반적인 해수의 pH는 약 8.0이지만, 해수 냉각계통 내부에서 CO₂ 용해, 미생물 부식, 또는 틈(crevice) 구조에서 수소이온 축적에 의한 국부적인 산성 환경이 형성될 수 있다.

각 인자의 수준을 제어하기 위해, 염도와 pH는 각각 NaCl과 염산을 이용하였다. 각 인자의 수준은 ANN 모델의 학습효율 향상을 위해 equation (1)를 통해 0과 1 사이의 값으로 정규화(normalization)되었다.

$$X = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (1)$$

여기에서, x 는 정규화된 값이며, $x_{\max}$ 와 $x_{\min}$ 은 각 수준에서의 최대값과 최소값이다.

2.3 동전위 분극시험

동전위 분극실험은 작동전극(노출면적 1.36 cm²의 DSS 시편), 기준전극(Ag/AgCl sat. 3M KCl), 그리고 상대전극 (20 mm × 20 mm 백금 메쉬)으로 구성된 3 전극 부




Fig. 1. Schematic diagram for ANN architecture used for modeling polarization curves

식 셀을 사용하여 수행하였다. 분극시험은 개방회로전위(open-circuit potential, OCP)에서 1,800초 동안 안정화를 거친 후, OCP 대비 -0.25 V에서 1.2 V까지 1.67 mV/s의 주사 속도로 수행되었다.

2.4 ANN 모델 구조

본 연구에서 ANN은 지도학습 기반의 역전파(backpropagation) 알고리즘 모델이 사용되었다. 사용된 ANN은 입력층(input layer), 다수의 은닉층(hidden layer), 그리고 출력층(output layer)으로 구성된 다층 퍼셉트론(multilayer perceptron)구조이다. ANN 모델의 전체적인 구조는 Fig. 1에 제시하였다. 입력층은 온도, 염도, pH 및 인가전위의 4개 입력 변수를 각각 하나의 뉴런으로

구성하였으며, 출력층은 전류밀도를 예측하도록 설정하였다. 각 은닉층에 대한 활성화 함수는 비선형 함수 근사 성능이 우수하고, 복잡한 비선형 관계의 예측에 적합한 equation (2)의 쌍곡 탄젠트(hyperbolic tangent, tanh)가 적용되었다 [21,22]. 출력층의 활성화 함수는 연속값 예측에 적합한 선형(linear)함수를 사용하였다. 분극시험으로부터 도출된 전체 데이터(23,239 샘플)는 학습(training), 검증(validation), 시험(test) 데이터로 각 80%(18,823 샘플), 10%(2,092 샘플), 10%(2,324 샘플)의 비율로 분할하였으며, 학습 편향을 최소화하기 위해 매 학습 과정에서 무작위로 분할하였다. 모델 학습을 위한 비용함수는 equation (3)의 평균제곱오차(mean squared error, MSE)를 사용하였으며, 비용함수의 최적화를 위해 Adam (adaptive moment estimation) 알고리즘을 적용하였다. 해당 과정에서 사용된 신경망 모델에 대한 설계

및 구현은 Python 3.7 환경에서 Tensorflow 2.0 라이브러리를 이용하여 수행되었다.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

$$\frac{1}{n} \sum_{i=1}^n (X(t) - X'(t))^2 \quad (3)$$

3. 연구결과 및 고찰

3.1 미세조직

Fig. 2는 S31803 DSS의 미세조직이며, 전형적인 페라이트-오스테나이트 이중상 구조를 나타낸다. 또한, 오스




Fig. 2. SEM image of microstructure for S31803 duplex stainless steel

테나이트는 가공된 방향을 따라 연신된 형태로 분포함에 따라 제조 공정의 특성이 관찰된다.

Fig. 3은 S31803 DSS의 XRD 패턴을 나타낸 것이며,




Fig. 3. XRD pattern for S31803 duplex stainless steel

페라이트와 오스테나이트 상으로 구성된 전형적인 이중상 미세조직의 피크가 명확하게 관찰되었다. 약 43.3°와 50.4°에서 관찰되는 주요 회절 피크는 $\gamma(111)$, $\gamma(200)$, 그리고 $\gamma(220)$ 면에 해당한다. 약 44.7° 그리고 74.1° 부근의 피크는 $\alpha(110)$ 면과 $\alpha(211)$ 면에 기인한 것이다 [23].

3.2 동전위 분극곡선

ANN 모델에서 입력변수와 출력값 간의 상관관계를 파악하기 위해, 입력변수에 따른 출력값의 변동 특성을 분석할 필요가 있다. 이에 본 연구에서는 온도, 염도, 그리고 pH가 전기화학적 거동에 미치는 영향을 확인하기 위해 변수별 분극곡선의 특징을 비교·분석하였다. Fig. 4a는 염도 20 g/L과 pH 6 조건에서 온도 수준에 따른 분극 곡선을 나타낸 것이다. 온도가 상승함에 따라 전위 전 영역에 걸쳐 전류밀도는 점진적으로 증가하는 경향을 나타냈다. 이는 전기화학 반응 속도의 온도 의존적 증가를 의미한다. 더욱이, 온도 90 °C(no. 21) 조건은




Fig. 4. Experimental and ANN model predicted polarization curves for some training data sets. These conditions are included in Table 3

일정 전위 이상에서 전류밀도가 급격히 증가하는 공식 전위(pitting potential)가 관찰되었다. 해당 거동은 고온 조건에서 부동태피막의 안정성이 저하되거나 전기화학 반응 지배 메커니즘이 전환된다는 것을 의미한다.

Fig. 4b는 온도 30 °C와 pH 6 조건에서 염도 수준에 따른 동전위 분극곡선을 나타낸 것이다. 염도 수준에 따라 부식 전위 및 전류밀도는 명확한 차이를 나타냈다. 염도가 증가함에 따라 부식전위는 점진적으로 비전위 방향으로 이동하고, 각 분극전위에서 전류밀도가 증가하는 경향을 나타냈다. 또한, 양극 분극 영역에서 염도 40 g/L(no.9) 조건에서 준 안정 공식(metastable pit) 전류가 관찰되었는데, 이는 고농도 염화이온 환경에서 부동태 피막의 국부적 붕괴 후 부동태 회복이 발생하는 현상이다. Fig. 4c는 온도 30 °C 및 염도 20 g/L 조건에서 pH 변화에 따른 동전위 분극곡선을 나타낸 것이다. pH가 6(no.1)에서 4(no.2)로 감소함에 따라 부식 전위는 급격하게 활성 방향으로 이동하였으며, 이에 따라 부식전류 밀도가 매우 증가하는 경향을 나타냈다. 이러한 현상은 음극 구간에서 환원반응이 산소환원($O_2 + 2H_2O + 4e^- \rightarrow 4OH^-$)에서 수소발생($2H^+ + 2e^- \rightarrow H_2$) 반응으로 전환됨에 따른 반응속도 증가이다. 또한, pH 2(no.3) 조건에서는 가장 활성화된 부식 전위와 최대 부식전류밀도가 관찰되었다. 이는 높은 수소이온 농도로 인해 음극 수

소 발생 반응이 촉진되고, 양극활성 용해반응이 강화되었기 때문으로 판단된다.

3.3 입력변수 상관관계 분석

Fig. 5는 온도, 염도, pH, 과전압(overpotential, η) 및 해당 과전압에서 측정된 전류(current under overpotential, I_o) 간의 Pearson 상관관계를 나타낸다. Pearson 상관관계는 변수 간의 초기 관계를 파악하고, 이를 통해 ANN 모델의 입력 특성을 선정을 위한 분석단계이다.

분석 결과, 분극 전위는 분극전류와 가장 강한 상관관계(0.69)를 나타내어, 전기화학 반응 거동에 있어 지배적인 인자로 확인되었다. 또한, 온도는 분극전류와 중간 정도의 상관관계(0.44)를 보여, 온도상승에 따른 전기화학 반응 속도 증가가 분극 거동에 영향을 미치는 것으로 확인되었다. 반면, pH는 분극전류와 약한 음의 상관관계(-0.15)를 나타내어, pH가 감소할수록 전기화학적 반응이 가속되는 경향이 나타났으나, 단독 변수로서 영향은 분극전위, 온도 대비 제한적으로 확인되었다. 염도는 분극전류와 상관계수가(0.02) 매우 낮게 나타났다. 이에 따라 단일 인자로써 분극전류에 미치는 영향은 거의 없는 것으로 확인되었다. 반면, Fig. 4c에서 염도 조건에 따른 분극곡선의 차이가 확인됨에 따라 다른 변수들과의 복합 상호작용이 나타날 가능성이 있다. 본 결




Fig. 5. Heat-map for correlation coefficients between factors and polarization current




Fig. 6. R^2 values of ANN models with single and double hidden layers using the tanh activation function for different numbers of nodes. (b) Training and validation loss versus epoch

과는 단일 변수 기반의 선형 해석으로 분극 거동을 충분히 설명할 수 없다는 점을 의미하며, 비선형적이고 교호작용(interaction effect)을 고려할 수 있는 ANN 모델의 적합성을 나타냈다.

3.4 ANN 모델구조 최적화

Fig. 6a는 은닉층 구조 및 노드 수에 따른 ANN 모델 학습에 대한 결정계수(coefficient of determination, R^2) 변화를 나타낸다. 단일 은닉층에 대해 이중 은닉층 구조에서 전반적으로 높은 결정계수가 산출되어 우수한 학습 성능을 보였다. 특히, 이중 은닉층 구조에서 노드 수가 30일 때 0.993의 가장 높은 결정계수가 산출되었으며, 이후 노드 수 증가에 따른 결정계수의 추가적인 향상은 제한적으로 나타났다.

따라서, ANN 모델의 최적 구조는 4-30-30-1로 설정하였다. Fig. 6b는 4-30-30-1 구조를 가진 ANN 모델의 학습횟수(epoch)에 따른 학습 데이터와 검증 데이터의 MSE 변화를 나타낸다. 학습 초기 단계에서 MSE는 epoch가 증가에 따라 급격하게 감소하여, 약 100 epoch에서 0.05수준에 도달하였다. 이후 구간에서는 MSE가 점진적으로 감소하는 경향을 보였으며, 추가적인 학습에 따른 오차 감소는 상대적으로 제한적으로 나타났다. 이는 100 epoch 이후 모델의 성능 향상이 제한적이고, 과적합(overfitting)이 발생할 수 있다는 것을 의미한다 [24,25]. 따라서, 본 연구에서는 해당 결과를 통해 최적 epoch 수를 100회로 설정하고 학습을 수행하였다.

3.5 ANN 모델 성능

Fig. 7은 Table 3의 학습 조건에서 획득한 실험 분극

곡선과 학습된 ANN 모델을 통해 예측된 분극곡선을 일부 비교한 것이다.

모든 조건에서 ANN에 의해 예측된 분극곡선은 실험 결과와 전반적으로 높은 일치도를 나타냈으며, OCP, 활성영역, 고전위 영역을 포함한 주요 전기화학적 특성이 높은 적합도를 나타냈다. 이는 학습된 ANN 모델이 분극 거동의 비선형적 특성을 효과적으로 학습하고, 다양한 환경조건에 대해 신뢰성 있는 예측에 대한 가능성을 의미한다. 그러나, Fig. 7b의 준 안정 공식특성과 같은 국부적이고 미세한 전류 변동 특성은 도출되지 않았다. 준안정 국부 부식 거동은 표면 미세결함, 국부적 화학 조성 등에 의해 발생하는 확률적 현상으로, 동일 조건에서 발생 시점과 크기의 재현성이 낮다. 따라서, 평균적 거동을 학습하는 데이터 기반 모델에서 확률적 현상에 대한 재현은 구조적 한계를 가진다. ANN 모델이 더욱 깊은 은닉층, 증가한 노드 수의 복잡한 구조를 가지고, 매우 높은 학습횟수가 적용된다면, 해당 영역에 대한 학습이 가능할 것으로 판단된다. 그러나, 본 연구에서는 과적합 문제를 방지하기 위해 모델에 대한 구조 변경은 수행하지 않았다.

Fig. 8은 log(i) 실측값과 예측값 간의 일치도를 나타낸 것이다. ANN 모델은 학습, 검증, 시험 데이터에 대해 각각 0.993, 0.987, 0.987의 R^2 값을 나타내며, 실험 데이터와 매우 우수한 적합성을 나타냈다. 대부분의 데이터 포인트는 $Y=T$ 기준선에 가깝게 분포하며, 매우 높은 적합성을 나타냈다.

그러나, $10^{-10} \sim 10^{-7} \text{ A/cm}^2$ 전류밀도 범위에서 데이터의 산포가 크게 나타나 상대적으로 적합성이 낮게 나오는 경향이 있다.




Fig. 7. Comparison between experimental and ANN model-predicted polarization curves for training data sets under conditions listed in Table. 3




Fig. 8. Comparison between actual and ANN predicted $\log(i)$ values for the training (18,823 plots) validation (2,092 plots), and test (2,324 plots) with a total of 23,239 plots




Fig. 9. Distribution of training data samples and summed current density with a current range

3.6 데이터 분포에 따른 오차분석

Fig. 9는 전류 구간별 데이터 분포 특성 분석 결과를 나타낸 것이다. 전류밀도 분포는 $10^{-6} \sim 10^{-5} \text{ A/cm}^2$ 구간에 집중되어 있고, 데이터 출력값의 합은 10^{-2} A/cm^2 범위에서 상대 구간 대비 매우 큰 값을 나타냈다. ANN

모델은 표본 수와 개별 표본의 오차 크기에 큰 영향을 받는다 [26]. ANN 학습 과정에서, 표본 수가 많은 $10^{-6} \sim 10^{-5} \text{ A/cm}^2$ 구간에 학습이 집중되어 반복 학습 효과가 크게 나타났으며, 10^{-2} A/cm^2 구간은 상대적으로 적은 표본 수에도 불구하고 큰 전류값으로 인해 개별 오차 기여도가 크게 나타났다. 반면, $10^{-10} \sim 10^{-7} \text{ A/cm}^2$ 범위의 저 전류 영역에서는 타 영역보다 표본 수와 오차 크기가 매우 작아서, 전체 학습에 미치는 영향이 상대적으로 제한적이었다. 따라서, 데이터의 분포 특성으로 인해 해당 영역에서 편차가 비교적 크게 나타난 것 판단된다.

3.7 미학습 조건에 대한 예측 성능

Fig. 10은 ANN 모델의 학습 과정에서 제공되지 않은 새로운 인자 수준에 대한 분극 거동의 예측 성능을 평가하기 위한 실험결과이다. 전체적으로 예측 곡선은 실험 곡선의 주요 특성을 잘 반영하고 있다. 특히 공식 개시 전위 부근에서의 거동은 실험결과와 유사한 양상을 나타냈다. 이는 ANN 모델이 단순한 데이터 학습을 통한 패턴 적합을 넘어 분극 거동의 전반적인 경향이 학

습된 결과로 판단된다. 반면, 일부 조건에서 국부적인 편차가 관찰되었으나, 전기화학 분극시험의 비선형 특성을 고려할 때 불가피한 요소로 판단된다. 본 연구에서 사용된 데이터는 27개의 인자 조합 범위에 국한되어 있다. 따라서, 향후 다양한 조건에서 데이터 확장에 의한 모델 재현성과 예측 신뢰성은 더욱 향상될 수 있을 것으로 판단된다.

4. 결론

본 연구에서는 해양환경 조건에서 S31803 듀플렉스 스테인리스강의 동전위 분극 거동을 예측하기 위한 ANN 기반 모델을 적용하였다. 온도, 염도 및 pH를 변수로 하는 완전 요인 실험 설계를 통해 분극곡선 데이터를 획득하고, 이를 기반으로 ANN 모델에 대한 학습을 수행하였다.

분극시험 결과, 온도와 인가전위는 분극전류와 높은 상관관계를 나타내어 주요 지배 인자로 확인되었으며, pH 감소에 따라 부식 활성화 거동이 강화되는 경향이




Fig. 10. Comparison between experimental and ANN model-predicted polarization curves for conditions not-listed in Table. 3

관찰되었다. 최적화된 ANN 모델은 학습, 검증 및 시험 데이터에 대해 모두 0.98 이상의 결정계수를 나타내어 우수한 적합 성능을 나타내었다. 또한, 학습 과정에서 제공되지 않은 조건에 대한 예측 분극곡선은 실험 결과와 상당한 적합도를 나타내며, 주요 전기화학적 특성을 재현하였다.

본 연구에서 제안한 ANN 기반 예측 모델은 다양한 해양환경 조건에서 DSS의 부식 거동을 효율적으로 예측할 수 있는 도구로서, 해양 설비의 부식 관리 및 상태 진단 분야에 활용될 수 있을 것으로 기대된다.

감사의 글

본 과제(결과물)은 교육부와 전라남도의 재원으로 지원을 받아 수행된 지역혁신중심 대학지원체계(RISE) 연구결과입니다.

References

1. H. P. Kim and D. J. Kim, Intergranular corrosion of stainless steel, *Corrosion Science and Technology*, **17**, 183 (2018). Doi: <https://doi.org/10.14773/CST.2018.17.4.183>
2. S. T. Kim, K. H. Kong, I. S. Lee, Y. S. Park, J. H. Lee, and D. H. Kim, Investigation of the pitting corrosion behavior between the constituent phases in F53 super duplex stainless steel in acidified chloride environments, *Corrosion Science and Technology*, **13**, 95 (2014). Doi: <https://doi.org/10.14773/cst.2014.13.3.95>
3. G. Li, M. Du, J. Wang, G. Huang, and L. Ma, Effect of hydrogen on pitting corrosion of 2205 duplex stainless steel under alternating dry/wet marine environment, *International Journal of Hydrogen Energy*, **48**, 17983 (2023). Doi: <https://doi.org/10.1016/j.ijhydene.2023.08.078>
4. S. P. Kim and H. C. Choe, Corrosion characteristics of titanium for dental implant with surface modifications, *Corrosion Science and Technology*, **24**, 281 (2025). Doi: <https://doi.org/10.14773/cst.2025.24.4.281>
5. J. Kim and C. Jeong, A study on the surface properties and corrosion behavior of functional aluminum 3003 alloy using anodization method, *Corrosion Science and Technology*, **21**, 290 (2022). Doi: <https://doi.org/10.14773/cst.2022.21.4.290>
6. C. Jeong, B. S. Kong, J. Chen, Q. Xiao, and C. Jang, The effect of microstructure of an advanced duplex stainless steel on the pitting corrosion and chloride-induced stress corrosion cracking resistance, *Corrosion Science*, **240**, 112489 (2024). Doi: <https://doi.org/10.1016/j.corsci.2024.112489>
7. H. Y. Ha, M. H. Jang, T. H. Lee, and J. Moon, Interpretation of the relation between ferrite fraction and pitting corrosion resistance of commercial 2205 duplex stainless steel, *Corrosion Science*, **89**, 154 (2014). Doi: <https://doi.org/10.1016/j.corsci.2014.01.036>
8. Y. J. Jeong, M. Kim, J. Seo, J. H. Lee, H. J. Jang, and H. S. Kim, Machine learning-based analysis of environmental effects on the corrosion of AA1100 alloy, *Corrosion Science and Technology*, **24**, 269 (2025). Doi: <https://doi.org/10.14773/cst.2025.24.4.269>
9. K. H. Jung and S. J. Kim, An investigation on application of experimental design and linear regression technique to predict pitting potential of stainless steel, *Corrosion Science and Technology*, **20**, 52 (2021). Doi: <https://doi.org/10.14773/cst.2021.20.2.52>
10. M. Hajeeh, Estimating corrosion: a statistical approach, *Materials & Design*, **24**, 509 (2003). Doi: [https://doi.org/10.1016/S0261-3069\(03\)00110-9](https://doi.org/10.1016/S0261-3069(03)00110-9)
11. W. Xie, W. Jia, L. Mou, X. Wu, and Y. Liu, Big data-driven quantitative analysis of influencing factors importance for internal corrosion in sour gas pipelines, *Process Safety and Environmental Protection*, **200**, 107432 (2025). Doi: <https://doi.org/10.1016/j.psep.2025.107432>
12. L. B. Coelho, D. Zhang, Y. Van Ingelgem, D. Steckelmacher, A. Nowé, and H. Terryn, Reviewing machine learning of corrosion prediction in a data-oriented perspective, *npj Materials Degradation*, **6**, 8 (2022). Doi: <https://doi.org/10.1038/s41529-022-00284-8>
13. M. Akrom, S. Rustad, T. Sutojo, D. R. I. M. Setiadi, H. K. Dipojono, R. Maezono, and M. Solomon, Quantum machine learning for corrosion resistance in stainless steel, *Materials Today Quantum*, **3**, 100013 (2024). Doi: <https://doi.org/10.1016/j.mtquan.2024.100013>
14. J. S. Almeida, Predictive non-linear modeling of complex data by artificial neural networks, *Current Opinion in Biotechnology*, **13**, 72 (2002). Doi: [https://doi.org/10.1016/S0958-1669\(02\)00288-4](https://doi.org/10.1016/S0958-1669(02)00288-4)
15. P. Rothman, Forecasting asymmetric unemployment rates, *Review of Economics and Statistics*, **80**, 164 (1998). Doi: <https://doi.org/10.1162/003465398557276>
16. M. J. Jiménez-Come, E. Muñoz, R. García, V. Matres, M. L. Martín, F. Trujillo, and I. Turias, Pitting corrosion behaviour of austenitic stainless steel using artificial intelligence techniques, *Journal of Applied Logic*, **10**, 291 (2012). Doi: <https://doi.org/10.1016/j.jal.2012.07.005>
17. K. H. Jung and S. J. Kim, Statistical and ANN modeling of corrosion behavior of austenitic stainless steels in

- aqueous environments, *Materials*, **18**, 4390 (2025). Doi: <https://doi.org/10.3390/ma18184390>
18. H. Ji, H. Wang, Q. Chen, X. Ma, and Y. Cai, Corrosion behavior prediction for hull steels under dynamic marine environments by jointly utilizing LSTM network and PSO-RF model, *Ocean Engineering*, **300**, 117371 (2024). Doi: <https://doi.org/10.1016/j.oceaneng.2024.117371>
 19. H. S. Heo, H. K. Hwang, D. H. Shin, and S. J. Kim, Effect of seawater concentration on electrochemical corrosion of duplex stainless steel, *Corrosion Science and Technology*, **23**, 255 (2024). Doi: <https://doi.org/10.14773/cst.2024.23.4.255>
 20. S. T. Daqamseh, A. K. Al-Fugara, B. Pradhan, A. Al-Oraiqat, and M. Habib, MODIS derived sea surface salinity, temperature, and chlorophyll-a data for potential fish zone mapping: West Red Sea coastal areas, Saudi Arabia, *Sensors*, **19**, 2069 (2019). Doi: <https://doi.org/10.3390/s19092069>
 21. T. De Ryck, S. Lanthaler, and S. Mishra, On the approximation of functions by tanh neural networks, *Neural Networks*, **143**, 732 (2021). Doi: <https://doi.org/10.1016/j.neunet.2021.08.006>
 22. M. S. Alhajeri, Y. M. Ren, F. Ou, F. Abdullah, and P. D. Christofides, Model predictive control of nonlinear processes using transfer learning-based recurrent neural networks, *Chemical Engineering Research and Design*, **205**, 1 (2024). Doi: <https://doi.org/10.1016/j.cherd.2024.04.003>
 23. Z. Yan, S. Shu, Y. Yang, and B. Du, Surface and electrochemical performance variations of 2205 duplex stainless steel in multistep surface processing, *ACS Omega*, **10**, 2450 (2025). Doi: <https://pubs.acs.org/doi/10.1021/acsomega.4c04805>
 24. B. Ghojogh and M. Crowley, The theory behind overfitting, cross validation, regularization, bagging, and boosting: tutorial, *arXiv preprint arXiv:1905.12787* (2019). Doi: <https://doi.org/10.48550/arXiv.1905.12787>
 25. T. Miseta, A. Fodor, and Á. Vathy-Fogarassy, Surpassing early stopping: a novel correlation-based stopping criterion for neural networks, *Neurocomputing*, **567**, 127028 (2024). Doi: <https://doi.org/10.1016/j.neucom.2023.127028>
 26. T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd ed., p. 220, Springer, New York (2009). Doi: <https://doi.org/10.1007/978-0-387-84858-7>