

증류탑을 위한 머신러닝 기반 플랫폼 개발

오광철* · 권혁원*** · 노지원**** · 최영렬***** · 박현도***** · 조형태* · 김정환*†

*한국생산기술연구원 친환경재료공정연구그룹

44413 울산광역시 중구 중가로 55

**부산대학교 화공생명공학부

46241 부산광역시 금정구 부산 대학로 63번길 2

***연세대학교 화공생명공학과

03722 서울특별시 서대문구 연세로 50

(2020년 3월 2일 접수, 2020년 4월 21일 수정본 접수, 2020년 5월 30일 채택)

Development of Machine Learning-Based Platform for Distillation Column

Kwang Cheol Oh*, Hyukwon Kwon***, Jiwon Roh****, Yeongryeol Choi*****, Hyundo Park*****,
Hyungtae Cho* and Junghwan Kim*†

*Green Materials and Processes R&D Group, Korea Institute of Industrial Technology,

55 Jongga-ro, Jung-gu, Ulsan, 44413, Korea

**School of Chemical & Biomolecular Engineering, Pusan National University, 2, Busandaehak-ro,

63beon-gil, Geumjeong-gu, Busan, 46241, Korea

***Department of Chemical and Biomolecular Engineering, Yonsei University,

50, Yonsei-ro, Seodaemun-gu, Seoul, 03722, Korea

(Received 2 March 2020; Received in revised from 21 April 2020; Accepted 30 May 2020)

요 약

본 연구는 증류탑 분리공정 시스템 최적화를 위하여 인공지능 머신러닝이 적용된 소프트웨어 플랫폼을 개발하였다. 증류탑 분리공정은 석유화학 산업의 대표적인 핵심적인 공정이다. 하지만 다양한 운전조건과 연속식공정 특성으로 인하여 안정적인 운전이 어려우며 운전자 숙련도에 의하여 공정효율에 차이가 발생된다. 이를 해결하기 위하여 이론적 시뮬레이션을 활용한 제어방법이 개발되어 사용되고 있지만 특수하거나 복잡한 반응이 포함된 공정에는 적용이 어려우며, 거대한 시스템에 대하여 분석이 이루어질 경우 계산비용 증대로 인하여 실시간 제어와 연동이 어려운 한계점을 지니고 있다. 따라서 본 연구에서는 이러한 문제점을 해결하기 위하여 머신러닝을 기반으로 한 경험적 시뮬레이션 모델을 개발하고 이를 통하여 최적의 공정운영방법을 제시하고자 한다. 경험적 시뮬레이션 개발은 실제 공정에서 수집된 빅 데이터, 데이터마이닝을 통한 특성추출, 공정을 대표하는 데이터 선별, 화학공정 특성에 맞는 모델 선정으로 이루어졌으며, 현장검증 및 테스트를 통하여 증류탑 분리공정 플랫폼이 개발되었다. 최종적으로 개발된 플랫폼을 통하여 운전 조작변수의 예측이 가능하며, 최적화된 운전조건을 제공하여 효율적인 공정운영을 달성할 수 있다. 본 논문은 머신러닝 기법을 화학공정에 적용한 기초연구로서 이후 다양한 공정에 적용하여 4차 산업의 스마트 팩토리의 초석이 되어 널리 활용될 수 있을 것이라 판단된다.

Abstract – This study developed a software platform using machine learning of artificial intelligence to optimize the distillation column system. The distillation column is representative and core process in the petrochemical industry. Process stabilization is difficult due to various operating conditions and continuous process characteristics, and differences in process efficiency occur depending on operator skill. The process control based on the theoretical simulation was used to overcome this problem, but it has a limitation which it can't apply to complex processes and real-time systems. This study aims to develop an empirical simulation model based on machine learning and to suggest an optimal process operation method. The development of empirical simulations involves collecting big data from the actual process, feature extraction through data mining, and representative algorithm for the chemical process. Finally, the platform for the distillation

†To whom correspondence should be addressed.

E-mail: kjh31@kitech.re.kr

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.

column was developed with verification through a developed model and field tests. Through the developed platform, it is possible to predict the operating parameters and provided optimal operating conditions to achieve efficient process control. This study is the basic study applying the artificial intelligence machine learning technique for the chemical process. After application on a wide variety of processes and it can be utilized to the cornerstone of the smart factory of the industry 4.0.

Key words: Big data, Machine learning-based platform, Empirical simulation, Process optimization

1. 서 론

최근 컴퓨터의 계산속도 증가에 따라 과거에 이론적으로 해석할 수 없었던 복잡한 열 및 유체유동에 대한 분석이 가능하게 되어, 다양한 산업분야에 시뮬레이션 분석을 통한 시스템 개선이 이루어지고 있다. 기존의 수학적 모델링을 기반으로 한 이론적 시뮬레이션 분석 방법은 대상공정의 종류에 상관없이 제어, 최적화, 스케줄링에 핵심적으로 활용되어왔다. 기본적으로 단순한 내부유동이나 화학반응을 포함하는 공정은 이론적 시뮬레이션을 통하여 보다 효율적으로 운영이 가능하다. 하지만 비선형이며 다차원의 복잡한 공정의 경우 수많은 가정이 필요하기 때문에 이론적 시뮬레이션을 통한 공정최적화는 한계가 있다[1]. 따라서 인공지능기술을 기반으로 한 경험적 예측모델 개발을 통하여 이러한 문제점을 해결하고자 한다. 인공지능 머신러닝 알고리즘을 활용한 분석방법은 4차 산업혁명의 핵심 분야로 데이터 사이언스를 기반으로 다양한 분야에 활용되고 있다. 공정 전반에 걸쳐 수집되는 빅 데이터로부터 현상을 학습(Learning)하고 학습 결과를 스스로 공정의 제어 및 운영에 반영 가능한 공장 지능화에 대한 관심이 증대 되고 있다.

따라서 본 연구에서는 인공지능 다중신경망 이론이 적용된 경험적 모델을 개발하여 화학공정 현장에 적용 하고자 한다. Fig. 1과 같이 전통적인 시뮬레이션 프로그램은 목표 시스템에 대한 예측모델을 개발한 후 입력에 대한 해답을 도출하는 과정으로 구성되어있다. 하지만 머신러닝(Machine Learning)은 경험적 데이터를 기반으로 입력데이터와 해답을 통해 컴퓨터가 스스로 학습하여 모델을 개발한다[2]. 특히 Yunduan Cui (2017)등은 KDPP (Kernel Dynamic Policy Programming)를 적용한 새로운 알고리즘 개발에 성공하였으며 기존의 시스템과 사람에 의한 조작이 합쳐진 최적화 공정을 달성하였다[3]. 또한 송영은(2018)등은 스마트 그린하우스 내부 온도 예측을 위하여 LSTM (Long Short-Term Memory) 모델을 활용하여 데이터를 분석하였으며, RNN (Recurrent Neural Network)보다 시계열 데이터 분석에 적합하다고 보고하였다[4]. 또한 이동현(2017)등은 LSTM과 RNN의 Hybrid 접근방법을 개발하여 모델 개선 및 효율적인 계산방법을 제시하였으며[5], 송정현(2018)은 기존 예측 정확도 향상을 위하여 순환 신경망 기법을 활용[6]하는 등 머신러닝을 이용한 분석기술은 다양한 분야에 널리 활용되고 있다.

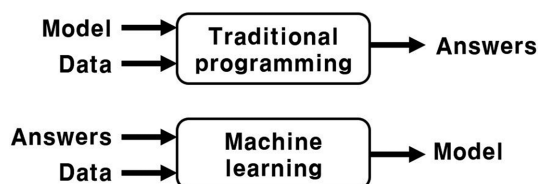


Fig. 1. Paradigm of machine learning programming.

2. 증류탑 분리공정 플랫폼 개발

2-1. 배경

기존의 이론적 시뮬레이션 분석은 과학적 이론과 최소한의 가정을 통하여 이루어지며, 각각의 물리량에 대하여 제어체적(Control volume)을 정의하고 에너지보존법칙을 적용하여 공간과 시간에 따라 계산한다. 이론적 시뮬레이션 접근방법은 한정된 조건과 수식들을 통하여 새로운 설계에 대한 선행시간 및 비용의 막대한 절감 및 구조변경, 운전조건변화에 대하여 명확한 특성을 도출할 수 있는 장점을 지니고 있다. 이러한 특성으로 인하여 나누어져 실제 현장(Farm scale)에서 특성단위로 분석이 이루어지며, 초기개발단계 및 장치개선에 광범위하게 활용되고 있다. 하지만 각각의 공정 특성에 따른 여러 가지 모델을 개발하는 것은 시간 및 경제적으로 한계가 있으며, 거대하고 복잡하게 구성된 현장을 모두 모사하는 것은 불가능하다[7]. 따라서 이러한 문제점을 해결하기 위하여 머신러닝을 통한 경험적 시뮬레이션 분석 방법을 제안하고자 한다. 경험적 시뮬레이션 분석 방법은 측정된 데이터를 기반으로 현상을 단순화시켜 결과를 도출한다. 특히 복잡하게 구성된 공정시스템이나 거대한 크기의 현장에 대하여 적은 시간과 비용으로 분석이 가능한 장점을 지니고 있다. 따라서 본 연구에서는 머신러닝이 적용된 경험적 모델을 통하여 플랫폼 소프트웨어를 개발하고자 한다.

2-2. 머신러닝 모델 개발 및 검증 단계

본 논문에서 제안하는 머신러닝 기반 통합 플랫폼 소프트웨어의 전체 흐름은 다음 Fig. 2와 같다. 공정 특성에 따라 수집된 데이터는 데이터마이닝을 통한 특성 변수 추출이 이루어진다. 이후 선별된 데이터특성에 따라 지도(분류, 회귀) 및 비지도(군집) 학습으로 나누어 모델개발이 진행된다. 개발된 모델은 매개변수 수정을 통하여 최적화 후 사용자 인터페이스 프로그램과 통합하여 현장 적용이 이루어졌다.

2-2-1. 단계 1 : 데이터 수집

머신러닝 모델 개발의 첫 번째 단계는 데이터 수집으로 모델개발에 기반이 되는 중요한 단계이다. 수집된 데이터의 특성에 따라 개발 모델에 적용되는 변수추출, 모델선택, 적용기법 선정에 가장 많이 관여하고 있다. 오랜 시간 운전되어온 공정의 경우 중요 데이터를 기반으로 운영되어 왔기 때문에 비교적 쉽게 공정을 대표하는 데이터를 수집할 수 있으나, 특성 변수 추출이 불가능할 경우 추가적인 데이터 수집을 통하여 반복적인 분석이 이루어져야 한다[8].

2-2-2. 단계 2 : 데이터 마이닝

머신러닝 모델 개발의 두 번째 단계는 데이터 마이닝으로 머신러닝 모델 개발에 기반이 되는 중요한 단계이다. 데이터마이닝이란 대규모의 데이터베이스 안에서 일정한 규칙을 찾아내어 데이터를 분석하는 작업으로 각 공정에 대한 전반적인 이해도를 바탕으로 가

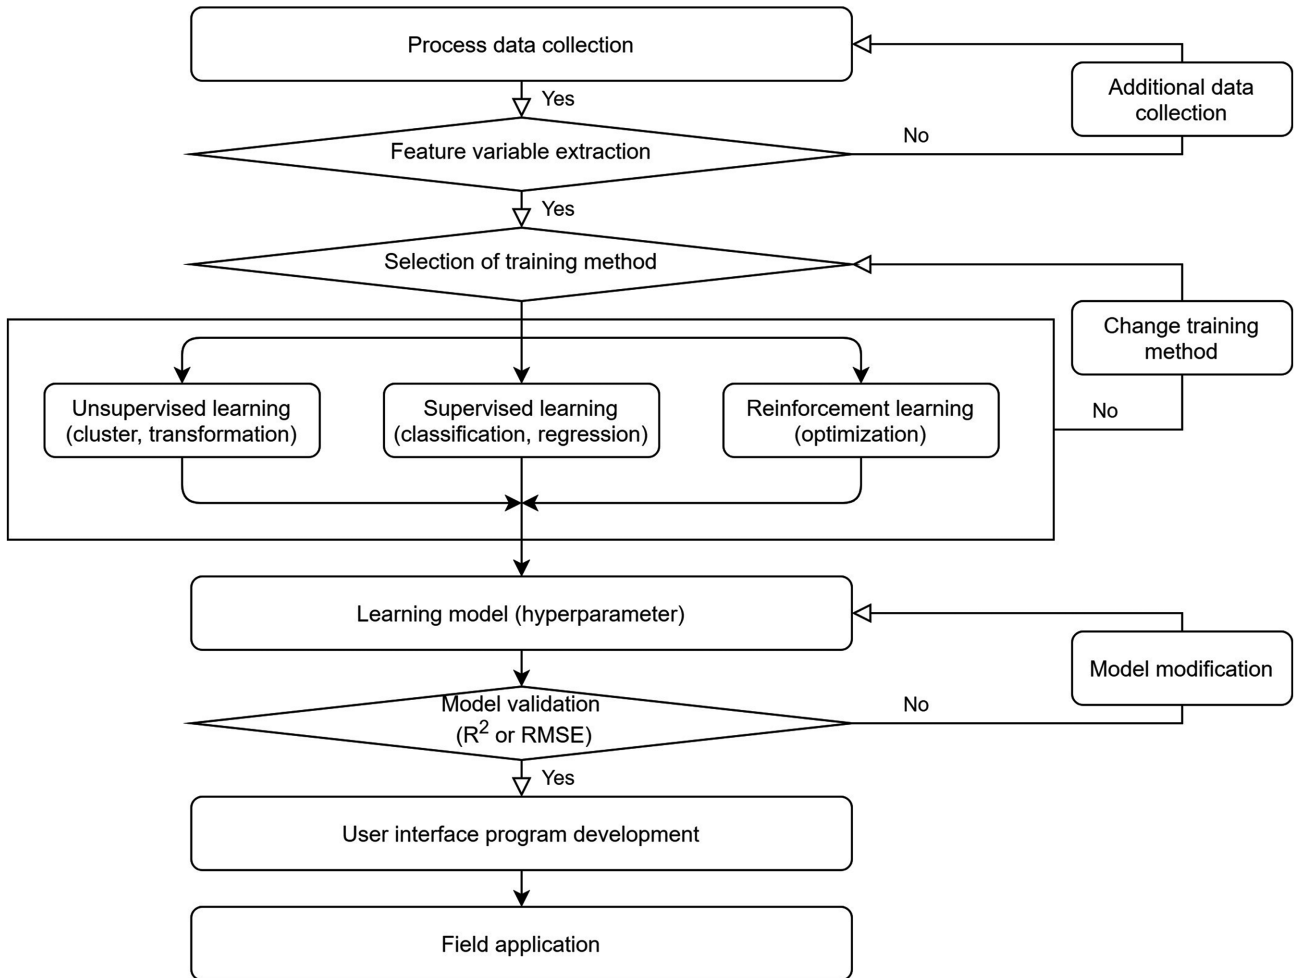


Fig. 2. The architecture of the machine learning system for distillation column.

장 적절한 데이터 분석이 이루어져야 한다. 정규화를 통하여 각기 다른 단위의 수집데이터를 머신러닝에 적용 가능한 데이터로 전환한다[9]. 또한 측정 오차 및 신뢰도를 확보하기 위하여 데이터 전처리가 이루어져야 하며, 대상공정의 특성 모집단에 속하지 않는다고 의심이 될 정도로 정상범위 밖으로 관측된 값은 필요에 따라 제거한다.

2-2-3. 모델 학습 방법 선정

앞선 단계에서 수집되고 정규화 된 데이터를 활용하여 실제 공정에 적용할 학습모델 선정이 이루어진다. 머신러닝이 적용된 경험적 모델 개발의 Fig. 2와 같이 구성되어있다. 이 단계는 개발자가 직관적으로 데이터와 모델의 관계를 통하여 결정해야하는 단계로 각각의 공정 특성에 알맞은 모델 선정이 이루어져야 한다. 증류탑 분리공정의 경우 시간의 흐름에 따라 데이터가 수집되며 운전자가 실시간으로 공정 입력 조건을 변경하여 운영되기 때문에 지도학습의 회귀 분석을 이용한 분석방법이 적용 된다. 또한 유전자적 선택 알고리즘을 통하여 모델 개선이 이루어진다[10-13].

2-2-4. 모델 학습

증류탑 분리공정은 시계열 및 운전자의 입력에 따른 공정 운영방안이 결정되는 특성으로 인하여 지도학습을 활용한 회귀 분석 모델 학습방법이 선정되었다. 기본적으로 모델 구성을 위하여 활성화함

수를 선정하고 문제의 종류에 적합한 손실함수를 결정하였다. 마지막으로 최적화 함수를 선정하며, 이때 각각의 매개변수(Epochs, Bathsize, Learning rate)와 반복계산(iteration)통하여 모델 학습이 이루어진다. 이때, 매개변수의 가중치의 업데이트를 통하여 모델의 성능이 향상된다[11-13].

2-2-5. 모델 검증

개발된 모델검증은 일반적으로 단순홀드아웃검증을 통하여 이루어진다. 데이터의 일정량을 훈련세트와 테스트세트로 구분하여 훈련을 통하여 모델을 개발하고 테스트를 통하여 평가를 진행한다. 이 검증 방법은 수집된 데이터가 적은 경우 공정특성을 통계적으로 대표하지 못할 경우가 발생되며[14], 이러한 문제점은 k-겹 교차검증을 통하여 해결될 수 있다. k-겹 교차검증은 데이터를 동일한 크기를 가진 k개 분할로 나누어 각각의 분할로 i에 대하여 남은 k-1개의 분할로 모델을 훈련하고 분할된 i에 대하여 교차로 모델을 평가한다. 최종적으로 도출된 얻은 k개의 모델의 평균을 통하여 검증하여 보다 안정화된 모델이 도출될 수 있다. 하지만 계산비용이 증가하는 도출된 모델의 대표성이 감소될 수 있는 단점이 있다. 기본적으로 검증을 위한 데이터는 대표성 있는 데이터로 구성하여 분석이 진행되어야 한다. 또한 모델이 과대적합(overfitting)이나 과소적합(underfitting)으로 인하여 정밀도가 감소 될 경우 현장적용이 불가

능하기 때문에 일반화 성능을 증대시키는 방법이 필요하다. 최종적으로 과대적합을 막기 위하여 모델이 포함하고 있는 파라미터의 수를 감소시켜 개선이 가능하며, 세부적으로 네트워크용량의 감소, 가중치 규제(weight regularization), 드롭아웃(dropout)의 방법들이 존재한다[8].

2-3. 머신러닝 모델 현장 적용 단계

2-3-1. 사용자 인터페이스 개발

앞서 개발된 머신러닝 모델을 실제 공정에 적용하기 위하여 사용자 인터페이스 개발이 필요하다. 머신러닝 전문가가 아니더라도 쉽게 활용할 수 있는 공정-데이터-모델 간 확인이 가능한 플랫폼 형태의 프로그램이 요구된다[15-18]. 개발된 프로그램은 사용자가 수집된 데이터를 직관적으로 확인가능하며, 시물레이션에서 요구되는 기본적인 설정 및 계수의 조작이 용이하여야한다[19-21]. Fig. 3은 머신러닝 기반 플랫폼 시스템의 기본 인터페이스를 나타내고 있다. 앞서 구성된 내용들을 모두 포함하고 있으며 개발된 시물레이션 플랫폼은 크게 Overview, Process trend, Optimization, Controller simulation 탭으로 구성되어있다.

1. Overview

1.1 System PFD (Process flow diagram)

1.2 Real time data collection

1.3 Key operating conditions

1.4 Recommendations

2. Process trend

2.1 Trend display of data

2.2 Key operating conditions

2.3 Recommendations

2.4 Estimated composition

3. Optimization

3.1 Composition prediction

3.1.1 AI-model (Artificial Intelligence model)

3.1.2 MLR-model (Multiple Linear regression model)

3.2 Optimization plan

3.2.1 Maximization of profits

3.2.2 Minimization of utilities

3.3 Specifications

3.3.1. Total production target

3.3.2. Load ratio and feed rate(Max, Min)

3.3.3. Product composition

3.4 Cost data

3.4.1. Output

3.4.2. Input

4. Controller simulation

4.1 Precess model

4.1.1. Process type

4.1.2. Process gain

4.1.3. Dead time

4.1.3. Time constant

4.2 Controller simulation

4.2.1. Control algorithm

4.3. Simulation settings

4.3.1. Simulation time

4.3.2. Set point change

4.3.3. Load change

4.3.3. Noise level

2-4. 머신러닝 기반 플랫폼 구성

2-4-1. Overview

Fig. 3(a)의 개요(Overview) 탭에서는 시스템 공정흐름도(System process flow diagram)를 통하여 시스템 구성 및 데이터 측정 위치를 가시화하여 직관적으로 프로그램이 수집하고 평가하는 데이터의 종류 및 위치를 판단할 수 있으며, 공정 특성에 따라 표본화 시간(Sample time)을 변화시켜 실시간 데이터(Real time data collection)를 수집할 수 있다. 또한 실제 수집되는 데이터를 통하여 예측된 주요 운전조건(Key operating conditions)과 추천값(Recommendations)을 운전자가 실시간으로 관측하여 공정전체 특성을 쉽게 이해할 수 있는 편의성을 탑재하였다.

2-4-2. Process trend

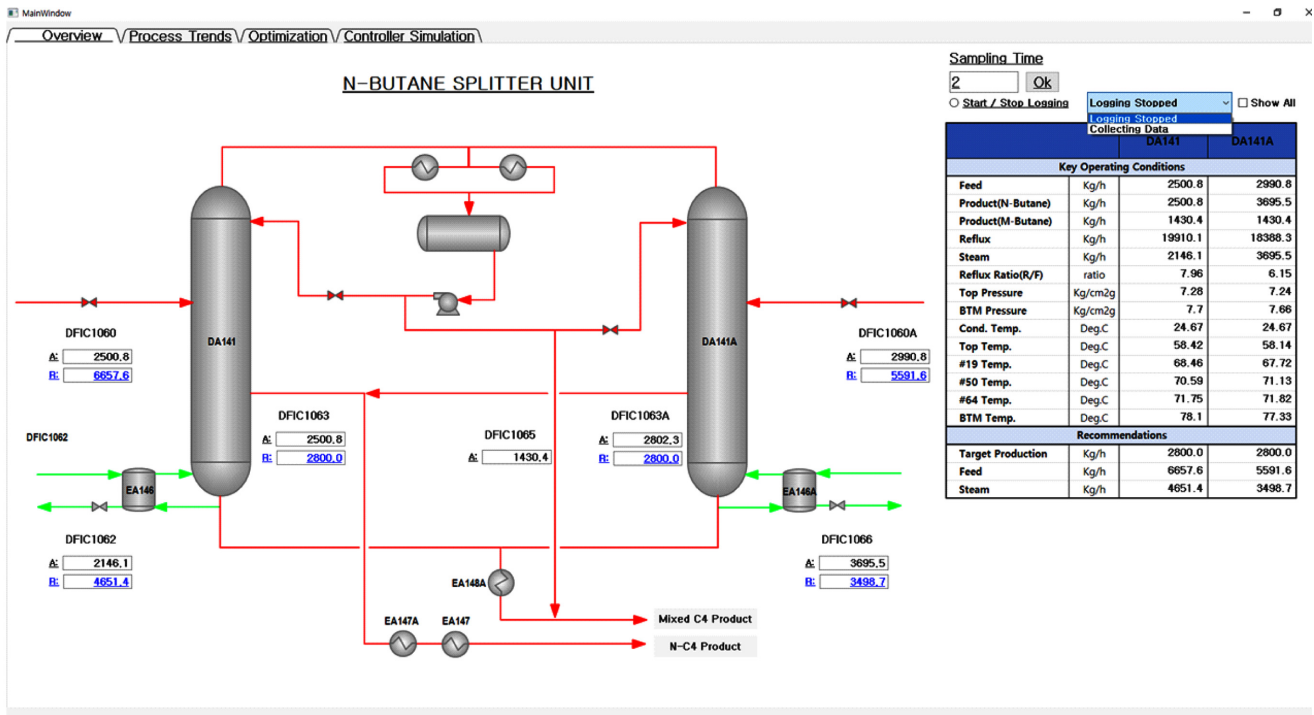
Fig. 3(b)의 공정 추세(Process trend) 탭에서는 사용자가 실제 공정한 전 시 주요 작동 특성이 한눈에 파악가능하며 특히 권장값(recommendations)과 주요 운전조건(Key operating conditions)을 확인할 수 있다. 이후 진행되는 모델 최적화(Optimization) 및 시물레이션 컨트롤(Controller simulation) 탭과 연계하여 지속적으로 모니터링이 이루어진다.

2-4-3. Optimization

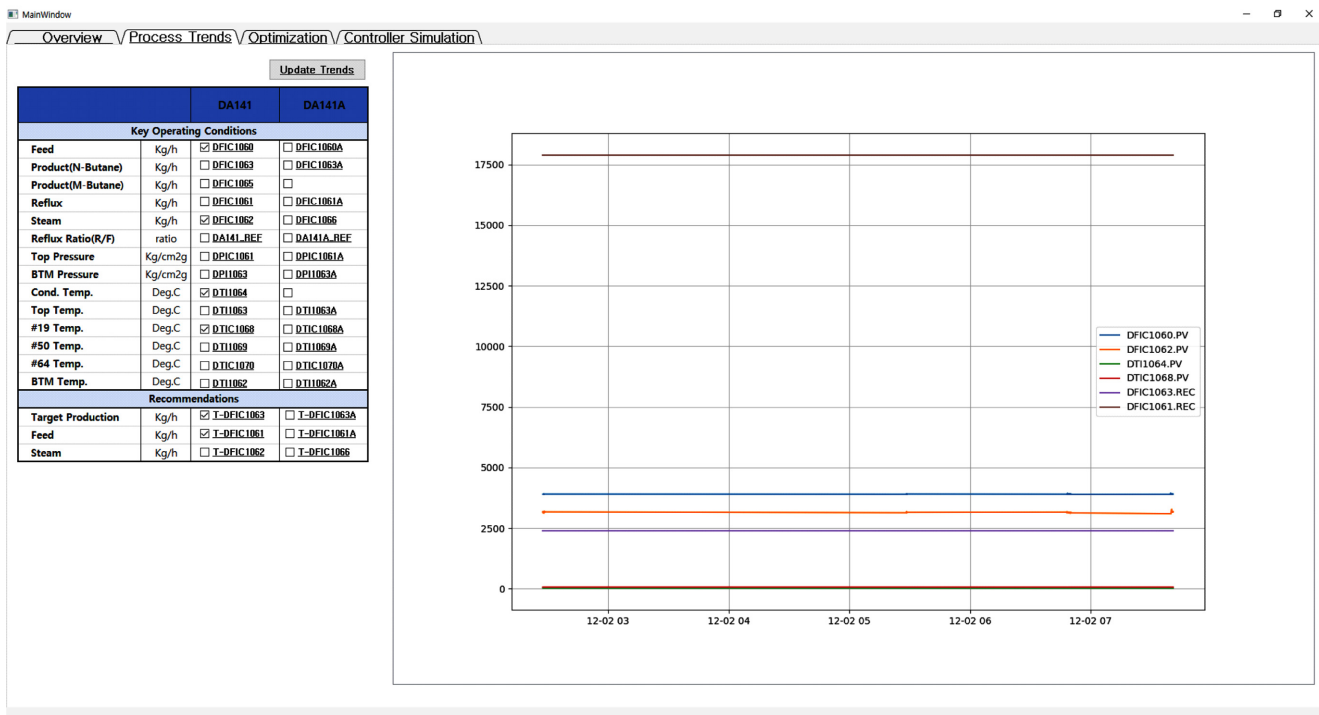
Fig. 3(c)의 최적화(Optimization) 탭에서는 수집된 데이터를 활용하여 모델 최적화가 이루어진다. 사용자가 학습모드(Learning mode)와 예측모드(Prediction mode)를 선택하여 머신러닝 모델 수정이 진행되며, 다중선형회기(Multiple Linear regression)분석방법은 기존의 전통적인 방법인 베이즈안분석(Bayesian analysis)기법으로 개발된 머신러닝 모델과 비교분석을 통하여 보다 적절한 모델 최적화가 이루어진다. 또한 목적함수 이익최대화(Maximization of profits) 및 장치최소화(Minimization of utilities)를 통하여 목표변수인 공정의생산량(Total production target), 원료공급량(Load ratio and feed rate), 제품구성(Product composition)을 통한 비용데이터(Cost data)의 최적화가 가능하다.

2-4-4. Controller simulation

Fig. 3(d)의 시물레이션 조작(Controller simulation) 탭에서는 개발된 모델에서 도출된 최적 제어값이 실제 공정 적용 시 목표 값에 도달하는 응답시간의 최적화가 이루어진다. 앞서 기술한대로 화학공정의 운영은 미세한 조작을 통해서도 공정 내부의 큰 변화가 나타나 문제점이 발생될 수 있다. 이러한 오차를 최소화하기 위하여 특성 제어인 비례, 적분, 미분제어기법(Proportional Integral Differentia)이 활용되었다. 또한 공정특성에 따라 각기 다르게 발생하는 목표값 변화(Setpoint change), 부하변화(Load change), 잡음레벨(Noise



(a) Overview



(b) Process trend

Fig. 3. Machine learning-based platform for distillation column.

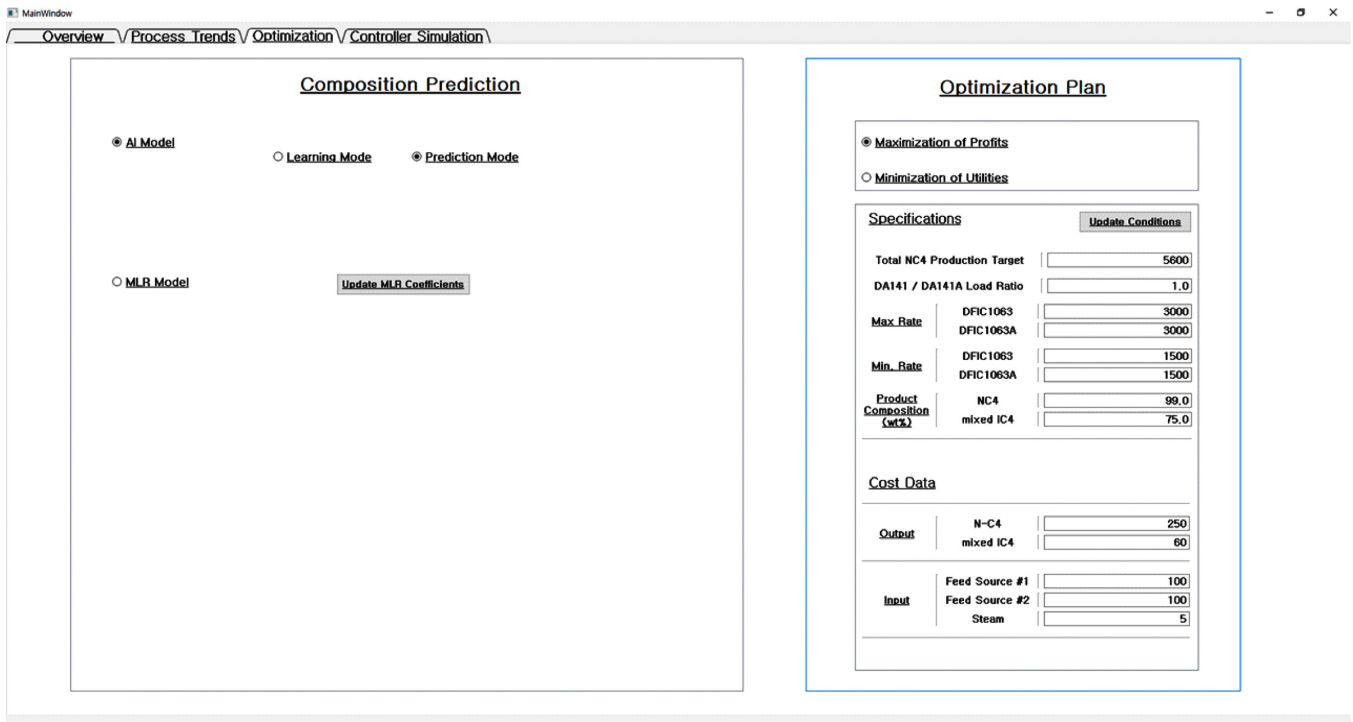
level)에 따라 최적의 제어 방법을 도출할 수 있다.

3. 머신러닝 플랫폼 응용

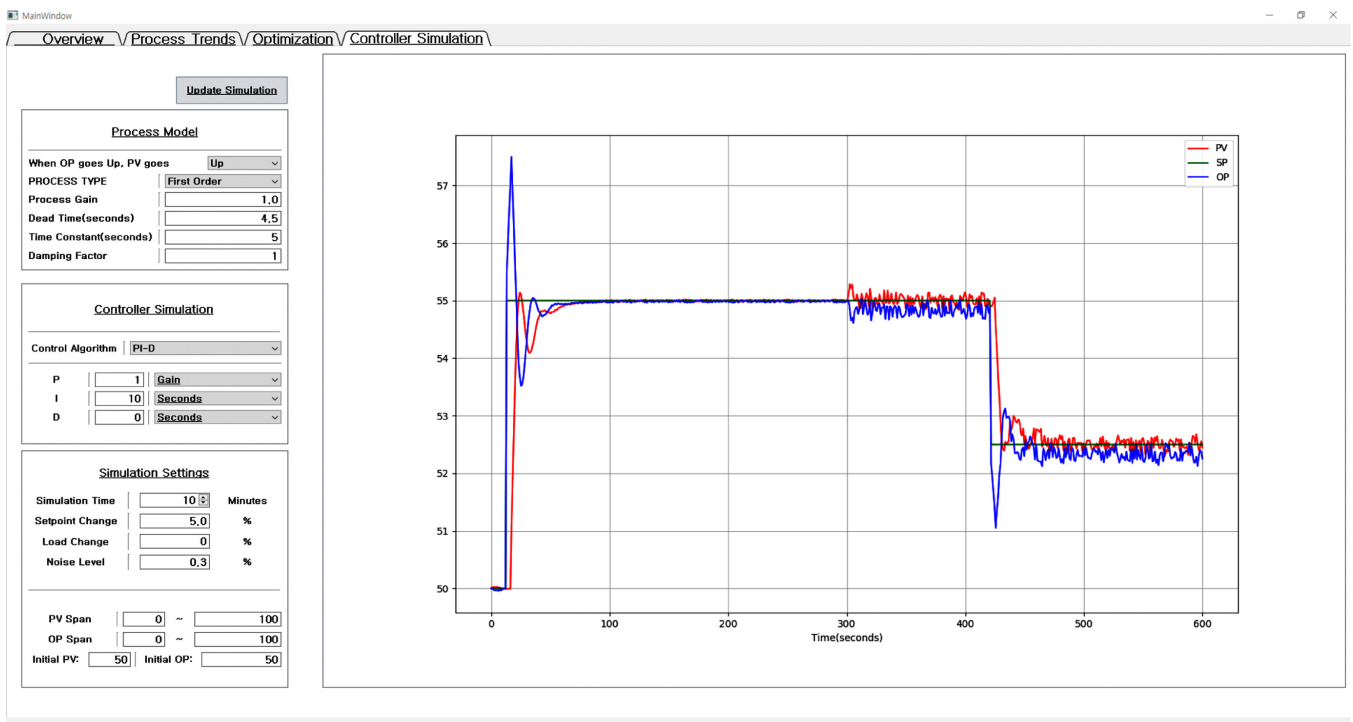
3-1. 응용

본 연구의 대상 공정은 석유화학산업의 가장 기본적이고 일반적인

시설로써, 혼합물을 분리하여 일정순도(99 wt.%) 이상의 제품을 생산하는 공정 시스템이다(Fig. 4). 78단의 증류탑으로 구성되어 있고 원료탱크와 제품탱크로 구성되어있다. 공정 중 공급되는 혼합부탄 중 노말부탄의 원료 수급처가 다양하여(원료 1, 60~80 wt.%), 원료 2(96~98 wt.%) 운전 조건 변화가 빈번하고 효율적 운전이 어렵다. 따라서 안정적인 운전을 위하여 머신러닝을 통한 지능화 시스템이



(c) Optimization



(d) Controller simulation

Fig. 3. Continued

필요하다. 제품생산 시 실제 내부 64단 온도에 영향을 주는 변수들로 혼합부탄 유량, 탑 하부 온도, 50단 온도, 혼합부탄 온도 등이 있으며 이러한 데이터를 바탕으로 실제 64단 온도 예측 모델이 개발되었다.

3-2. 학습 환경

본 연구에서 제안하는 증류탑 내부 온도 예측방법은 기존에 얻어진 일주일 데이터를 학습하여 인공신경망을 학습시키고 이때 개발된 모델을 적용하여 새로운 온도데이터를 예측한다. 이때 시스템 시계열 데이터의 시퀀스가 길기 때문에 RNN(Recurrent Neural

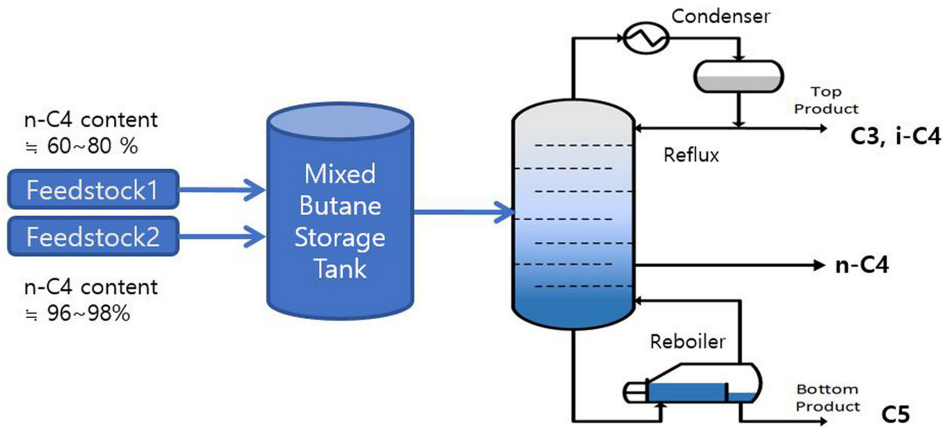


Fig. 4. Schematic diagram of the distillation column.

Network)를 적용하여 모델링 할 경우 베니싱 문제(Vanishing Gradient Problem) 발생으로 인하여 모델 정확도가 감소될 수 있다. 따라서 LSTM(Long Short-Term Memory)을 기반으로 분석이 이루어졌다. LSTM은 Hidden Layer와 Input Gate, Output Gate, Forget Gate의 세가지 게이트로 구성된 메모리 블록으로 Cell을 생성하여 베니싱 문제를 해결된 알고리즘[8,12,22]이다. 경험적 모델 훈련은 프리소프트웨어인 Python기반의 TensorFlow를 이용하여 수행되었으며 Keras 딥러닝 라이브러리를 사용하였다[6,23]. 훈련 및 테스트 데이터는 실제 공정의 일주일(30초당 1회 저장)데이터를 이용하여 이루어졌으며 최적화함수는 Adam optimizer, 활성화함수는 Sigmoid와 Tanh가 사용되었다[24].

3-3. 결과

개발된 프로그램을 이용하여 예측된 64단 온도와 실제 온도의 비

교결과는 Fig. 5와 같이 나타났다. r^2 : 0.951의 정확도와 RMSE : 0.054 정밀도로 예측모델이 최적화 되었다. 결과의 2/8, 2/12일 지점에서 다소 실험값과 예측 값의 차이가 크게 나타났는데 이는 학습기간에 테스트구간을 예측할 수 있는 데이터가 부족하여 발생된 결과라 사료된다. 이러한 문제는 경험적 모델의 특성으로 추가적인 학습 데이터를 수집하거나, 이론적 모델을 바탕으로 한 공정 데이터가 필요하다고 판단된다.

4. 결론 및 토의

전 세계적으로 컴퓨터 연산속도의 증대와 빅데이터의 시너지 효과로 인하여 인공지능 분야의 연구는 급속도로 증가되고 있는 추세이다. 이러한 머신러닝이 적용된 경험적 시뮬레이션기법은 데이터를 기반으로 분석이 이루어지기 때문에 실제 현장에 빠르게 적용

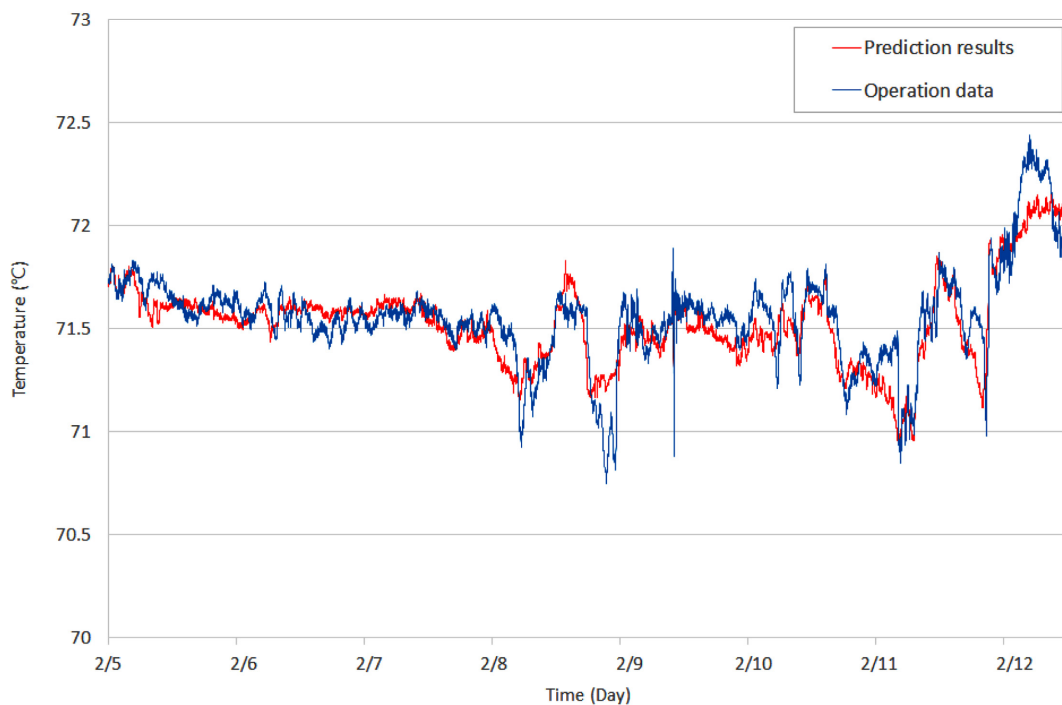


Fig. 5. Comparison of prediction results and operation data.

가능하다. 또한 경험적 모델은 아주 거대하거나 밝혀지지 않은 현상에 대한 해석도 가능하기 때문에 다양한 분야에 활용되고 있다. 최근 예지보전이나 위험 감지 분야에 머신러닝 기술이 활용되고 있으나 실제 화학공정에 적용된 연구는 미비하다. 본 연구에서는 경험적 머신러닝 모델을 기반으로 소프트웨어 플랫폼을 개발하였으며, 실제 증류탑 분리공정에 적용하여 실제 운전 데이터와 비교가 이루어졌다. 머신러닝 기반 모델은 기계학습을 통하여 사람이 운전하면서 발생하는 오류를 최소화 할 수 있으며 데이터를 기반으로 한 개선을 통하여 한 단계 업그레이드 된 공정최적화를 달성할 수 있을 것이라 판단된다. 또한, 기계학습을 통하여 해당 공정 전문가의 운전 노하우가 데이터로 남겨지기 때문에 초보자도 효율적인 공정 운영이 가능하다. 하지만 경험적 시뮬레이션 모델은 이전에 발생되지 않은 원인과 결과에 대한 예측이 불가능하기 때문에 오류가 발생할 수 있으며[25], 이를 해결하기 위하여 각 공정특성을 대표하기 위한 추가적인 데이터수집 및 개발모델의 매개변수 최적화가 요구된다. 더 나아가 가까운 미래에 머신러닝의 강화학습 알고리즘의 발전과 머신러닝 플랫폼의 통합이 이루어진다면 더 효율적인 성능을 도출하는 연구결과를 기대할 수 있다. 최종적으로 본 연구는 머신러닝 기법을 화학공정에 적용한 기초연구로 이후 다양한 공정에 적용하여 4차 산업의 중심인 스마트 팩토리의 초석이 되어 널리 활용될 수 있을 것이라 판단된다.

감 사

본 논문은 한국생산기술연구원 제조혁신지원사업 화학산업 고도화를 위한 스마트 제조공정 AI 플랫폼 기술 개발(1/2) (Kitech-JH-20-0005)의 지원으로 수행한 연구입니다.

Reference

- Na, J. G. and Lee, U., "Research Trends and Application Examples of Process Optimization Methodology Using Machine Learning" NICE (News & Information for Chemical Engineers), **36**(1), 4-8 (2018).
- Cho, Y. S., "A Study on the Machine Learning and Computational Analysis for Injury Prediction of Traffic Accident" Hanyang university, GRADUATE SCHOOL(2018).
- Cui, Y., Matsubara, T. and Sugimoto, K., "Kernel Dynamic Policy Programming: Applicable Reinforcement Learning to Robot Systems with High Dimensional States," *Neural Networks*, **94**, 13-23(2017).
- Song, Y. E., Moon, A. K., An, S. Y. and Jung, H. Y., "Prediction of Smart Greenhouse Temperature-Humidity Based on Multi Dimensional LSTMs," *J. Korean Soc. Precis. Eng.*, **36**(3), 239-246(2019).
- Lee, D. H., Lim, M. K., Park, H. S. and Kim, J. H., "LSTM RNN-based Korean Speech Recognition System Using CTC", *Journal of Digital Contents Society*, **18**(1), 93-99(2017).
- Song, J. H., "RNN Based Temperature Prediction Method for Improving Accuracy of Forecasting Temperature," M. S, Department of Software Convergence(2018).
- Oh, K. C., Euh, S. H., Oh, J. H. and Kim, D. H., "Simulation and Model Validation of Combustion in a Wood Pellet Boiler Using Computational Fluid Dynamics," *Journal of Energy Engineering*, **23**(3), 213-220(2014).
- François, C., "Deep learning with Python," (2017).
- Oh, S. M., Lee, D. S., Kim, J. S. and Park, J. H., "A Study on Stable Response of the CNN-Based Monitoring Applications Through Virtualized Platform," *Journal of Digital Contents Society*, **20**(12), 2525-2533(2019).
- Hope, T., Resheff, Y. S. and Lieder, I., "Learning Tensorflow: A Guide to Building Deep Learning Systems," O'Reilly Media(2017).
- Muller, A. C. and Guido, S., "Introduction to Machine Learning with Python: a Guide for Data Scientists," O'Reilly Media(2017).
- Ariga, M., Nakayama, S., Nishibayashi, D., "Machine Learning at Work," O'Reilly Media(2018).
- Kim, S. Y. and Jung, Y. J., "First Learning Machine Learning," Hanbit Media(2017).
- Seo, T. H., Byun, M. K. and Lee, H. S., "Development of Web Content Similarity Search Platform using Blockchain," *Journal of Digital Contents Society*, **21**(1), 165-172(2020).
- Park, K. S., Hwang, K. S. and Lee, K. M., "Model Pattern Extraction and Visualization for Deep Learning Modeling," *Journal of Korean Institute of Intelligent Systems*, **29**(1), 23-29(2019).
- Jo, Y. H. and Seo E. G., "Building a Digital Repository Platform for Academic Department Records," *Journal of Korean Society of Archives and Records Management*, **16**(3), 209-233(2016).
- Jin, J. H., "Development of a Test Platform for Variable Speed Control Moment Gyroscopes," *Journal of Korean Soc. of Mechanical Technology*, **16**(3), 1447-1453(2014).
- Liu, X., Ounifi, H. A., Gherbi, A., Lemieux, Y., and Li, W., "A Hybrid GPU-FPGA-based Computing Platform for Machine Learning," *Procedia Computer Science*, **141**, 104-111(2018).
- Kim, M. H. and Joo, S. C., "Construction of CORBA Object - Group Platform for Distributed Real - Time Service," *Journal of KIISE : Computing Practices and Letters*, **7**(6), 602-613(2001).
- Kim, J., Lim, W., Lee, Y., Kim, S., Park, S. R., Suh, S. K. and Moon, I., "Development of Corrosion Control Document Database System in Crude Distillation Unit," *Industrial & Engineering Chemistry Research*, **50**(13), 8272-8277(2011).
- Lee, K. M., Yoo, J., Kim, S. W., Lee, J. H. and Hong, J., "Automatic Machine Learning Platform," *International Journal of Information Management*, **49**, 491-501(2019).
- Chang, Z., Zhang, Y. and Chen, W., "Electricity Price Prediction Based on Hybrid Model of Adam Optimized LSTM Neural Network and Wavelet Transform," *Energy*, **187**, 115804(2019).
- Keshavarzian, A., Sharifian, S. and Seyedin, S., "Modified Deep Residual Network Architecture Deployed on Serverless Framework of IoT Platform Based on Human Activity Recognition Application," *Future Generation Computer Systems*, **101**, 14-28(2019).
- Zhao, H., Liu, F., Zhang, H. and Liang, Z., "Research on a Learning Rate with Energy Index in Deep Learning," *Neural Networks*, **110**, 225-231(2019).
- Seul, M. S., "Current Status and Future Developments of Machine Learning Artificial Intelligence in Law Focusing the Cusp of Machine Learning in U.S. and Discourses over Legal Profession and Law School Education," *The Justice*, **10**, 269-302(2016).