

기계학습을 이용한 다중물리해석 결과 예측

Prediction of Multi-Physical Analysis Using Machine Learning

이근명*, 김기영*, 오 웅**, 유성규**, 송병석**
Keun-Myoung Lee*, Kee-Young Kim*, Ung Oh**, Sung-kyu Yoo**, Byeong-Suk Song**

Abstract

This paper proposes a new prediction method to reduce times and labor of repetitive multi-physics simulation. To achieve exact results from the whole simulation processes, complex modeling and huge amounts of time are required. Current multi-physics analysis focuses on the simulation method itself and the simulation environment to reduce times and labor. However this paper proposes an alternative way to reduce simulation times and labor by exploiting machine learning algorithm trained with data set from simulation results. Through comparing each machine learning algorithm, Gaussian Process Regression showed the best performance with under 100 training data and how similar results can be achieved through machine-learning without a complex simulation process. Given trained machine learning algorithm, it's possible to predict the result after changing some features of the simulation model just in a few second. This new method will be helpful to effectively reduce simulation times and labor because it can predict the results before more simulation.

요 약

본 논문에서는 기계학습 알고리즘을 이용하여 다중물리(Multi-physics) 시뮬레이션의 반복 횟수를 획기적으로 줄일 수 있는 다중물리해석 예측 방법을 제안한다. 기존의 다중물리해석 시뮬레이션의 경우 소요되는 시간과 노력을 줄이기 위해 시뮬레이션 자체에 대한 방법과 환경 개선에 초점이 맞추어져 있으나 본 논문에서는 다중물리 시뮬레이션 결과를 기계학습 알고리즘으로 학습하여 추가적인 시뮬레이션을 수행하지 않고 학습된 기계학습 알고리즘을 사용하여 수십분에서 수시간에 걸리는 다중 물리 해석과 유사한 결과를 수초 내에 예측할 수 있음을 보였다. 기계학습 알고리즘 간의 성능을 비교하여 다중물리해석에 적합한 기계학습 알고리즘을 확인하였으며 가장 우수한 성능을 보인 가우시안 프로세스 회귀(Gaussian Process Regression)의 경우 100개 이하의 학습 샘플만으로도 우수한 예측 결과를 얻어낼 수 있음을 확인하였다. 제안하는 방식을 통해 시뮬레이션을 하고자 하는 모델의 형상이나 재질이 변경될 경우 기존의 시뮬레이션 결과로 학습된 알고리즘이 있다면 시뮬레이션을 반복 수행하기 전에 알고리즘을 이용하여 결과를 예측할 수 있어 시뮬레이션의 반복 횟수를 줄일 수 있을 것으로 기대한다.

Key words : Multi-physics, Machine Learning, Multi-layer perceptron, Gaussian Process, M5P Model Tree

* Smart Device Center, CEWIT Korea

** Certificate & Test Center, CEWIT Korea

★ Corresponding author songbs@cewit.re.kr

Manuscript received Feb 12, 2016; revised Mar 18, 2016; accepted Mar 22, 2016

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.

1. 서론

현실 세계에서 일어나는 물리적 현상은 여러 가지 물리현상이 공존하며 상호 작용하는 다중물리(Multi-physics)현상을 수반한다. 도선에 전류가 흐르면서 발생한 열이 PCB 기판을 휘어지게 하는 경우와 같이 전자기, 열, 구조 등 성질이 다른 물리적 변화가 다른 물리적 성질 변화에 영향

을 미치는 경우가 그 예이다. 각 물리계는 서로 다른 물리법칙과 지배방정식이 존재하며 이를 정확하게 계산하기 위해 전산해석 분야에서는 각 물리계별로 적합한 해석 기법을 채택하여 보다 현실에 가까운 결과를 얻기 위한 기법들을 개발하고 있다. 최근 많은 시물레이션 툴들이 다중물리해석을 지원하고 있으나 서로 다른 계산 해를 가지는 여러 개의 해석 프로그램을 이용하여 계산된 데이터를 반복적으로 주고받아야 하는 어려움이 있고 이는 상당한 계산시간을 요구하게 된다[1].

전기전자, 열, 구조해석 분야에서 대표적인 시물레이션 툴인 ANSYS[2]의 경우 전자기 해석 툴인 HFSS[3]를 이용한 전기해석의 결과를 열해석 툴인 Icepak[4]에서 넘겨받아 발열량을 계산하고 계산된 발열량을 구조해석툴인 Mechanical[5]에서 넘겨받아 열에 의한 변형량을 산출하는 순차적 해석 방법이 한 예이다. 이런 툴 간의 연동은 Workbench[6] 내에서 연동이 가능하도록 환경이 구성되어 있으나 연동되는 해석 툴마다 별도의 모델링을 해야 하고 다양한 환경 변수, 메쉬(mesh) 구성 등이 제대로 설정되지 못할 경우 해석 결과의 오차가 커지던지 오류가 있을 경우 시물레이션 진행 자체가 되지 않아 해석에 적지 않은 시간이 걸리게 된다. 예를 들어 전기해석 툴인 HFSS에서 사용한 모델링 내용은 메쉬 생성 방식의 차이로 인해 Icepak에서 그대로 사용할 수 없다. HFSS에서 사용한 모델은 모델링 툴을 이용하여 수정 후 Icepak으로 넘겨주어야만 한다. 이러한 과정을 통해 모델링을 넘겨받았다고 하더라도 형상이 바뀔 경우 메쉬를 비롯하여 필요한 설정을 다시 해주어야 한다. 따라서 형상이 조금 바뀔 경우 시물레이션을 하기 위해 준비하고 설정하는 시간이 매우 길어지게 되어 여러 가지 상황에 대한 다양한 시물레이션을 진행해 보고자 하는 경우 어려움이 있다.

이러한 문제를 해결하기 위한 다양한 다중물리 해석 소프트웨어들이 연구 개발되고 있으나 물리 해석방법의 개선과 통합개발환경 구성에 초점이 맞추어져 있고 다른 물리계에 각각의 지배방정식이 존재하는 다중물리해석의 특성상 획기적인 개선은 쉽지 않은 문제이다.

본 논문에서는 다중물리해석 결과를 기계학습

알고리즘을 이용하여 학습하고 학습된 알고리즘이 다중물리해석 결과를 예측할 수 있음을 검증하여 기계학습이 다중물리 시물레이션에 적용될 수 있음을 보였다. 이는 현실세계에서는 통합될 수 없는 개별 물리계의 지배방정식이 기계학습을 통해 가상의 단일 방정식으로 나타낼 수 있음을 의미한다. 또한 기계학습 알고리즘 간의 예측 성능에 대한 비교를 통해 다중물리 시물레이션에 적합한 기계학습 알고리즘을 확인하였다. 구조를 바꾸어 가며 결과를 예측해야 하는 시물레이션의 경우 시물레이션이 반복될수록 정확도 높은 알고리즘을 확보할 수 있게 되어 시물레이션을 하지 않고도 시물레이션 결과에 근접한 예측이 가능하게 될 것이다.

II. 본론

1. 다중물리해석의 기계학습 모델링

가. 다중물리해석

본 논문에서 기계학습을 적용한 다중물리해석은 도선에 흐르는 전류에 대한 전기해석과 열해석으로 구성된다. 전기해석에서 전류에 의한 열손실 결과를 추출하고 이를 열해석에서 넘겨받아 해석을 수행하면 열평형이 이루어진 상태에서 도선의 최대 온도를 구할 수 있다. 이러한 다중물리해석은 기하학적 형상과 물성을 입력으로 하고 온도를 출력으로 하는 함수로 표현될 수 있으며 이러한 입출력 관계는 기계학습 알고리즘의 레이블로 모델링 할 수 있다. (그림 1)

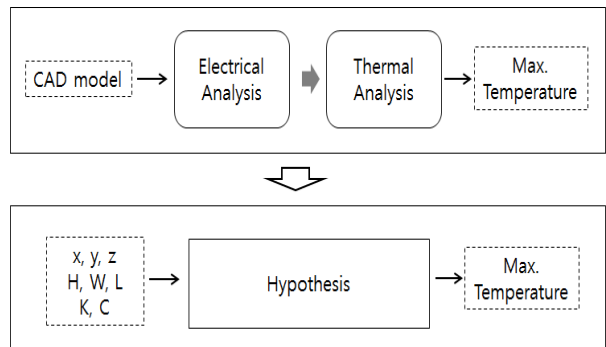


Fig. 1. Machine Learning Modeling of Multi-physical Analysis

그림 1. 다중물리해석의 기계학습 모델링

나. 실험 모델 형상

실험에 사용된 모델의 형상은 그림 2 와 같다.

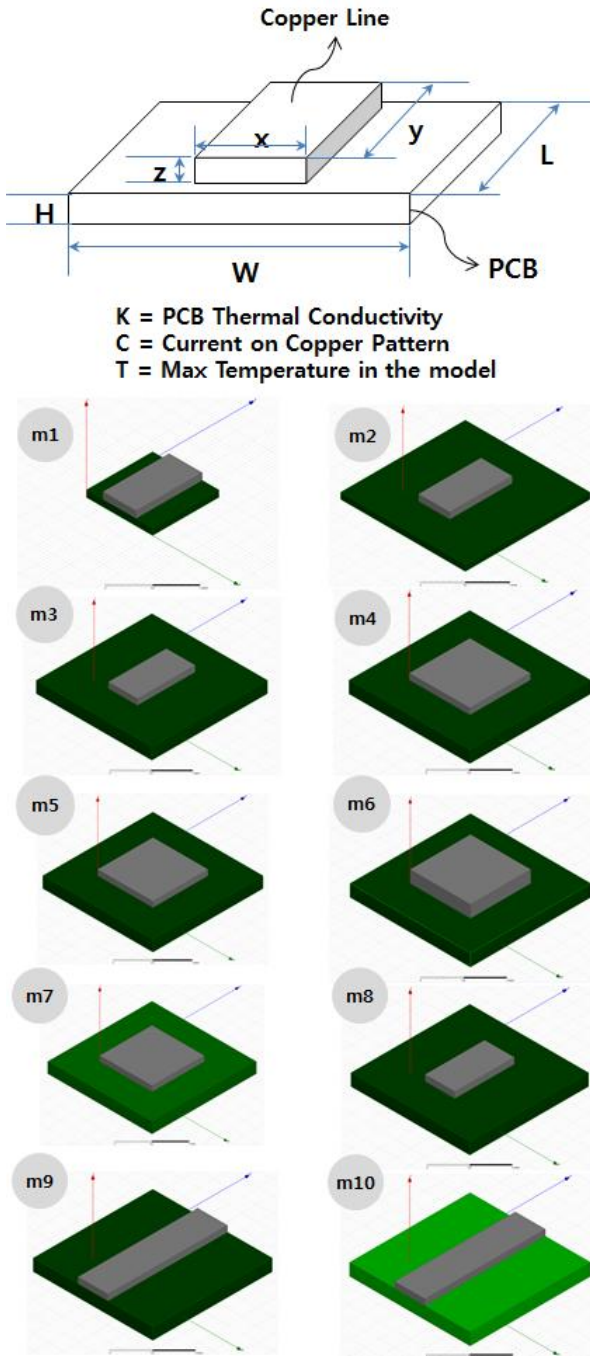


Fig. 2. Geometry of Test model
 그림 2. 테스트 모델의 형상

FR-4 재질의 PCB 기판과 기판 상에 형성된 구리 재질의 신호선의 형태로 일반적인 PCB 기판의 구성 요소에서 최소 단위의 블록이라고 할 수 있다. 모델은 PCB 기판의 가로(W), 세로(L), 높이(H)와 도선의 가로(x), 세로(y), 높이(z) 의 6가지 변수를 가지며 모델 형상에 따라 x, y, z, W,

L, H 의 변수 값이 달라지게 된다. 실제 시뮬레이션 시 목표로 하는 특성을 얻기 위해 모델의 형상과 특성을 조금씩 변화시키게 되는데 본 논문에서는 이런 경우를 가정하여 그림 2와 같이 m1부터 m10 까지 형상이 다른 10가지 모델을 선정하였으며 특성의 차이는 아래 표 1과 같다.

Table1. Feature of Test Models

표 1. 테스트 모델의 특성

Model	x	y	z	W	H	L	K
m1	0.5	0.1	1	1	0.1	1	0.35
m2	0.5	0.1	1	1	0.1	2	0.35
m3	0.5	0.5	1	2	0.1	1	0.35
m4	0.5	0.1	1	2	0.2	1	0.35
m5	1	0.1	1	2	0.2	1	0.35
m6	1	0.2	1	2	0.2	1	0.35
m7	1	0.2	1	2	0.2	1	0.3
m8	0.5	0.1	1	2	0.2	1	0.3
m9	0.5	0.1	2	2	0.2	1	0.3
m10	0.5	0.1	2	2	0.2	1	0.25

다. 변수 선정

모델의 형상과 특성에 따라 변화하는 최대온도(T)를 구하고자 하는 목표 값이라고 할 때 도선의 최대 온도에 영향을 미치는 변수들을 주요 변수로 선정하였다. 실험 모델은 PCB상에 전류가 흐르는 도선이 자리한 형태로 형상, 열전도율, 입력 전류에 따라 온도가 변화하게 된다. 도선상에 전류가 흐르면 전류로 인해 발생한 열은 신호선과 PCB 형상, 열전도율의 차이로 인해 각 모델의 열전달 특성이 달라지게 된다. 전류가 일정할 경우 발생하는 열은 이러한 전달 특성의 차이로 인해 주위로 전달되어 열평형 상태에 이르게 된다. 열평형 상태에 이르렀을 때의 모델 내 최고 온도(T)가 시뮬레이션을 통해 구하고자 하는 목표 값이다. 도선의 발열량은 전류의 공급에 비례하며 도체에 흐르는 전류가 정해지면 체적내의 발열량이 계산된다. 발생한 열은 열전도도에 따라 도선과 PCB를 통해 방출된다. 따라서 앞서 기술된 도선과 PCB의 형상에 대한 6가지 변수와, PCB의 열전도율(K), 전류(C)를 출력변수인 최대 온도(T)에 영향을 주는 입력변수로 선정하였다. 실험 시 도선의 열전도율과 같이 온도

변화에 영향이 작은 변수들은 제외하여 모델을 단순화하였다 (표 2).

Table2. Input and Output Variable

표 2. 입력 / 출력 변수

Category	Variable Name
Input Variable	x : Line Length
	y : Line Width
	z : Line Height
	H : PCB Length
	W : PCB Width
	L : PCB Height
	K : PCB thermal conductivity
	C : Current
Output Variable	T : Max. Temperature (in the line)

2. 데이터 셋 생성

기계학습 알고리즘을 학습하기 위한 데이터 셋은 목표값인 최대온도를 예측하기 위해 최대온도를 출력변수로 하고 온도에 영향을 미치는 변수들을 입력변수로 한다. 본 논문에서는 그림 2의 10가지 테스트 모델과 전류 및 열전도율의 변화를 조합하여 다중 물리 해석을 수행하여 100개의 데이터 셋을 생성하였다. 학습에 사용되는 데이터의 개수가 많을수록 생성된 알고리즘의 예측 정확도가 높아질 수 있으나 실제 시뮬레이션 상황을 고려할 때 유사 형상에 대한 시뮬레이션을 최대 100회로 가정하였다. 시뮬레이션을 진행하는 경우는 많지 않으므로 최대 100개의 데이터 셋을 이용하여 기계학습 알고리즘을 시험하는데 사용하였다. 8개의 입력변수에 대한 다변량 데이터에 대한 출력변수의 변화를 시각화하기 위해 그림 3의 평행좌표도[7]를 사용하였다. 입력변수의 값이 반복되는 경우가 있고 평행좌표도그래프의 특성상 여러 변수의 값을 도표 상에 한꺼번에 표현하므로 그래프가 겹쳐서 잘 보이지 않게 되는 경우가 있기 때문에 이를 피하기 위해 노이즈를 추가하여 데이터 값이 겹치지 않도록 표현하였다. m1부터 m10 까지 각 그룹별로 갈색, 주황, 노랑, 파랑, 연두, 군청, 연하늘, 라임, 보라, 빨강의 색상이 할당되어 있다. 8개의 입력변수의 조합으로 구성된 테스트 모델별로 인가되는 전류의

크기에 따라 출력변수인 최대 온도 값이 변화하고 있음을 볼 수 있으며 온도의 경우 고온 쪽보다 저온 쪽의 샘플의 수가 더 많아 알고리즘은 저온 쪽에서 더 좋은 성능을 보일 것으로 예상할 수 있다.




Fig. 3. Parallel coordinates plot of data set

그림 3. 데이터 셋의 평행좌표도

3. 기계학습을 이용한 학습 및 예측

본 논문에서는 알고리즘의 학습을 위해 대표적인 데이터마이닝 소프트웨어인 Weka[8]를 사용하였다. 학습에 사용된 알고리즘으로는 다층퍼셉트론 (MLP, Multi-Layer Perceptron), 선형회귀 (Linear Regression), M5P 트리 모델 (M5P Tree Model), 가우시안 프로세스 회귀 (Gaussian Process Regression)을 이용하여 데이터 셋을 학습하였다. 생성된 100개의 데이터 셋에 대하여 크로스 밸리데이션 (Cross-Validation)을 통해 각 알고리즘의 성능을 평가하였다.

가. 다층 퍼셉트론 (MLP, Multi Layer Perceptron)

다층 퍼셉트론은 대표적인 인공신경망 (Artificial Neural Network) 모델로 입력층 (Input layer), 은닉층 (hidden layer), 출력층 (Output layer)의 3종류의 레이어로 구성된다.

다층퍼셉트론은 목표값과 출력값의 차이를 은닉층에 반영하여 웨이트를 변경하는 오류역전파 알고리즘(Error Back Propagation)을 이용하여 신경망을 학습하게 된다. 이 과정을 반복할수록 보다 높은 정확도를 갖게 되므로 학습 횟수가 성능에 큰 영향을 미치게 된다.

은닉층이 2~3개인 경우가 다층 퍼셉트론, 은닉층이 4~30개 정도로 많은 경우를 심층신경망(Deep Neural Network, DNN)이라고 한다[9]. 3개 이하의 레이어를 갖는 다층 퍼셉트론에 비해 심층신경망은 많은 수의 은닉층을 학습시키기 위한 대량의 트레이닝 데이터 셋과 컴퓨팅 파워가 요구되어 본 논문에서 해결하고자 하는 바와 같이 최소한의 시뮬레이션 데이터를 이용하여 예측 알고리즘을 생성하기에는 적합하지 않다.

다층퍼셉트론의 입력층으로는 앞서 선정된 입력변수를, 출력층으로 출력변수를 할당하였다. 은닉층과 노드(Node)의 수, 학습 횟수에 따라 성능의 차이가 생기게 되며 본 논문에서 최적의 성능을 나타내는 경우는 히든 레이어 수가 1인 경우 노드의 수는 10개, 학습은 5,000 회의 경우이다 (표 3).

최적 성능을 나타내는 경우를 보면 상관계수는 0.9995, RMSE (Root Mean Square Error)는 0.8108 이다. 알고리즘을 이용한 예측값과 실제 시뮬레이션을 수행한 값을 비교한 결과는 그림 4와 같다. 왼쪽 하단에서 오른쪽 상단 방향의 대각선이 예측치와 시뮬레이션 결과가 동일한 경우이며 대각선으로부터 멀어질수록 예측값이 시뮬레이션 값을 잘 반영하지 못한다고 할 수 있다.

Table3. Performance according to Parameters

표 3. 패러미터 별 성능

No. of Hidden Node	Epoch	Correlation Coefficient	RMSE
8	500	0.9979	1.5548
10	500	0.9979	1.5521
12	500	0.9975	1.6744
8	2,000	0.9987	1.2938
10	2,000	0.9987	1.2298
12	2,000	0.9987	1.2041
8	5,000	0.9992	1.0693
10	5,000	0.9995	0.8108
12	5,000	0.9986	1.3441

다층퍼셉트론의 출력변수가 저온인 경우가 고온인 경우보다 비교적 잘 맞는 결과를 보이고 있

으며 이는 학습에 사용된 데이터 셋이 고온 부분의 데이터가 부족하기 때문으로 볼 수 있다.




Fig. 4. Prediction performance of Multi-layer perceptron (HN = 10, Epoch = 5000, CC = 0.9995, RMSE = 0.8108)

그림 4. 다층 퍼셉트론 예측 성능

(HN = 10, Epoch = 5000, CC = 0.9995, RMSE = 0.8108)

성능이 비교적 낮은 경우인 8 노드, 500 학습의 경우의 예측 결과도 시뮬레이션 결과와 크게 다르지 않음을 볼 수 있다 (그림 5).




Fig. 5. Prediction performance of Multi-layer perceptron (HN = 8 Epoch = 500, CC = 0.9979, RMSE = 1.5548)

그림 5. 다층 퍼셉트론 예측 성능

(HN = 8 Epoch = 500, CC = 0.9979, SE = 1.5548)

나. 선형회귀 (LR, Linear Regression)

도출된 선형회귀식은 아래 식 (1)과 같고 예측 성능은 그림 6과 같다. 저온과 고온에 이르는 전체 영역에서 다층퍼셉트론의 결과와 비교하여 예측치가 많이 벗어나고 있음을 볼 수 있으며 이는 변수의 수가 많고 입출력 간에 선형적인 특성을 띄지 않는 데이터 셋의 특성으로 인한 선형회귀의 한계라고 볼 수 있다.

$$T_{exp} = 9.2853x - 33.1923y - 9.9191W + 6.3918C + 35.1642 \quad (1)$$

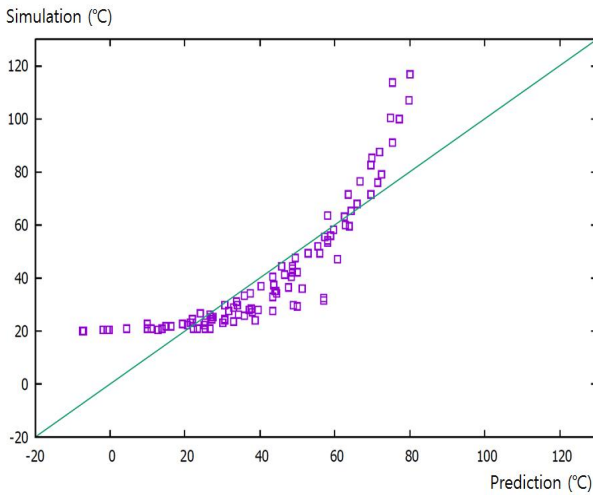


Fig. 6. Prediction performance of Linear Regression

(CC = 0.8614, RMSE = 12.0683)

그림 6. 선형 회귀 예측 성능

(CC = 0.8614, RMSE = 12.0683)

다. M5P 트리 (M5P model Tree)

M5P 는 회귀 모델 트리를 유도하기 위해 Quinlan의 M5 알고리즘[10]을 재구성한 것으로 모델 트리에서 각각의 가지가 선형회귀식을 가지는 구조로 되어있다. 트리와 회귀식의 장점을 결합한 방식으로 앞서 확인한 선형회귀식과 같이 전체 영역을 하나의 선형함수로 표현할 수 없는 경우에 적합한 알고리즘으로 더 크고 복잡하나 정확하다. M5P 는 결정 트리의 각 노드의 정보 획득량 (Information Gain)을 최대화하는 대신 각 부분집합 내의 변동성(variation)이 최소화 되도록 가지를 나눠준다. 가지치기 (pruning)를 할 때 내부 노드가 말단 노드가 되면서 노드의 내용이 회귀식으로 전환된다[11].

선형회귀식이 연결되는 부분의 경우 불연속 문제를 해결하기 위해 스무딩 (Smoothing) 과정을 거쳐 정확도를 높이게 된다[12]. 테스트 데이터 셋으로 학습된 M5P 트리 구조는 그림 7과 같으며 도출된 M5P 트리의 상관계수는 0.974, RMSE 는 5.4266 으로 다층퍼셉트론보다는 다소 떨어지나 선형회귀식과 비교하여 우수한 성능을 보인다(그림 8). 다른 기존 연구에서는 M5P 가 MLP 보다 우수한 결과를 나타낸 경우도 있으며 [13-15] 이는 데이터 셋의 특성에 따른 결과라고 할 수 있다.

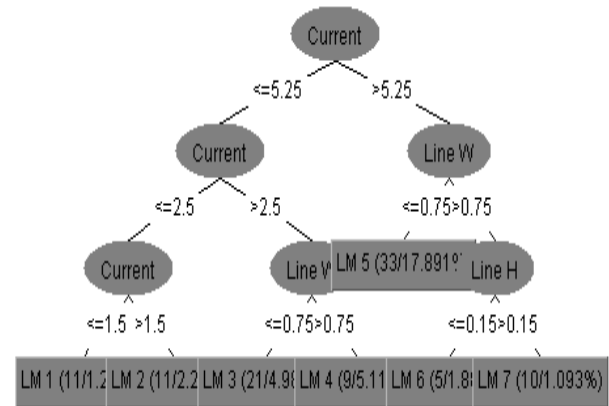


Fig. 7. M5P Tree Structure

그림 7. M5P 트리 구조

M5P 모델 트리에서 각 브랜치별로 도출된 선형 모델(LM, Linear Model) 회귀식은 식 (2)~(8)과 같다.

LM num: 1

$$T_{exp} = -11.3128x + 2.9025y - 3.0591W + 3.0293C + 24.8991 \quad (2)$$

LM num: 2

$$T_{exp} = -12.2767x + 2.9025y - 3.0591W + 3.0293C + 24.8753 \quad (3)$$

LM num: 3

$$T_{exp} = -12.3927x + 4.9781y - 5.4775z - 5.0075W - 5.1372H + 5.1477C + 23.0183 \quad (4)$$

LM num: 4

$$T_{exp} = -13.6154x + 4.0378y - 13.1459z - 4.4121W + 3.8189C + 27.5046 \quad (5)$$

LM num: 5

$$T_{exp} = -16.5884x + 12.5323y - 28.1639z \quad (6)$$

$$- 10.8532W - 68.2831H - 60.9565K$$

$$+ 10.2726C + 29.8158$$

LM num: 6

$$T_{exp} = -21.7997x + 7.5026y - 73.6358z \quad (7)$$

$$- 6.7957W - 31.6709H - 27.8564K$$

$$+ 6.3595C + 39.4639$$

LM num: 7

$$T_{exp} = -21.7997x + 7.5026y - 67.921z \quad (8)$$

$$- 6.7957W - 31.6709H - 27.8564K$$

$$+ 6.0839C + 39.5734$$




Fig 8. Prediction performance of M5P Tree
(CC = 0.974, RMSE = 5.4266)

그림 8. M5P 트리 예측 성능

(CC = 0.974, RMSE = 5.4266)

라. 가우시안 프로세스 회귀 (GPR, Gaussian Process Regression)

베이저안 비모수 (Bayesian nonparametric) 알고리즘 중 대표적 알고리즘인 가우시안 프로세스 회귀모델은 데이터의 레이블을 평균과 분산의 확률 분포로 예측하는 기계학습 모델이다. 예측 성능이 높은 반면 다른 회귀분석 모델에 비해 효율성 면에서 복잡도가 커서 대규모의 데이터를 다룰 경우 어려움이 있어 다양한 근사화 방법이 사용되고 있다[16]. 가우시안 프로세스 (GP)는 평균(Mean)과 공분산(Covariance)으로 정의될 수 있고 공분산은 하이퍼 패라미터 (Hyper-Parameter)로 규정된다. 학습 시에는 하이퍼 패라미터의 초기값을 주고 대수 한계우도 (log marginal likelihood)를 최소화하면서 반복적인 계산을 통해 최적의 하이퍼 패라미터를 찾는 학습과정을 가진다. 본 논문에서는 RBF 커널(Radial Basis Function Kernel)이 사용되었으

며 데이터를 학습하는 데 걸린 시간은 약 0.21 초로 M5P (0.16 초), LR (0 초) 에 비해 다소 길지만 MLP (1.24 초) 와 비교해서는 짧다. 데이터의 수가 많은 편이 아니므로 각 알고리즘 간에 큰 차이를 보이지는 않는다. 예측 성능은 그림 9와 같고 GPR의 상관계수는 0.9997, RMSE는 0.6346 으로 다층퍼셉트론보다 더 높은 예측 정확도를 나타내고 있다.(표 3).




Fig. 9. Prediction performance of Gaussian Process
(CC = 0.9997, RMSE = 0.6346)

그림 9. 가우시안 프로세스 예측 성능

(CC = 0.974, RMSE = 0.6346)

4. 다중물리해석의 예측 성능 검토

본 논문에서 가장 우수한 예측 성능을 보인 모델은 RMSE 가 0.6346 인 가우시안 프로세스 회귀 모델이다.(표 4)

Table4. Performance Comparison between Algorithm

표 4. 알고리즘 간 성능 비교

Algorithm	Correlation Coefficient	RMSE
Multi Layer Perceptron	0.9995	0.8108
M5P Tree	0.974	5.4266
Linear Regression	0.8614	12.0683
Gaussian Process	0.9997	0.6346

시뮬레이션 결과의 출력변수인 최대온도의 범위는 21.1~116.9℃ 이다. 학습 데이터 셋의 수가 100개 일 때 가우시안 프로세스 회귀의 RMSE 는 0.6346 로, 최저 온도에서의 시뮬레이션 결과 대비 예측 정확도는 96.99% 이다. 시뮬레이션 모델의 수정이 발생하였을 때 모델을 수정하고 시

물레이션을 돌려서 결과를 얻어내기 까지 소요되는 시간이 최소 수십분에서 수시간이 걸린다고 할 때 학습된 알고리즘을 이용하여 1초 내에 우수한 예측 정확도로 결과를 예상할 수 있다.

가우시안 프로세스 회귀 알고리즘의 데이터 셋의 수에 따른 성능은 그림 10과 같다. 데이터 셋의 갯수가 100개 아래로 줄어들 경우 예측 성능이 감소하는 것을 볼 수 있으며 예측 데이터의 범위와 응용 분야에 따라 적절한 예측 정확도를 확보할 수 있는 학습 데이터의 개수는 줄어들 수 있을 것이다.

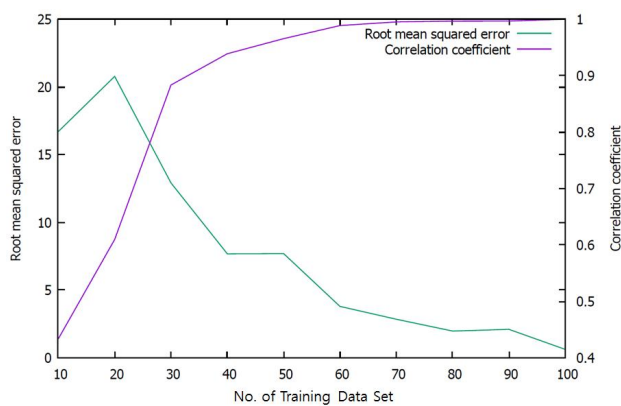


Fig. 10. Prediction performance of Gaussian Process according to the number of training data set

그림 10. 트레이닝 데이터 셋의 수에 따른 가우시안 프로세스 예측 성능

III 결론

본 논문에서는 다중물리해석 시물레이션 결과를 기계학습 알고리즘으로 학습하고 학습된 알고리즘을 이용하여 시물레이션을 하고자 하는 대상 모델이 수정되었을 경우 추가적인 시물레이션 없이 목표값을 예측할 수 있음을 확인하였다. 또한 다층퍼셉트론, 선형회귀, M5P 트리, 가우시안 프로세스 회귀 알고리즘 간의 성능을 비교하여 가우시안 프로세스 회귀 알고리즘이 다중물리해석에서 가장 좋은 성능을 보여줌을 확인하였다.

다중물리해석에 걸리는 시간과 노력을 줄이는 보조적인 수단으로써 기계학습이 보다 높은 예측 정확도를 가지며 실질적으로 활용되기 위해서는 데이터의 특성에 따라 알고리즘별로 적합한 패러미터 값의 선정이 요구된다. 또한 단순화된 모델이 아닌 실제 모델에 대한 시물레이션에 기계학습이 적용될 수 있기 위해서는 복잡하면서도 다

양한 형상에 대한 일반화와 이러한 다양한 요소들이 복합적으로 연결된 경우에 대한 연구가 필요할 것이다.

References

- [1] Youngtaek Im, “Multi-physics analysis case using ANSYS software”, *Journal of KSME*, Vol. 54, No. 6, p46, June 2014
- [2] <http://www.ansys.com/About-ANSYS>
- [3] ANSYS Product Brochure, “ansys-hfss-brochure-16.0.pdf”, ANSYS Incorporated, 2016
- [4] ANSYS Product Brochure, “ansys-icepak-brochure-14.0.pdf”, ANSYS Incorporated, 2011
- [5] ANSYS Product Brochure, “ansys-mechanical-suite-brochure.pdf”, ANSYS Incorporated, 2011
- [6] ANSYS Product Brochure, “workbench-platform-12.1.pdf”, ANSYS Incorporated, 2011
- [7] https://en.wikipedia.org/wiki/Parallel_coordinates
- [8] <http://www.cs.waikato.ac.nz/ml/weka/>
- [9] Cheolho HanO, Hanock Kwak, Sangwoong Yoon, Munbo Shim, Byoung-Tak Zhang, “Optimization by Neural Networks Learned from Minimum Function Evaluations”, *Korea Computer Congress 2015 (KCC 2015)*, pp867-869, CheJu Island, Korea, June 2015
- [10] Ross J. Quinlan, “Learning with Continuous Classes”, 5th Australian Joint Conference on Artificial Intelligence, pp343-348, Singapore, Nov 1992
- [11] Wang ,Y., Witten, I. H., “Induction of model trees for predicting continuous classes”, *9th European Conference on Machine Learning*, Prague, Czech Republic, April 1997
- [12] Chengjun Zhan, Albert Gan, and Mohammed Hadi, “Prediction of Lane Clearance Time of Freeway Incidents Using the M5P Tree Algorithm”, *IEEE Transactions on Intelligent Systems*, Vol. 12, No. 4, Dec 2011
- [13] Khaled Bashir Shaban, Abdullah Kadri, Eman Rezk, “Urban Air Pollution Monitoring System with Forecasting Models”, *Sensors Journal, IEEE*, Vol.PP, Issue.99, pp1, Jan 2016
- [14] E. K. Onyari, F. M. Ilunga, “Application of MLP Neural Network and M5P Model Tree in Predicting Streamflow: A Case Study of


Luvuvhu Catchment, South Africa”, *International Journal of Innovation, Management and Technology*, Vol.4, No. 1, p15, Feb 2013

[15] Seung-Woo Kim, Kyung-Duck Suh, “Prediction of Stability Number for Tetrapod Armour Block Using Artificial Neural Network and M5’ Model Tree”, *Journal of Korean Society of Coastal and Ocean Engineers*, Vol.23, No.1, pp109-117, Feb 2011

[16] Park sunho, Seungjin Choi, “Hierarchical Gaussian process model for regression”, *Korea Computer Congress 2010 (KCC 2010)*, pp66-67, CheJu Island, Korea, July 2010

BIOGRAPHY

Keun-Myoung Lee (Member)



1999 : BS degree in Electronic Engineering, Sogang University.
2001 : MS degree in Electronic Engineering, Sogang University.

2001~2010 : Senior Engineer, Samsung Electronics.
2010~current : Senior Research Engineer, CEWIT Korea

Kee-Young Kim (Member)



2004 : BS degree in Computer Science & Engineering, Seoul National University
2006 : MS degree in Electronics & Computer Engineering, Seoul National

University

2015 : MS degree in Computer Science, Stony Brook University

2006~2010 : Research Engineer, Samsung Electronics

2011~current : Assistant Researcher, CEWIT Korea

Ung Oh (Member)



2000 : BS degree in Mechanics and Automobiles Engineering, Doowon Technical University College.

2009~2013 : Research Engineer, Lumi Micro

2013~current : Assistant Researcher, CEWIT Korea

Sung-Kyu Yoo (Member)



2003 : BS degree in Automobile System, Kyung Moon University.
2010 : MS degree in Industrial & Automobiles Engineering, Kyung Hee

University.

2003~2013 : Assistant Researcher, KETI

2013~current : Assistant Researcher, CEWIT Korea

Byeong-Suk Song (Member)



1992 : BS degree in Material Engineering, Hanbat National University.

1997 : MS degree in Industrial & Management Systems Engineering, Kyung

Hee University.

2010 : PhD degree in Industrial & Management Systems Engineering, Kyung Hee University.

1985~1993 : Senior Researcher, ADD

1993~2011 : Principal Research Engineer, KETI

2011~current : Principal Research Engineer, CEWIT Korea