

# 전이학습 방법을 이용한 철도차량 추진용 배터리의 상태진단 방안 연구

권도훈, 나석진, 조인호<sup>†</sup>  
국립한국교통대학교 전력변환시스템

## Study on State Diagnosis of Railway Vehicle Propulsion Batteries Using Transfer Learning

Do-Hun Kwon, Seok-Jin Na, In-Ho Cho<sup>†</sup>  
Korea National University of Transportation, Power Conversion System Lab.

### ABSTRACT

배터리를 통해 추진하는 친환경 철도차량은 높은 효율과 안전성 확보를 위해 배터리의 상태를 진단하는 것이 중요하다. 모델 기반 상태진단 방법이나 임피던스 측정을 통한 기존의 상태진단 방법은 시간이 오래 걸리고 고가의 장비가 필요한 단점이 있다. 이러한 문제를 해결하기 위해 높은 정확도와 빠른 상태진단이 가능한 인공지능 기반 상태진단 방법이 최근 각광받고 있다. 하지만, 인공지능 방법을 적용한 상태진단을 위해 다량의 데이터가 요구되고, 친환경 철도차량은 데이터 수집 환경이 제한되어 있어 인공지능 기반 상태진단의 적용이 어려운 상황이다. 이에, 본 논문에서는 비교적 다량의 데이터가 공개되어 있는 전기자동차의 데이터를 친환경 철도차량에 적용한 전이학습 기반 상태진단 방법을 제안한다.

### 1. 서론

지구온난화가 가속화되면서 탄소중립과 같은 저탄소 정책이 대두되고 있다. 저탄소 정책 중 내연기관 퇴출과 같은 조건에 맞추어 자동차, 철도차량과 같은 모빌리티의 내연기관을 배터리 기반 추진시스템으로 변화시키는 추세이다. 배터리는 높은 에너지 밀도를 가진 리튬이온 배터리를 주로 사용하지만, 내부의 화학적인 반응으로 인해 화재가 발생할 위험이 존재하므로 상태진단을 통한 안전성 확보가 필요하다. 모델 기반의 상태진단 방법과 임피던스 측정과 같은 기존의 리튬이온 배터리 상태진단 방법은 시간이 오래 걸리고 초기용량에 따른 오차가 누적되며, 고가의 장비가 요구되는 단점이 있다.

이러한 단점을 해결하기 위해 인공지능을 통한 상태진단 방법의 연구가 최근 진행되고 있다.<sup>[1]</sup> 인공지능 기반 상태진단은 높은 정확도와 기존 상태진단 대비 빠른 진단 속도, 모빌리티 사용 중에도 배터리 팩의 진단이 가능한 장점이 있다. 하지만, 인공지능 기반의 방법을 통해 상태진단을 적용하기 위해서는 다양하고 데이터가 요구되는데, 철도차량 추진용 배터리의 데이터는 수집환경이 제한되어 있어 인공지능 기반 상태진단 방법의 적용에 어려움이 있다.

이에, 본 논문에서는 전이학습 방법을 이용하여 철도차량에 적용하는 방법을 제안한다. 전이학습에 필요한 사전학습 데이터는 배터리로 구동하는 모빌리티 중 가장 많이 공개되어 있는 EV의 주행 데이터를 선정하였다. 진단하고자 하는 철도차량의 상태 변수는 화재와 직접적인 연관이 있는 배터리 셀 온도 데

이터를 선정하였으며<sup>[2]</sup>, 상태진단에 사용하는 상태진단 모델은 Transformer를 사용하였다.

## 2. 전이학습 방법의 적용 방안

### 2.1 전이학습

전이학습은 어떠한 데이터를 통해 사전학습하여 진단하고자 하는 데이터에 맞게 모델을 조정하여 적용하는 방법으로, 사전학습과 미세 조정의 두 단계를 통해 진행된다.

#### 2.2.1 상태진단 모델 구성

철도차량에 전이학습을 방법을 통한 상태진단을 적용하기 위해 상태진단 모델을 구성해야 한다. 전압, 전류, 셀간 전압 표준편차를 입력 데이터로 설정하고, 배터리의 온도를 출력 데이터로 설정하여 상태진단을 진행하였다. 입·출력 데이터는 시간에 따라 변화하므로, 이러한 시계열 데이터를 다루는데 뛰어난 성능을 가진 Transformer를 통해 상태진단 모델을 구성하였다.<sup>[3]</sup> Transformer는 인코더와 디코더로 구성되는데, 전체적인 입력과 출력의 관계를 학습하기 용이한 인코더를 사용하였다. 그림 1은 상태진단 모델의 구조도를 나타낸 것이다.



그림 1 상태진단 모델 구조  
Fig. 1 Structure of state diagnosis model

#### 2.2.2 사전 학습(Pre-Training)

사전학습은 입력(전압, 전류, 셀간 전압 표준편차)과 출력(온도)간의 관계성을 사전에 학습하는 과정이다. 따라서, 전이학습을 적용할 플랫폼과 같은 특징을 가진 플랫폼의 데이터를 선정해야 한다. 본 논문에서는 친환경 철도차량의 상태진단에 전이학습 방법을 적용하기 위해 배터리로 구동하는 특징을 공유하는 EV의 주행 데이터를 사전학습 데이터로 선정하였다.

#### 2.2.3 미세 조정(Fine-Tuning)

미세 조정은 사전학습된 모델을 진단하려는 데이터에 맞추어 내부 파라미터를 조정하는 과정이다. 그림 2는 사전학습한 데이터와 진단하고자 하는 데이터의 유사도에 따라 모델의 내부 파라미터를 조정하는 과정을 나타낸 것이다. 정사각형 부분

은 조정이 불가하고, 원 부분은 조정이 가능하다. (a)는 데이터 간의 유사도가 높을 때의 조정 과정이고, (b)는 데이터 간의 유사도가 낮을 때의 조정 과정을 나타낸다. 따라서, 사전학습 데이터인 EV의 주행 데이터는 같은 철도차량 주행 데이터에 비해 진단하려는 데이터와의 유사도가 떨어지므로, (b)와 같은 과정으로 조정하는 것이 상태진단의 정확도를 높일 수 있다.




그림 2 데이터의 유사도에 따른 미세 조정 과정  
Fig. 2 Fine-tuning process according to data similarity

### 2.3 사전학습 및 진단 데이터 선정

사전학습 데이터는 5종류의 EV 테스트 주행 데이터(KD147, UDDS, US06, Highway, ASM2525)를 4세트씩 사용하였고, 상태를 진단할 데이터는 철도차량의 주행 데이터를 사용하였다. 그림 3은 선정한 입·출력 데이터를 상태진단 모델에 적용하기 위해 0과 1 사이의 값으로 정규화하여 그래프로 나타낸 것이다. (a)는 테스트 주행 데이터 중 KD147의 그래프이고, (b)는 철도차량 주행 데이터 중 1cycle만을 나타낸 그래프이다.




그림 3 주행 데이터 그래프  
Fig. 3 Driving data graph

## 3. 전이학습 방법을 적용한 상태진단 분석

### 3.1 실험 및 비교분석

전이학습의 효율성을 알아보기 위해 EV 데이터로 사전학습한 상태진단 모델을 그림 2의 (b)와 같은 과정을 통해 내부 파라미터를 조정 후 철도차량의 상태를 진단하였다. 비교 및 분석을 위하여 전이학습을 적용하지 않은 기본 상태진단 방법을 통해 철도차량의 상태를 진단하였다. 표 1에 사전학습과 미세 조정, 조정하지 않은 기본 상태진단 방법(Vanilla)에 적용한 하이퍼 파라미터를 나타내었다. 기본 상태진단 방법에 사용한 학습 데이터는 괄호 안에 표기하여 나타내었다.

표 1 하이퍼파라미터  
Table 1. Hyperparameter table

	batch	window	epochs
Pre-training	2048	20	200
Fine-tuning	2048	20	100
Vanilla(EV)	2048	20	200
Vanilla(Railway)	2048	20	100

원본 온도 데이터와 기본 상태진단 방법 및 전이학습의 상태진단 방법의 결과를 비교한 그래프를 그림 4를 통해 나타내

었고, 그에 따른 상태진단의 오차는 MAE(Mean Absolute Error)를 사용하여 표 2에 나타내었다. 오차 분석 결과, 전이학습 방법을 적용한 상태진단의 오차는 9%(0.056°C)로 두 기본 상태진단 방법 대비 낮은 오차를 기록하였다. Vanilla(EV)를 통한 상태진단 오차는 28% (0.17°C)로 전이학습 기반 상태진단 방법에 비해 높은 오차를 기록하였다. Vanilla(Railway)를 통한 상태진단 오차는 9.3% (0.057°C)로 전이학습 기반 상태진단 방법에 비해 약 0.3% 높은 오차를 기록하였다. 이를 통해, 전이학습을 통한 상태진단이 기본 상태진단 방법에 비해 더 정확하게 철도차량의 상태를 진단할 수 있음을 알 수 있다.




그림 4 온도 데이터 진단 그래프  
Fig. 4 Temperature diagnosis graph

표 2 상태진단 오차 표

Table 2. State diagnosis error table

	Vanilla (EV)	Vanilla (Railway)	Transfer Learning
MAE(%)	28%	9.3%	<b>9.0%</b>
MAE(°C)	0.17	0.057	<b>0.056</b>

## 4. 결론

본 논문에서는 EV 주행 데이터와 전이학습 방법을 기반으로 철도차량의 상태를 진단하는 방안을 제안하고, 이를 전이학습을 적용하지 않은 기본 상태진단 방법과 비교 및 분석하였다. 그 결과, 기본 상태진단 방법에 비해 전이학습 방법을 적용한 상태진단 방법이 더 낮은 오차를 기록하였다. 이를 통해, 제안한 상태진단 방법의 성능을 검증하였으며, 철도차량 외의 배터리로 추진하는 모빌리티의 상태진단에도 전이학습 방법을 적용할 경우, 기본 상태진단 모델을 통한 상태진단 대비 낮은 오차를 기대할 수 있을 것이다.

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No.RS-2023-00510755)

## 참고 문헌

- [1] Ram Machlev, EV battery fault diagnostics and prognostics using deep learning: Review, challenges & opportunities, Journal of Energy Storage, Volume 83, 2024, 110614, ISSN 2352-152X
- [2] Xuning Feng, Thermal runaway mechanism of lithium ion battery for electric vehicles: A review, Energy Storage Materials, Volume 10, 2018, Pages 246-267
- [3] Vaswani, "Attention is all you need." Advances in neural information processing systems 30 (2017).