

건설재료 성능예측을 위한 기계학습 알고리즘 적용 사례

Case Studies of Machine Learning Algorithms Applied to Predicting Performance of Construction Materials



방 진 호

충북대학교 토목공학부 석사과정



신 윤 재

충북대학교 토목공학부 석사과정



조 길 재

현대L&C 세종사업장 차장



박 솔 미

부경대학교 토목공학과 조교수



김 형 기

조선대학교 건축공학과 교수



양 범 주

충북대학교 토목공학부 조교수

1. 서론

최근 매우 빠른 속도로 발전하고 있는 기계학습 기술은 오늘날 다양한 분야에 활용되고 있으며, 이의 적용속도는 향후 점차 증가될 것으로 예상된다[1]. 이는 최근 몇 년 사이에 이루어진 데이터 발생과 축적의 폭발적인 증가와 다양한 자료들을 처리할 수 있는 컴퓨팅 파워의 기하급수적 성장에 기인하는 것으로 사료된다[2]. 또한 산업현장에서의 머신러닝 기술의 높은 수요와 투자의 쏠림현상은 다수의 알고리즘 고차원화를 이끌었으며, 동시에 매우 빠른 속도로 공유·전파되어 산업계의 생태계를 변화시키고 있다[1,2].

건설재료 분야는 전통적으로 실험에 의한 연구가 재료의 배합과 성능을 확인하는데 주요한 방법으로 인식되고 있다[3]. 초기 경화를 시작으로 약 28일에 걸친 집중적인 수화작용과 그 이후의 열화와 손상과정을 거치는 대다수 건설재료의 복잡한 화학작용을 이론적으로 해석하는 것은 상대적으로 난해하며 비효율적이기 때문이다. 그러나 최근 전통적 배합 이외의 특수소재를 혼입하는 건설재료 개발연구가 전 세계적으로 활발히 수행되고 있으며, 기존과 상이한 특성과 반응에 대한 상관관계를 실험과 기존 이론만으로 분석하는 데에 한계를 나타내고 있다[4]. 차세대 건설재료는 구조물의 친환경화, 제로 에너지화, 스마트화를 구현하기 위한 핵심 요소기술로 인식되고 있다. 이의 구현과 성공적인 상용화를 위해서는 신뢰할 수 있는 재료 배합별 상호작용의 규명이 필수적이며, 재료 성능예측에 관한 실용적인 방법론이 요구된다. 따라서 실험과 기존의 해석 개념 이외에 데이터 기반의 분석 및 모델개발에 대한 요구가 증가할 것으로 예상된다.

본 고에서는 머신러닝 기술을 적용한 건설재료 연구개발 및 적용사례를 소개하여 해당 분야에 대한 기초 정보를 제공하고자 한다. 먼저 대표적 나노물질인 탄소나노튜브(Carbon nanotube, CNT)를 혼입한 시멘트 복합재료의 압전특성 예측을 위한 사례를 소개한다[5]. 적절한 양의 CNT를 시멘트 모재내에 분산시키면 기존대비 월등한 전기전도도를 띄게 되며, 이를 압전소재로 활용할 수 있게 된다. 현존하는 다양한 머신러닝 알고리즘을 적용하고 그 결과를 비교 검토하여 가장 적합한 안을 도출하였다.

다음으로, 파쇄벽돌(Crushed clay brick, CCB)을 굵은골재로 활용한 콘크리트 압축강도 특성 예측 사례를 소개한다[6]. CCB 굵은골재를 혼입한 콘크리트의 압축강도는 기존과 상이한 거동을 보이며, 이를 모사하기 위한 미세역학과 머신러닝을 결합한 구성방정식을 유도하였다. 재료의 비선형적 특성을 모사하기 위한

미세균열 상수를 머신러닝 기법을 통해 도출하였으며, 이의 유효성을 실험결과와의 비교검토를 통해 검토하였다. 마지막으로, 보조결합재(Supplementary cementitious materials, SCM)를 함유한 시멘트 페이스트의 반응도 예측 및 관련 모델식 구축에 관한 사례를 소개한다[7]. SCM은 수화물질을 생성할 수 있는 클링커 대체 물질로써, 재료성능 개선과 콘크리트의 CO₂ 배출량 저감을 위해 많은 연구가 이루어지고 있다. 머신러닝을 활용한 데이터 훈련과 분석을 통하여 SCM의 주요 성분과 반응성을 예측할 수 있는 모델식을 수립하였으며, 이의 타당성을 검토하였다.

2. 탄소나노튜브 혼입 전도성 건설재료의 압전 특성

2.1 연구 개요

CNT 혼입 전도성 시멘트 복합재료는 일반 시멘트 페이스트에 비해 전기전도도가 대폭 향상되어 발열, 전자파 차폐, 압전 등의 기능을 구현할 수 있다[5]. 이 중 압전은 외부 하중에 따라 재료의 전기적 물성이 변화하는 특성으로, 건설 구조물 및 차량 모니터링 시스템 등에 적용이 기

대되고 있다. 그림 1에는 CNT 혼입 건설재료의 압전 메커니즘에 대하여 간략히 나타내고 있다. 시멘트 내에 고르게 분포된 CNT 필러는 외부 압축하중에 의해 서로 간에 더욱 밀착되며, 이렇게 변형된 전도성 경로에 의해 초기대비 낮은 전기저항을 띄게 된다. 이후 외부하중이 다시 제거되면 CNT 일부가 재배열되며, 다시 전기저항이 상승하게 된다.

이러한 특성을 올바르게 모사할 수 있는 해석 모델개발 연구가 다수 시도되었으나, 시멘트계 재료 고유의 비균질성과 복잡성, 시간과 수화반응에 따른 내부구조의 변화 등으로 효과적인 성과를 나타내기 어려웠다. 또한 상대적으로 작은 사이즈인 CNT 필러는 재료 내부에 다양한 형태로 존재하게 되며, 이는 재료해석시 선행되는 대상 모델의 단순화에 큰 걸림돌이 되었다. 그림 2에 주사전자현미경을 통해 얻은 시멘트계 모재내의 다중벽 탄소나노튜브(Multi-walled CNT, MWCNT) 형상을 나타내었다. 일부는 솜털과 같이 뭉친 형태로 존재하며, 다른 일부는 실이 꼬인 형태로 분산되어 있다. 또한 각 개별적으로 다양한 길이와 각도로 휘어져 있는 것을 알 수 있다.

2.2 해석과정 및 결과

Bang 등[5]에서는 CNT가 혼입된 시멘트 복합재료의 압




그림 1 CNT 혼입 건설재료의 압전 메커니즘 개요




그림 2 바인더 재료내 혼입된 MWCNT의 주사전자현미경 이미지

전특성 예측을 위하여, 다양한 종류의 기계학습 방법을 적용하여 이의 결과를 비교 검토하였다. Kim 등[8]이 수행한 다양한 물/바인더(w/b) 비, CNT 함량, 경화조건에 따른 CNT/시멘트 복합재료의 압전특성에 대한 데이터를 훈련 값으로 활용하였으며, 해당 데이터들을 선형 회귀(Linear regression), 결정 트리(Decision Tree), 서포트 벡터 머신(Support vector machine, SVM), 심층 신뢰 신경망(Deep belief network, DBN), 가우시안 프로세스 회귀(Gaussian process regression, GPR), 유전 알고리즘(Genetic algorithm, GA), 배깅 앙상블(Bagging ensemble), 랜덤 포레스트 앙상블(Random forest ensemble), 부스팅 앙상블(Boosting ensemble) 알고리즘에 적용하였다. 머신러닝은 학습을 시킬 때 결과 값까지 같이 학습하는 지도학습과, 결과 값을 학습하지 않고 데이터의 분포에 기반을 두고 특징을 추출해 그 특징을 바탕으로 결과를 추정하는 비지도 학습으로 나눌 수 있다. 진술한 알고리즘 중 DBN을 제외한 알고리즘은 모두 지도 학습법으로, 각각의 알고리즘의 고유한 특성을 다음과 같이 정리하였다.

선형 회귀는 가장 널리 알려진 회귀분석 기법으로, 종속 변수 Y와 한 개 이상의 독립변수 X와의 선형 상관 관계를 모델링한다. 결정 트리는 데이터를 특정 값이나 조건을 기반으로 그룹을 만들어 데이터를 나누는 방법으로, 데이터 사이에 존재하는 패턴을 분석하여 통해 결과 값을 예측하는 기법이다. SVM은 학습 데이터를 두 개의 집단으로 나누어 새로운 데이터가 어느 집단에 속할지를 예측하는 모델로써, 최대한 많은 데이터가 포함되는 방향으로 최적화를 수행한다. 최근 SVM은 패턴인식, 자료분석에 다수 활용되고 있다.

DBN은 압력층과 은닉층이 여러 층으로 쌓여있는 구조로서, 기존의 인공신경망 가중치의 학습이 원활하게 이루어지지 않는 문제를 해결하기 위해 제안된 기법이다. 학습 데이터의 분포를 파악하고 인공신경망을 통한 추가적인 미세조정을 수행해 예측 모델을 구축한다. GPR은 모델을 설정해 예측하는 방식이 아닌, 특정 지점에 유사한 분포로 나타내는 데이터의 확률을 바탕으로 예측하는 기법이다. 분포를 바탕으로 예측하기 때문에 이를 표현하는 공분산의 함수를 어떻게 가정하느냐에 따라 모델의 성능이 크게 좌우되는 특징이 있다. GA는 생물학적 진화 과정에서 착안된 방법으로 선택, 교차, 대치의 방식을 반복하며 이 과정에서 잘못된 값으로 수렴하는 것을 방지하기 위해 일정 확률로 변이가 발생하게 하여 최적의 해 집단을 선정하는

기법이다.

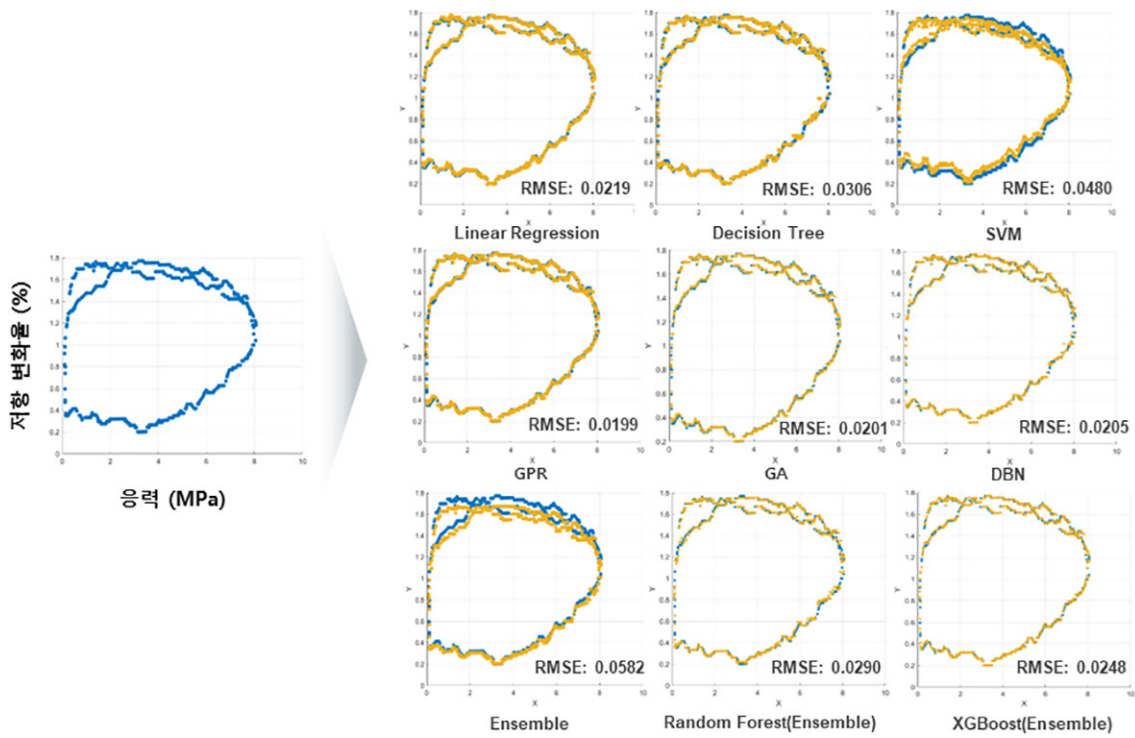
배깅, 랜덤 포레스트, 부스팅은 모두 앙상블의 일종으로, 앙상블은 여러 개의 결정트리를 결합해 예측성능을 높인 기법이다. 배깅 앙상블은 다수의 샘플을 선택한 후 각 모델을 학습시켜 결과물을 집계하는 방법이며, 랜덤 포레스트는 무작위로 선정한 요소로 구성된 다수의 트리로부터 이후의 모델을 예측하는 기법이다. 마지막으로 부스팅 앙상블은 여러 개의 결정트리가 순차적으로 학습을 수행하며, 이전 단계에서 수행한 계산 결과가 다음 데이터에 가중치를 부여하여 영향을 주도록 설계되어 있다. 본 연구에서 랜덤 포레스트와 앙상블 기법은 텐서플로(TensorFlow)에서 제공하는 기본 알고리즘과 하이퍼파라미터를 튜닝없이 사용하였으며, 이외의 모든 알고리즘은 MATLAB에서 제공하는 기본 알고리즘을 적용하였다.

그림 3에 CNT 혼입 시멘트 건설재료의 압전성능에 관한 머신러닝 알고리즘별 예측결과를 비교하여 나타내었다. 앞서 소개한 아홉 가지 알고리즘이 적용되었으며, 분석결과는 평균제곱근오차(Root mean square error, RMSE)를 사용하여 표현하였다. 이때 분석대상은 상온경화 조건에서 CNT 함량 0.1, 0.5 wt.%와 w/b 0.5, 0.6인 경우를 대표적으로 선별하였으며, 이에 대한 결과를 그림 3(a)와 (b)에 각각 정리하였다. 그림 3에서 파란색은 실제 실험 값이며 노란색은 예측 값을 의미한다. 따라서 오른쪽의 그래프에서 파란색이 거의 보이지 않으면 목표 값과 예측 값이 일치하는 것으로 간주할 수 있다. 비선형에 가까운 특이한 분포를 지니고 있는 데이터 일수록 예측 정확도는 낮았으며, CNT 함량 0.1 wt.%, w/b 0.5 케이스의 경우 RMSE 값은 대체로 0.02~0.04를 내었다. 반면 CNT 함량 0.5, w/b 0.6 케이스의 RMSE는 0.03~0.08로 다소 높았다. 모든 경우에 있어 GPR과 GA 기법이 가장 높은 정확도를 나타내었다.

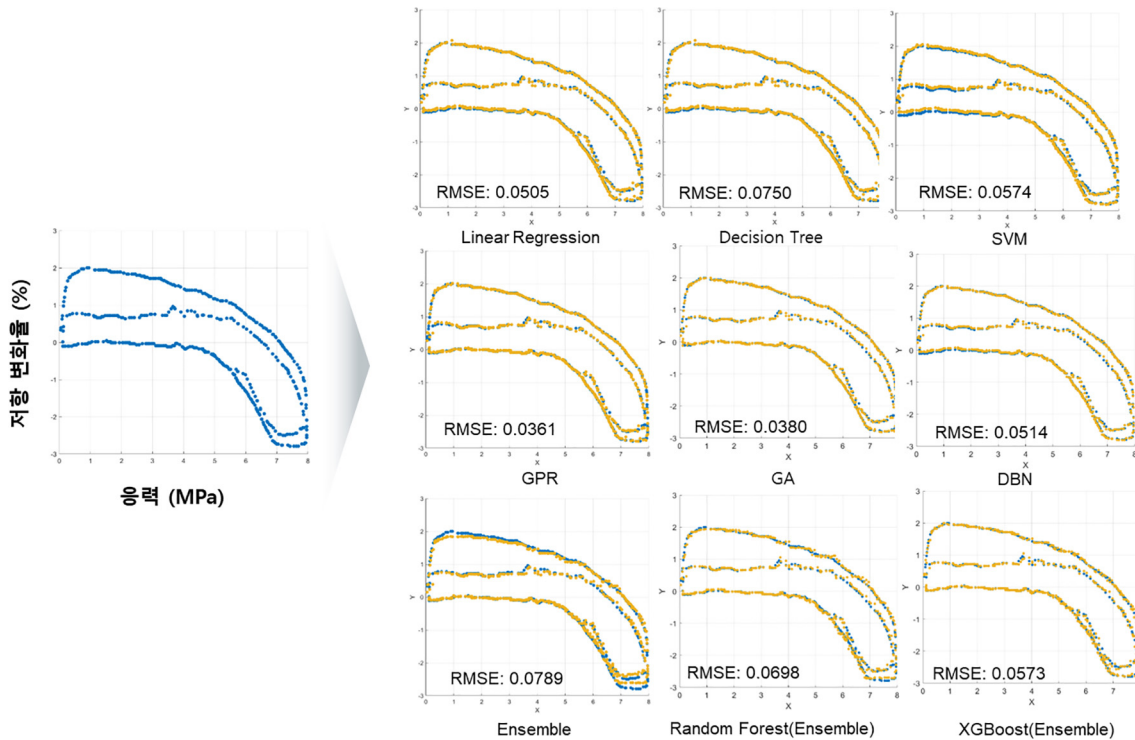
3. 파쇄 벽돌골재 혼입 콘크리트의 압축강도 특성

3.1 연구 개요

굵은골재는 콘크리트 부피의 대부분을 차지하는 주요 구성재료로서, 이의 수급이 어려울 경우 건설시공 전체의 문제로 이어질 수 있다. 자연에서 굵은골재를 추출하기 어려운 방글라데시는 굵은골재 수급이 어려운 대표적인 지역 중 하나이며, 이를 극복하기 위해 점토를 구워서 만든 파쇄



(a)



(b)

그림 3 CNT 혼입 시멘트 건설재료의 압전성능에 관한 머신러닝 알고리즘별 예측 비교:
 (a) CNT 함량: 0.1 wt%, w/b: 0.5, (b) CNT 함량: 0.5 wt%, w/b: 0.6




그림 4 CCB 골재 제조과정에 관한 개요

벽돌 (CCB)을 굵은골재 대용으로 활용하는 안을 시도하고 있다. 그림 4에 파쇄벽돌 골재 제작과정을 간략히 나타내었다. 점토를 몰드에 타설한 후 일정시간이 지나면 이를 탈영하여 오븐에 넣으며, 이후 가열과 식힘, 재가열 과정을 통해 벽돌을 제조한다. 완성된 벽돌은 최종적으로 적절한 크기로 파쇄하여 골재형태로 제조된 후 콘크리트에 적용된다.

기존 문헌들에 따르면, 인공골재를 적용한 콘크리트의 물리적 거동은 일반 콘크리트와 상이하며, 일반적으로 낮은 압축강도와 탄성계수를 보이게 된다. CCB 골재를 적용한 콘크리트의 이론적 해석을 수행하기 위하여 다양한 배합의 물시멘트비(w/c)와 골재 대체율을 적용한 콘크리트

공시체 시편을 제작하였다. 해당 시편들은 28일간 양생 후 압축거동 실험을 통하여 각 배합별 탄성계수, 압축강도, 하중-변형률 곡선 데이터를 기록하였다.

3.2 해석과정 및 결과

그림 5에 CCB 골재 혼입 콘크리트의 유효강성텐서 유도를 위한 재료구성 개요를 나타내고 있다. 콘크리트는 시멘트와 잔골재로 구성된 모르타르 매트릭스(phase 0)와 굵은골재로 이루어져 있으며, 굵은골재는 배합에 따라 일반 굵은골재(phase 1)와 CCB 골재(phase 2)가 단독 혹은 혼입되




그림 5 CCB 골재 혼입 콘크리트의 유효강성텐서 유도를 위한 재료구성 개요

어 존재하는 것으로 가정하였다. 또한 매트릭스 내부에는 일부 미세균열(phase 3)이 존재하며, 이는 외부응력이 진전될수록 점차 그 체적량이 증가하여 전체 콘크리트의 강성을 저하시키게 된다. 위와 같은 가정은 미세역학 기반 이론에 적용되어 구성방정식이 도출되었으며, 이에 대한 보다 자세한 유도과정과 수식의 정의는 Kim 등[6]에 나타내었다.

유도된 재료 모델에는 실험상수 외에도 네 개의 미세균열 상수가 존재하게 된다. 즉 미세균열의 임계 유효 변형률, 초기 미세균열 부피비, 미세균열 진전의 형상 상수, 미세균열 진전의 분포 상수의 값을 올바르게 설정해 주어야 한다. 이 과정에서 실험을 통해 측정된 w/c와 CCB 골재 적용 비율을 달리한 18개의 배합의 54개 콘크리트 시편에서 측정된 하중-변형률 곡선이 GA에 적용되었다. GA 계산을 통하여 모든 실험 결과와 가장 부합하는 단일의 값을 지닌 네 개의 모델상수를 도출하였으며, 이를 정답으로 가정하여 구성방정식에 적용되었다.

완성된 구성방정식은 상용 유한요소프로그램에 적용되어 실제 실험과 유사한 환경에서의 압축강도 실험을 모사하였으며, 이에 대한 개요를 그림 6에 나타내었다. $\phi 100 \times 200$

mm 공시체의 위·아래 양 끝단에는 각각 강체의 캡을 두었으며, 하단은 모든 방향에 대하여 구속, 상단의 로드셀은 Y축 방향으로 변위 제어하였다. 이의 해석결과를 추출하여 실험 데이터와 비교하였으며, 대표 결과를 선별하여 그림 7에 나타내었다. w/c 값이 작은 경우에는 비교적 예측과 실험결과가 부합하나, w/c 값이 높아질수록 이의 오차는 커짐을 알 수 있다. 제안된 방법에 따른 해석결과는 대체로 재료의 하중-변위 경향을 올바르게 모사하였으나, 일부 극단적인 배합에서 매우 큰 오차를 나타내었다. 이는 단일의 모델상수 값의 적용에 따른 이유로 사료되며, 향후 보다 심층적인 연구를 통하여 케이스별 비선형 메커니즘의 구별과 정량화가 필요할 것으로 예상된다.

4. 시멘트 페이스트 내의 보조결합재 반응도

4.1 연구 개요

콘크리트의 주요 구성요소인 시멘트는 제조과정에서 매우 많은 양의 CO₂를 배출하며, 이는 전 세계 CO₂ 배출량의




그림 6 유도된 재료 구성방정식을 적용한 상용 유한요소해석 프로그램 적용 예시




그림 7 CCB 골재 혼입 콘크리트의 응력-변형률 곡선 실험 및 예측결과 비교

약 8%에 달하는 것으로 알려져 있다[9]. 이에 콘크리트가 발생시키는 탄소발자국을 줄이기 위한 다양한 연구가 시도되고 있으며, 그중 SCM의 적극적인 활용이 현실적인 대안 중 하나로 고려되고 있다. SCM은 콘크리트 수화에 도움을 줄 수 있는 추가적인 규산염, 알루미늄규산염, 칼슘 알루미늄 규산염 등을 제공할 수 있는 물질을 총칭한다[7]. 일반적으로 슬래그(Slag), 플라이애시(Fly ash), 메타카올린(Metakaolin; 소성점토), 실리카푼(Silica fume)이 SCM 물질로 활용되며, 잠재수경성 혹은 포졸란 반응을 통해 시멘트계 재료물성을 개선시키게 된다.

위에서 언급한 주요 SCM은 과거에서부터 많은 연구가 이루어져 관련 연구 데이터가 풍부하다는 장점이 있다. 그러나 각 SCM과 시멘트 페이스트 내에서의 반응도를 결정하는 실험론적 방법은 아직까지 다양한 재료 및 실험실별 편차와 불확실성을 나타내고 있다[10]. 이에 머신러닝을 이용하여 SCM의 주요 성분으로부터 반응도를 예측할 수 있는 모델 수립 연구가 수행되었다[7]. 기존에 발표된 SCM 연구의 재료구성 원소와 반응도를 심층적으로 분류하였으며, 이를 GA 기반의 분석기법에 적용하여 데이터를 해석하였다.

4.2 해석과정 및 결과

GA 해석을 수행하기 위하여 MATLAB 기반의 오픈소스 프로그램인 GPTIPS(Genetic programming toolbox for the identification of physical systems)를 활용하였다. GPTIPS는 객체 계산을 기호적으로 처리하며, 데이터 결과를 바탕으로 구조-활성의 정량적 관계(Quantitative structure - activity relationship, QSAR) 모델을 생성한다[11]. 표 1에는 해석에 적용하기 위해 정리한 기존 문헌 데이터를 나타내었다. 248개의 문헌이 검토되었으며, 각 데이터는 w/c, 양생 조건, 주 결합재 및 SCM 구성성분, 표면적으로 분류하였으며, 주 결합재와 SCM은 해당 구성성분(SiO₂, Al₂O₃, Fe₂O₃, CaO, MgO, SO₃, Na₂O, K₂O 등) 비율로 다시 세분화하였다. 각 요소별 항목은 GA 기반의 GPTIPS 프로그래밍에 적용되어 해석이 수행되었다. 이에 대한 개요를 그림 8에 나타내었다.

해석을 통해 각 변수별 가장 영향력 있는 인자들을 분류하였으며, 이로 구성된 기호 모델식을 구성할 수 있었다. 유도된 모델에 다양한 w/c 값과 SCM 치환율에 따른 반응도 예측 결과를 그림 9에 나타내었다. 모든 경우에 있어 w/c증가는 반응도의 증가를 유도하였으며, SCM 치환율이

표 1 해석에 적용된 시편 양생조건 및 구성성분에 따라 분류된 입력 데이터 예시

Ref.	w/c	양생조건		주 결합재 구성성분				SCM 구성성분				표면적 (m ² /g)	반응도 (%)
		온도(°C)	양생기간 (일)	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	...	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	...		
1	0.65	23	112	17.19	2.89	1.14	...	13.98	10.21	0.47	...	20.62	100
2	0.65	23	112	17.19	2.89	1.14	...	24.49	0.00	0.03	...	21.62	100
3	0.45	23	90	9.85	2.55	1.33	...	17.94	7.18	0.29	...	0.48	51.43
4	0.75	20	90	0.00	0.00	0.00	...	18.09	0.46	0.09	...	0.7	45
5	0.75	20	90	0.00	0.00	0.00	...	36.17	0.92	0.18	...	0.7	51
6	0.75	20	90	0.00	0.00	0.00	...	54.26	1.38	0.27	...	0.7	54
7	0.5	20	182	17.11	2.65	0.23	...	3.26	2.35	0.08	...	1.89	93.7
8	0.5	20	182	16.71	2.62	0.22	...	6.58	4.74	0.17	...	1.89	81.4
9	0.5	20	182	16.36	2.59	0.20	...	9.56	6.88	0.25	...	1.89	79
10	0.5	20	182	16.00	2.56	0.19	...	12.54	9.03	0.32	...	1.89	63.2
11	0.5	20	182	15.79	2.54	0.18	...	14.33	10.32	0.37	...	1.89	54.3
12	0.5	20	182	15.36	2.51	0.17	...	17.93	12.91	0.46	...	1.89	49.9
13	0.45	21	90	0.00	0.00	0.00	...	8.41	23.97	1.09	...	1.373	75

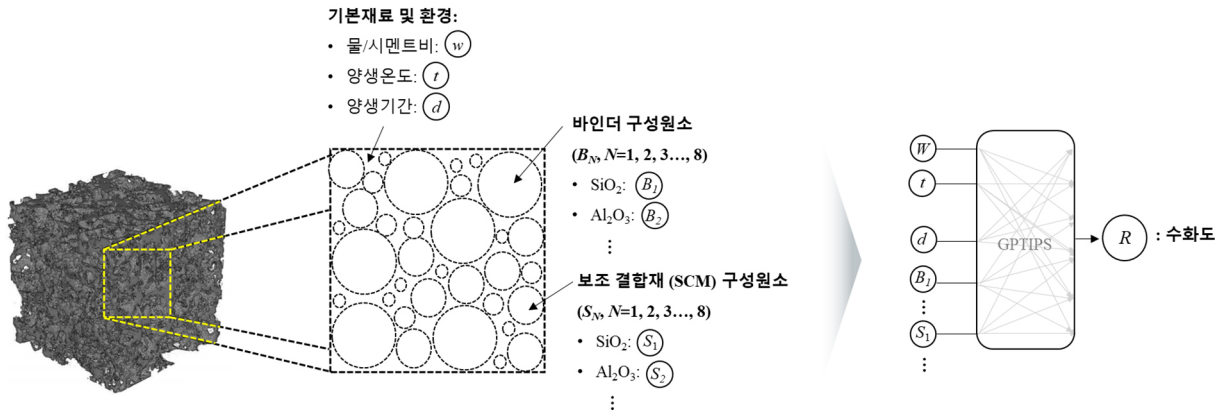


그림 8 SCM이 포함된 시멘트 페이스트의 GA 적용을 위한 입력값 및 출력값 설정




그림 9 (a) 슬래그 (b) 플라이애시, (c) 메타카올린 및 (d) 실리카폼의 치환율과 w/c에 따른 반응도 경향 예측

높아질 그 효율은 감소하는 것으로 예측되었다. 그러나 이는 비교적 제한적인 수의 데이터에 따른 경향도 예측결과로, 향후 보다 다양한 실험 데이터의 보강과 추가와 알고리즘의 수정 및 고도화가 요구된다.

5. 결론

본 고에서는 건설재료의 물성해석 및 데이터 분석을 위하여 최근 다양한 분야에 적용되고 있는 기계학습 방법 적용사례를 소개하였다. CNT 혼입 시멘트 복합재료의 압전

성능, CCB 굵은골재 콘크리트의 압전성능, SCM 반응도 평가분야에 적용되었으며, 각각 최적 알고리즘의 선정, 시편의 기계적 물성 예측, 평가모델 수립이라는 목표로 수행되었다. 단순 X-Y축 좌표의 비선형 성능 예측은 GPR과 GA가 가장 우수한 정확도를 나타내었으며, GA는 미세역학 이론과 결합되었을 시 합리적인 미세균열 모델상수를 도출하였다. 또한 GA 기반 GPTIPS를 통해 수립된 기호 모델식은 SCM 반응성 경향을 높은 정확도로 예측하였다. 그러나 상기 결과는 모두 제한된 수의 데이터 내에서 도출된 결과로서, 평균을 벗어나는 극단적 조건을 적용하였을 시 정확도가 크게 떨어지는 연구적 한계가 존재하였다.

머신러닝 기반의 접근법은 다양한 건설재료의 현장적용에 있어 물질의 안정성과 관련한 근거 및 신뢰성을 확보하는데 도움을 줄 수 있을 것으로 사료된다. 또한 대부분의 건설공사에 필수적으로 활용되는 시멘트계 재료의 데이터 상관관계 파악과 메커니즘 규명을 통한 과학적 지식의 진보에 기여하여, 향후 높은 기술적 파급력이 기대된다.

감사의 글

이 논문은 충북대학교 국립대학육성사업(2022) 지원을 받아 작성되었음.

참고문헌

- Basha, S. M. and Rajput, D. S. (2019). Survey on evaluating the performance of machine learning algorithms: past contributions and future roadmap. *In Deep Learning and Parallel Computing Environment for Bioengineering Systems*, 153-164.
- Schmidt, J., Marques, M. R., Botti, S., and Marques, M. A. (2019). Recent advances and applications of machine learning in solid-state materials science. *npj Computational Materials*, 5(1), 1-36.
- Xu, Y., Zhou, Y., Sekula, P., and Ding, L. (2021). Machine learning in construction: From shallow to deep learning. *Developments in the Built Environment*, 6, 100045.
- Chou, J. S., Tsai, C. F., Pham, A. D., and Lu, Y. H. (2014). Machine learning in concrete strength simulations: Multi-nation data analytics. *Construction and Building materials*, 73, 771-780.
- Bang, J., Park, S., and Jeon, H. (2022). Piezoresistive Prediction of CNTs-Embedded Cement Composites via Machine Learning Approaches. *Computers Materials and Continua*, 71(1), 1503-1519.
- Kim, H. K., Lim, Y., Tafesse, M., Kim, G. M., and Yang, B. (2022). Micromechanics-integrated machine learning approaches to predict the mechanical behaviors of concrete containing crushed clay brick aggregates. *Construction and Building Materials*, 317, 125840.
- Degefa A. B., Yang, B., Park, S. (2022). Predicting the degree of reaction of supplementary cementitious materials in hydrated portland cement, under review.
- Kim, H. K., Park, I. S. and Lee, H. K. (2014). Improved piezoresistive sensitivity and stability of CNT/cement mortar composites with low water-binder ratio. *Composite Structures*, 116, 713-719.
- Cormos, C. C. (2022). Decarbonization options for cement production process: A techno-economic and environmental evaluation. *Fuel*, 320, 123907.
- Bullard, J. W., Garboczi, E. J., Stutzman, P. E., Feng, P., Brand, A. S., Perry, L., Hagedorn, J., Griffin W., and Terrill, J. E. (2019). Measurement and modeling needs for microstructure and reactivity of next-generation concrete binders. *Cement and Concrete Composites*, 101, 24-31.
- Searson, D. P., Leahy, D. E., and Willis, M. J. (2011). Predicting the toxicity of chemical compounds using GPTIPS: a free genetic programming toolbox for MATLAB. *Intelligent Control and Computer Engineering* (pp. 83-93). Springer. 