

Development of Artificial Intelligence Model for Outlet Temperature of Vaporizer

Sang-Hyun Lee* · Gi-Jung Cho** · Jong-Ho Shin**†

*Dept. Industrial Engineering & IT-Bio Convergence System, Chosun University

**Dept. Industrial Engineering, Chosun University

기화 설비의 토출 온도 예측을 위한 인공지능 모델 개발

이상현* · 조기정** · 신종호**†

*조선대학교 산업공학과 & IT-Bio 융합시스템 전공

**조선대학교 산업공학과

Ambient Air Vaporizer (AAV) is an essential facility in the process of generating natural gas that uses air in the atmosphere as a medium for heat exchange to vaporize liquid natural gas into gas-state gas. AAV is more economical and eco-friendly in that it uses less energy compared to the previously used Submerged vaporizer (SMV) and Open-rack vaporizer (ORV). However, AAV is not often applied to actual processes because it is heavily affected by external environments such as atmospheric temperature and humidity. With insufficient operational experience and facility operations that rely on the intuition of the operator, the actual operation of AAV is very inefficient. To address these challenges, this paper proposes an artificial intelligence-based model that can intelligent AAV operations based on operational big data. The proposed artificial intelligence model is used deep neural networks, and the superiority of the artificial intelligence model is verified through multiple regression analysis and comparison. In this paper, the proposed model simulates based on data collected from real-world processes and compared to existing data, showing a 48.8% decrease in power usage compared to previous data. The techniques proposed in this paper can be used to improve the energy efficiency of the current natural gas generation process, and can be applied to other processes in the future.

Keywords : AI, AAV, Multiple Regression Analysis, Deep Neural Network, Vaporizer

1. 서 론

4차 산업혁명의 시대로 접어들면서 마이크로 칩, 센서, 인터넷, 클라우드 컴퓨팅, 기술의 발전으로 데이터 수집 및 분석 능력 등이 향상되고 있다. 제조 산업에서 이러한 기술의 발달은 빅데이터 및 인공지능 기술과 융합을 통해 스마트 팩토리(Smart Factory) 구현을 가능하게 한다. 스마

트 팩토리는 제품의 기획부터 설계, 생산, 유통 등 생산 전체 과정에 ICT, 빅데이터, 인공지능 등의 기술을 융합하여 생산성 및 생산 품질, 고객 만족 등을 향상시킬 수 있는 지능형 자동화 공장이다. 본 연구의 대상 설비가 설치된 천연가스 생산 제조 시스템도 제조 공정에서 수집되는 대량의 센서 데이터를 통해 운영과 유지보수를 지능화하는 스마트 팩토리로 전환을 지속적으로 추진하고 있다.

천연가스 생산 공장은 해상을 통해 수송된 액화상태의 가스를 탱크에 저장해 두었다가 수요에 맞춰 기화 설비를 통해 기체 상태로 변화시켜 수요처인 가정과 기업 등에 제공하는 제조 시스템이다. 액화 천연가스를 기화

하는 공정에서 주요한 역할을 하는 설비가 기화기이다. 기화기는 공정에서 많은 연료를 사용하기 때문에 빅데이터 기반 인공지능 기술의 접목을 통해 이를 효율적으로 운용하는 것이 필요하다.

국내에 상용화되고 있는 LNG(Liquefied Natural Gas) 기화기의 종류에는 연소식 기화기(Submerged vaporizer, SMV), 해수식 기화기(Open-rack vaporizer, ORV), 공기식 기화기(Ambient Air Vaporizer) 등이 있다. 연소식 기화기는 가장 일반적인 형태의 기화기로 LNG 저장 및 이동 과정에서 기화된 NG(Natural Gas)를 연소하여 LNG를 기화시킨다. 이는 판매되어야 하는 천연가스를 연소에 사용하여 생산비용이 증가한다는 문제점이 있다. 해수식 기화기는 바닷물을 열교환의 매체로 사용하여 기화비용이 적게 소요되는 반면, 해수 온도가 5°C 이상일 때 효과적으로 기화가 가능하여 겨울철 혹은 수온이 낮은 경우에는 해수식 기화기의 사용은 제한된다. 뿐만 아니라 기화기 주변 해수 온도의 영향을 미쳐 해수 온도가 높은 경우에도 설비 사용이 제한적일 수 있다. 공기식 기화기는 대기 중의 공기를 열교환의 매체로 사용하여 질소 산화물과 미세 먼지 등을 배출하지 않는 친환경 설비로 인정받고 있다. 하지만 공기식 기화기는 해수식 기화기 대비 10배 이상의 전열 면적이 필요하며, 외부 대기 조건에 따라 성능 변동이 매우 큰 탓에 세계적으로 상용화 실적이 적다. 널리 상용화 되고 있는 해수식 기화기나 연소식 기화기와 달리 기화기 운영에 대한 데이터가 부족하여, 이를 실제 현장에서 기화기의 최적화된 운영 매뉴얼을 설정하는 것이 쉽지 않다. 때문에 현재 국내에서는 에너지 사용 절감 및 생산단가 감소를 위해 해수식 기화기를 사용하고 부족한 공급은 연소식 기화기를 사용하고 있다. 공기식 기화기의 최적화된 운영이 가능해질 경우 탄소 배출량 감소, 생산비용 감소 등 국내 천연가스 생산에 보다 경제적이고 친환경적인 효과를 불러올 수 있을 것으로 기대된다. 이에 본 연구의 대상이 되는 설비는 현재 운영에 대한 자동화가 가장 부족한 공기식 기화기를 대상으로 하고 있다.

LNG를 기화시켜 공급하기 위하여 액체 상태의 온도인 -162°C부터 0°C까지 온도를 상승시켜야 하며, 1kg의 LNG를 기화시키는 데 필요한 열량을 보면 1기압 상태의 경우 200kcal, 고압인 72bar 경우 약 170kcal 정도의 열량이 필요하게 된다[6]. 공급온도가 0°C 이하로 떨어지게 되면 수요처에 공급이 어렵게 되며, 이를 보완하기 위한 승온 설비의 추가 가동이 필요하게 되는 등 다양한 운용상의 문제점이 존재하게 된다. 이를 위해 본 연구에서는 국내 공기식 기화기 상용화를 위해 기화기 운영 시 발생하는 불필요한 에너지 사용을 줄이고, 외부조건에 민감하게 영향을 받는 기화기의 유연한 대처가 가능한 인공


지능 기반 자동화 알고리즘을 개발에 필요한 기화 후 온도(토출온도) 예측 모델을 만들고자 한다. 이를 통해 기화 설비의 생산 효율성뿐만 아니라 친환경 설비인 공기식 기화기의 선도적인 요소 기술 개발을 통해 공기식 기화기의 상용화를 활성화하고자 한다.

본 논문의 구성은 공기식 기화기에 대한 개요를 다음 장에서 먼저 소개하고, 현재 운영방식에 대한 문제점을 정의한다. 제 3장에서 공기식 기화기의 인공지능 기반 운영을 위한 활용 데이터에 관해서 설명하고 개발된 모델을 다음 장에서 소개한다. 마지막 장은 본 연구의 결론과 앞으로의 연구 방안을 제안한다.

2. 공기식 기화기

2.1 공기식 기화기 구조

공기식 기화기(Ambient Air Vaporizer, AAV)는 액체 형태의 가스를 대기 중 공기와의 열교환을 통해 기체 상태의 가스로 변환한다. -162°C로 냉각된 액체 상태의 가스가 기화기 중심부에 위치한 관을 통해 공급이 되면 기화기 하부에 있는 팬을 가동하여 대기 중의 공기와 열교환을 하게 된다(<Figure 1> 참조). 기화된 가스는 중심 관 상부를 통해 외부로 나가게 되고 기화되지 못한 가스는 관 내부에 남게 된다. 설비 운영자가 설정한 목표 기화 유량이 전부 기화되면 이를 기화 종료 시점으로 본다. 공기식 기화기의 운영에서 에너지를 소모하는 부분은 외부 공기의 순환을 담당하고 있는 팬이며 본 연구의 개발 목표도 팬 회전수 운영을 자동화할 수 있도록 팬 회전수 운영 속도에 따라 LNG의 기화 후 온도 예측(토출온도) 모델을 만드는 것이다.




<Figure 1> Structure of Ambient Air Vaporizer[9]

2.2 현행 시스템 문제점

본 논문에서는 공기식 기화기의 문제점을 두 가지로 분류하였다. 첫 번째 문제는 액화 천연가스가 기체로 변화하는 과정에서 발생하는 열교환으로 기화기 표면에 서리가 성장하고 이로 인한 기화 성능의 저하 문제이다. LNG는 기화 과정에서 가스 1kg당 200kcal의 냉열을 외부로 방출하게 된다. 이로 인해 기화기 외부에 서리가 맺히게 되는데 서리가 일정 수준 이상으로 성장하면 기화 성능이 저하되어 설비 운영 효율이 떨어지게 된다. 때문에 공기식 기화기는 연속적인 사용이 불가하고 일정 시간 운행 후 서리가 녹을 휴식 시간이 필요하다. 이를 해결하기 위해 Jeong et al.[3]은 기화기 표면의 얼음 층 두께와 내부 기화기 온도 분포, 핀 두께, 두 핀 사이의 각도 사이의 상관관계를 통해 기화기의 최적 설계를 위한 상관관계를 제안하였고, Le Gall[7]은 시간에 따른 서리의 밀도와 두께를 예측하기 위한 1-D 성에 형성 모델을 제안하였다. Lee et al.[8]은 강건한 기화기를 설계하기 위해 웨이블릿 기반 최적화를 사용하였다. 두 번째 문제는 기화기 하부의 팬 회전수와 관련 있다. 타 기화기와 달리 공기식 기화기의 경우 기화운전 성공에 대한 데이터 및 설비 운영 관련 알고리즘 부족으로 현행 시스템에서는 설비 운영자의 설비 운영 경험을 기반으로 특정 팬 회전수에 국한된 보수적인 운전을 진행하고 있다.

현 공기식 기화기 운영 데이터를 기반으로 분석한 결과(<Figure 2> 참조)에 따르면 현행 시스템의 운영방식은 경험을 통해 얻어진 기화 운전 시 실패하지 않는 운전조건인 550rpm이나 600rpm에서 빈도수가 전체 총 팬 회전수 중 대다수(약 92.38%)로 다른 팬 회전수들에 비해 높게 나타난다. 이러한 운영 방식은 설비 운영자의 경험에 의존한 운전 조건설정으로 보다 경제적인 운영을 하기보다는 기화에 실패하지 않는 보수적인 운전을 하고 있다는 것을 의미한다.



<Figure 2> AAV Fan RPM Histogram

2.2 기화기 최적 운용을 위한 문제 정의

공기식 기화기의 운영 효율성을 높이기 위한 팬 회전수 운영은 첫 번째로 기화기를 통과해 기체 상태로 변환 가스의 토출온도를 0℃ 이상으로 유지하여 승온 설비의 불필요한 가동을 방지해야 한다. 두 번째, 토출온도를 0℃ 이상으로 유지할 수 있는 기화기의 성능을 확보해야 한다. 앞서 언급했듯 공기식 기화기의 특성상 기화 운전을 하는 동안 기화기에 결빙이 생기게 되고, 이는 효율성 저하와 기화 운전의 목표치를 미달성의 문제를 발생하게 한다. 따라서 기화기의 성능을 유지하기 위해서는 기화성능이 떨어지는 시점을 탐지하고, 기화성능이 유지되는 구간 안에 기화 운전이 종료될 수 있도록 해야 한다. 이러한 운영 조건에 맞춰서 최소의 팬 속도를 조정해서 에너지를 절감할 수 있도록 지원하는 것이 필요하다. 이를 위해서는 우선 외부의 대기 상태와 팬 회전수에 따라서 공기식 기화기를 통과하는 기체 상태의 NG 토출온도를 정확하게 예측하는 것이 필요하다.

3. 데이터 수집

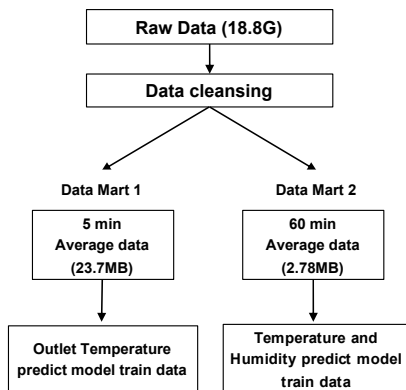
3.1 수집 데이터

공기식 기화기에서 센서를 통해 실시간으로 수집되는 데이터는 인입밸브, 팬 회전수, LNG 온도, 토출온도, 기화 유량이고, 기화기 운영에 큰 영향을 미치는 환경데이터는 대기온도, 습도로 구성된다. 공기식 기화기에서 인입밸브는 액체 상태의 천연가스가 관을 통해 기화기로 들어가는 양을 조절한다. 인입밸브의 센서 데이터 값은 0~100 사이의 값으로 인입밸브의 열린 정도를 의미한다. 예를 들어 인입 밸브의 값이 0일 경우 기화기의 중심 관에 밸브가 닫혀 있는 것을 의미하고 100일 경우 밸브가 열려 있는 것을 의미한다. 인입밸브의 값은 실제 공기식 기화기가 가동 중인지 아닌지 판단하는 데 사용된다. LNG 온도는 공기식 기화기에 들어오는 LNG의 액화 상태의 온도를 측정 한 값으로 평균적으로 -162℃ 내외의 값을 갖는다. 토출온도는 LNG가 NG로 기화되어 중심 관 상부를 통해 나왔을 때의 기화 상태의 온도를 측정 한 값이다. LNG는 -120℃에서 기화가 시작되어 -40℃ 정도 되면 기화가 완료된다. 하지만 수요처에 공급을 하기 위해서는 토출온도가 0℃ 이상이 되는 것이 필요하다. 기화유량은 해당 공기식 기화기를 통해 기화되는 NG의 양을 측정한다. 기화유량 데이터는 기화기에 들어오는 LNG의 유량과 동일하므로 LNG 인입유량으로 기화 유량을 계산해 볼 수 있다. 대기 온도와 습도 데이터는 기화기 주변의 측정된 대기 온도와 습도를

사용하며, 팬 회전수를 결정에 영향을 미치는 주요 요인들 중 하나이다. 팬 회전수는 공기식 기화기에 외부 공기를 순환시키는 역할을 하고 있으며, 400RPM에서 700RPM 정도로 운전되고 있다. 너무 낮은 팬 회전수는 열교환을 충분하게 하지 못하게 해서 필요한 토출온도를 달성하는데 실패하게 한다. 반대로 너무 높은 팬 회전수는 소음과 설비의 안정성에 영향을 미치고, 또 에너지 사용량이 증가되어 생산 비용을 높이는 요소가 된다.

3.2 데이터 전처리 및 데이터 마트 구축

공기식 기화기(Ambient Air Vaporizer, AAV)의 운영은 기화 시 발생하는 서리 때문에 가동과 휴지를 반복한다. 따라서 기화기가 언제 가동되고 있는지는 파악하는 것이 중요하다. 전체 데이터에서 기화 운전 시에 수집된 데이터만을 추출하기 위해 인입밸브의 값이 100이고, 팬 회전수 데이터의 값이 최소 팬 회전수인 450rpm 이상일 때의 설비 데이터의 값들만을 추출하여 가동 데이터로 선별하였다. 선별된 데이터에는 센서의 및 데이터 수집 시스템의 오류로 인한 이상 데이터가 존재하기 때문에 이를 제거하기 위한 전처리 과정을 거친다. 선별된 데이터를 센서 종류별로 평균점을 기준으로 3 sigma를 초과하는 데이터는 이상 치로 간주하고 제거하는 방식으로 이상 치를 정리한다. 이후 데이터의 결측을 해결하기 위해 선형 보간법(linear interpolation)을 사용하여 데이터의 결측치를 처리하였다. 다양한 센서에서 데이터가 서로 다른 주기로 수집되기 때문에 각 데이터의 수집 시점을 일치시키기 위해 전체 데이터를 5분 단위의 평균 데이터와 1시간 단위의 평균 데이터로 변환하여 시점의 불일치를 완화하였다. 단위 시간에 대한 평균값으로 압축하여 정리하면, 전체 18GB 정도의 데이터가 각각 23.7MB(5분 단위 압축)와 2.78MB(1시간 단위 압축)로 데이터가 축소되며, 이를 데이터 마트 1과 데이터 마트 2로 구축하였다. <Figure 3>은 위의 과정을 데이터 마트 구축을 도식화한 그림이다.



<Figure 3> Data Mart Development Process

TIMESTAMP	Fan RPM	Gas amount	Ing Temp	Valve	Outlet Temp
2019-12-01 00:00:00	0	-0.148992	-54.184453	19.909453	13.369922
2019-12-01 00:10:00	0	-0.249922	-53.517244	19.909053	13.350476
2019-12-01 00:20:00	0	-0.249766	-52.885625	19.909688	13.356142

<Figure 4> Structure of DataMart

전처리와 특징 추출을 수행한 데이터 마트(<Figure 4> 참조)는 다음 장에서 기화기의 토출온도 예측을 위한 인공지능 모델을 만드는 데 사용된다.

4. 모델 개발

4.1 상관관계 분석을 통한 독립변수 도출

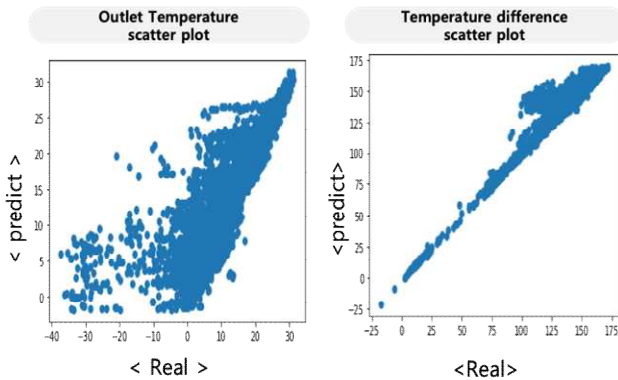
토출온도를 예측하는 인공지능 모델을 개발하기 전에 토출온도 예측에 영향을 미치는 독립변수와 그 독립변수 간의 상관성을 확인하기 위해 데이터 마트의 요소 간 상관분석을 실시하였다. 상관관계 분석 결과를 바탕으로 상관관계수 r의 절댓값을 기준으로 0.5 이상인 변수들을 종속변수인 토출온도에 영향을 미치는 주요 변수들로 판단하였다. 이를 바탕으로 독립변수를 선정하였다. 선정된 독립변수는 팬 회전수, 기화 유량, LNG 온도, 대기 온도, 습도이다. 선정된 독립변수들과 종속변수의 인과관계를 검증하기 위해 데이터와의 선형 상관관계를 모델링하는 분석기법인 ‘다중 선형 회귀(Multiple Linear Regression)분석’을 통해 독립변수와 종속변수의 인과 관계를 검증하였다. 다중 선형 회귀분석은 독립변수(dependent variable)가 2개 이상으로 구성되고, 독립변수의 값을 이용하여 종속변수(independent variable)의 값을 예측하는 통계적 기법이다[4]. 다중 선형 회귀모형에서는 독립변수들 간의 상관관계가 높을 경우 회귀모형의 회귀 계수가 불안정해지는 다중공선성 문제가 발생한다[5]. 다중공선성 문제를 판별하기 위한 방법에는 독립변수들간의 상관계수를 평가하는 방법과 분산팽창요인(Variance Inflation Factor, 이하 VIF)을 통해 평가하는 방법 등이 있으며 일반적으로 VIF을 통한 평가 방법을 사용한다. 본 논문에서는 VIF 방법을 사용하여 다중 선형 회귀 모형의 다중공선성 문제를 진단하였다. 다중공선성 문제 진단 시 통상적으로 VIF가 10 이상일 때, 잠재적으로 유해한 다중공선성을 나타내며, 엄격한 기준에서는 5이상을 판단기준으로 한다[1]. 본 논문에서는 통상적인 기준인 10을 기준으로 하였으며 독립변수별 VIF는 <Table 1>과 같다. VIF를 통한 다중공선성 문제 판별 결과 모든 독립변수에서 10 이하의 VIF값을 확인하였다.

<Table 1> VIF by Independent Variable

	Fan RPM	Lng Temp	Temp	Humidity	Gas amount
VIF	1.30084	1.03539	1.83695	1.50036	1.11911

4.2 매개변수 생성을 통한 종속변수 도출

다중 선형 회귀분석을 통해 값의 산점도를 표현한 결과 종속변수를 토출온도로 설정하였을 경우 85%의 정확도로 독립변수와 종속변수의 관계를 설명할 수 있었다. 하지만 보다 뚜렷하게 각 변수 간의 인과 관계를 잘 설명할 수 있도록 온도변화량(토출온도-LNG 인입온도)이라는 독립변수와 종속변수 사이에 매개변수를 생성하여 매개변수인 온도변화량을 예측하고, 예측된 온도변화량 값을 LNG 인입온도를 더해 최종 토출온도로 예측하였다. 그 결과, 95%의 정확도로 단순히 바로 토출온도를 종속변수를 설정했을 때보다 더 높은 인과 관계를 설명할 수 있었다. <Figure 5>는 다중 선형 회귀분석의 예측 값과 실제 값을 산점도로 표현한 그림이다. 이를 통해 수집된 데이터에서 직접 토출온도를 예측하는 것이 아니라, 온도의 변화량만을 예측해서 이를 인입온도와 더해서 계산하는 방식으로 토출온도를 예측하는 것이 더 좋은 결과를 주는 것을 알 수 있다.




<Figure 5> Scatterplot by Variable

4.3 온도변화량 예측모델 수립

온도변화량을 예측하는 모델로 통계적 기법인 다중 회귀 분석모델과 기계학습(Machine learning) 기법 중 하나인 심층 신경망(Deep Neural Network, DNN)모델을 활용하여 비교 분석하였다. 다중 회귀 분석모델은 앞서 4.2 절에서 사용한 온도변화량 예측 모델을 사용하였으며 성능 평가 결과 MSE값은 5.2741, RMSE값은 2.2965로 나타났다.

심층 신경망모델은 인공 신경망(Artificial Neural Network, ANN)의 일종으로 여러 개의 은닉층을 지닌다는 점이 특징이다[10]. 본 연구에서는 심층 신경망모델의 Input Data로 앞서 상관관계 분석을 통해 도출한 독립변수 데이터를 데이터 매트 1에서 추출하여 사용하였고, Output Data를 온도변화량으로 설정하여 기화기 내외부의 환경(LNG 온도, 대기 온도, 습도)이 주어졌을 때 특정 운영조건(팬 회전수, 기화유량)에 따른 온도변화가 얼마나 이뤄지는지를 예측하였다.




<Figure 6> Temperature Difference DNN Model

<Table 2> Temperature Difference DNN Model Hyper Parameter

Layer	Node	Activation	Optimizer	Epoch	Batch
1	32	relu	Adam	100	16
2	16	relu			
3	1	linear			

온도변화량 심층 신경망 모델은 input layer, hidden layer 1, hidden layer 2, output layer 형태로 2개의 은닉층을 구성하였다(<Figure 6> 참조). Hidden layer 1의 Node 수는 32개, hidden layer 2의 Node 수는 16개로 구성하였고 activation function은 relu를 설정하여(<Table 2> 참조) 역전파 과정에서 기울기(Gradient)가 점차 작아지는 현상인 Gradient Vanishing 문제를 해결하였다[2]. 이후 전체 데이터의 60% 학습 데이터로 사용하여 100회 학습을 진행하였다. 온도변화량 예측 모델의 예측치가 타당한 결과를 보이는지 검증하기 위해 모델이 예측한 온도변화량의 값과 실제 값의 차이를 RMSE(Root Mean Square Error)를 사용하여 모델의 성능을 검증하였다. 측정된 RMSE값은 2.2217로 토출온도를 계산하였을 때 본 연구에서 설정한 예측 허용오차 범위인 -3~3℃ 범위 내에 포함되는 것으로 확인되어 개발한 예측 모델의 타당성을 확인할 수 있었다.

예측 데이터 오차의 산포를 분석하기 위해 히스토그램을 사용하였다(<Figure 7> 참조). 히스토그램 분석결과 예측 허용오차 범위안에 24239개로 약 93.72%의 데이터가 속하는 것으로 나타났다.



<Figure 7> Histogram of Prediction Error

다중 회귀 분석모델과 심층 신경망모델의 비교 분석 결과 심층 신경망모델을 사용하였을 경우 RMSE기준 0.07 가량 더 나은 성능을 보이는 것으로 나타났으나 다중 회귀 분석모델에 비해 월등한 성능을 보이지는 않았다(<Table 3> 참조). 하지만 데이터의 양이 많아질수록 성능이 선형적으로 증가하는 심층 신경망 모델의 특성상 데이터 증가에 따른 성능 향상이 가능할 것으로 판단되어 본 연구에서는 심층 신경망모델을 공기식 기화기의 온도변화량 예측모델로 선정하였다.


<Table 3> Performance Indicators by Model

model	MSE	MAPE	RMSE
Multiple Linear Regression	5.2741	0.865%	2.2965
Deep Neural Network	4.9358	0.817%	2.2217

4.4 온, 습도 예측모델 수립

공기식 기화기의 경우 4시간 정도 가동을 지속하기 때문에 시간이 지날수록 외부환경이 변하게 되고, 현재 설정된 팬 회전수는 같은 성능을 발휘하기 어렵다. 공기식 기화기의 운영을 자동화하기 위해서는 미래 시점에서의 외부환경 변화를 미리 예측하고 이에 맞춰 현재 팬 회전수를 조정하는 것이 필요하다.

온도변화량 예측모델의 경우 예측하는 시점에서의 온도변화량을 예측한다. 따라서 현재 시점에서 현재 시점 이후의 값을 예측하기 위해서는 미래 시점의 대기 온도와 습도를 알아야 한다. 이를 위해 대기 온습도 예측 모델을 개발하였다. 온도변화량 예측 모델의 독립변수는 시계열특성을 갖는 변수와 그렇지 않은 변수들로 구분할 수 있다. 먼저 기화 유량의 경우 시간과 관계없이 항상 일정하다. LNG 온도의 값은 특정 범위 안에서 랜덤하게 변화한다. 즉, 시간에 따라 값의 중심점이 변하지 않는다. 반면 대기 온, 습도의 경우 다른 독립변수들과 달리 시간에 따라 유동적으로 값이 변하게 된다. 이 때문에 현재 시점에서 현재 시점 이후의 값을 얻기 위해선 변수의 값을 예측해야 한다.



<Figure 8> Temperature and Humidity DNN Model

<Figure 8>의 대기 온, 습도 예측 심층 신경망 모델은 예측 시점부터 예측 시점 이전 12시간의 데이터를 INPUT 데이터로 사용하여 예측 시점 기준 1시간 후의 온도, 습도 예측하도록 하였다.


대기 온, 습도 예측 모델의 경우 온도 변화량 모델에서 Node 수를 각각 16과 8로 조절하여 구성하였다(<Table 4> 참조). 대기 온도/습도 예측 모델의 성능 평가를 위해 RMSE와 MAPE를 사용하였고 성능 평가 결과는 대기온도는 RMSE 0.525, MAPE 6.1088 습도 RMSE 4.3728, MAPE 6.5704로 나타났다(<Table 5> 참조). <Figure 9>와 <Figure 10>은 대기 온도/습도 예측 모델의 실제 치와 예측 치를 비교한 그래프이다. 총 500시간동안의 온도와 습도를 예측한 그래프로 파란색이 실제 값을 나타내고, 빨간색이 예측 값을 나타낸다.

<Table 4> Temperature and Humidity DNN Model Hyper Parameter


Layer	Node	Activation	Optimizer	Epoch	Batch
1	16	relu	Adam	50	16
2	8	relu			
3	1	linear			

<Table 5> Temperature and Humidity DNN Model Performance Indicators

	RMSE	MAPE
Temperature	0.525	6.1088
Humidity	4.3728	6.5704




<Figure 9> Compare the Actual and Predicted Values of the Temperature DNN Model



<Figure 10> Compare the Actual and Predicted Values of the Humidity DNN model

4.5 모델 검증

개발된 인공지능 모델을 평가 및 검증하기 위해 새로 3개월가량의 설비 운영 데이터를 시뮬레이션 검증 Data로 활용하였다. 실제 설비 운영에 사용된 전력량과 개발한 인공지능 모델로 예측하여 산정된 전력 사용량을 비교 및 분석하여 개발한 알고리즘의 평가척도로 사용하였다. <Figure 11>과 <Figure 12>를 통해 기화기 운영 시 발생하는 전력요금의 감소 비율을 살펴보면 8월에는 50.37%, 9월 49.74%, 10월 44.63% 가량 전력 사용량이 감소하였고, 8~10월 동안 사용했던 총 전력요금은 48.8%가량 감소한 것을 확인할 수 있었다.



<Figure 11> Electrical Energy Graph

	Aug.	Sep.	Oct.	Total
real electricity bill	6,861,016	4,875,466	3,671,744	15,408,226
predict electricity bill	3,405,303	2,450,240	2,033,118	7,888,661
Reduction(%)	50.37%	49.74%	44.63%	48.8%

<Figure 12> Compare the Electricity Bill

5. 결론 및 토의

본 연구를 통해 LNG를 NG로 변화하는 제조 공정에서 주요한 역할을 담당하고 있는 기화기의 한 종류인 공기식 기화기의 최적 운용을 위한 토출온도 예측 인공지능 모델

을 개발하였다. 토출온도 예측을 위해 토출온도에 영향을 주는 주요 독립변수들을 탐색하여 선정하였고, 종속변수인 예측 변수는 토출온도를 직접 사용하지 않고, 온도변화량이라는 새로운 매개변수를 중간에 도입함으로써 토출온도 예측의 정확도를 높였다. 또한, 미래 시점에서의 토출온도 예측을 위해 외부환경의 변화를 예측할 수 있는 모델을 만들고 이를 통합하여 미래 시점에서의 토출온도 예측이 가능하도록 하였다. 예측을 위해 사용된 인공지능 모델은 모두 심층 신경망 모델을 사용하였으며, 두 모델 모두 높은 예측 성능을 보이고 있음을 테스트하였다.

본 논문에서 개발된 예측 모델들은 공기식 기화기의 운영을 자동화하기 위한 작업 조건을 논리적으로 테스트해 볼 수 있는 시뮬레이션으로 사용이 가능하며, 이를 활용하여 향후 공기식 기화기의 팬 회전수 운영을 자동화하는 부분을 확장하려고 한다.

Acknowledgement

This paper was researched with the support of Chosun University's academic research fund in 2017.

References

- [1] Gareth, J., Daniela, W., Trevor, H., and Robert, T., An Introduction to Statistical Learning : With Applications in R, 1st ed., Corr. 7th printing 2017 edition, Springer, 2013.
- [2] Ide, H. and Kurita, T., Improvement of Learning for CNN with ReLU Activation by Sparse Regularization, In 2017 International Joint Conference on Neural Networks, 2017.
- [3] Jeong, H.-M., Chung, H.-S., Lee, S.-C., Kong, T.-W., and Yi, C.-S., Optimum Design of Vaporizer Fin with Liquefied Natural Gas by Numerical Analysis, Journal of Mechanical Science and Technology, 2006, Vol. 20, pp. 545-553.
- [4] Kim, D.H., Kim, J.W., and Kwak, J.W., Development of Water Level Prediction Models Using Deep Neural Network in Mountain Wetlands, Journal of Wetlands Research, 2020, Vol. 22, No. 2, pp. 106-112.
- [5] Kim, J.W, Lee, B.E., Kim, J.G., Oh, S.H., Jung, J.W., Lee, M.J., and Kim, H.S., Functional Assessment of Gangcheon Replacement Wetland Using Modified HGM, J. Wetl. Res., 2017, Vol. 19, No. 3, pp. 318-326.
- [6] Kim, N.-K. and Yun, S.-K., Study on the LNG Vaporization Characteristics of Open Rack Vaporizer(ORV)

- with Two-way Seawater Supplying System, *Journal of the Korean Institute of Gas*, 2017, Vol. 23, No. 1, pp. 41-16.
- [7] Le Gall, R., Experimental Study and Modeling of Frost Formation in Heat Exchangers; Etude Experimentale et Modelisation du Phenomene de Givrage Dans Les Echangeurs de chaleur, *Institut National Polytechnique de Grenoble*, 1994.
- [8] Lee, Y.K., Na, J.G., and Lee, W.B., Robust Design of Ambient-Air Vaporizer based on Time-Series Clustering, *Computers & Chemical Engineering*, 2018, Vol. 118, pp. 236-247.
- [9] Ma, G., Zhang, C., and Zhao, L., Analysis on Heat Transfer Effect of Air-Temperature Vaporizer in LNG Satellite Station, *Advances in Mechanical Engineering*, 2017, Vol. 9, No. 6, pp. 1-11.
- [10] Schmidhuber, J., Deep Learning in Neural Networks : An Overview, *Neural Networks*, 2015, Vol. 61, pp. 85-117.

ORCIDSang Hyun Lee | <http://orcid.org/0000-0002-4596-0799>Gi jung Cho | <http://orcid.org/0000-0003-3553-6991>Jong Ho Shin | <http://orcid.org/0000-0002-1271-4057>