

CAE와 Decision-tree를 이용한 사출성형 공정개선에 관한 연구

황순환¹, 한성렬², 이후진^{1*}

¹한성대학교 스마트융합컨설팅학과, ²공주대학교 금형설계공학과

A Study on the Improvement of Injection Molding Process Using CAE and Decision-tree

Soonhwan Hwang¹, Seong-Ryeol Han², Hoojin Lee^{1*}

¹Department of Smart Convergence Consulting, Hansung University

²Department of Metal Mold Design Engineering, Kongju National University

요약 현재 사출성형분야의 Computer Aided Testing(CAT) 방법론으로 CAE(Computer Aided Engineering)를 이용한 수치 해석 기법이 주를 이루고 있다. 그러나 최근 시뮬레이션에 추가로 인공지능 기법을 응용하는 방법론이 연구되고 있다. 우리는 지난 연구에서 다양한 Machine Learning 기법을 활용하여 사출 성형 공정에 따른 변형 결과를 비교하였으며, 최종적으로 MLP(Multi-Layer Perceptron) 예측모델을 생성하였고, HMA(Hybrid Metaheuristic Algorithm)를 이용하여 최적화 결과를 얻어냈다. 그러나 MLP는 예측 성능이 우수한 반면 블랙박스과 같이 결정 과정에 대한 설명이 부족하다. 본 연구에서는 Radiator Tank 부품에 대하여 사출 성형 해석 소프트웨어인 Autodesk Moldflow 2018을 이용하여 수치 해석 기법으로 데이터를 생성하고, Machine Learning 소프트웨어인 RapidMiner Studio version 9.5를 활용하여 여러 Machine Learning Algorithms 모델을 생성하여 평균 제곱근 오차를 비교하였다. Decision-tree는 Root Mean Square Error(RMSE) 값이 다른 Machine Learning 기법에 비해 양호한 예측 성능을 갖추고 있었다. Decision-tree의 크기를 결정하는 Maximal Depth에 따라 분류 기준을 높일 수 있지만 복잡성도 함께 증가시켰다. Decision-tree를 이용하여 구속 조건을 만족하는 중간 값을 선정하여 시뮬레이션을 진행한 결과 기존의 시뮬레이션만 진행한 것보다 7.7%의 개선 효과가 있었다.

Abstract The CAT methodology is a numerical analysis technique using CAE. Recently, a methodology of applying artificial intelligence techniques to a simulation has been studied. A previous study compared the deformation results according to the injection molding process using a machine learning technique. Although MLP has excellent prediction performance, it lacks an explanation of the decision process and is like a black box. In this study, data was generated using Autodesk Moldflow 2018, an injection molding analysis software. Several Machine Learning Algorithms models were developed using RapidMiner version 9.5, a machine learning platform software, and the root mean square error was compared. The decision-tree showed better prediction performance than other machine learning techniques with the RMSE values. The classification criterion can be increased according to the Maximal Depth that determines the size of the Decision-tree, but the complexity also increases. The simulation showed that by selecting an intermediate value that satisfies the constraint based on the changed position, there was 7.7% improvement compared to the previous simulation.

Keywords : Artificial Neural Networks, Computer Aided Engineering, Decision-tree, Injection Molding, Multi-Layer Perceptron, Warpage

본 논문은 한성대학교 교내학술연구비로 수행되었음.

*Corresponding Author : Hoojin Lee(Hansung Univ.)

email: hjlee@hansung.ac.kr

Received January 6, 2021

Revised January 29, 2021

Accepted April 2, 2021

Published April 30, 2021

1. 서론

최근 제조 공정을 컴퓨터로 미리 검토하고 최적화하는 CAT(Computer Aided Testing)에 대한 관심이 늘어나고 있다. 현재 사출성형분야의 CAT 방법론으로 CAE(Computer Aided Engineering)를 이용한 수치 해석 기법이 주를 이루고 있다. 사출성형분야의 수치해석은 Table 1과 같이 다양한 물성정보와 공정변수, 그리고 형상정보를 유한요소로 나누어 가정 기반의 지배방정식을 이용하여 계산하는데 형상이나 조건에 따라 1회 시뮬레이션을 진행하는데 1시간에서 수 일이 소요된다. 이러한 시간적 제약으로 인하여 많은 실험을 할 수 없어 실험하지 않은 변수와 조건의 결과가 무시되어 수치 해석 자체의 성능에 대한 문제가 제기되고 있다.

우리는 지난 연구에서 다양한 Machine Learning 기법을 활용하여 사출 성형 공정에 따른 변형 결과를 비교하였으며, 최종적으로 MLP(Multi-Layer Perceptron) 예측모델을 생성하였고, HMA(Hybrid Metaheuristic Algorithm)를 이용하여 최적화 결과를 얻어냈다[1]. 그러나 MLP는 신뢰성은 우수하지만 블랙박스과 같이 결정 과정에 대한 설명이 부족하여 생성된 결과나 예측에 대한 설명 즉 변수의 영향력 및 우선순위 등을 분석할 수 없고 이에 따라 신뢰성 문제가 제기될 때 내부 결정 과정을 사용자에게 이해시킬 수 없다.

최근 사출 성형 제조 공정에서 복잡한 불량률의 요인에 대하여 머신러닝기법으로 학습하여 잘못된 조건과 관련된 패턴에 대한 연구가 이루어지고 있다[2]. 사출 성형 공정을 통해 얻은 제품은 완제품이기 때문에 고품질이어야 하며, 수지의 온도나 성형 압력에 따라 품질이 달라진다[3]. 데이터 기반 품질 관리 기술은 스마트 공장 구현을 위해 적극적으로 개발하고 있으며, 제조 프로세스 중 품질 예측 빅 데이터 분석으로 제조 환경에 좋은 영향을 주고 있다. 사출 공정 조건의 변화에 따른 양품과 불량품으로 분류하는 방법에 대한 연구 중 의사 결정 나무(Decision-tree)는 설명 가능한 머신러닝 기법으로 널리 사용되고 있다[4]. 사출 성형 불량률의 복잡한 상관관계로 인해 최종 제품 품질에 영향을 미치는 변수를 의사 결정 나무와 인공 신경망(ANN), 딥러닝(MLP) 기법으로 학습하고 품질을 비교한 연구도 진행 되었다[5]. 위와 같은 연구는 현장의 데이터를 기반으로 진행되어 데이터를 확보하기 위한 센서구입 및 실험장비를 제작하는 비용과 시간의 진입장벽이 있다. 또한 데이터 분석을 위한 코딩 전문가 및 통계 전문 인력이 필요하다. 본 연구는 시뮬레이

션 기반으로 데이터를 확보하고, 인공지능 플랫폼 소프트웨어를 활용한 분석을 통해 저비용의 쉽고 빠른 CAT 방법론을 제시하기 위해, 자동차 Radiator Tank 부품의 사출공정 변화에 대하여 Machine Learning 기법 중 하나인 의사 결정 나무를 활용하여 형체력과 사출압력과 같은 구속 조건을 만족하는 휨 개선 공정을 제안하면서 설명 가능한 예측 모델을 작성하고자 한다.

2. 본론

2.1 연구 방법

Radiator Tank는 엔진블록 외곽을 순환시켜 가열된 냉각수를 냉각하는 Radiator의 외곽에 조립되는 부품이다. 이 부품은 자동차 경량화와 복잡성 그리고 생산성 향상을 위해 철강 재료에서 플라스틱으로 변경되었다. 플라스틱 재료의 그레이드는 Technyl One J60 X1 V30 Grey 7035인 PolyAmides66에 첨가제로 Glass fiber가 30% 함유된 수치 재료를 사용한다. Fig. 1은 Radiator Tank의 사출 생산 중 발생하는 휨 결과를 예측한 결과이다. 게이트가 중심에 위치하여 용융 수지가 제품에 주입될 때 방사 형태로 충전되다가 유동 선단이 벽면을 부딪치고 방향이 바뀌어 Glass fiber의 배향이 복잡해지면서 배향이 강한 부분은 수축이 낮고, 배향이 약한 부분은 수축이 높아 수축 편차로 휨이 발생하였다[6].

Table 1. Parameters of injection molding process

Tooling variable	Part/resin variable	Molding variable
Mold material	Size & thickness	Molding window
Shrinkage rate	Strength design	Mold temp.
Gate design	Assembly	Melt temp.
Runner design	Resin material	Injection time
Sprue design	Viscosity	Packing pressure
Hot/Cold runner	PvT	Packing time
Cooling line	Thermal property	V/P Switch over
Cooling temp.	Transition temp.	Machine spec.
Eject system	Ejection temp.	Machine condition
Air venting	Mechanical prop	Reproducibility
Cavity number	Filled or unfilled	Environment

Table 2와 같이 제한된 시간에 전역적인 조건을 검토하기 위해 지난 연구에서는 직교배열 (Orthogonal Array)에 따른 L108의 108 실험점을 생성하여 학습하

였고, 테스트를 위해 L18에서 L108과 겹치는 3점을 제외하고 15회 실험을 선정하여 테스트하였다.

Table 2. Process setting problem formulation

No.	Process setting Variables	Unit	Lower	Initial	Upper bound
x1	IT(Injection time)	sec	1	2	3
x2	PP(Packing pressure)	MPa	20	50	80
x3	PT(Packing time)	sec	5	10	15
x4	MeT(Melt temperature)	°C	270	290	310
x5	MoT(Mold temperature)	°C	60	80	100

이번 연구에서는 학습데이터와 테스트데이터를 80:20 비율로 학습 세트와 평가세트로 배분하였다.[7] 수치해석은 Autodesk사의 Moldflow Insight 2018를 이용하였으며, 3D Tetra mesh로 10개 Layer로 작성하여 총 1,187,104개를 사용하였다. 또한 제품의 중심에 사출 주입점을 설정하였다. 미성형이 발생하지 않는 조건을 위하여 사출 시간은 1초에서 3초를 선정하였으며, 보압 시간과 크기는 제품 외곽 사이즈가 가능한 범위로 결정하였다. 또한 수지의 온도와 금형 온도는 수치 회사에서 추천하는 범위를 사용하였다. 요구 사항을 충족시키기 위해 설계 문제를 아래와 같이 수학 문제로 공식화하였다. 식 (1)과 같이 설계 변수는 5개로 사출 시간(x1), 보압 크기(x2), 보압 시간(x3), 수지 용융 온도(x4), 금형 표면 온도(x5)이다. 본 실험의 목표는 식 (2)와 같이 휨 최소화이며 위치는 Fig. 1에서 같이 빨간색과 파란색으로 표현된 휨 결과이다. 구속 조건으로는 식 (3), (4)와 같이 형체력은 270ton 이하, 최대 사출압력은 80MPa 이하이다.

- Find: $x_n \ n=1, 2, 3, 4, 5$ (1)
- To minimize: Max_deflection (2)
- Subject to: Clamp_force \leq 270 (3)
- Max_pressure \leq 80 (4)

근사모형을 평가하는 도구로 기존 연구와 동일한 방법인 Root Mean Square Error(RMSE)를 사용하였다[8]. 식 (5)와 같이 θ 값은 시뮬레이션에서 얻은 값이며, θ' 는 근사모형의 예측 값이다. 예를 들어 시뮬레이션 상으로 예측한 휨 양은 4mm 인데, 근사 모형인 Decision-tree에서 예측한 값이 3.9mm라면 RMSE는 0.1mm 이다. 시뮬레이션 값과 근사모형의 차이를 양수로 만들어 수치화한 것이다. 즉 0 에 가까울수록 신뢰성이 높은 모델이다.




Fig. 1. Moldflow deflection result of radiator tank part

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\theta'_i - \theta_i)^2} \quad (5)$$

2.2 Decision-tree 모델 생성

Machine Learning 기법 분석을 위해 RapidMiner Studio version 9.5를 활용하였다. Fig. 2는 RapidMiner Software에서 Decision-tree의 모델을 생성하고 평가하기 위한 Process를 구성하여 나타내고 있다. 'Read CSV'는 Autodesk Moldflow 2018를 통해 생성한 123회 Case 예측 결과를 CSV파일 형식으로 불러온다. 'Set Role'은 휨 결과인 'Sum X'를 학습용 속성으로 목표 역할을 지정한다. 그리고 'Split Data'를 통해 학습 데이터를 80%, 테스트 데이터를 20%로 나눈다. 'Decision-tree'는 분류를 위해 각 노드는 수치 목표 값의 추정에 대한 의사 결정을 작성하기 위한 모음으로 나무의 크기를 결정하기 위해 Maximal Depth를 변수로 지정한다. 매개 변수는 분리할 속성을 선택하는 기준으로 최소 제곱을 지정하여 실제 값과 평균 값 사이의 제곱 거리를 최소화하는 노드로 분할하여 학습한다. 'Apply Model'은 'Decision-tree'를 사용하여 학습한 모델로 'Split Data'의 테스트용 데이터를 평가한다. 'mod' 포트는 Decision-tree 학습 모델과 연결하고 'unl' 포트는 Split Data에서 테스트용으로 분리한 데이터로 연결한다. 그리고 Performance를 통해 회귀 모델의 통계 성능 평가를 진행한다.




Fig. 2. Process of Decision-tree analysis

3. 실험 평가 및 분석

3.1 실험 평가

우리가 사용하는 Decision-tree 기법 평가를 위해 Fig. 3은 휨 예측 성능에 대하여 5가지 머신러닝 기법과 비교 하였다. 평가 방법은 식 (5)에서 설명한 것과 같이 RMSE를 계산하였다. 휨 양의 평균이 4.5mm일 때 Gradient Boosted Trees의 RMSE가 가장 낮은 0.056mm이며 예측 값이 평균대비 1.24%의 변동성을 가진다. Decision-tree의 RSME는 0.094mm로 예측값이 평균대비 2.09%의 변동성을 가져 모두 양호한 신뢰 수준을 나타내고 있다.




Fig. 3. Compare of machine learning algorithms of sum X

사출 성형 압력 예측 성능 평가 결과 Decision-tree가 가장 예측 성능이 좋았으며 RMSE값은 1.24MPa으로 사출압력의 평균이 67.8MPa일 때 예측 값이 평균대비 1.83%의 변동성을 가져 양호한 신뢰 수준을 나타내고 있다.

요구되는 형체력 예측 결과 Decision-tree가 가장 예측 성능이 좋았으며 전체적으로 심한 편차가 발생하는 것을 확인하였다. RMSE값은 3.26Ton으로 형체력의 평균이 179Ton일 때 예측 값이 평균대비 1.82%의 변동성을 가져 양호한 신뢰 수준을 나타내고 있다.




Fig. 4. Compare of machine learning algorithms of injection pressure




Fig. 5. Compare of machine learning algorithms of clamp Force

결과적으로 Decision-tree 는 RMSE 값이 휨 예측은 0.094mm, 성형 압력은 1.24MPa, 형체력은 3.26Ton으로 다른 Machine Learning 기법에 비해 양호한 예측 성능을 갖추고 있었다.

3.2 실험 분석

우리는 Decision-tree의 크기를 결정하는 Maximal Depth에 따라 예측 성능 및 설명력의 변화를 연구하였다. Fig. 6과 같이 Maximal Depth를 3으로 설정할 경우 휨 최소화를 위해 PP(Packing Pressure)를 65MPa 초과, IT(Injection Time)을 1.5sec 이하로 설정해야 함을 확인하였다.




Fig. 6. Decision-tree result of deflection Maximal Depth 3

Fig. 7과 같이 Maximal Depth를 4로 설정할 경우 휨 최소화를 위해 PP를 65MPa 초과, IT을 1.5sec 이하, PT(Packing Time)을 7.5sec 이상으로 설정해야 함을 확인하였다. Maximal Depth 증가가 분류 기준을 높일 수 있지만 복잡성도 함께 증가하였다.




Fig. 7. Decision-tree result of deflection Maximal Depth 4

Fig. 8 ~ 9와 같이 형체력의 Decision-tree 결과에서 65MPa 초과일 때 구속 조건 값 270Ton을 넘어서고 있다. 이는 목표인 힘 최소화 조건과 구속조건인 형체력 조건이 상충되었으며, Maximal Depth를 변경해도 개선되지 않았다.




Fig. 8. Decision-tree result of clamp force Maximal Depth 3




Fig. 9. Decision-tree result of clamp force Maximal Depth 4

상충된 문제가 학습 데이터를 추가 했을 때 해결되는 지 평가하기 위해 추가 시뮬레이션을 진행하였다. 기존의 보압 크기는 20MPa, 50MPa, 80MPa을 진행하였으나 상충되는 영역인 60MPa과 70MPa 조건에 대하여 추가 실험을 하였고, 수지의 온도는 기존의 270℃, 290℃, 310℃에서 300℃와 290℃로 추가하였으며, 금형의 온도는 80℃로 한정하였고, 보압 시간은 기존의 5sec, 10sec, 15sec에서 12.5sec와 7.5sec를 적용하였다. Fig. 10와 같이 Maximal Depth를 3으로 했을 때 보압 조건을 75MPa이하로 적용해야 함을 확인하였다.




Fig. 10. Modified Decision-tree result of clamp force Maximal Depth 3

Fig. 11과 같이 Maximal Depth를 4로 적용 했을 때 형체력을 더 세분화 되게 분류 했지만 보압 조건을 75MPa이하로 적용해야 함은 변화가 없었다.




Fig. 11. Modified Decision-tree result of clamp force Maximal Depth 4

추가 실험을 통해 얻은 힘 최소화를 위한 예측 분석 결과 Fig. 12와 같이 Maximal Depth 3일 경우 기존의 65MPa 기준에서 75MPa 기준으로 변경되었다. Maximal Depth 4를 적용할 경우 Fig. 13와 같이 보압 크기 75MPa, 사출 시간 1.5sec 이하, 수지 온도 300℃ 이하일 때 힘 결과가 최소화 되었다.




Fig. 12. Modified Decision-tree result of deflection Maximal Depth 3




Fig. 13. Modified Decision-tree result of deflection Maximal Depth 4

구속 조건 중 하나인 사출 압력은 80MPa 이하가 되기 위해서 Fig. 14과 같이 Maximal Depth 3일 경우 수지의 온도가 280℃ 초과일 때로 예측되었다.




Fig. 14. Modified Decision-tree result of pressure at V/P switch over Maximal Depth 3

Fig. 15과 같이 Maximal Depth 4일 경우 Maximal Depth 3과 같이 수지의 온도가 280℃ 초과일 때로 예측되었다.




Fig. 15. Modified Decision-tree result of pressure at V/P switch over Maximal Depth 4

Decision-tree 결과를 기반으로 구속조건을 만족하는 힘 최소화를 위해 보압을 72.5MPa, 충전 시간을 1.25sec, 수지온도 290℃ 로 선정하여 시뮬레이션을 진행하였다. Table 3과 같이 CAE를 단독적으로 진행했을 때 123회의 시뮬레이션 중 가장 큰 힘이 예측된 것은 Case44로 5.207mm, 가장 작은 힘 예측 결과는 Case33으로 3.686mm지만 모두 구속조건에서 벗어났으며, 최종적으로 구속 조건을 만족하는 힘 양은 Case24로 4.253mm 이다. Decision-tree 기법을 활용한 공정 조건 개선을 적용하여 시뮬레이션을 진행한 결과(CAE of DT) 구속 조건은 만족하면서 힘 양이 3.924mm로 Case 24 대비 7.7% 개선되었다.

Table 3. Comparison of Decision-tree results

	Case study	CAE of case 44	CAE of case 33	CAE of case 24	CAE of DT
Variable	IT(sec)	2	1	1	1.25
	PP(MPa)	20	80	50	72.5
	PT(sec)	10	15	10	8.75
	MeT(℃)	270	290	310	290
	MoT(℃)	100	80	100	80
Result	FT(sec)	2.168	1.038	1.037	1.296
	V/P(MPa)	85.78	81.33	61.82	75.36
	CF(Ton)	104.1	297.4	184.6	267
	SumX(mm)	5.207	3.686	4.253	3.924

4. 결론

본 연구에서는 지속 가능한 플라스틱 제조 산업을 위해 환경 및 경제에 긍정적인 영향을 주기 위한 방법으로 성형성 및 제조 공정 최적화를 CAT를 이용하는 방법론을 제시하였다. CAE를 이용한 수치 해석 기법으로 데이터를 생성하고, 인공지능 기법의 한 축인 Machine Learning을 활용하여 모델을 생성하고 모델 별로 평균 제공된 오차를 비교하였으며, 설명이 가능한 Machine Learning 기법인 Decision-tree를 활용하여 힘 최소화를 위한 공정조건을 예측하였으며 아래와 같은 결론을 도출하였다.

1. Decision-tree는 RMSE 값이 힘 예측은 0.094mm, 성형 압력은 1.24MPa, 형체력은 3.26Ton 으로 모두 97.5%의 신뢰 수준이 나타났으며, 다른 Machine Learning 기법에 비해 양호한 예측 성능을 갖추고 있었다.
2. Decision-tree의 크기를 결정하는 Maximal Depth에 따라 예측 성능 및 설명력의 변화를 연구한 결과 Maximal Depth 증가가 분류 기준을 높일 수 있지만 복잡성도 함께 증가시켰다.
3. 힘 최소화를 위해 보압은 65MPa 이상이 필요하지만, 형체력은 270MPa를 넘어 힘 최소화 조건과 구속조건 상충되며, Maximal Depth를 변경해도 상충된 결과의 변화는 없었다.
4. 상충된 문제가 실험점을 추가 했을 때 해결되는지 평가하기 위해 추가 시뮬레이션을 진행한 결과 상충된 지점의 위치가 달라졌고, 구속 조건을 만족하는 중간 값을 선정하여 시뮬레이션을 진행한 결과 기존 시뮬레이션 대비 7.7%의 개선 효과가 있었다.

References

- [1] S. H. Hwang, J. S. Kim, "Injection mold design of reverse engineering using injection molding analysis and machine learning", *Journal of Mechanical Science and Technology*, Vol.8, pp.3803-3812, 2019. DOI: <https://doi.org/10.1007/s12206-019-0723-1>
- [2] D. Kozjeka, R. Vrabiča, D. Kraljib, P. Butalaa, N. Lavračc, "Data mining for fault diagnostics: A case for plastic injection molding", *Procedia CIRP*, Vol.81, pp.809-814, 2019. DOI: <https://doi.org/10.1016/j.procir.2019.03.204>
- [3] K. C. Ke, M. S. Huang, "Quality prediction for

injection molding by using a multilayer perceptron neural network”, *Polymers*, Vol.12, pp.1812, August, 2020

DOI: <https://doi.org/10.3390/polym12081812>

- [4] A. K. Kim, K. H Oh, J. Y Jung, B. H Kim, “Imbalanced classification of manufacturing quality conditions using cost-sensitive Decision-tree ensembles”, *International Journal of Computer Integrated Manufacturing*, pp.701-717, Dec, 2017
DOI: <https://doi.org/10.1080/0951192X.2017.1407447>
- [5] O. Ogorodnyk, O. V. Lyngstad, M. Larsen, K. Wang, K. Martinsen, “Application of machine learning methods for prediction of parts quality in thermoplastics injection molding”, *International Workshop of Advanced Manufacturing and Automation*, pp.237-244, Dec, 2018
DOI: <https://doi.org/10.1080/0951192X.2017.1407447>
- [6] S. H. Hwang, S. H. Park, S. J. Hwang, J. H. Lee, *Moldflow Basic Course*, Chung-Dam Books, Korea, pp.378-383, 2018
- [7] Training and Test Sets: Splitting Data, Machine Learning Crash Course[Internet], Available From: <https://developers.google.com/machine-learning/crash-course/training-and-test-sets/splitting-data?hl=ko> (accessed Dec. 20, 2020)
- [8] Descending into ML: Training and Loss, Machine Learning Crash Course[Internet], Available From: <https://developers.google.com/machine-learning/crash-course/descending-into-ml/training-and-loss> (accessed Dec. 20, 2020)

황 순 환(Soonhwan Hwang)

[정회원]



- 2017년 8월 : 공주대학교 일반대학원 기전공학과 (공학석사)
- 2017년 9월 ~ 현재 : 한성대학교 스마트융합컨설팅 대학원 제품전공 (공학박사과정 중)
- 2009년 11월 ~ 현재 : ㈜이디앤씨 기술팀 이사

<관심분야>

사출성형, 금형, 시뮬레이션, 인공지능, 머신러닝

한 성 렬(Seongryeol Han)

[정회원]



- 2014년 3월 ~ 현재 : 공주대학교 금형설계 부교수
- 2017년 3월 ~ 현재 : 공주대학교 글로벌 금형기술연구소 임원
- 2017년 3월 ~ 현재 : 한국금형공학회 학술이사

<관심분야>

사출성형, 금형설계, 사출 성형 시뮬레이션

이 후 진(Hoojin Lee)

[정회원]



- 1997년 2월 : 서울대학교 전기공학부 (공학사)
- 2002년 6월 : The University of Texas at Austin ECE (공학석사)
- 2007년 12월 : The University of Texas at Austin ECE (공학박사)
- 2009년 12월 ~ 현재 : 한성대학교 IT융합공학부 및 스마트융합컨설팅학과 교수.

<관심분야>

신호 처리, 통신 이론, 통신 물리 계층 보안