

트랜스포머 알고리즘을 활용한 탄소나노튜브와 플라이애시 혼입 시멘트 복합재료의 압저항 특성 분석

김 종 혁¹·방 진 호²·전 해 민^{3†}

¹한밭대학교 건설환경공학과 학부과정, ²충북대학교 토목공학부 박사과정, ³한밭대학교 건설환경공학과 부교수

Analysis of Piezoresistive Properties of Cement Composites with Fly Ash and Carbon Nanotubes Using Transformer Algorithm

Jonghyeok Kim¹, Jinho Bang² and Haemin Jeon^{3†}

¹Undergraduate Student, Department of Civil and Environmental Engineering, Hanbat National University, Daejeon, 34158, Korea

²Graduate Student, School of Civil Engineering, Chungbuk National University, Cheongju, 26844, Korea

³Associate Professor, Department of Civil and Environmental Engineering, Hanbat National University, Daejeon, 34158, Korea

Abstract

In this study, the piezoresistive properties of cementitious composites enhanced with carbon nanotubes for improved electrical conductivity were analyzed using a deep learning-based transformer algorithm. Experimental execution was performed in parallel for acquisition of training data. Previous studies on mixture design, specimen fabrication, chemical composition analysis, and piezoresistive performance testing are also reviewed in this paper. Notably, specimens in which fly ash substituted 50% of the binder material were fabricated and evaluated in this study, in addition to carbon nanotube-infused specimens, thereby exploring the potential enhancement of piezoresistive characteristics in conductive cementitious materials. The experimental results showed more stable piezoresistive responses in specimens with fly-ash substituted binder. The transformer model was trained using 80% of the gathered data, with the remaining 20% employed for validation. The analytical outcomes were generally consistent with empirical measurements, yielding an average absolute error and root mean square error between 0.069 to 0.074 and 0.124 to 0.132, respectively.

Keywords : cement composites, deep learning, transformation algorithm, carbon nanotube, piezoresistive, fly ash

1. 서론

전도성 시멘트 복합체는 고전도성 필러의 혼입을 통해 다양한 응용분야에 사용되며, 특히 발열체, 압저항 센서, 전자파 차폐 건자재와 같은 분야에서의 활용을 위한 연구가 지속적으로 수행되고 있다(Wang and Aslani, 2022). 최근에는 지진이나 구조물의 노후화 등으로 인한 안정성 이슈가 대두되면서, 전도성 시멘트 복합체를 이용한 구조물 진단용 센서의 필요성이 점점 강조되고 있다. 전도성 시멘트 복합체 기반의 압저항 센서는 내부 필러의 간격 변화에 따른 전기 저항 특성의 변화를 활용하며, 하중의 유무 및 크기를 모니터링하는 데 있어 유용하

다(Luo *et al.*, 2023). 이러한 센서는 설치가 용이하고 높은 내구성을 보인다는 장점이 있다. 특히, 탄소나노튜브(Carbon nanotube, CNT)와 같은 고전도성 필러의 활용은 이러한 성능 향상에 크게 기여하고 있다.

Azhari(2008)은 전도성 시멘트 복합체 센서의 다양한 응용분야를 분석하고 소개한바 있다. 특히 지진이나 노후화로 인한 구조물의 안정성 문제에 대해 전도성 시멘트 복합체의 효용성을 언급하고 있다. Kim 등(2019)은 CNT를 혼입한 시멘트 복합체의 기계적 및 전기적 특성에 대해 다루고 있으며, CNT의 혼입이 시멘트 모재의 전도성과 기계적 성능 향상에 어떻게 기여하는지에 대해 심층적으로 분석하였다. Dinesh 등(2021)은

†Corresponding author:

Tel: +82-42-821-1103; E-mail: hjeon@hanbat.ac.kr
Received November 7 2023; Revised November 9 2023;
Accepted November 9 2023

© 2023 by Computational Structural Engineering Institute of Korea

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

CNT를 적용한 시멘트 기반 센서의 변형을 감지 성능에 대해 연구하였다. 해당 연구는 CNT의 혼입이 시멘트 복합체 센서의 압저항 특성을 향상시키고, 따라서 구조물의 변형을 보다 민감하게 모니터링할 수 있음을 나타내었다.

위와 같은 CNT 혼입 시멘트 센서는 반복적으로 높은 하중을 받게 되면, 저항 변화율이 점차 감소하는 문제가 발생할 수 있다. 이는 센서의 전반적인 성능에 악영향을 미칠 수 있으며, 이에 대한 해결책으로 추가적인 필러의 혼입이 고려되어야 할 필요가 있다. 이를 위해 다양한 나노 입자나 섬유형 필러가 내구성과 저항 변화율을 일정하게 유지하는 데에 활용될 수 있다.

Ding 등(2019)은 CNT와 나노 카본 블랙(Nano carbon black) 복합 필러를 이용한 시멘트 센서를 콘크리트 기둥에 적용하여 센싱 성능을 평가하였다. 이를 통해 복합 필러의 적용이 재료의 센싱 성능을 향상시키며, 성능 안전성을 높이는 데 기여할 수 있음을 나타내었다. Park 등(2019)은 다양한 함량의 CNT와 탄소섬유, 물-시멘트 비율을 지닌 시멘트 복합체를 제작하고, 이의 내부 구조특성과 전기 전도성과의 상관관계를 분석하였다. 탄소섬유 필러의 추가 혼입은 전도성 경로를 보다 견고하게 높이는 데 기여하며, 이를 통해 전기적 특성을 향상시킬 수 있음을 확인하였다.

전도성 나노 복합재료의 정확한 이론적 해석과 예측은 연구 및 산업분야에서 주목받는 중요한 주제이다. Hashemi와 Weng (2016)은 미세역학을 기반으로 비균질 재료의 전기적 특성에 대한 모델을 제시하고, 이를 활용하여 CNT 혼입 나노 복합체의 임계치 분석과 터널링 효과를 검증하였다. 또한 Souri 등 (2017)은 다중스케일 모델링을 사용하여 CNT를 혼입한 시멘트 나노복합재료의 복잡한 물리적 특성과 이로 인한 압저항 특성 예측에 관한 내용을 연구하였다. 그러나 CNT 혼입 시멘트 복합체의 비균질 특성과 압저항 거동 모사의 복잡성으로 인해 많은 진전이 이루어지지 못한 측면이 있다. 오늘날 활발한 연구가 진행되고 있는 데이터에 기반한 머신러닝 기법을 활용한다면 보다 정확한 압저항 성능의 해석과 예측이 가능할 것으로 기대된다.

본 연구에서는 CNT와 플라이애시(Fly ash, FA)을 혼입한 시멘트 복합재료의 데이터 기반 압저항 특성 평가를 위한 기초 연구를 수행하였다. 특히 트랜스포머 알고리즘을 통해 전도성 시멘트 복합체의 압저항 성능을 평가하고 예측하기 위한 방안을 탐구하였다. 본 연구에서 수행된 실험 및 해석 연구를 통하여 안정적이고 경제적인 건설용 시멘트 센서기술의 발전에 기여하며, 구조물의 안전성과 지속 가능성을 높이는 방안을 제시하고자 하였다.

2. 압전특성 실험 및 결과

2.1 재료 및 시편

본 연구에서 제작된 시멘트 복합재료의 조성비는 시멘트 중량 기준으로 실리카폼 10%, CNT 0.5%, 계면활성제 2%, 잔골재 150%, 그리고 물 35%로 구성되었다. 또한 FA는 혼입한 경우와 그렇지 않은 경우로 나누었으며, 혼입 비율을 50%로 하였다. FA는 재료의 장기강도 향상과 비용절감을 위해 사용되는 시멘트 대체제로서, 이의 유효성에 대해서는 기존 다양한 연구를 통해 검증된 바 있다(Provis *et al.*, 2009; Zhang *et al.*, 2014). 특히 FA의 금속계 성분이 재료의 전기적 특성을 변형시킬 수 있다는 연구논문이 발표된 바(Jang *et al.*, 2022; Piro *et al.*, 2023), 이에 대한 사항을 함께 검토해 보고자 하였다. 위의 내용을 정리한 시편의 라벨링과 배합구성을 Table 1에 나타내었다.

시편 제작과정은 다음과 같다: 시멘트, FA, 실리카폼, 잔골재는 믹서에 함께 넣어 건비빔 상태로 준비하며, 전도성 필러인 CNT는 폴리카르복실계 계면활성제가 첨가된 물에서 초음파 처리(최대진폭 50% 및 펄스 간격 10초)된 후 혼입되었다. 3분가량 건비빔을 한 후, CNT 수용액을 함께 믹서에 추가하여 5분간 추가적으로 혼합하였다.

시편은 거푸집(5 × 5 × 5mm³)에 부어진 후 은페이스트로 코팅된 길이 50mm, 폭 20mm의 구리전극을 내장하고 28일간 양생 처리되었다. 이때 모든 시편은 수분손실을 방지하기 위해 랩으로 밀봉된 후 상온(25 ± 2°C)에서 양생되었다. Fig. 1(a)과 (b)에 전도성을 띄는 CNT 필러의 주사전자현미경(Scanning electron microscope, SEM) 이미지와 시멘트 시편 개요를 나타내었다. 이후 반복하중 시험을 통해 하중에 따른 압저항 변화 데이터를 수집하였으며, 이에 대한 실험 개요도를 Fig. 2에 나타내었다.


2.2 실험결과 분석

피로성능평가 기능이 있는 만능시험기(Walter Bai, LFW 2500HH)를 통해 압축하중을 반복적으로 시편에 부하하였으며, 이때 하중은 0-50kN 범위의 힘으로 2Hz 주기로 적용되었


Table 1 Mix ratio of specimens

| Specimen code | Binder | | Silica fume | Fine aggregate | CNT | Water | Super-plasticizer | w/b |
|---------------|--------|----|-------------|----------------|-----|-------|-------------------|------|
| | OPC | FA | | | | | | |
| C5F0 | 100 | 0 | 10 | 150 | 0.5 | 35 | 2 | 0.35 |
| C5F5 | 50 | 50 | | | | | | |

*OPC: Ordinary Portland Cement, FA: Fly ash, w/b: Water-binder ratio



(a)



(b)

Fig. 1 (a) SEM image of CNT and (b) outline of CNT-incorporated cement composites

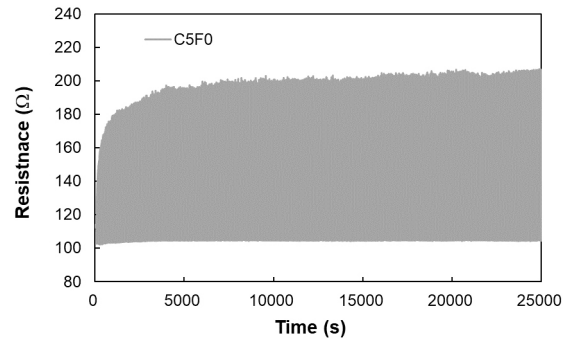


Fig. 2 Overview of piezoresistive test setup

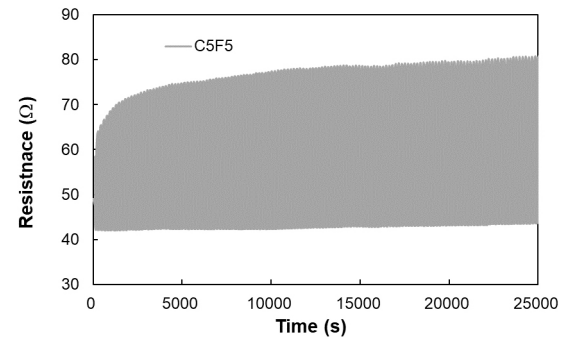
다. 또한 멀티미터(Keysight, U1282A)를 통해 전기저항을 동시에 측정하였다. Fig. 3은 반복하중에 따른 시편의 압저항 특성 시험결과를 나타내고 있다. 전체적으로 C5F5 시편이 C5F0 시편과 비교하여 낮은 저항수치를 나타내고 있다.

C5F0은 초기에 낮은 저항 값을 보이며, 시간이 지남에 따라 저항이 꾸준히 증가하여 안정화되었다. 저항의 전반적인 변화는 상당히 높으며, 이는 반복하중 하에서 CNT의 재배열 또는 정렬로 인한 결과로 추정된다. 최종 저항값은 약 200Ω로, 이때 시멘트 매트릭스 내의 CNT는 일부 불가역적 변화를 겪었거나 전도성 경로에 영향을 미치는 미세균열이 형성되었을 가능성이 있다(Kim *et al.*, 2019).

C5F5의 초기 저항값은 C5F0과 비교하여 더 낮았으며, C5F0보다 빠르게 안정화되며 더 낮은 값을 유지하였다. 또한 반복하중에 따른 저항값의 변동성이 C5F5에서 더 작아, FA가 혼합



(a)



(b)

Fig. 3 Piezoresistive test results under cyclic loading condition: (a) C5F0 and (b) C5F5

된 경우 더 일관된 압저항 특성을 보임을 알 수 있었다. 이는 FA 존재 시 CNT와 바인더 매트릭스 간의 상호 작용이 다름에 기인한 것으로 사료된다. 즉 FA가 매트릭스 내에서 CNT의 분산이나 내부 수화구조물 형성에 영향을 미치는 것으로 해석된다.

이에 대한 분석을 위해 시멘트와 FA의 화학조성 분석을 X선 형광 분광법(X-ray fluorescence analysis, XRF)을 통해 Table 2에 정리하였다. 시멘트의 경우 CaO의 함량이 62.4wt%로 가장 높고, SiO₂, Al₂O₃ 및 Fe₂O₃이 각각 21.1wt%, 5.8wt% 및 3.1wt%의 순으로 뒤를 이었다. FA는 SiO₂의 높은 함량(56.9wt%)으로 특징지어지며, Al₂O₃와 Fe₂O₃ 함량도 각각 20.9, 9.8wt%로 상대적으로 높은 값을 나타내었다.

Table 2에서와 같은 화학조성의 차이는 시멘트와 FA를 복합화 했을 때 서로 다른 특성을 나타내게 하는 요소로 작용할 것으로 예상된다. 특히, FA의 상대적으로 높은 금속계 성분의 함량은 시멘트 복합재료의 전기적 특성에 영향을 주어 적용된 하중 하에서 더 안정된 압저항 특성을 유지할 수 있게 도움을 주었을 것으로 사료된다.

3. 트랜스포머 알고리즘을 이용한 압전성능 평가

3.1 트랜스포머 알고리즘 개요

컴퓨터 하드웨어 성능의 개선 및 이에 따른 연산 능력의 향

Table 2 Chemical compositions of cement and fly ash used in the present study (wt%)

| Chemical composition | Cement | FA |
|--------------------------------|--------|------|
| CaO | 62.4 | 4.7 |
| SiO ₂ | 21.1 | 56.9 |
| Al ₂ O ₃ | 5.8 | 20.9 |
| Fe ₂ O ₃ | 3.1 | 9.8 |
| SO ₃ | 2.0 | 0.4 |
| MgO | - | 1.2 |
| K ₂ O | - | 1.3 |
| P ₂ O ₅ | - | 1.4 |
| LOI* | 5.6 | 3.4 |

*Loss on ignition

상과 다양한 형태의 네트워크가 개발되면서 딥러닝은 데이터가 존재하는 모든 분야에서 유용한 분석도구로써 사용되고 있다(Bang *et al.*, 2022). 딥러닝 네트워크는 시계열 데이터의 예측, 분류 및 경향 분석과 같은 다양한 작업에 성공적으로 활용되어 왔으며, RNN(Recurrent Neural Network), LSTM(Long Short-Term Memory) 및 GRU(Gated Recurrent Unit)와 같은 순환 신경망(Recurrent Neural Network, RNN) 네트워크가 사용되었다(Goodfellow *et al.*, 2016). RNN은 시간적 순서를 고려하여 정보를 처리하며, 순환적 구조로 인한 단기 및 장기 의존성 모델링 능력을 제공한다(Lipton *et al.*, 2019; Williams and Zipser, 1989). 즉, RNN의 은닉층의 노드에서 활성화 함수를 통해 나온 결과값을 출력층 뿐 아니라, 은닉층 노드의 다음 계산의 입력으로 보내면서 이전 그리고 현재 정보를 바탕으로 이후 값을 예측하는 시퀀스 모델이다. 그러나 이러한 RNN 모델은 긴 시퀀스의 데이터를 처리하면서 입력층과 출력층 간 거리가 늘어남에 따라 정보 전달이 감소하여 데이터들 간 연관관계가 줄어드는 장기 의존성(Long-Term Dependency)가 발생하였다. 즉, 깊은 신경망에서 발생하는 기울기 소실(Vanishing Gradient) 문제가 발생하게 됨에 따라, 이를 극복하기 위하여 LSTM(Long Short Term Memory) 및 GRU 등의 변형된 RNN 네트워크 구조가 개발되었다(AI-Selwi *et al.*, 2023).

LSTM은 입력, 망각, 출력 게이트를 통해 정보를 추가하거나 삭제하면서, 정보를 선택적으로 전달하도록 한다(Hochreiter and Schmidhuber, 1997; Yu *et al.*, 2019). 이러한 게이트 메커니즘 기반의 장기 및 단기 메모리 유닛을 활용한다는 점과 기존 순환 신경망 모델이 단기 기억만을 가지고 순환적으로 학습을 진행하였다면, LSTM은 층(Layer) 출력 값 이외에도 LSTM 셀(Cell) 사이에서 공유되는 셀의 상태(Cell State)도 고려한다. 즉, 장기 및 단기 메모리 유닛의 활용과 더불어 셀 상태가 다음 층으로 전달되면서, 이전의 상태를 보존하여 장기 의존성 문제를 해결한다. 한편, GRU는 리셋 게이트 및 업데이트 게이트의

메커니즘을 통하여 LSTM보다 간결한 구조를 가지며, 매개변수가 적고 모델 학습이 보다 빠르게 구현된다는 차이점을 지닌다(Cho *et al.*, 2014).

기존의 순환 신경망과 달리 셀프 어텐션(Self-attention) 메커니즘만을 사용하여 시계열 데이터의 장기 의존성을 효과적으로 학습할 수 있는 트랜스포머(Transformer) 아키텍처가 개발되었다(Vaswani *et al.*, 2017). 이러한 트랜스포머 모델은 기존의 순환 신경망 계열의 알고리즘과는 다르게 어텐션으로 구현된 인코더에서 별도의 시퀀스 데이터를 압축하는 과정 없이 진행되며, 이에 기존 인코딩 과정에서의 압축에 따른 정보의 손실 문제를 해소하였다. 또한, 디코더의 현재 입력 벡터인 쿼리(Query)와 인코더의 모든 시점의 은닉상태 벡터인 키(Key), 벨류(Value)를 계산하여 각 벡터들을 균일하게 나눈 다음, 나누어진 벡터의 일부분인 헤드(Head)를 여러 개로 분할하여 다중 특징들을 학습하여 기존 알고리즘에 비해 비약적인 성능 향상을 이루었다. 이에 본 논문에서는 이러한 트랜스포머 모델을 이용하여 건설 재료의 특성을 분석하고자 한다.

3.2 전도성 시멘트 해석을 위한 트랜스포머 모델

시계열 기반의 전도성 시멘트 데이터의 학습을 위하여 기존 트랜스포머 모델 네트워크를 Fig. 4와 같이 수정하였다. 시계열 데이터의 특징을 추출하고 위하여 입력층에 아래의 함수를 적용하였다. 각 순전파 네트워크(Feed Forward Network) 내부에는 ReLU 활성화 함수(Activation Function)를 도입함에 따라 기울기 소실 등의 문제를 완화하였다. 또한, 입력 데이터의 차원이 트랜스포머 모델 인코더의 입력 층의 차원과 동일한 차원이 되도록 구성함으로써, 추출된 입력 데이터의 특징들이 트랜스포머 인코더를 통해 시계열 데이터의 맥락(Contexts) 정보를 추출하고 다수개의 인코더 블록을 통과함으로써 유의미한 정보를 갖는 벡터값을 유지되도록 하였다(Bona-Pellissier *et al.*, 2023).

즉 선형 레이어를 통과한 1차원의 단일한 입력 데이터는 다차원으로 변환되었으며, 변환되어 나온 데이터는 ReLU 활성화 함수를 통과한 다음, Linear Layer를 한 번 더 통과하여 최종적으로는 트랜스포머 인코더의 입력차원과 동일한 차원으로 변환한 뒤, 이를 인코더에 통과시켰다. 최종적으로 기존 트랜스포머 모델의 디코더(Decoder)를 입력층과 동일한 활성화 함수를 가지는 순전파 네트워크 연이어 출력층으로 구성함으로써 다양한 출력값 생성되고, 이에 따라 예측 성능의 향상시키고자 하였다.

3.3 트랜스포머 모델 학습 환경 구축

3.2절에서 제안한 트랜스포머 모델을 학습하기 위하여 아나콘다(Anaconda) 환경과 Python 3.8, PyTorch GPU 버전을 사

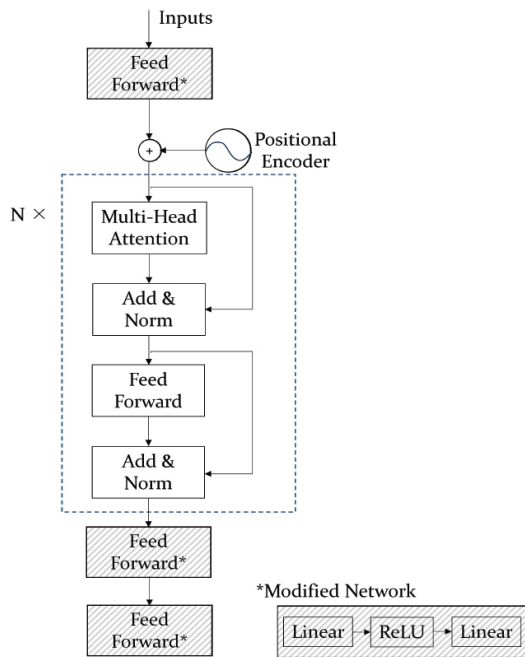


Fig. 4 Overview of the transformer model's architecture

용하였으며, 다양한 하이퍼 파라미터들을 적용하며 경험적으로 최적의 모델성능을 확보하기 위하여 시간적 측면에서 학습 속도의 효율을 높이는 분산 GPU 환경을 구축하였다. 이러한 분산 GPU 환경을 구축하기 위해 분산 데이터 병렬 처리(Distributed Data Parallel) 방법을 사용하였으며, 모델 복제(Replicated Model) 문제, 입력 값을 분산시키고 출력 값을 다시 수집하는 과정에서 추가적으로 발생하는 오버헤드(Overhead)에 따른 성능 저하 문제 등을 해결하고자 하였다. 구축한 GPU 서버는 VRAM이 각각 12GB인 총 2대의 동일한 NVIDIA RTX 3080 TI를 이용하여 연구를 수행하였다.

4. 압전성능 평가를 위한 트랜스포머 네트워크의 적용

압전성능 평가 실험 데이터의 날짜에 대한 명목형(Nominal) 데이터를 수치형 데이터로 변환하였으며, 표준화 작업을 수행하였다. 모델 하이퍼 파라미터의 경우 인코더(Encoder)의 층의 갯수 N은 4로 설정하였으며, 입력층의 순전파 레이어(Feed Forward Layer) 모델 내의 모든 하위 층에서 만들어내는 출력 차원은 512로 설정하였다. 또한, 평행한 어텐션(Attention) 층의 헤드(Heads)를 8개로 설정하였으며, 각 레이어의 드롭아웃(Dropout)은 모두 0.5로 설정하였다. 배치 크기와 학습률은 각각 128과 10^{-5} 로 설정하였으며, 손실 함수(Loss Function)와 최적화(Optimizer) 알고리즘은 각각 MSE(Mean Squared Error)와 Adam을 이용하였다.

반복하중에 따른 시편의 압전성능 데이터로 학습 데이터셋

Table 3 Prediction results using transformation algorithm

| Specimen code | C5F0 | C5F5 |
|---------------|-------|-------|
| MAE | 0.069 | 0.074 |
| RMSE | 0.124 | 0.132 |


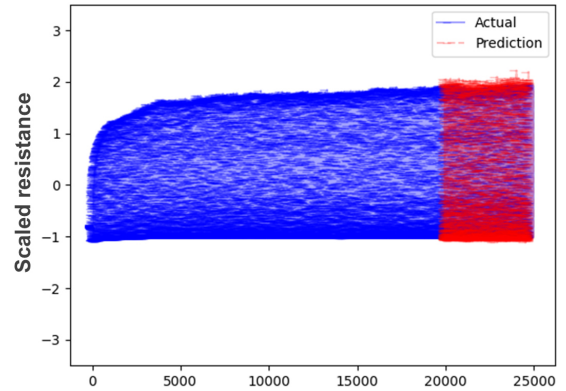


Fig. 2 Overview of piezoresistive test setup

을 구성하여 모델의 학습을 진행하였으며, 학습 및 테스트 데이터는 8:2로 나누어 모델을 학습하고, 그 성능을 검증하였다. 모델에 대한 성능을 검증하기 위해 평균 절대 오차(Mean Absolute Error; MAE)와 평균 제곱근 오차(Root Mean Squared Error; RMSE)를 사용하였으며, 그 결과는 Table 3에 나타내었다.

Table 3의 MAE는 모델 예측치와 실제 값의 차이의 절대값을 평균낸 것으로, 모델의 예측의 정확도를 나타낸다. C5F0의 MAE는 0.069로, C5F5의 MAE 0.074보다 낮아, C5F0 예측이 C5F5보다 더 정확하다는 것을 의미한다. 반면 RMSE는 제공된 오차의 평균의 제곱근으로, 오차의 크기를 과장해서 보여주는 경향이 있어 큰 오차에 더 큰 가중치를 부여한다. C5F0의 RMSE가 0.124으로 C5F5의 RMSE 0.132보다 낮아, C5F0의 예측이 전반적으로 더 정확함을 다시 한번 확인할 수 있다.

Fig. 5는 C5F0과 C5F5로 명명된 두 시멘트 기반 복합재료의 압저항 특성을 트랜스포머를 이용하여 예측한 결과와 비교분

석한 것으로, 반복하중에 따른 저항값 변화의 규모를 인덱스 하여 나타내고 있다. 모델 예측치(빨간색)가 측정치(파란색) 후반부에만 배치되어 비교된 이유는, 초기 실험 측정치는 예측을 위해 훈련 데이터로 활용되었음에 기인한다.

C5F0 시편이 C5F5 시편에 비해 예측 모델이 더 정확한 결과를 제공하는 것으로 계산되었으나, 육안으로 판별하기에 두 시편의 경우 모두 측정치와 모델 예측치 간에 높은 일치성을 보여주고 있다. 본 연구에서 적용된 훈련 데이터 이외에 해당하는 시편 배합, 하중조건, 외부 실험 조건 등과 같은 추가적인 데이터를 입력값으로 제공한다면 예측 모델의 정확도는 보다 개선될 수 있을 것으로 기대된다.

5. 결론

본 연구에서는 딥러닝 기반의 트랜스포머 알고리즘을 적용하여 CNT 혼입 건설 복합재료의 압저항 특성변화 분석에 대한 기초연구를 수행하였다. 두 종류의 시편인 C5F0과 C5F5에 대한 압저항 실험을 수행하였으며, 해당 데이터를 훈련 및 예측 성능평가에 사용하여 알고리즘의 정확도를 파악하고자 하였다. 예측 모델의 성능을 평가하기 위해 MAE와 RMSE 지표를 사용하였으며, 결과적으로 대체로 실제 실험결과와 높은 부합도를 나타내었다.

본 연구에서 적용된 훈련 및 비교평가 데이터는 시계열에 따른 압저항 변화 값으로, 이는 향후 트랜스포메이션 알고리즘의 적용 범위와 모델 구조에 대한 추가적인 연구와 개선이 필요함을 시사한다. 향후 연구에서는 보다 다양한 입력값과 시멘트계 재료 고유의 특성을 포괄할 수 있는 알고리즘 개발, 데이터 전처리 기법의 최적화 등의 방법을 모색하여 예측의 정확도를 높이고 실용성을 강화할 수 있을 것으로 예상된다.

References

Al-Selwi, S.M., Hassan, M.F., Abdulkadir, S.J., Muneer, A. (2023) LSTM Inefficiency in Long-Term Dependencies Regression Problems, *J. Adv. Res. Appl. Sci. & Eng. Technol.*, 30(3), pp. 16~31.

Azhari, F. (2008) Cement-based Sensors for Structural Health Monitoring, Doctoral Dissertation, University of British Columbia.

Bang, H., Yu, B., Jeon, H. (2022) Assembly Performance Evaluation for Prefabricated Steel Structures Using *k*-nearest Neighbor and Vision Sensor, *J. Comput. Struct. Eng. Inst. Korea*, 35(5), pp.259~266.

Bona-Pellissier, J., Bachoc, F., Malgouyres, F. (2023) Parameter

Identifiability of a Deep Feedforward ReLU Neural Network, *Mach. Learn.*, 112(11), pp.4431~4493.

Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., Bengio, Y. (2014) Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation, *arXiv preprint arXiv:1406.1078*.

Dinesh, A., Sudharsan, S.T., Haribala, S. (2021) Self-Sensing Cement-based Sensor with Carbon Nanotube: Fabrication and Properties-A Review. *Mater. Today: Proc.*, 46, pp.5801~5807.

Ding, S., Ruan, Y., Yu, X., Han, B., Ni, Y.Q. (2019) Self-Monitoring of Smart Concrete Column Incorporating CNT/NCB Composite Fillers Modified Cementitious Sensors, *Constr. & Build. Mater.*, 201, pp.127~137.

Goodfellow, I., Bengio, Y., Courville, A. (2016) *Deep learning*, The MIT Press, 2016, ISBN: 0262035618.

Hashemi, R., Weng, G.J. (2016) A Theoretical Treatment of Graphene Nanocomposites with Percolation Threshold, Tunneling-Assisted Conductivity and Microcapacitor Effect in AC and DC Electrical Settings, *Carbon*, 96, pp.474~490.

Hochreiter, S., Schmidhuber, J. (1997) Long Short-Term Memory, *Neural Computation*, 9, pp.1735~1780.

Jang, D., Yoon, H.N., Yang, B., Seo, J., Farooq, S.Z., Lee, H.K. (2022) Synergistic Effects of CNT and CB Inclusion on the Piezoresistive Sensing behaviors of Cementitious Composites Blended with Fly Ash, *Smart Struct. & Syst.*, 29(2), pp.351~359.

Kim, G.M., Nam, I.W., Yang, B., Yoon, H.N., Lee, H.K., Park, S. (2019) Carbon Nanotube (CNT) Incorporated Cementitious Composites for Functional Construction Materials: The State of the Art, *Compos. Struct.*, 227, p.111244.

Lipton, Z.C., Berkowitz, J., Elkan, C. (2015) A Critical Review of Recurrent Neural Networks for Sequence Learning, *arXiv preprint arXiv:1506.00019*.

Luo, T., Wang, Q., Fang, Z. (2023) Effect of Graphite on the Self-Sensing Properties of Cement and Alkali-Activated Fly Ash/Slag based Composite Cementitious Materials, *J. Build. Eng.*, 77, p.107493.

Park, H.M., Park, S.M., Lee, S.M., Shon, I.J., Jeon, H., Yang, B.J. (2019) Automated Generation of Carbon Nanotube Morphology in Cement Composite Via Data-Driven Approaches, *Compos. Part B: Eng.*, 167, pp.51~62.

Piro, N.S., Mohammed, A.S., Hamad, S.M. (2023) Electrical Resistivity Measurement, Piezoresistivity behavior and Compressive Strength of Concrete: A Comprehensive Review, *Mater.s Today Commun.*, p.106573.

- Provis, J.L., Yong, C.Z., Duxson, P., van Deventer, J.S.** (2009) Correlating Mechanical and Thermal Properties of Sodium Silicate-fly Ash Geopolymers, *Colloids & Surf. A: Physicochem. & Eng. Aspect.*, 336(1-3), pp.57~63.
- Souri, H., Yu, J., Jeon, H., Kim, J.W., Yang, C.M., You, N.H., Yang, B.J.** (2017) A Theoretical Study on the Piezoresistive Response of Carbon Nanotubes Embedded in Polymer Nanocomposites in an Elastic Region, *Carbon*, 120, pp.427~437.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, Polosukhin, I.** (2017) Attention Is All You Need, *Adv. Neural Inf. Proc. Syst.*, 30.
- Wang, L., Aslani, F.** (2022) Self-Sensing Performance of Cementitious Composites with Functional Fillers at Macro, Micro and Nano Scales, *Constr. & Build. Mater.*, 314, p.25679.
- Williams, R.J., Zipser, D.** (1989) A Learning Algorithm for Continually Running Fully Recurrent Neural Networks, *Neural Comput.*, 1, pp.270~280.
- Yu, Y., Si, X., Hu, C., Zhang, J.** (2019) A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures, *Neural Comput.*, 31, pp.1235~1270.
- Zhang, Z., Provis, J. L., Reid, A., Wang, H.** (2014) Fly Ash-based Geopolymers: The Relationship between Composition, Pore Structure and Efflorescence, *Cement & Concr. Res.*, 64, pp.30~41.

요 지

본 논문에서는 시멘트에 탄소나노튜브를 혼입하여 전기 전도성을 향상시킨 복합재료의 압저항 특성을 딥러닝 기반 트랜스포머 알고리즘을 적용하여 분석하였다. 훈련 데이터 확보를 위한 실험수행을 병행하였으며, 기존 연구문헌을 참조하여 배합설정, 시편제작, 화학조성 분석, 압저항 성능측정 실험을 수행하였다. 특히 본 연구에서는 탄소나노튜브 혼입 시편뿐 아니라 플라이애시를 바인더 대비 50% 대체한 시편에 대한 제작 및 성능평가를 함께 수행하여, 전도성 시멘트 복합재료의 압저항 특성 향상 가능성을 탐구하였다. 실험결과, 플라이애시 대체 바인더의 경우 보다 안정적인 압저항 특성결과가 관찰되었으며, 측정된 데이터의 80%를 이용하여 트랜스포머 모델을 훈련시키고 나머지 20%를 통해 검증하였다. 해석 결과는 실험적 측정과 대체로 부합하였으며, 평균 절대 오차 및 평균 제곱근 오차는 각각 0.069~0.074와 0.124~0.132을 나타내었다.

핵심용어 : 시멘트 복합재료, 딥러닝, 트랜스포메이션 알고리즘, 탄소나노튜브, 압저항, 플라이애시