

## 탄소 배출을 고려한 스마트 팩토리에서의 생산 최적화 기술 동향

이현수, 박수현\*, 김중헌

고려대학교, \*숙명여자대학교

hyunsoo@korea.ac.kr, \*soohyun.park@sookmyung.ac.kr, joongheon@korea.ac.kr

### Carbon Aware Production Optimization in Smart Factories: Technology Trends and Outlook

Hyunsoo Lee, Soohyun Park\*, and Joongheon Kim

Korea Univ., \*Sookmyung Women's Univ.

#### 요 약

본 논문에서는 스마트 팩토리 환경에서 탄소 중립 목표를 달성하기 위한 최신 생산 최적화 기술 동향을 분석하였다. 제조 산업은 전 세계 탄소 배출량의 상당 부분을 차지하고 있어, 생산 효율과 탄소 배출량을 동시에 최적화하는 기술 개발이 필수적이다. 특히 IoT 센서, 디지털 트윈, 클라우드 및 엣지 컴퓨팅과 같은 첨단 기술들이 스마트 팩토리에서 에너지 효율 개선을 위한 핵심 요소로 자리 잡고 있다. 특히 휴리스틱 최적화 기법과 기계학습 기법의 두 가지 주요 접근 방식을 중점적으로 다룬다. 휴리스틱 접근법에서는 작업장 스케줄링(JSSP) 문제에 참새 검색 알고리즘(SSA)과 회색 늑대 최적화(GWO)를 적용하여 생산 시간과 탄소 배출량을 효과적으로 감소시키는 연구 사례들을 분석하였다. 기계학습 기법에서는 강화학습 및 그래프 주의 네트워크(GAT)를 활용한 다목적 최적화 사례를 통해 공정 간의 복잡한 상호작용을 효율적으로 관리하고, 생산 지연과 에너지 소비를 동시에 개선하는 방법론을 살펴보았다. 결론적으로 스마트 팩토리에서 지속 가능한 생산 시스템을 구축하기 위한 기술적 가능성을 제시하고, 이를 통해 제조 산업의 지속 가능성과 생산 효율을 동시에 달성할 수 있을 것으로 기대된다.

#### I. 서 론

지구 평균기온 상승을 연  $1.5^{\circ}\text{C}$  이내로 제한하려는 파리 협약 이후, 2050년까지 전지구 이산화탄소 순배출량을 0이 되도록 하는 Net-Zero.로드맵은 각국 정부와 글로벌 공급망 전반에 구속력 있는 감축 목표를 부여하고 있다 [1]. 특히 제조업은 에너지 직접 사용과 공정 배출을 합쳐 전 세계  $\text{CO}_2$  배출의 약 25%를 차지하며, 전력 사용을 포함하면 그 비중은 더 커진다 [2]. 스마트 팩토리가 주도하는 디지털 전환이 생산 효율을 높일 수 있다고 하더라도, 여전히 탄소 집약적 공정이 남아있는 한 친환경과 고효율이라는 두 목표를 동시에 달성하는 것은 어렵다. 이에 따라 스마트 팩토리에서의 탄소 배출 최적화는 생산 기술 최적화와 동등한 수준의 설계 목표로 부상하고 있다.

스마트 팩토리에서는 IoT 센서, 디지털 트윈, 클라우드/엣지 컴퓨팅 등을 활용하여 실시간으로 공정에서의 에너지 데이터를 이미 확보하고 있다. 이러한 데이터들을 기반으로 스마트 팩토리에서의 에너지 효율 개선을 통해 온실가스 배출을 줄이고 생산 비용을 낮추려는 연구가 활발하게 이루어지고 있다 [3]. 이에 본 논문에서는 탄소 배출을 고려한 스마트 팩토리에서의 생산 시스템 최적화 기술 동향에 대해 논한다.

#### II. 본론

스마트 팩토리에서의 생산 최적화에는 탄소 배출량 절감과 함께 생산 효율을 높이는 것을 함께 고려하여야 한다. 복잡한 여러 문제를 공동으로 최적화하기 위한 방법으로 휴리스틱 최적화 기법과 기계학습 기법으로 각각 나누어 논하였다.

##### i. 휴리스틱 최적화 기법을 통한 생산 최적화

생산 시스템 최적화에 주로 사용되는 모델링으로는 작업장 스케줄링(Job Shop Scheduling Problem, JSSP)이 있다. [4]에서는 에너지 소비와 작업자의 학습 효과를 고려한 JSSP 모델링을 통해 현장에서 업무를 많이 하면 작업 속도가 빨라지는 숙련도 상승 효과를 모델링하고, 공정을 운영할 때 뿐만 아니라 idle 상태일때의 전력을 고려한 탄소 배출량을 함께 고려한 모델을 제시하였다. 생산 완료 시간과 총 탄소 배출량을 동시에 최소화하기 위해, 참새 검색 알고리즘(Sparrow Search Algorithm, SSA)을 적용하여 다른 휴리스틱 방식에 비해 생산 시간은 최대 46%, 탄소 배출량은 최대 41% 감소하는 효과를 보였다. [5]는 용접 공정이 많은 제조 공정에서 제품 생산 속도와 탄소 배출량을 동시에 최적화하고자 하였다. 특히 용접 공정에 특화하여 각 작업이 여러 단계를 동일한 순서로 거쳐야 하지만 한 번에 여러 대의 용접기를 사용하는 것이 가능하여, 몇 대를 동시에 같이 쓸 것인지를 의사결정 변수로 설정하였다. 이를 위해 생산 시간과 탄소 배출량의 균형을 이루기 위한 이중목적 혼합정수 모델(Multi-Objective Mixed Integer Model)을 만들고, optimal solution을 도출하는 데는 연산량 폭증 문제가 있기 때문에 회색 늑대 알고리즘(Grey Wolf Optimization, GWO)을 용접 스케줄링 문제에 맞게 수정한 알고리즘을 제시하였다. GWO는 늑대 무리에서의 서열을 최적화 식의 해에 대입하여, 추적과 포위, 공격으로 이어지는 사냥 전략에 맞추어 최적 해를 업데이트하는 방식의 알고리즘이다 [6]. [5]에서는 초기에는 무작위 휴리스틱으로 늑대(해)의 탐색 폭을 넓히고, 우수 해의 비중을 점점 늘려서 수렴을 가속화시킨다. 이 때 해가 거의 수렴되어 작업 시퀀스가 고정되면 작업과 단계 시퀀스에 따른 Activity on Edge (AoE) 네트워크 다이어그램을 만든다. 이를 통해 생산 시간(makespan)을 계산하고 그에 따라 공정

기계 운영 대수를 결정하여 시간과 탄소 배출량을 공동으로 최적화한다.

## ii. 기계학습 기법을 통한 생산 최적화

강화학습은 다목적 최적화 문제를 해결하는 데에 널리 사용되고 있다 [7-8]. 여러 군데의 공장이 있고 각 라인마다 공정 단계와 기계 구성이 다를 때, [9]에서는 납기 지연을 최소화하면서 공정의 총 에너지 소비를 최소화하는 문제를 풀고자 하였다. 공정별로 단계별 작업 정보, 에너지 상태, 블로킹 위험 등을 강화학습의 상태로 구성하고, 현재 작업 풀에 있는 8개의 후보 작업 중 하나를 선택하는 것을 행동으로 한다. 그에 따른 보상은 현재 선택한 행동으로 인해 발생한 지연 시간과 에너지 사용량의 음수값으로 하여, 지연 시간과 에너지 사용량이 작을수록 높은 보상을 받게 된다. 각 공장을 에이전트로 하고, 이들을 비동기 작업으로 배치하면서 각 에이전트가 선택한 작업이 전체 스케줄에 반영되면 이는 다른 에이전트의 관측에 즉시 반영되어 간접적으로 에이전트 간 협력 효과를 낼 수 있다. 강화학습 기반 접근법을 통해 지연 시간은 18%, 에너지 소비는 27% 개선하였다. [10]에서는 작업장 스케줄링과 기계의 탄소 배출을 통합하고, 여러 노드의 작업을 이접 그래프 (Disjunctive Graph)로 모델링하여 스케줄 효율 향상과 탄소 배출 절감을 동시에 최적화하고자 하였다. 그래프 주의 네트워크 (Graph Attention Network, GAT)를 적용하여 공정 단계, 남은 처리시간, 기계의 가동/유휴 정보 등 상태를 표현하여 중요 노드의 가중치를 파악하고, 공정 선택과 기계 할당을 동시에 수행하는 행동 쌍을 만든다. 보상은 단일 스칼라로 합치면 한쪽이 가려질 수 있어 원료 시간과 탄소 배출량의 벡터로 구성하여 두 축을 독립적으로 학습한 후 최종 의사결정 시 가중합을 이용해 파레토 해를 생성한다. 이를 통해 휴리스틱 방법론 대비 최대 12%의 효율 향상을 이루면서도 탄소배출량은 최대 8%까지 절감하는 효과를 보였다.

## III. 결 론

본 논문에서는 탄소 중립 실현을 목표로 스마트 팩토리 환경에서 생산 효율과 탄소 배출량을 동시에 최적화하는 최신 연구 동향을 살펴보았다. 스마트 팩토리는 IoT 센서, 디지털 트윈, 클라우드 및 엣지 컴퓨팅 기술을 활용하여 공정의 에너지 데이터를 실시간으로 수집하고 있으며, 이를 기반으로 하는 데이터 주도의 최적화 기법들이 두드러지게 연구되고 있다. 휴리스틱 최적화 방법론에서는 JSSP와 같은 복잡한 공정 스케줄링 문제에서 탄소 배출량과 생산 원료 시간을 동시에 최소화하기 위한 모델링과 솔루션이 제안되었다. 개선된 SSA와 GWO 같은 휴리스틱 접근법은 문제의 연산 복잡도를 효율적으로 다루면서도 실질적으로 생산 시간과 탄소 배출량의 감소를 보였다.

한편, 기계학습 기반 최적화는 강화학습과 GAT 등을 활용하여 공정 상호작용과 복잡한 의사결정을 효과적으로 모델링하였다. 이러한 접근은 개별 공정의 에너지 상태, 지연 시간, 블로킹 위험 등 세부적인 요소를 상태로 통합하고, 행동의 결과에 따라 직접적인 보상을 제공하여 복잡한 다목적 문제의 최적화를 이루었다. 특히, 여러 공장을 에이전트로 하는 강화학습 기반의 비동기적 협력 전략을 통해 납기 지연과 에너지 소비를 효과적으로 동시에 개선하였다.

이와 같은 연구들은 스마트 팩토리에서의 지속 가능한 생산 최적화의 중요성을 강조하며, 앞으로의 연구 방향으로는 다양한 최적화 기법의 하이브리드화와 현장 적용성을 높이기 위한 실시간 의사결정 시스템의 개발이 요구된다. 이를 통해 제조업에서 탄소 중립 목표 달성과 생산 효율의 동시 실현이라는 글로벌 과제를 효과적으로 해결할 수 있을 것으로 기대된다.

## ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획지원-대학ICT연구센터(ITRC)의 지원을 받아 수행된 연구임 (IITP-2025-RS-2024-00436887).

## 참 고 문 헌

- [1] Y. Yang, J. Shi, D. Wang, C. Wu and Z. Han, "Net-Zero Scheduling of Multi-Energy Building Energy Systems: A Learning-Based Robust Optimization Approach With Statistical Guarantees," *IEEE Transactions on Sustainable Energy*, vol. 15, no. 4, pp. 2675-2689, Oct. 2024.
- [2] IEA, "Tracking Clean Energy Progress 2023", IEA, 2023, (<http://www.iea.org/reports/tracking-clean-energy-progress-2023>).
- [3] N. Mohamed, J. Al-Jaroodi and S. Lazarova-Molnar, "Leveraging the Capabilities of Industry 4.0 for Improving Energy Efficiency in Smart Factories," *IEEE Access*, vol. 7, pp. 18008-18020, Feb. 2019.
- [4] Z. Li and Y. Chen, "Minimizing the Makespan and Carbon Emissions in the Green Flexible Job Shop Scheduling Problem with Learning Effects," *Scientific Reports*, vol. 13, no. 1, p. 6369, Apr. 2023.
- [5] R. H. Meng, Z. Y. Wang, W. H. Zeng, F. Guan, D. K. Lei, Z. J. Wu, and S. H. Deng, "Research on Low Carbon Welding Scheduling based on Production Process," *Scientific Reports*, vol. 14, no. 1, p. 28704, Nov. 2024.
- [6] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey Wolf Optimizer," *Advances in Engineering Software*, vol. 69, pp. 46 - 61, Mar. 2014.
- [7] W. J. Yun, D. Kwon, M. Choi, J. Kim, G. Caire and A. F. Molisch, "Quality-Aware Deep Reinforcement Learning for Streaming in Infrastructure-Assisted Connected Vehicles," *IEEE Transactions on Vehicular Technology*, vol. 71, no. 2, pp. 2002-2017, Feb. 2022, doi: 10.1109/TVT.2021.3134457.
- [8] D. Kwon, J. Jeon, S. Park, J. Kim and S. Cho, "Multiagent DDPG-Based Deep Learning for Smart Ocean Federated Learning IoT Networks," *IEEE Internet of Things Journal*, vol. 7, no. 10, pp. 9895-9903, Oct. 2020, doi: 10.1109/JIOT.2020.2988033.
- [9] X. Sun, W. Shen, J. Fan, B. Vogel-Heuser, F. Bi, and C. Zhang., "Deep Reinforcement Learning-based Multi-Objective Scheduling for Distributed Heterogeneous Hybrid Flow Shops with Blocking Constraints," *Engineering*, vol. 46, no. 3, pp. 278-291, Mar. 2025.
- [10] Y. Tang, L. Shen, and S. Han, "Low-Carbon Flexible Job Shop Scheduling Problem Based on Deep Reinforcement Learning," *Sustainability*, vol. 16, no. 11, p. 4544, May 2024