

해양 플랫폼 공정 디지털 트윈 기술 개발 동향

서유탉, 이나영(서울대학교), 박명철(대우조선해양)

1. 서론

디지털 기술의 발전은 산업 전반에 걸쳐 큰 변화를 불러일으키고 있으며, 화학 공정 분야도 예외는 아니다. 해양 플랫폼 상부에 설치되는 화학 공정들은 육상에서 개발된 다양한 공정 제어 기술들이 적용됐으며, 최근 3차원 가시화 기술과 결합된 디지털 트윈 기술이 해양 플랫폼 공정의 모니터링 뿐 아니라 효율 향상과 예측 유지 보수를 위해 활발히 개발되고 있다. (그림 1)

디지털 트윈은 통상적으로 공정에서 얻어지는 실시간 주요 운전데이터를 디지털 환경에 저장하고 이를 가시화(Visualization)하여 보여주는 것을 의미한다. 즉, 디지털 환경 상에 만들어진 해당 공정의 복제품, 그 중에서도 데이터 측면의 복제품으로 생각할 수 있다. 주요 구성 요소로는 (1) 센서 데이터와 그 저장소 (2) 가상물리시스템(Cyber Physical System) (3) 3D 가시화 모델 이렇게 3가지를 들 수 있으며 추가적인 요소로서 예지보전 및 효율 향상을 위한 알고리즘, 가상현실 및 증강현실을 도입한 가시화 모델, 작업자 훈련 시스템(OTS, Operator Training System) 등을 들 수 있다. 그러나 디지털 트윈의 개념은 전문가 및 기업마다 다르며, 구성 요소나 충족 조건 역시 아직 명확하지 않다. 가장 큰 이유는 공정상의 모든 데이터를 취득할 수 없다는 현실적인 한계와 이 데이터들을 이용하려는 목적이 서로 매우 다르다는 것이다. 최근 많이 개발되고 있는 공정 디지털 트윈은 실시간으로 수집된 센서 데이터를 기반으로 공정 운영 및 의사결정을 지원하기 위한 시스템을 구축하는 부분으로, 디지털 트윈의 구성 요소 중 가상물리시스템 부분에 초점이 맞추어져있는 것으로 볼 수 있다. 센서를 통해 얻어진 운전 데이터들을 기반으로 기존 공정 시뮬레이션 프로그램이나 기계 학습 알고리즘을 이용해 분석한 뒤 공정 효율 향상과 예상 이슈를 가시화하는 것이 대표적이다. 즉, 해양 플랫폼 공정의 정상 상태를 기반으로 실시간 모니터링을 수행하고, 지속적으로 축적되는 운전 데이터를 문제 발생 탐색 및 예지 보전 모델에 입력하는 것이다. 화학 공정의 제어를 위한 주요 변수 즉, 각 유닛의 온도와 압력, 유량을 주요 운전 데이터라고 하면, 이제는 공정 운전에서 필요한 주요 장비들의 운전 데이터까지 기계 학습 모델에서 분석하여 공정 효율 향상과 예측 유지 보수에 활용된다.

본 기사에서는 해양 플랫폼 공정을 위한 디지털 트윈 및 기계 학습 알고리즘 연구 동향을 소개하고, 다양한 알고리즘의 특성과 활용 방안을 소개하고자 한다.

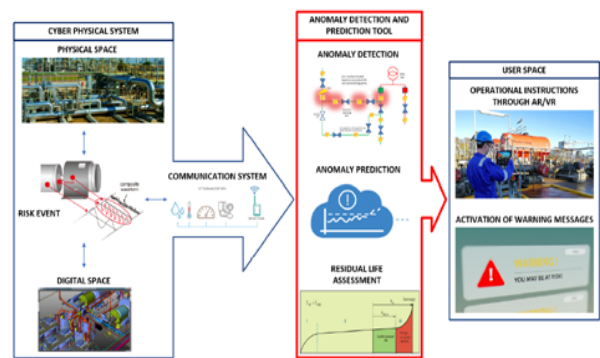


그림 1 디지털 트윈을 이용한 공정 효율화 및 위험성 진단 평가

2. 국외 기술 개발 동향

미국과 일본, 유럽의 주요 엔지니어링 및 에너지 기업들은 4차 산업혁명으로 촉발된 Digital Transformation 기술을 적극적으로 채용하여 단순 공정 모니터링 및 제어가 아닌, AI 기반 플랜트 운영·유지관리 시스템을 제공하고 있다. 공정 시뮬레이션 모델에 주요 장비가 포함된 공정 디지털 트윈과 예측 기반 공정 시스템 최적화 및 운영 기술이 핵심이라고 할 수 있다. 해양 플랫폼의 디지털 전환은 공정 시뮬레이션 모델과 주요 장비 모니터링 및 성능 예측 기술을 통합한 공정 디지털 트윈으로 이루어지고 있으며, 클라우드 기반 설계 및 운영 데이터 분석을 통한 공정 효율 향상 및 주요 장비 유지·보수가 포함된다. 특히 APC (Advanced Process Control) 연구와 산업 적용을 위한 기업들의 기술개발이 진행되어 왔으며, 다 변수 모델 예측 제어, 압축기 제어 등 최신 제어 기법이 연구되고 있다. 대표적인 기업으로 Honeywell은 AI 기반 APC 기술을 통해 공정 라이프 사이클의 모든 단계에서 성능과 효율을 최적화하는 프로젝트를 진행하고 있다. 실시간 공정 데이터 연결을 통해 운전데이터 분석 및 문제 발생 탐색 및 예지 엔진을 적용하였으며, 예상 이슈를 가시화하여 공장 운영 및 의

사결정을 지원하는 스마트 O&M 엔지니어링 서비스 플랫폼을 개발하였다. GE는 공정 터빈이나 엔진과 같은 산업용 장비나 부품에 부착된 센서를 통해 축적되는 빅데이터를 시가 스스로 분석, 제어하는 기술을 개발해 왔다. 클라우드 기반 산업 인터넷 S/W 플랫폼인 Predix를 개발하여 GE가 판매하는 항공기 엔진이나 철도, 선박제품에 센서를 부착하여, 발생하는 데이터를 분석함으로써 기계의 고장을 미리 예측하고, 보다 나은 효율을 달성하기 위한 스마트 팩토리 솔루션을 개발하고 있다. Aspen Tech은 AI 기반 APC를 적용한 공정 제어를 통해 LNG 생산 및 가스 플랜트 수율을 2~5% 증가시켰으며, LNG 액화공정의 생산 효율을 증가시키는 고급 제어 기술을 개발하고 있다. 또한, 생산 최적화 솔루션 'Aspen Unified'을 개발하여 생산 계획과 스케줄링을 APC와 동적 최적화와 같은 높은 수준의 운영 효율 체계를 갖추고 있다. Siemens사는 AI 기반 APC 시스템 중 하나인 Model-predictive multi-variable control을 적용하여 공장의 안정적인 작동과 효율적인 에너지 관리 모듈을 개발하고 있다. 빅데이터를 바탕으로 운영되는 스마트 팩토리이며, 천 여 개의 IoT 센서로 설비를 연결하여 각 공정 단계마다 제품의 이상 유무를 점검하고, 불량품 발생 시 바로 생산라인을 멈추고 부품 교체가 가능하다. 하루에 5,000만 건의 정보를 통해 제조 공정마다 실시간으로 작업 지시를 내려 작업 및 공정을 최적화할 수 있으며, 전체 공정에 75%가 자동화로 진행되고 불량률은 0.001% 수준이다. Yokogawa는 AI 기반 APC 기술을 통해 LNG 액화 공정의 생산 효율과 에너지 효율을 극대화하는 프로젝트를 진행하였으며, Multivariable Predictive Control (Exasmoc), Quality Estimator (Exarqe), Surge Volume Control (Exacoast) 등을 개발하여, 액화플랜트 시장에 많이 적용하고 있다.

DNV-GL에서는 해양 플랫폼의 디지털 트윈 개념을 제공하면서 (그림 2), 다음과 같은 키워드로 정리하고 있다. 1) Digital Value Chain run by Machines and Algorithms (Improving the capital value): 클라우드 계산, 가상현실, 기계 학습, 인공지능 등을 활용한 디지털 기술은 에너지 플랜트 효율을 크게 향상 시키고, 초기 투자 및 운전비용을 절감 할 수 있다. 2) Machines will increasingly replace people in oil and gas operation: 디지털 기술들이 적용된 디지털 트윈은 실시간 데이터 획득 및 분석 기술과 접목되어, 해양 플랫폼의 개념 설계 단계에서 설치 및 운전, 해체에 이르기까지 전 주기에 활용 가능하다. 공정 자동화, 로봇, 시스템 모델링이 디지털 트윈에 블렌딩 되면서, 향후 해양 플랫폼 공정 운전은 cyber-physical model 을 통해 인간의 개입을 최소화 할 것이다. 3) Building trust in Algorithms – Probabilistic machine

learning: 에너지 플랜트 운전의 자동화는 필연적으로 알고리즘의 신뢰성에 대한 의문으로 연결된다. 센서에서 얻어진 데이터를 실시간 시뮬레이션과 연동 해석함으로써 기계 학습과 인공지능을 제대로 활용하는 것이 가능하다.

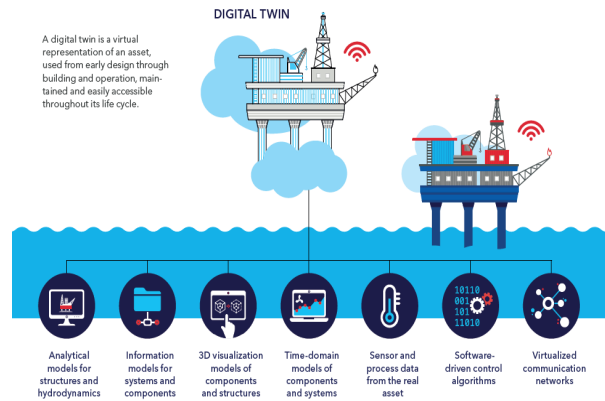


그림 2 DNV-GL 디지털 트윈 개념도

디지털 트윈 알고리즘의 신뢰성을 확보하기 위해서는 “유용한”, “많은” 데이터를 획득하고, 이를 기계 학습과 인공지능으로 강화된 Advanced Simulation Model에서 분석해야 한다. 해양 플랫폼 공정의 주요 설비에 대한 Digital Twin을 개발해 운전 및 유지/보수비용 절감이 가능하며, 이때 Digital Twin은 단순 3D 가시화에 그치지 않고, 실제 설비와 연결된 제어 시스템을 통해 예측 모델링 및 운전 최적화가 가능해야 한다. 공정에서 얻어진 데이터(Data gathering)는 virtual world에서 공정 모델을 구축하는데 활용되며 (Cyber-Physical model), 여기에 3D 가시화 기술이 적용되면 디지털 트윈이 완성된다 (Visualization).

호주 정부 산하 기관인 National Energy Resources Australia (NARA)에서 2017년에 분석한 결과에 의하면, 에너지 산업 전반에 걸쳐, 상호 호환 가능한 디지털 기술을 적용하는 경우 제어 시스템 업그레이드를 위해 소요되는 비용을 매년 10 million 달러 절감 가능하다고 한다. 또한 디지털 기술을 적용한 공정 최적화를 통해 매년 80만 톤의 LNG 증산 효과를 얻을 수 있으며, 이는 3억 달러의 가치에 해당한다. 또한 검증된 디지털 기술을 이용해 시스템 유지/보수를 수행하는 경우 CPEX의 1% 해당하는 비용을 절감할 수 있으며, 이는 매년 1억 달러의 가치에 해당한다. 호주 정부가 지원하고 서호주 대학에서 추진 중인 CRC project - Future Energy Exports (FEnEx)에서는 Digital technologies를 통해 LNG 생산 설비의 생산성과 신뢰성, 안정성을 향상시키고자 한다. Digital Twin

에 기반한 관리 기술과 예비 부품 저장을 최소화 하는 것도 목표에 포함되어 있다. 주요 연구 과제는, 1) Advanced process modelling and control: self tuning 공정 제어 모델; 2) Debottlenecking and Maintenance Improvement: 운전 중단 기간 최소화 전략; 3) Data Driven Modelling: 빅 데이터 분석 모델 개발 및 검증; 4) Digital Technologies for Reliable Remote Operations: 공정 무인화 기술; 5) Predictive maintenance : 예측 유지, 보수 기술, 등을 포함한다. 각 세부 기술은 주요 공정의 Advanced Process Control (APC)을 위한 도구로 활용되며, APC는 데이터 획득, 동적 모델, 다중 모델 제어, 공정 최적화의 단계를 통해 기존 제어보다 향상된 공정 제어 기술을 제공한다. 또한 공정 응답 테스트를 연속으로 실시하여 정상 상태 상황을 정확히 모사할 수 있는 운전 데이터를 획득한다. Cross correlation과 power spectrum density 등 빅데이터 해석 tool을 활용하여 cause-and-effect 상호 작용 분석한다. 지속적으로 축적되는 운전 경험 데이터와 맞물려 공정의 특징적인 운전 형태가 파악될 수 있다. APC는 공정 제어 변수 제어를 동적 운전에 기반하여 조정하기 때문에 독립적으로 이루어지는 많은 제어 루프들을 효과적으로 분리하여 제어할 수 있다. 또한 다중 모델을 활용하여 예측 제어할 수 있으며, 제어기의 운전 중단 없이 생산이 연속적으로 이루어지면서 공정 운전 상황에 적합한 모델로 switching 하는 것이 가능하다. APC는 공정에 존재하는 한계 즉, 밸브 작동 시간, 공정 변수의 반응 속도 등을 체계적으로 관리한다. 이를 위해 quadratic programming 등의 기술이 적용된다.

3. 국내 기술 개발 동향

에너지 산업의 패러다임 변화와 함께 진행되고 있는 디지털 전환은 산업 생태계에서 살아남기 위한 필수 요소가 되고 있지만, 2018년 이후 길게 이어진 에너지 산업의 불경기로 인해 국내 기업들은 디지털 전환에 대한 대처가 늦어지고 있다. 국내에서는 정유, 화학 업계를 중심으로 디지털 트윈을 이용한 제어 기술이 구축되고 있으나, 대부분 해외 클라우드나 분석 SW에 의존한 해외 솔루션을 기반으로 개발하고 있다. 즉, 자체 솔루션을 개발한 기업이라 할지라도 일부 분야에만 초점을 맞추는 경우가 많고 자체 솔루션이 없는 기업들 중 상당수가 국외 기업들의 솔루션을 이용한 SI/컨설팅/교육 사업을 진행하고 있다.

SK케미칼은 MPC 핵심기술을 적용하여 제어하고자 하는 공정의 동특성을 미리 구축하고, 실시간 변화를 예측하여 공

정의 조업 안정성과 경제성을 위한 실시간 공정제어 장치를 개발하고 있다. LG CNS는 제조업 혁신에 앞장서 스마트 제어 시스템을 적용한 스마트 팩토리 플랫폼 팩토바 컨트롤 시스템 (Factova Control System)을 개발하였다. 이를 통해 제조 현장의 다양한 설비에 대해 전문 프로그래밍 지식이 없어도, 쉽고 빠르게 제어 시스템을 구축할 수 있는 스마트 팩토리 솔루션을 개발하였으며, LG그룹사와 외부업체에 IT 서비스 및 컨설팅 서비스를 제공하고 있다. 특히 MES같은 소프트웨어나 공정설계 서비스와 같이 공장의 전반적인 솔루션을 제공하고 있다. 현대오일뱅크는 '디지털전환 추진 5개년 세부계획'을 통해 2025년까지 스마트컴퍼니 구축을 진행하고 있으며, 주요 공정에 APC 시스템을 적용하여 설정된 범위 내에서 공정의 최적 조건을 유지하도록 자동제어 시스템을 개발하고 있다. LS 산전은 수요예측 시스템(APS)이 적용된 유연생산 시스템 방식의 스마트 팩토리 체제를 구축하여 설비 대기 시간 50% 감축하고, 생산성 60% 향상, 에너지 사용량 60% 이상 절감, 불량률 6 ppm, 급감 등의 성과를 달성하였다.

공정 디지털 기술의 확산을 위해서는 엔지니어링 기술 고도화 및 디지털 전환 지원, 테스트 플랜트에서 얻어진 데이터로 실증 실적을 확보한 신뢰성 높은 기술 개발이 필요하다. 공정 주요 장비와 시뮬레이션 모델을 연계하여 공정 디지털 트윈으로 발전시킬 수 있는 가상화 운영·유지관리 플랫폼 개발과 테스트 플랜트를 활용한 플랫폼 검증을 통해 상용화 기반을 구축해야 한다.

4. 공정 디지털 트윈 상에서 사용되는 알고리즘 - 기계 학습 기법을 이용한 예측 유지보전 모델

앞서 공정 디지털 트윈에 이용될 수 있는 여러 알고리즘으로 예측 유지 보전 모델 및 공정 효율 향상 알고리즘을 들었다. 실시간으로 수득된 센서 데이터를 단순히 시각화 하는 것을 넘어서, 데이터를 이용해 현재의 이상을 진단하고 예방하며 효율 향상을 위한 방안을 수립할 수 있도록 하는 것이다. 화면상의 센서 수치만으로 의사결정이 쉽지 않은 공정 시스템의 경우 디지털 트윈 상에 위와 같은 알고리즘들이 함께 탑재되는 것이 매우 중요하다. 특히 예측 유지 보전 모델은 기술적인 한계 때문에 잘 시도되지 않았던 분야였으나, 최근 기계 학습 방법론의 대두에 힘입어 많은 발전이 이루어지고 있는 분야이다.

4.1 예측 유지 보전(Predictive Maintenance)의 개념

해양 플랫폼 공정을 위한 예측 유지 관리는 크게 4가지로 구분되는데, 이는 (1) 고장/사후 보전, (2) 예방/정기유지 보전 (3) 예지/상태기반 유지보전 (4) 선행 예방 보전으로 나눌 수 있다.

(1) 고장/사후 보전(Corrective/Reactive Maintenance) : 장비가 완전히 가동 중지된 이후 수리하는 방법

(2) 예방/정기유지 보전 (Preventive/Time Based Maintenance) : 미리 정해진 시간 간격으로 수리하는 방법

(3) 예지/상태기반 유지보전 (Predictive Maintenance) : 장비의 주기적인 모니터링을 통해 비정상적인 경향이 감지되면 수리하는 방법

(4) 선행 예방 보전 (Proactive Maintenance) : 고장 원인을 추적하여 해당 원인을 미리 제거하는 방법

현재는 (3) 예지/상태기반 유지보전과 (4) 선행 예방 보전 둘 모두를 함께 사용하며, 선행 예방 보전을 예지/상태기반 유지 보전 개념에 포함하기도 한다. 모니터링의 경우 비파괴 검사법을 이용하며, 주로 적외선/음향/진동 등의 검사법을 이용한다. 이러한 방법을 통해 연속 생산 공정 산업에서의 가동 중지 상황을 막을 수 있으며, 수리 시간을 개선하고 기계의 생산성 및 수명을 연장할 수 있다.

기계 학습은 이러한 예지 기반 유지 보전을 위한 하나의 방법으로, 최근 대두되고 있는 Model Based Condition Monitoring에 속한다. 기계 학습을 통해서 기존에 설정된 알람이나 트립 설정치 보다 빠른 시점에 이상을 감지하여 이른 시점에 유지보수를 수행할 수 있다. 이는 디지털 트윈과도 밀접한 관계가 있는데, 디지털 트윈을 제작하는 주요 목적 중 하나가 이러한 예지 보전 기술에의 활용을 위한 것이기 때문이다.

Anomaly Detection의 경우는 이러한 예지 기반 유지 보전에 빈번하게 사용되는 기계학습 분야로 기본적으로는 정상적이라고 정의된 상태의 반대 상태를 이상 상황으로 정의하여 이를 찾아낼 수 있는 모형을 구축한다. 많은 산업 현장에서 고장 데이터를 구하기 어려운데, Anomaly Detection의 경우는 고장 데이터가 없는 상황에서 정상상태 데이터를 가지고 이상 여부를 판별할 때 유용하게 사용될 수 있다.

4.2 예측 유지 보전을 위한 기계 학습 알고리즘

기계 학습은 데이터를 기반으로 컴퓨터가 학습할 수 있는

모델을 만들어내는 알고리즘이며, 실제 공정에서 얻어진 운전 데이터들로 예측 유지 보전을 수행할 수 있다. 이때 활용 가능한 다양한 알고리즘을 알아보았다.

Regression: 블랙박스 함수를 만드는 방법으로, 기본적으로 주어진 여러 변수들이 각각 이상 상황을 만드는 데 얼마만큼의 가중치를 가질 것인가를 데이터를 이용해 학습한다.

Support Vector Machine(SVM): Svm은 여러 데이터 포인트들을 분류하는 경계면을 찾는 방법론으로, 내/외부의 분포에는 상관없이 집합의 경계면만을 학습한다. 테스트 개체가 학습된 영역에 들어가면 정상으로 판별하고, 아니면 이상으로 판별한다. 발전소 이상 탐지에 사용된 사례가 있다.

Nearest Neighbor: 비지도 학습 기반이며, 자료에 대해 어떠한 가정도 필요하지 않다. 이상값이 학습 집합에서 가까운 근방을 형성할 확률이 매우 낮아 준지도 기법이 비지도 기법보다 이상값을 잘 찾아내는 면에서 더 우수하고, 거리만 잘 정의되어 있으면 자료의 형태에 구애받지 않는다. 단, 테스트 과정에서 각각의 근방을 구해야 하므로 오랜 시간이 걸린다. 자료의 차원이 높아질수록 거리를 계산하는 데 있어 어려움이 많이 따른다.

Clustering: 군집화는 비슷한 개체들을 군집으로 형성하여 탐색적 자료 분석과 자료 시각화를 위해 사용한다. 주로 비지도 기법으로 사용되며, 거리 및 조밀도에 기반하여 정상 군집과 이상 군집을 구분, 이상 상황을 찾아낸다.

Neural Network: Regression Model을 만들 때 사용하는 기본적인 신경망으로, Parameter들을 가지고 있을 때 이를 기반으로 각 Parameter가 어떤 영향을 미치는지 학습한다. 각 레이어는 여러 노드로 구성되어 있으며, 각 노드는 다음 노드로 넘어갈 때 활성화 함수를 거쳐 가중치가 곱해진 상태로 값을 전달한다.

Deep Neural Network은 기본적으로 Neural Network의 내부 은닉 레이어의 수를 1개에서 여러 개로 증가시킨 네트워크로 다양한 비선형적 관계를 학습할 수 있는 네트워크다. 응용분야에 따라서 다양한 알고리즘들이 개발되고 있다. CNN(Convolution Neural Network)은 이미지 처리에서 주로 사용되는 기법으로, filter를 이용한 convolution 기법이 포함된 신경망을 일컫는다. LSTM(long short-Term Memory Model)은 RNN(Recurrent Neural Network)의 일종으로, RNN에서 시간적으로 멀리 떨어진 두 정보의 영향력이 많이 감소하는 문제를 보완하기 위해 만들어졌다. 이전 상태를 기억하는 항을 가지고 있으며 이 때문에 음성이나 문자 등 순차적으로 들어오는 시계열 데이터 처리에 적합하다.

신경망(딥러닝)이 예지 보전에서 사용되는 경우, Reinforcement Learning을 적용하는 것이 가능하다. 딥러닝 모델이 1회 학습 후 고정되는 것이 아니라 지속적으로 들어오는 입력값을 받아서 정상 상태를 직접 정의하고 해당 상태를 유지할 수 있도록 하는 방법으로, DQN(Deep Q-Network) 등의 방법이 있다.

4.3 LSTM을 이용한 공정 이상 감지 및 유지 보수 모델 개발 사례

LSTM기반의 Anomaly Detection은 LSTM Auto Encoder 모델을 이용해서 Prediction Error Distribution을 계산하는 방식을 이용한다. 즉 LSTM 모델을 이용해 예측한 지점이 이상치에 해당할 확률을 계산하는 것이다. 정상적인 구간에 해당하는 값들을 기반으로 딥러닝 모델에 넣으면 이것이 해당 센서값의 시계열 벡터에 대한 정상 구간 예측 모델이 되고, 이 모델에서 돌려주는 결과값인 Prediction Error Distribution 값을 기반으로 이상치를 예측한다. 이때 Error Distribution상에서 정상값과 이상값을 구분하는 경계를 threshold라 부르며, threshold 안쪽을 tolerance band라고 부른다. 여기서 예측한 이상치들의 누적값을 기반으로 Degradation Level을 계산하고, 장비의 MTTF(Mean Time To Failure)값을 기반으로 RUL Estimation을 수행할 수 있다.

기본적인 RNN 모델은 공통적으로 체인처럼 연결이 되어 있는데 Standard RNN은 직전 Cell의 출력값을 그대로 가져와서 새로운 Input과 의 연산을 수행한다. 그러나 LSTM 레이어는 직전 Cell의 출력값 뿐만 아니라 기억을 담당하는 구조가 Cell에 포함되어있다. 즉, 이전 Cell들과 연관성을 가지는 RNN모델을 사용하며, 시간적으로 오래 전인 Cell과의 연관도 역시 연산에 포함될 수 있도록 하는 구조인 Cell State라는 개념이 추가된 형태라고 보면 된다. Autoencoder는 차원을 축소하는 encoder와 차원을 확장하는 decoder를 합쳐놓은 것으로, 주로 Feature Extraction을 위해 많이 쓰였다. Encoder는 Layer의 Cell 개수가 점점 줄어들고, Decoder는 Layer의 Cell 개수가 점점 늘어난다. 이때 Layer의 Cell 개수를 신경망에 들어오는 Input의 Feature로 해석할 수 있는데, 신경망 내부에서 Layer가 진행되는 동안 Cell 개수가 점점 줄어들게 되면 Feature가 점점 단순하게 표현된다고 볼 수 있다. 동일한 데이터를 100개의 Cell, 즉 100개의 값으로 나타냈다가 10개의 값으로 나타내려고 한다면 더 적은 수로 동일한 데이터를 표현해야 하므로 특징들을 추출하는 방법을 찾아야 한다. 즉 Encoder에서는 신경망이 판단하기에 가장 중요하다고 생각되

는 특징만을 남기고, 신경망이 판단하기에 별로 중요하지 않다고 생각되는 형태들은 생략하거나 다른 값으로 합친다. 점점 더 차원이 작은 특성 공간으로 이동한다고 볼 수도 있다.

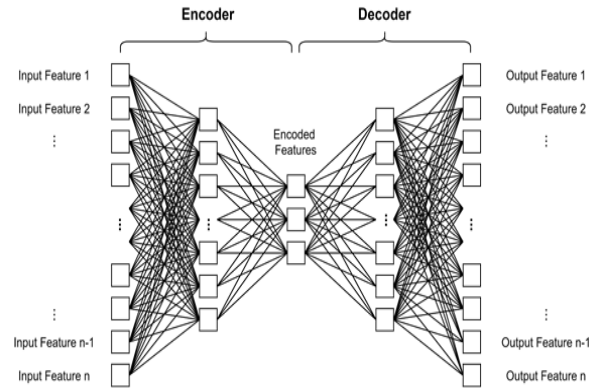


그림 3 LSTM Autoencoder 개념도

기계 학습 알고리즘을 이용해 공정에서 얻어진 시계열 데이터를 분석하면, 정상 상태 데이터를 학습하여 이상 데이터를 감지하는 것이 가능하다. 센서에서 얻어지는 값들에 대해서 얻어지는 이상 감지 결과는 공정마다 다르게 나오기 때문에, 각 센서에 대해서 한계값(Threshold)을 지정해주는 것이 필요하다. 즉, 정상 상태를 벗어나 한계값에 가까워질수록 공정은 이상 상황에 가까워지는 것이며, 한계값을 넘어서는 경우 이상 상황이 발생했다고 정의할 수 있다. 주목할 점은 한계값을 설정하고 이를 벗어났을 때 경고하는 것은 기계 학습 알고리즘이 아닌 일반적인 공정 제어 모델에서도 가능하다. 기계 학습 알고리즘을 적용하는 것은 단일 센서에서 이상 상황에 가까워지는 상황과 다양한 센서들에서 이상 상황에 가까워지는 것을 통합 분석해 점수화 할 수 있다는 것이다. 이상 상황에 가까워질수록 점수는 높아질 것이고, 한계값에 얼마나 가까워졌는지를 예측할 수 있다. 이렇게 학습된 기계학습 모델은 디지털 트윈 시스템에 탑재되어 사용될 수 있으며, 전이 학습을 이용하여 차후에 새로운 데이터로 또다시 학습시키는 것 역시 가능하다.

4.4 다중 센서 공정 이상 감지 및 유지 보수 모델 개발 사례

LSTM을 이용한 단일 센서 이상 감지 기법을 응용하여, 공정 상의 다양한 센서 값을 하나의 입력값으로 받은 뒤 이 값들의 연관도를 행렬로 만들어 다중 센서를 기반으로 한 이상

감지 모델을 구성할 수 있다. 이러한 연관도 행렬은 1차원 시계열 데이터의 모음을 2차원 데이터로 만든 것으로, LSTM 네트워크 전단에 합성곱 신경망(CNN, Convolutional Neural Network)을 추가하여 처리할 수 있다. 합성곱 신경망을 이용하는 기계학습 알고리즘은 이미지 처리 분야에서 많이 사용되어 그 성능이 검증된 네트워크로, 2차원 및 3차원 데이터에서 한 지점과 그 지점 주변 사이의 연관도를 처리하기 위해 합성곱을 이용한다. 이와 같은 네트워크 조합으로 여러 개의 센서 간의 연관도를 반영한 이상 감지를 수행할 수 있다. 이상의 종류나 위치에 따라서 이상 감지 결과 값이 다르게 나오므로, 데이터가 충분히 많은 경우에는 위 알고리즘에서 도출된 이상 감지 결과 값을 기반으로 어떤 이상 상황인지 추정하는 것도 가능하다.

그림 4는 미국 Eastman Chemical Company에서 발표한 Tennessee Eastman Benchmark Process에 앞서 개발한 기계 학습 알고리즘을 적용한 결과를 보여주고 있다. 해당 공정은 4개의 반응물로부터 2개의 생성물을 얻는 공정으로, 반응기와 응축기, 분리기, 압축기, 증류탑 등으로 구성되어 있다.

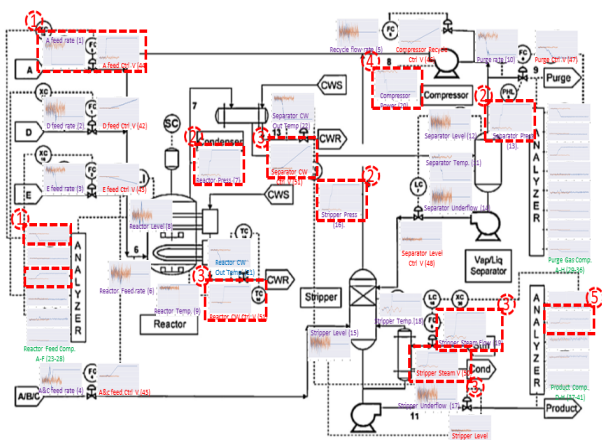


그림 4 Tennessee Eastman Benchmark Process 운전 데이터를 기반으로 감지된 이상 상황

그림 4에 제시된 시나리오는 정상적으로 공급되는 Feed가 중단되는 feed loss case에 해당한다. 먼저 Feed 유량이 0 kgmol/h로 감소하고, (2) 이로 인해 반응기와 분리기, 증류탑의 압력이 증가한다. (3) 일련의 변화와 함께 증기 유량이 증가하고, (4) 압축기에 가해지는 일이 감소하면서, (5) 반응물의 조성이 변한다. Feed가 중단되는 큰 변화이기 때문에, 많은 센서 값에 영향을 준다. 그렇기 때문에 정상 상태에서 학습한 연관도 행렬과는 많은 차이가 생기게 되어 기계 학습으로 감지한 이상 상황 점수는 200점을 훌쩍 넘어간다. 반면에 반응

기의 냉각수 공급 유량이 변하는 경우 반응기 온도에 약간의 변화가 있을 뿐 전체 공정 성능에는 별다른 영향을 미치지 않고, 기계 학습이 계산한 이상 상황 점수는 10점 미만에 불과하다.

기계학습 알고리즘을 이용하여 학습시킨 이상 감지 모델을 이용, 감지된 이상치의 빈도를 보고 예지보전의 시점 및 장비의 남은 수명(RUL, Remaining Useful Lifetime) 값을 유추하여 장비의 예측 유지 보전에 이용할 수 있다. 이러한 알고리즘이 실제로 잘 적용되기 위해서는 많은 데이터 및 시행착오가 필요하다. 이를 보완하기 위해 많은 운전 데이터 획득 및 과거 운전 데이터의 적절한 활용에 관한 방법론 수립이 필요하다.

5. 결론

해양플랫폼 공정 디지털 트윈은 지금까지 연구된 공정 모사 및 제어 기술에 기계 학습 알고리즘을 적용해 더욱 발전시킬 수 있는 플랫폼의 역할을 할 것이다. 앞서 설명한 바와 같이 이미 다양한 기계 학습 알고리즘이 개발되었고, 해양플랫폼 공정에 적용해 원하는 제어 기술을 개발하는 것이 가능하다. 하지만, 기계 학습 기반의 APC(Advanced Process Control)는 필연적으로 알고리즘의 정확도에 대한 의문으로 연결되며, 알고리즘의 정확도를 증명하기 위해서는 많은 데이터를 확보해주어야 한다. 연구를 위해 알고리즘을 개발한다 하더라도 원하는 공정의 운전 데이터가 없으면 알고리즘의 주요 파라미터를 검증하기 어려운 상황인 것이다. 이를 위해서는 알고리즘의 개발과 함께 이를 구축할 수 있는 데이터베이스 구축이 병행되어야 할 것이다.

참고 문헌

- Malhotra, Pankaj et al., [Long short term memory networks for anomaly detection in time series] Proceedings, Vol. 89, Presses universitaires de Louvain, (2015).
- Changsong Lee et al., [Fault Detection in LDPE Process using Machine Learning Techniques] Korean Chemical Engineering Research, 58(2), 224-229. (2020).
- Saha, Bhaskar, Goebel, Kai, [Model Adaptation for Prognostics in a Particle Filtering Framework] (2011).
- N, Daroogheh et al. [Prognosis and Health Monitoring of

Nonlinear Systems Using a Hybrid Scheme Through Integration of PFs and Neural Networks], IEEE Transactions on Systems, Man, and Cybernetics: Systems (2017).

Bevilacqua, M. et al. [Digital Twin Reference Model Development to Prevent Operators' Risk in Process Plants] , Sustainability (2020).

M. Orchard et al. [Data Mining in Systems Health Management: Detection, Diagnostics, and Prognostics] (2011).

Zhang, C et al. [A Deep Neural Network for Unsupervised Anomaly Detection and Diagnosis in Multivariate Time Series Data], Proceedings of the AAAI Conference on Artificial Intelligence (2019).

Malhotra, P. et al, [LSTM-based Encoder-Decoder for Multi-sensor Anomaly Detection](2016).



서유택

- KAIST 생물화학공학과 박사
- 현 재 : 서울대학교 조선해양공학과 교수
- 관심분야 : 에너지 시스템, 해양 플랫폼
- E-mail : Yutaek.Seo@snu.ac.kr



이나영

- 서울대학교 조선해양공학과 박사 과정
- 관심분야 : 시계열 데이터 활용 머신 러닝, 공정 디지털 트윈
- E-mail : yna0722@snu.ac.kr



박명철

- 현 재 : 대우조선해양 중앙연구원 책임연구원
- 관심분야 : 선박/해양공정 디지털트윈, 설비예지보전, 공정최적화
- E-mail : mcpark1@dsmc.co.kr