

# 디지털 트윈과 실측 전류 간 도메인 적응을 위한 부하 상태 분석 프레임워크 개발

김민규\*<sup>1</sup>, 카림 아킴 바요\*<sup>2</sup>, 손환민\*<sup>3</sup>, 허장욱\*\*

## Development of a Load Condition Analysis Framework for Domain Adaptation between Digital Twin and Measured Current

Min-Gyu Kim\*<sup>1</sup>, Akeem Bayo Kareem\*<sup>2</sup>, Hwan-Min Son\*<sup>3</sup>, and Jang-Wook Hur\*\*

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-대학ICT연구센터(ITRC)의 지원(IITP-2026-RS-2024-00438430, 기여율 40%)과 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-지역지능화혁신인재양성사업의 지원(IITP-2026-RS-2020-II201612, 기여율 40%)과 2026년도 경상북도 지역혁신중심 대학지원체계(RISE)-(특화산업 Scale-up, 기여율 20%)의 지원을 받아 수행된 결과입니다(2026-rise-15-105)

### 요약

본 연구는 샷블라스트 장비의 3상 유도전동기에서 발생하는 부하 변동을 전류 신호로 관측하고, MATLAB/Simulink 기반 디지털 트윈과 연계하여 부하 운전 상태를 분석하였다. 실측 부하율 레이블 부재를 고려해 디지털 트윈 시뮬레이션으로 부하율 0 - 120%의 참조 운전점을 구성하고, 정상 상태 전류 데이터를 기반으로 도메인 적응 분석을 수행하였다. Domain AUC, Silhouette 계수, Mean difference 비교 결과, DANN은 실제 데이터에서 가장 높은 Silhouette 계수(0.38)와 균형적인 Mean difference(0.69)를 보여 도메인 정렬과 클래스 구조 보존 측면에서 우수한 성능을 나타냈다. 또한 Soft ratio 기반 유사도 분석에서 40%에서 최대 유사도를 보여, Soft ratio가 부하 조건에 따른 유사도 민감도를 결정하는 핵심 파라미터임을 확인하였다.

### Abstract

This study investigates load variations in a three-phase induction motor of a shot-blast machine using current measurements integrated with a MATLAB/Simulink-based digital twin. Reference operating points for load ratios from 0 to 120% were generated via simulation, and domain adaptation was applied to steady-state current data to address the lack of load labels in real measurements. Using Domain AUC, Silhouette coefficient, and Mean difference, DANN shows the highest Silhouette value (0.38) with a balanced Mean difference (0.69), indicating superior domain alignment and class structure preservation. Additionally, similarity analysis identifies the soft ratio as a key parameter, with maximum similarity observed at 40%, highlighting its influence on similarity sensitivity across load conditions.

### Keywords

digital twin, domain adaptation, motor current signal, load state analysis, DANN, CORAL

\* 국립금오공과대학교 기계공학과(항공기계전자융합전공) · Received: Jan. 22, 2026, Revised: Feb. 09, 2026, Accepted: Feb. 11, 2026  
- ORCID<sup>1</sup>: <https://orcid.org/0009-0004-7205-163X> · Corresponding Author: Jang-Wook Hur  
- ORCID<sup>2</sup>: <https://orcid.org/0000-0003-3382-0382> · Dept. of Engineering, Kumoh National Institute of Technology,  
- ORCID<sup>3</sup>: <https://orcid.org/0009-0007-0646-4489> · 61 Daehak-ro (yangho-dong), Gumi, Gyeongbuk, [39177] Korea  
\*\* 국립금오공과대학교 기계시스템공학부 교수(교신저자) · Tel.: +82-54-478-7399, Email: hhjw88@kumoh.ac.kr  
- ORCID: <https://orcid.org/0000-0002-4718-3540>

## I. 서 론

샷블라스트 공정은 고무 성형 부싱 생산 과정에서 금속 표면의 이물질을 제거하여 후속 접착 품질을 확보하기 위한 전처리 단계로, 소형 금속 부품을 회전시키며 샷볼을 분사해 균일한 표면 처리를 수행한다. 해당 장비는 유도전동기에 직결된 회전체를 포함하므로 장시간 운용에 따른 마모와 성능 저하가 불가피하며, 회전체 열화(불평형, 마찰 증가, 간극 변화 등)는 구동계 부하 변동으로 나타난다. 이러한 부하 변동은 전류 신호로 확인이 가능하며, 이는 가공 품질과 생산성 저하로 이어진다[1][2].

그러나 실제 현장에서는 공정 특성상 고장을 임의로 재현하기 어렵고 고장 데이터 확보에도 제약이 있어, 유지보수 판단이 작업자의 경험에 기반한 육안 점검이나 청음에 의존하는 한계가 있다[3][4].

따라서, 본 연구는 비침습적으로 취득 가능한 전류 신호를 상태 분석을 위한 주요 관측치로 선정하고, 디지털 트윈 모델 기반의 부하 운전 상태 해석 및 실측과 시뮬레이션 간 도메인 갭을 고려한 분석 프레임워크를 제안하였다. 즉, 그림 1과 같이 실제 장비에서 계측된 전류 시계열 데이터는 불규칙 운전 구간을 반영한 구간 단위로 분석되며, MATLAB/Simulink 환경에서 구현한 유도전동기 모델은 부하 조건별 시뮬레이션 데이터를 생성하여 참조 운전점 제공이 가능하다. 이후 DANN 및 CORAL 기반 도메인 적응 기법을 적용하여 시뮬레이션과 실측 데이터의 표현 공간을 정렬하고 운전점 간 유사도를 평가함으로써, 기존 신호 크기 중심 진단 방식에서 벗어난 디지털 트윈 연계 전류 기반 상태 분석 프레임워크 개발 방법을 제시하고자 한다.




그림 1. 디지털 트윈 모델 기반 모터의 상태분석 형상[5]  
Fig. 1. Schematic of digital twin model-based motor state analysis[5]

## II. 실제 장비와 디지털 트윈 모델

### 2.1 샷블라스트 장비 및 모터 구동

샷블라스트의 구성과 분사 원리를 그림 2에 나타내었다. 장비 내부에서 샷볼은 공급부를 통해 임펠러로 유입된 뒤, 회전하는 블레이드의 원심력에 의해 디스트리뷰터를 거쳐 가공 영역으로 분사된다. 분사된 샷볼은 금속 표면과 반복적으로 충돌하며 산화물과 이물질을 제거하고, 표면 상태를 변화시킨다. 이러한 분사 특성은 임펠러, 블레이드, 디스트리뷰터 등 회전체 구성품의 형상과 동작 상태에 의해 좌우되며, 구성품의 마모나 손상은 분사 균일성과 표면 처리 특성에 영향을 미친다.

공정 적용 전·후 금속 시편의 표면 처리 결과는 그림 3과 같으며, 공정 이후 이물질 제거와 표면 거칠기 변화가 확인된다. 또한, 실제 설비에서는 제품 변동과 무관하게 모터 평균 토크가 일정하게 유지되므로 관측되는 부하 변동은 주로 회전체 구성품의 열화에 기인한다. 장비 매뉴얼[6]에서도 블레이드, 컨트롤 게이트, 디스트리뷰터의 열화가 표면 처리 재현성을 저하시킬 수 있음을 언급하나, 현장 특성상 고장 시 정량적 데이터 확보에는 제약이 있다.




그림 2. 샷블라스트 장비의 기술 도면[7]

Fig. 2. Shotblast equipment and technical drawing[7]



그림 3. 샷블라스트를 이용한 금속 시편 표면처리 전·후  
Fig. 3. Metal surface before & after shot blasting

## 2.2 디지털 트윈 모델(MATLAB)


Matlab/simulink 환경에서 구축한 유도전동기 기반 디지털 트윈 모델의 구성을 그림 4와 같이 나타내었다. 모델은 전기적 구동부와 기계적 부하부로 구성되며, 내부 파라미터는 표 1과 같이 설정하였다. 여기에는 정격전력( $P_n$ ), 정격전압( $V_n$ ), 주파수( $f_n$ ), 극수( $p$ ), 고정자 및 회전자 저항( $R_s \cdot R_r$ ), 누설 인덕터스( $L_{ls} \cdot L_{lr}$ ), 자화 인덕터스( $L_m$ ), 관성 모멘트( $J$ ), 점성 마찰계수( $F$ ) 등의 전기적 파라미터들이 포함된다.

표 1. 유도전동기 내부 파라미터 설정값  
Table 1. Internal parameter settings of the induction motor


Parameter	Symbol	Value	Unit
Rated power	$P_n$	746x11	VA
Rated voltage/frequency	$V_n/f_n$	220/60	V/Hz
Number of poles	$p$	4	-
Stator resistance	$R_s$	0.02	$\Omega$
Rotor resistance	$R_r$	0.1	$\Omega$
Stator leakage inductance	$L_{ls}$	0.001	H
Rotor leakage inductance	$L_{lr}$	0.001	H
Magnetizing inductance	$L_m$	0.4	H
Moment of inertia	$J$	0.04	$kg \cdot m^2$
Viscous friction coefficient	$F$	0.02	$N \cdot m \cdot s$

모델의 정격 구간에서 시간 영역 응답은 그림 5(a)-(c)와 같으며, 기동 이후 정상상태로의 수렴을 통해 정격 조건에서의 안정적인 동특성을 확인할 수 있다. 또한, 샷블라스트 장비에서 발생 가능한 일시적 과부하를 고려하여[6], 무부하부터 정격 부하를 초과하는 120%까지 변화시킨 정상상태 응답 결과를 표 2에 나타내었다. 부하 증가에 따라 전자


기 토크( $T_e$ )는  $0.189N \cdot m$ 에서  $71.81N \cdot m$ 으로 증가하고, 슬립이 확대되면서 전자기 토크 전달이 증가하고 이에 따라 회전속도( $\tau$ )는 1,800 rpm에서 1745 rpm으로 감소한다. 또한, 전류( $I_{rms}$ )는 2.0 A에서 39.25 A로 증가하고 효율( $\eta$ )은 감소함을 보인다. 이러한 부하-슬립-전류 간의 상관관계는 실측 전류 기반 운전 상태 분류를 위한 대표 운전점 정의에 활용 가능하다.



(a) 전자기 토크( $T_e$ ) 파형  
(a) Electromagnetic torque( $T_e$ ) waveform



(b) 회전 속도( $\omega_m$ ) 파형  
(b) Rotational speed( $\omega_m$ ) waveform



(c) 실효값 전류( $I_{rms}$ ) 파형  
(c) RMS current( $I_{rms}$ ) waveform

그림 5. 유도전동기 시뮬레이션 모델의 측정 파형  
Fig. 5. waveforms of the induction motor model

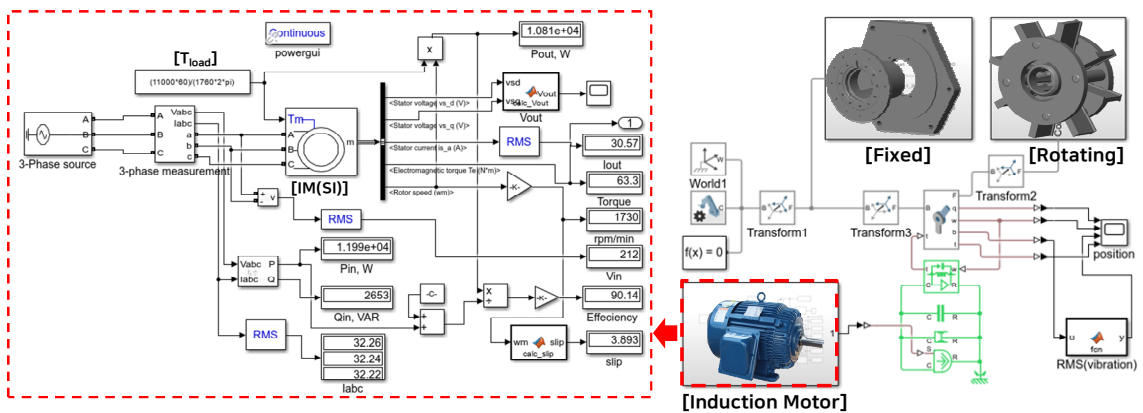


그림 4. 디지털 트윈 모델 구축(MATLAB/Simulink)  
Fig. 4. Development of the digital twin model(MATLAB/Simulink)

표 2. 부하단계별 시뮬레이션 결과

Table 2. Simulation results for different load levels

Load(%)	$I_{rms}$ [A]	$P_{out}$ [W]	$\eta$ [%]	slip[%]	$T_e$ [N*m]	$\tau$ [wrm]
0	2.0	-	-	0.7	0.189	1800
20	6.2	2240	96.70	43.9	12.12	1792
40	12.32	4460	95.74	89.6	24.06	1784
60	18.67	6657	94.19	138.2	36.00	1775
80	25.26	8829	92.44	190.1	47.93	1766
100	32.10	10970	90.54	246.0	59.87	1756
120	39.25	13090	88.52	306.6	71.81	1745

### III. 데이터 측정 및 도메인 적응 학습

#### 3.1 데이터 측정 및 전처리

HIOKI PW3360 전력분석기를 이용하여 3상 유도 전동기로 구동되는 샷블라스트 장비의 전기적 상태를 계측하였다. 연구에 적용한 모터 사양은 참고문헌 [8]에 제시된 환경과 동일하며, 전압은 악어 클립 방식으로, 전류는 비접촉식 클램프 센서를 사용하여 측정하였다. 선전류 RMS 값을 1초 간격으로 측정하였으며, 측정 환경은 그림 6에 나타내었다. 약 10일간 수집된 실측 전류 시계열 데이터는 그림 7과 같으며, 기동 및 정지의 반복과 운전 중 부하 변동에 따른 전류 변화 특성을 포함한다. 기동 시 정격( $I_{rated} = 40.2 \text{ A}$ ) 대비 6배를 초과하는 전류 구간은 과도 상태로 판단하여 분석에서 제외하였으며, 이에 따라  $0 < I \leq 6.0 \cdot I_{rated}$  범위의 데이터만을 정상 운전 상태로 정의하였다[9][10].




그림 6. 배전반 내 측정 환경구축[7]  
Fig. 6. Measurement configuration in MCCB[7]




그림 7. 실측 전류 데이터(시계열 단위)  
Fig. 7. Measurement motor current(time series)

본 연구에서 사용된 실측 데이터는 운전 조건에 대한 ground-truth 라벨을 포함하지 않으므로, 운전 상태 해석을 위해 전류  $I_{rms}$  기반의 구간화(Proxy label)를 적용하였다. 부하 구간은 디지털 트윈 모델 기반 정상 상태 결과를 참조하여 무부하부터 정격 부하를 초과하는 120%까지 20% 간격의 총 7개 해석적 구간으로 정의하였으며, 각 구간의 임계값은 시뮬레이션에서 도출된 단계별  $I_{rms}$  참조값을 기준으로 설정하였다. 비교를 위해 실측 전류 분포 기반 분위수(Quantile) 임계값 결과도 함께 산출하였다.

전처리된 실측 전류 데이터를 부하 구간별로 분류한 표본 분포를 그림 8에 나타내었으며, 특정 부하 구간에 표본이 집중되는 클래스 불균형이 확인되었다. 이에 따라 학습 단계에서는 부하 구간별 클래스 균형 샘플링을 적용하여 데이터 편향을 보정하였다. 전처리 결과, 하위 분위수 전류 값은 정상 운전 범위로 수렴하고, 상위 분위수 및 최대값에서는 비현실적인 전류 스파이크가 제거되어, 정격 전류 기반의 물리적으로 해석 가능한 전류 분포가 확보되었다. 이러한 전처리된 데이터는 이후 도메인 적응 학습 및 상태 해석에 활용하였다.

표 3. 데이터 전처리 및 전류 기반 부하 구간 정의  
Table 3. Data preprocessing and current-based intervals

Category	Description
Sampling unit	$1 \leq \text{RMS current time series}$
Filtering	$0 < I \leq 6.0 \cdot I_{rated}$
Rated current	40.2 A
Operating data	Idle and abnormal regions removed
Load intervals(%)	0-120 (20% step)
Interval thresholds	DT-based $I_{rms}$ thresholds
Imbalance handling	Load-wise balanced sampling




그림 8. 실측 데이터의 부하 구간별 표본 분포

Fig. 8. Real sample distribution by load interval

### 3.2 도메인 적응 학습

본 연구는 부하 기반 운전 상태 표현 공간에서의 도메인 적응 효과를 분석하기 위해 Source-only 기준선과 DANN, CORAL을 비교하였다. Source-only는 시뮬레이션(Source) 데이터에 대하여 특징 추출기와 운전 상태 예측기를 학습하고, 실측(Target) 데이터에는 추가적인 학습 없이 적용되는 기준선 모델이다. 이를 통해 도메인 정렬 기법을 적용하지 않은 경우의 기본적인 일반화 성능과 도메인 적응 기법에 따른 성능 향상을 정량적으로 비교·평가할 수 있다.

시뮬레이션 데이터셋  $D_s$ 와 실측 데이터셋  $D_t$ 를 각각 Source 도메인과 Target 도메인으로 식 (1)과 같이 구분할 수 있다. Source 도메인은 부하 수준에 의해 정의된 운전 상태에 대한 정답 클래스 레이블을 포함하는 반면, Target 도메인은 실측 입력 특징만으로 구성되며 운전 상태에 대한 정답 정보는 제공되지 않는다.  $D_s$ 에서  $y_i^s$ 는 각 샘플의 운전 상태 정답 클래스를,  $D_t$ 는 정답 레이블이 없는 입력 특징 벡터로 구성된다. 여기서,  $D_s, D_t$ 는 각각 가상 및 실측 데이터셋을 의미하며,  $x_i^s, x_j^t$ 는  $i$ 번째 가상 데이터와  $j$ 번째 실측 데이터의 특징 벡터를 나타낸다. 또한,  $y_i^s$ 는 가상의 운전 상태 레이블이며,  $n, m$ 은 각 데이터셋의 샘플 수,  $C$ 는 운전 상태 클래스의 개수를 의미한다.

$$D_s = (x_i^s, y_i^s)_{i=1}^n, y_i^s \in 1, \dots, C, D_t = (x_j^t)_{j=1}^m \quad (1)$$

입력 샘플  $x$ 로부터 특징 추출, 운전 상태 예측, 그리고 도메인 판별을 수행하는 공통 모델 구조를 식 (2)와 같이 정의할 수 있다. 입력  $x$ 는 특징 추출기  $G_f$ 를 통해 잠재 특징  $f$ 로 변환되며, 해당 특징

은 상태 예측기  $G_y$ 를 통해 예측된 운전 상태 클래스  $\hat{y}$ 를 산출하고, 동시에 도메인 분류기  $G_d$ 를 통해 도메인 예측결과  $\hat{d}$ 를 출력하는 데 사용한다.

여기서  $G_f$ 는 입력 데이터의 특징을 추출하고,  $G_y$ 는 상태 클래스를 예측하며,  $G_d$ 는 도메인을 판별한다. 또한  $\hat{y}$ 는 예측된 상태 클래스 레이블,  $\hat{d}$ 는 도메인 레이블로서 가상은 0, 실측은 1로 구분된다.

$$f = G_f(x; \theta_f), \hat{y} = G_y(f; \theta_y), \hat{d} = G_d(f; \theta_d) \quad (2)$$

Source-only 기준선에서는 시뮬레이션 데이터셋  $D_s$ 만을 사용하여 특징 추출기  $G_f$ 와 운전 상태 예측기  $G_y$ 를 학습하고, Source 분류 손실  $L_{src}$ 를 최소화한다. 이 과정에는 Target 데이터나 도메인 정렬 항이 포함되지 않으며, 도메인 적응 기법 적용 전 성능 비교를 위한 기준선으로 사용된다. 여기서  $L_{src}$ 는 가상 분류 손실,  $L_y$ 는 상태 분류 손실을 의미한다.

$$L_{src} = \frac{1}{n} \sum_{i=1}^n L_y(G_y(G_f(x_i^s)), y_i^s) \quad (3)$$

Source-only 학습 이후, 고정된 특징 추출기  $G_f$ 를 이용하여 실측(Target) 입력  $x_j^t$ 를 식 (4)와 같이 특징 임베딩  $f_j^t$ 로 변환한다. 이후 운전 상태 예측기  $G_y$ 는 임베딩에 대한 클래스(k)별 예측 확률을 산출하며, 이 중 softmax 출력의 최대값을 식 (5)와 같이 예측 신뢰도  $c_j^t$ 로 정의한다. 예측 신뢰도는 실측 데이터에 대한 모델 예측의 확실성을 나타내며, 이후 pseudo-label 생성 시 신뢰도 기반 샘플 선택 기준으로 활용된다.

$$f_j^t = G_f(x_j^t) \quad (4)$$

$$c_j^t = \max_k \text{softmax}(G_y(f_j^t))_k \quad (5)$$

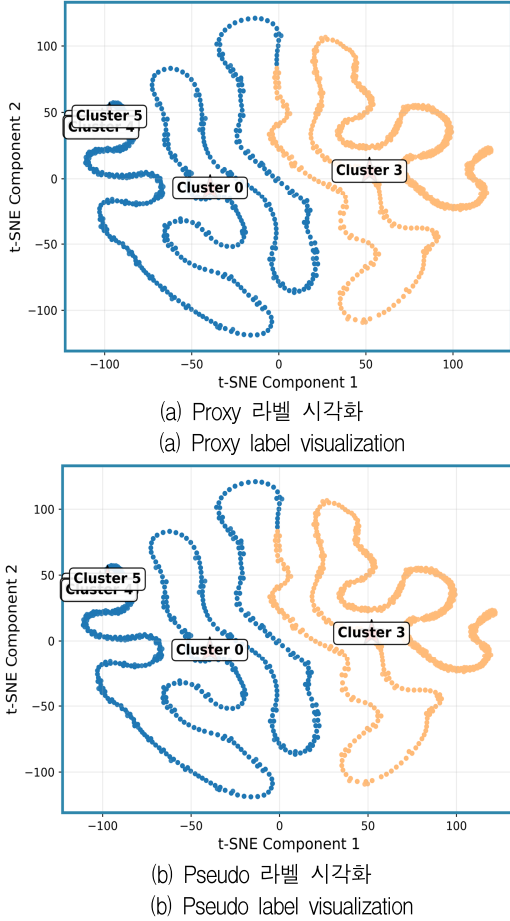


그림 9. 실측 특징 임베딩의 t-SNE(Source-only)  
Fig. 9. t-SNE of real embeddings(Source-only)

Source-only 기준선 학습 이후, 실측(Target) 데이터에 대한 추가적인 도메인 적응 효과를 분석하기 위해 모델 예측 결과를 기반으로 pseudo-label을 생성하였다. 정의된 Target 도메인 특징 임베딩  $f_j^t$ 에 대해, 예측기  $G_y(\cdot)$ 는 클래스별 예측 확률 분포를 산출하며, 이 중 최대 확률값을 해당 샘플의 예측 신뢰도  $c_j^t$ 로 정의하였다. Pseudo-label은 예측 신뢰도가 사전에 설정한 임계값 이상인 샘플에 대해서만 부여하였으며, 낮은 신뢰도의 예측 결과는 오류 방지를 위해 제외하였다. 또한 클래스 편향을 완화하기 위해 클래스별 예측 샘플 수를 제한하여 균형적으로 선택했으며, 선택된 pseudo-label 샘플은 이후 self-training 및 도메인 적응 학습에 활용하였다.

t-SNE 결과는 그림 9의 t-SNE 결과에서 실측 특징 임베딩은 진류 기반 proxy-label과 pseudo-label 기준 모

두에서 유사한 군집을 형성하나, 인접 부하 구간에서는 군집 중첩과 예측 불일치가 나타나 Source-only 환경에서의 도메인 갭이 확인된다.

표 4는 본 연구에서 사용한 모델의 구현 세부 설정을 나타낸다. 모든 모델은 동일한 기본 네트워크 구조를 공유하며, 특징 추출기, 운전 상태 예측기, 그리고 DANN에 적용된 도메인 판별기의 레이어 구성과 차원을 명시하였다. 학습에는 Adam 옵티마이저를 사용하고, 본 학습과 pseudo-label 기반 미세 조정을 위해 서로 다른 학습률을 적용하였다. 또한, 동일한 하이퍼파라미터(batch size, epochs, gradient clipping) 설정과 손실 가중치( $\lambda_{\text{domain}}$ ,  $\lambda_{\text{coral}}$ )를 적용하고, 난수 시드 기반 반복 실험을 수행하여 결과를 평균 및 표준편차로 나타내었다.

표 4. 도메인 적응 모델의 구현 및 학습 설정  
Table 4. Training settings for domain adaptation models

Category	Setting
Network architecture	$G_x$ : FC(1 $\rightarrow$ 64 $\rightarrow$ 128) + ReLU $G_y$ : FC(128 $\rightarrow$ 7) $G_d$ (DANN) : FC(128 $\rightarrow$ 6 $\rightarrow$ 2) + GRL
Training	Adam optimizer, LR = $3 \times 10^{-4}$ (main) batch 1024, epochs 10 gradient clipping 5.0
Loss weights	$\lambda_{\text{domain}} = 0.10$ (DANN) $\lambda_{\text{coral}} = 1.0$ (CORAL)
Reproducibility	Random seeds {42, 43, 44, 45, 46} results reported : mean $\pm$ std

DANN은 적대적 학습으로 특징 공간에서 Source와 Target 간 특징 분포 차이를 완화하기 위해 분류 손실과 도메인 분류 손실을 함께 고려하는 학습 구조를 갖는다[11]. 이 중 분류 손실  $L_y$ 는 식 (6)과 같이 시뮬레이션(Source) 데이터에 대해 예측된 운전 상태와 정답 간의 오차를 최소화하며, 특징 추출기  $G_f$ 와 예측기  $G_y$ 가 운전 상태 구분에 유효한 특징을 학습하도록 유도한다.

$$L_y = \frac{1}{n} \sum_{i=1}^n L_y(G_y(G_f(x_i^s)), y_i^s) \quad (6)$$

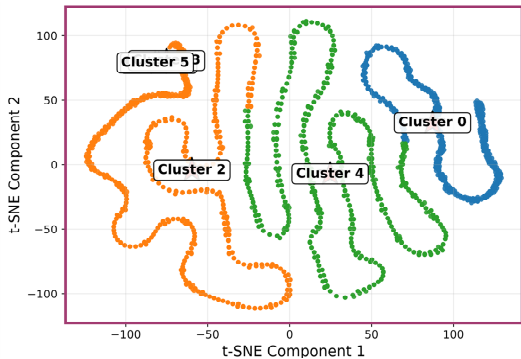
도메인 분류 손실  $L_d$ 는 식 (7)과 같이 정의되며, 특징 공간에서 Source와 Target 데이터의 도메인 구분 성능을 학습한다. 여기서, 도메인 분류기  $G_d$ 는 Source 특

징과 target 특징을 각각 도메인 레이블 0과 1로 예측하도록 학습되며, 이로써, 도메인 분포 차를 반영한다. 여기서,  $L_d$ 는 도메인 분류 손실을 의미한다.


$$L_d = \frac{1}{n} \sum_{i=1}^n L_d(G_d(G_f(x_i^s)), 0) + \frac{1}{m} \sum_{j=1}^m L_d(G_d(G_f(x_j^t)), 1) \quad (7)$$

DANN의 목적함수는 식 (8)과 같이 분류 손실과 도메인 분류 손실을 결합한 형태로 정의된다. 분류 손실은 최소화하고, 도메인 분류 손실은 계수  $\lambda$ 에 의해 부호가 변환된 형태로 적용되어, 특징 추출기가 도메인 판별 정보를 제거한 도메인 불변 특징을 학습하도록 유도한다. 여기서,  $L_{DANN}$ 은 DANN의 목적 함수,  $\lambda$ 는 도메인 적응과 분류 성능 간 균형을 조절하는 가중치 파라미터를 의미한다.

$$L_{DANN} = L_y - \lambda L_d \quad (8)$$



(a) Proxy 라벨 시각화  
(a) Proxy label visualization



(b) Pseudo 라벨 시각화  
(b) Pseudo label visualization

그림 10. 실측 특징 임베딩의 t-SNE(DANN)  
Fig. 10. t-SNE of real embeddings(DANN)

그림 10의 t-SNE 결과에서 DANN으로 학습된 특징 추출기로부터 얻어진 실측 데이터의 잠재 특징 임베딩은 전류 기반 proxy 부하 구간에 따라 군집을 형성하며, 저부하에서 고부하로 이어지는 연속적인 배열을 보인다. Proxy-label과 pseudo-label 시각화 모두에서 유사한 공간적 분포가 유지되었고, 특히 중간 부하 영역에서 군집 경계가 보다 명확해져 도메인 정렬을 통한 부하 기반 특징 분리의 개선을 확인할 수 있다.

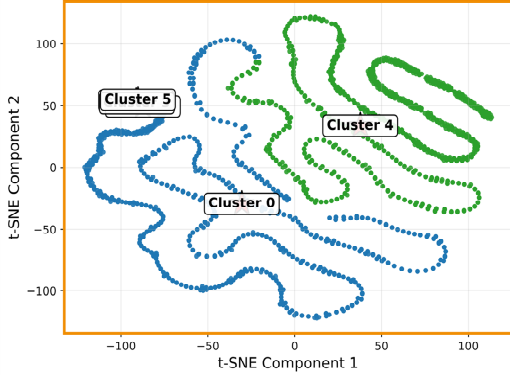
반면, CORAL은 시뮬레이션과 실측 데이터 간 특징 공분산을 정렬하는 통계적 접근을 통해 도메인 차이를 완화하는 방법으로, 적대적 학습이나 도메인 분류기를 사용하지 않는 단일 목적 함수 기반의 도메인 정렬 방법이다. 이를 통해 적대적 학습 기반 기법과 비교 가능한 분포 정렬 기준을 제공한다[12]. 특징 추출기( $G_f$ )로부터 얻어진 source( $G_f(x^s)$ ) 및 target( $G_f(x^t)$ ) 잠재 특징의 공분산 행렬 간 Frobenius norm 거리를 최소화하여, 미니배치 단위에서 도메인 간 특징 분포를 식 (9)와 같이 정렬한다.

여기서,  $G_f(x^s)$ ,  $G_f(x^t)$ 는 각각 가상데이터와 실측 데이터의 잠재적인 특성을 의미하며,  $Cov$ 는 미니배치 공분산,  $\|\cdot\|_F$ 은 Frobenius norm,  $L_{CORAL}$ 은 CORAL 기반 도메인 정렬 손실을 의미한다.

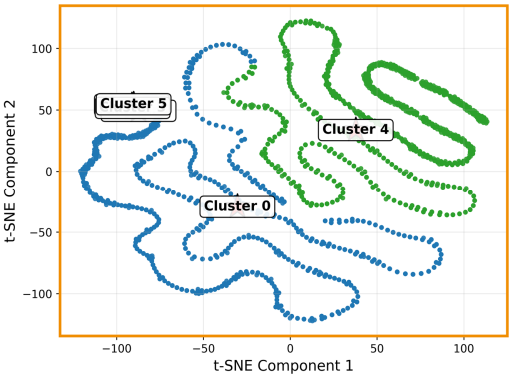
$$L_{CORAL} = \|Cov(G_f(x^s)) - Cov(G_f(x^t))\|_F^2 \quad (9)$$

CORAL 손실  $L_{CORAL}$ 은 특징 추출기와 운전 상태 예측기를 동시에 학습하면서, 분류 손실과 함께 최소화된다. 이를 통해 적대적 학습이나 도메인 분류기 없이도 Source와 Target 특징이 유사한 통계적 구조를 갖도록 유도하며, 분포 정렬 효과를 비교분석할 수 있는 비적대적 도메인 적응 기준을 제공한다.

그림 11의 t-SNE 결과에서 CORAL 적용 시 실측 데이터의 특징 임베딩은 전류 기반 proxy 라벨에 따라 저부하에서 고부하까지의 연속적인 군집 구조를 형성하며, 이는 공분산 정렬을 통한 도메인 간 특징 분포 정렬을 반영한다. Pseudo-label 기준에서도 유사한 분포가 유지되나, 일부 인접 부하 구간에서는 군집 경계가 완전히 분리되지 않는 한계가 관찰된다.



(a) Proxy 라벨 시각화  
(a) Proxy label visualization



(b) Pseudo 라벨 시각화  
(b) Pseudo label visualization

그림 11. 실측 특징 임베딩의 t-SNE(CORAL)  
Fig. 11. t-SNE of real embeddings(CORAL)

#### IV. 결과 및 고찰

본 연구는 도메인 적응 성능을 도메인 정렬, 클래스 구조 보존, 예측 안정성의 관점에서 평가하였다. 이 중 시뮬레이션 데이터와 실측 데이터 간의 도메인 정렬 정도는 Domain AUC를 이용하여 정량화하였다. 식 (10)에 나타난 Domain AUC는 feature 공간에서 두 도메인의 분리 가능성을 나타내는 지표로, 값이 0.5에 가까울수록 두 도메인의 분리도가 낮아 정렬 성능이 우수함을 의미한다. 여기서,  $P$ 는 확률,  $z$ 는 특징 추출기를 통해 얻은 특징 벡터,  $g$ 는 도메인 점수를 출력하는 도메인 분류기를 의미한다.

$$\text{Domain AUC} = P(g(z^{\text{REAL}}) > g(z^{\text{SIM}})) \quad (10)$$

다음으로, 도메인 정렬 과정에서 클래스 구조가 유지되는지를 평가하기 위해 Silhouette 계수를 사용하였다. 식 (11)에 나타난 Silhouette 값은 동일 클래스 내 응집도와 서로 다른 클래스 간 분리도를 동시에 반영하며, 값이 클수록 feature 공간에서 클래스 간 구조가 명확하게 유지됨을 의미한다[13]. 여기서,  $a(i)$ 는 동일 클래스 내 데이터들의 평균 거리,  $b(i)$ 는 최근접 클래스 내 평균 거리를 의미한다.

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}, \quad S = \frac{1}{N} \sum_{i=1}^N s(i) \quad (11)$$

마지막으로, 실제 데이터에 대한 예측의 안정성 평가를 위한 soft ratio를 도입하였다. 식 (12)와 같이 예측 신뢰도가 임계값 이상인 샘플의 비율로 정의되며, 이는 실제 환경에서 모델이 얼마나 일관되고 안정적인 예측을 수행하는지를 나타낸다. 여기서,  $N$ 은 실제 데이터 수,  $c_i$ 는  $i$ 번째 데이터의 예측 신뢰도,  $\tau$ 는 0.9로 설정된 신뢰도 임계값,  $1(\cdot)$ 은 지시 함수(Indicator function)를 의미한다.

$$\text{soft ratio} = \frac{1}{N} \sum_{i=1}^N 1(c_i \geq \tau) \quad (12)$$

도메인 적응 성능을 도메인 정렬, 클래스 구조, 분포 차이의 관점에서 Domain AUC, Silhouette 계수, Mean difference의 정량 지표를 표 5에 나타내었다.

Source-only는 Domain AUC가 0.94로 높게 나타나 시뮬레이션과 실제 데이터가 feature 공간에서 쉽게 구분되었으며, Mean difference 또한 15.95로 커 도메인 간 분포 차이가 크게 유지됨을 확인하였다. 또한 실제 데이터 기준 Silhouette 계수는 -0.24로 나타나 클래스 구조가 충분히 형성되지 않았다.

반면 CORAL은 Domain AUC가 0.89로 감소하고 Mean difference가 0.63으로 감소하여 평균 기반 도메인 정렬이 수행되었음을 보여주었다. 실측 데이터의 Silhouette 계수 또한 0.33으로 양의 값을 나타내어 유의미한 클래스 구조가 형성됨을 확인하였다.

DANN은 Domain AUC가 0.92로 CORAL보다 높았으나, Silhouette 계수는 0.38로 가장 높게 나타나

실제 데이터에서의 클래스 분리도가 가장 우수하며, Mean difference는 0.69로 CORAL과 유사한 수준을 보여, 분포 정렬과 구조 형성을 동시에 달성함을 확인하였다. 종합적으로, CORAL은 분포 평균 정렬에 강점을 보이며, DANN은 도메인 정렬과 클래스 구조 보존 측면에서 상대적으로 우수함을 나타냈다.

또한, Soft ratio (0-120%) 변화에 따른 Soft-weighted similarity 비교 결과를 그림 12에 나타내었으며, 0%에서는 Source-only와 DANN이 상대적으로 높은 유사도를 보인 반면 CORAL은 낮게 나타났으며, 40%에서는 DANN이 최대를 표시하고, 60%에서는 3가지 방법의 편차가 작아지는 경향을 보인다. 그리고, 80% 이상 구간에서는 Source-only가 상대적으로 높게 유지되는 반면 DANN은 감소, CORAL은 중간 수준에서 완만하게 변동하였다. 이는 Soft ratio가 유사도 평가의 민감도와 정렬 특성에 영향을 미치는 핵심 파라미터이며, 특히 DANN은 중간 수준(40%) 설정에서 유사도 이점이 두드러짐을 나타낸다. 따라서 부하 운전 상태 분류 및 유사도 분석 관점에서, 디지털 트윈과 실측 데이터 연계는 DANN 기반 도메인 적응이 현실적인 정렬 접근임을 실증적으로 확인하였다.

표 5. 도메인 적응 기법별 성능 비교  
Table 5. Performance of domain adaptation methods

Algorithm	Domain AUC	Silhouette(REAL)	Mean difference
Source-only	0.94 ± 0.05	-0.24 ± 0.03	15.95 ± 1.45
DANN	0.89 ± 0.03	0.33 ± 0.02	0.63 ± 0.13
CORAL	0.92 ± 0.04	0.38 ± 0.03	0.69 ± 0.09




그림 12. Soft ratio에 따른 실측 부하 유사도  
Fig. 12. Real load similarity versus soft ratio

## V. 결 론

샷블라스트 장비를 대상으로 3상 유도전동기에 대한 실측 전류 신호와 MATLAB/Simulink 기반 디지털

트윈을 연계하여, 실측에서 직접 관측이 어려운 부하 운전 상태 해석과 도메인 적응 기반 정렬-유사도 분석을 수행하였다. 연구 결과를 요약하면 아래와 같다.

첫째, 디지털 트윈 모델을 구축하고 부하율 0-120% 구간의 정상상태 응답을 참조 운전점으로 분석하여, 실측 전류 기반 부하 구간 해석 기준을 마련하였다.

둘째, 도메인 정렬, 클래스 구조, 분포 차이 관점에서 Source-only, CORAL, DANN을 비교한 결과, DANN은 Domain AUC 0.92로 CORAL보다 다소 높았으나, Silhouette 계수 0.38로 실제 데이터에서 가장 우수한 클래스 분리도를 보였고, Mean difference 0.69로 분포 정렬과 구조 형성을 균형적으로 달성하였다.

셋째, Soft ratio(0 - 120%)에 따른 유사도 분석에서 DANN은 중간 수준(40%)에서 최대 유사도를 나타냈으며, 고부하 구간에서는 방법 간 유사도 차이가 감소하는 경향을 보였다. 이는 Soft ratio가 유사도 평가 특성에 중요한 영향을 미치며, DANN이 중간 설정에서 상대적인 이점을 가짐을 의미한다.

넷째, 디지털 트윈과 실측 전류 데이터 연계 기반의 도메인 적응 접근이 샷블라스트 장비의 부하 상태 분석과 상태 진단 및 예측정비 적용에 효과적인 분석 프레임워크임을 제시한 것으로 판단된다.

다섯째, 향후 연구에서 추가적인 운전 조건과 다중 신호를 반영한 확장된 도메인 적응 모델을 통해, 제안된 프레임워크의 성능과 적용성을 고도화할 계획이다.

## References

- [1] M. A. Khan, S. Ahmed, and J. M. Kim, "Deep learning-based identification of shaft imbalance faults in rotating machinery", International Journal of Dynamics and Control, Vol. 13, No. 2, pp. 1-12, Apr. 2025. <https://doi.org/10.1007/s42417-025-01823-8>.
- [2] R. K. Patel and P. K. Kankar, "A review on vibration-based condition monitoring of rotating machinery", Applied Sciences, Vol. 12, No. 3, pp. 972, Jan. 2022. <https://doi.org/10.3390/app12030972>.
- [3] J. W. Oh, "Research on data augmentation and LCNN for bearing fault detection", Master's Thesis, Sungkyunkwan University, Feb. 2021.

- <https://doi.org/10.23185/skku.000000161077.11040.0010801>.
- [4] D. W. Kang, S. W. Kim, E. H. Kim, S. G. Noh, K. Lee, H. S. Ryoo, and Y. S. Jung, "Maintenance strategy of semiconductor equipment under limited data conditions: A survival analysis approach", *Korean Management Science Review*, Vol. 42, No. 2, pp. 33-45, Jun. 2025. <https://doi.org/10.7737/kmsr.2025.42.2.033>.
- [5] G. F. Lukman and C. Lee, "Towards Digital Twin Modeling and Applications for Permanent Magnet Synchronous Motors", *Energies*, Vol. 18, No. 4, pp. 956, Feb. 2025. <https://doi.org/10.3390/en18040956>.
- [6] SINTOKOGIO, LTD., Operation Manual: Apron Shot Blast M/C SB-1G, SINTOKOGIO, LTD., Jun. 2014.
- [7] M. G. Kim, Y. A. Jeong, and J. W. Hur, "Application of CBM+ to Shot-Blast Rotating Components Based on Current Signal", *Journal of the Korea Academia-Industrial cooperation Society*, pp. 956-964, Feb. 2026. <https://doi.org/10.5762/KAIS.2026.27.2.956>.
- [8] K. M. Gyu and H. J. Wook, "Fault Diagnosis and Prediction of Shot Blast Machinery Using FFT and Wavelet Analysis", *Proc. Symposium of the Korean Institute of communications and Information Sciences, Korea Institute Of Communication Sciences, Jeju, Korea*, pp. 767-768, Feb. 2025.
- [9] M. F. Yakhni, S. Cautet, A. Sakout, H. Assoum, E. Etien, L. Rambault, and M. El-Gohary, "Variable speed induction motors' fault detection based on transient motor current signatures analysis: A review", *Mechanical Systems and Signal Processing*, Vol. 184, No. 109737, Sep. 2023. <https://doi.org/10.1016/j.ymssp.2022.109737>.
- [10] R. Jaros, R. Byrtus, J. Dohnal, L. Danys, J. Baros, J. Koziorek, P. Zmij, and R. Martinek, "Advanced signal processing methods for condition monitoring", *Archives of Computational Methods in Engineering*, Vol. 30, pp. 1553-1577, Oct. 2022. <https://doi.org/10.1007/s11831-022-09834-4>.
- [11] Y. Ganin, E. Ustinova, H. Ajakan, P. Germain, H. Larochelle, F. Laviolette, M. Marchand and, V. Lempitsky, "Domain-Adversarial Training of Neural Networks", *Journal of Machine Learning Research*, Vol. 17, No. 59, pp. 1-35, May 2016. <https://doi.org/10.48550/arXiv.1505.07818>.
- [12] B. Sun, J. Feng, and K. Saenko, "Correlation Alignment for Unsupervised Domain Adaptation", *Proc. 30th Conf. on Neural Information Processing Systems (NeurIPS 2016)*, Barcelona, Spain, pp. 3765-3773, Dec. 2016. <https://doi.org/10.48550/arXiv.1612.01939>.
- [13] Y. J. Lee and Y. Sun, "Entity Matching Method of Knowledge Graphs using Graph Convolutional Network and Embedding Techniques", *The Journal of Korean Institute of Information Technology*, Vol. 21, No. 6, pp. 9-19, Jun. 2023. <http://dx.doi.org/10.14801/jkiit.2023.21.6.9>.


### 저자소개

김민규 (Min-Gyu Kim)



2025년 2월 : 국립금오공과대학교 전자공학부(학사)  
 2025년 3월 ~ 현재 :  
 국립금오공과대학교 기계공학과 (항공기계전자융합전공) 석사과정  
 관심분야 : 커버리지 경로 계획, CBM, Digital Twin

카림 아킴 바요 (Akeem Bayo Kareem)



2017년 2월 : 나이지리아 일로린대학교(University of Ilorin) 기계공학과(열유체 전공)(학사)  
 2023년 2월 : 국립금오공과대학교 기계공학과(석사)  
 2023년 3월 ~ 현재 :  
 국립금오공과대학교 기계공학과 박사과정  
 관심분야 : Digital Twin, 메타버스 기반 가상·증강현실, PHM

손 환 민 (Hwan-Min Son)



2026년 2월 : 국립금오공과대학교  
전자공학부(학사)  
2026년 3월 ~ 현재 :  
국립금오공과대학교 기계공학과  
(항공기계전자융합전공) 석사과정  
관심분야 : System Engineering,  
Digital Twin, CBM+

허 장 욱 (Jang-Wook Hur)



1995년 9월 : 일본 동경공대  
기계물리공학과(박사)  
2006년 1월 ~ 2011년 12월 :  
방위사업청 체계종합 총괄담당  
2012년 3월 ~ 2012년 8월 : 탄약사  
기술관리처장  
2012년 9월 ~ 현재 :  
국립금오공과대학교 기계시스템공학부 교수  
관심분야 : System Engineering, 신뢰성공학, RAM-C, CBM+