

납기와 작업준비비용을 고려한 병렬기계에서 딥러닝 기반의 일정계획 생성 모델

Scheduling Generation Model on Parallel Machines with Due Date and Setup Cost Based on Deep Learning

유우식(Woosik Yoo)*, 서주혁(Juhyeok Seo)**, 이동훈(Donghoon Lee)***,
김다희(Dahee Kim)****, 김관호(Kwanho Kim)*****

초 록

4차 산업혁명이 진행되면서 제조업에서 사물인터넷(IoT), 머신러닝과 같은 지능정보기술을 적용하는 사례가 증가하고 있다. 반도체/LCD/타이어 제조공정에서는 납기일(due date)을 준수하면서 작업물 종류 변경(Job change)으로 인한 작업 준비 비용(Setup Cost)을 최소화하는 일정계획을 수립하는 것이 효과적인 제품 생산을 위해 매우 중요하다. 따라서 본 연구에서는 병렬기계에서 딥러닝 기반의 납기 지연과 작업 준비 비용 최소화를 달성하는 일정계획 생성 모델을 제안한다. 제안한 모델은 과거의 많은 데이터를 이용하여 고려되어지는 주문에 대해 작업 준비와 납기 지연을 최소화하는 패턴을 학습한다. 따라서 세 가지 주문 리스트의 난이도에 따른 실험 결과, 본 연구에서 제안한 기법이 기존의 우선순위 규칙보다 성능이 우수하다는 것을 확인하였다.

ABSTRACT

As the 4th industrial revolution progressing, manufacturers are trying to apply intelligent information technologies such as IoT(internet of things) and machine learning. In the semiconductor/LCD/tire manufacturing process, schedule plan that minimizes setup change and due date violation is very important in order to ensure efficient production. Therefore, in this paper, we suggest the deep learning based scheduling generation model minimizes setup change and due date violation in parallel machines. The proposed model learns patterns of minimizing setup change and due date violation depending on considered order using the amount of historical data. Therefore, the experiment results using three dataset depending on levels of the order list, the proposed model outperforms compared to priority rules.

키워드 : 일정계획, 심층신경망, 납기, 작업준비용, 머신러닝
Scheduling, Deep Neural Network, Due Date, Setup Cost, Machine Learning

This work was supported by Incheon National University Research Grant in 2019.

* First Author, Department of Industrial and Management Engineering, Incheon National University (wsyoo@inu.ac.kr)

** Co-Author, Department of Industrial and Management Engineering, Incheon National University (seojuhuyuk@naver.com)

*** Co-Author, Department of Industrial and Management Engineering, Incheon National University (dhlee@inu.ac.kr)

**** Co-Author, Department of Industrial and Management Engineering, Incheon National University (kmdj2003@nate.com)

***** Corresponding Author, Department of Industrial and Management Engineering, Incheon National University (khokim@inu.ac.kr)

Received: 2019-05-30, Review completed: 2019-06-19, Accepted: 2019-07-25

1. 서 론

4차 산업혁명이 진행되면서 국내외 제조 기업에서 스마트 팩토리를 구축하려는 요구가 늘어나고 있다. 이에 따라 제조시스템에 사물인터넷(IoT)기술, 머신러닝, 빅데이터 등과 같은 지능정보기술을 적용하려는 시도도 증가하고 있다.

반도체/LED 제조 공정이나 타이어제조 공정의 일정계획문제에서 상호 충돌하는 의사결정인 납기 준수를 최대화 하는 것과 작업물 종류 변경(Job change)으로 인한 작업 준비 비용(Setup Cost)을 최소화 하는 것 사이에서의 균형을 유지하는 것이 고가 생산 장비의 효율적인 활용을 위하여 매우 중요하다.

반도체/LED Photo 공정의 경우 작업물 종류 변경이 발생하게 되면 Mask를 교체해야하며, 타이어 가류 공정에서는 타이어 모양이 새겨진 몰드를 교체해야 하기 때문에 작업 준비 비용이 발생한다. 또한 작업물 종류 변경을 줄이기 위하여 납기를 준수하지 못하게 되면 다음 공정이 지연되는 등과 같은 문제가 발생하게 된다. 따라서 작업물 종류 변경 횟수를 최소화하면서 납기 준수를 최대화 하는 일정계획을 수립해야 한다.

복잡한 스케줄링 문제를 해결하기 위해서 우선순위 원칙(Heuristic Rule) 방식과 시뮬레이티드 어닐링(Simulated Annealing)[9], 유전알고리즘(Genetic Algorithm)[1]과 같은 메타 우선순위의 방법이 사용되어 왔다. 하지만 이러한 방법들은 현업의 복잡한 문제에 적용하는 데는 어려움이 있다. 최근 머신러닝이 관심을 받게 됨에 따라 머신러닝을 일정계획에 적용하는 다양한 연구들이 증가하고 있다.

머신러닝을 응용한 일정계획에 관한 기존 연구로는 다음과 같다. Huh[3]은 심층 신경망(Deep Neural Network: DNN)을 이용하여 반도체 패키징 공정에서 가동률을 높이는 의사결정 모델을 개발하였으며, Kim[6]은 강화학습을 이용하여 현재 스케줄링 상태를 고려하여 적합한 우선순위 원칙을 선택하는 연구를 하였다. Kang[5]는 Q-learning을 이용하여 단일기계에서 작업순서를 결정하는 모델을 개발하였으며, Jeong et al.[4]은 강화학습을 이용하여 다양한 길이의 작업과 다양한 요구조건을 지닌 잡삽 스케줄링 방법을 제안하였고, Shin et al.[11]은 강화학습을 기반으로 시간의 흐름에 따라 작업의 투입정책을 동적으로 변화시킬 수 있는 알고리즘을 제안하였다. 해외 연구로는 Gabel and Riedmiller[2]는 잡삽 스케줄링 문제를 순차적 의사결정문제로 보고 독립적으로 할당을 결정하는 강화학습 모델을 개발하였으며, Shahrabia et al.[10]은 랜덤 작업 도착 및 기계 고장을 고려하는 스케줄링 방법을 강화학습을 이용하여 구현하였다. 선행 연구에서 기존 우선순위 원칙 기반의 스케줄링 보다 개선된 결과를 확인하였다.

기존 연구가 유희시간(Idle time)을 감소시키기 위한 의사결정이나, 가동률을 최대화하기 위한 의사결정, 최종 작업 완료시간(make span)을 최소화 하는 의사결정 이었다면, 본 연구는 작업물 납기준수를 최대화하고 작업물 종류 변경을 최소화 하는 생산 장비를 선택하는 의사결정을 하는 것이다.

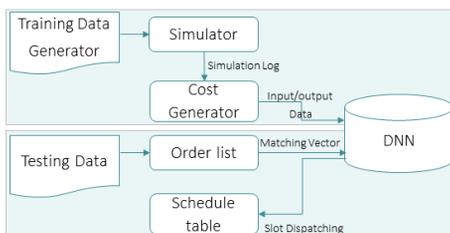
본 연구에서는 머신러닝 중 항생제 내성균 감염예측[8]이나 장기간 태양광 발전량을 예측[7]에 사용되고 있던 딥러닝을 이용하여 병렬기계에서 제품과 주문량, 납기가 있는 주문에서 납기 준수를 최대화하면서 작업물 종류 변경을

최소화 하는 모델을 개발하였고, 개발한 모델의 일정계획 결과와 기존의 우선순위 원칙 방식의 결과를 비교하였다.

2. 딥러닝 기반의 일정계획 생성모델

본 연구에서는 병렬기계에서 제품 종류와 주문량, 납기가 주어진 주문으로 구성된 리스트에 대해서 생산 장비가 M개, 제품 종류가 P개, 주문이 N개 있다고 가정할 때, 각각의 주문에 대하여 생산 장비를 할당하는 의사결정을 하는 것이다. 이 때, 주문 유형에 대한 알려진 분포는 없으며, 작업 순서나 기계 종류에 독립적이고, 장비 제약이 없어 모든 기계에서 모든 작업기 가능한 것으로 가정한다. 이러한 상황에서 작업물 종류 변경을 최소화 하고 납기 준수를 최대화 하는 일정계획을 생성하는 것을 목표로 하였다.

본 연구에서는 심층 신경망(DNN)을 이용하여 제품, 주문량, 납기가 있는 주문에서 납기 준수를 최대화하면서 작업물 종류 변경을 최소화 하는 일정계획을 생성해주는 모델을 개발하였다.



<Figure 1> Framework of DNN based Model

<Figure 1>은 일정계획 모델의 구성도(Framework)를 나타낸 것이다. 먼저 트레이닝 부분에서는 학습 데이터 생성기에서 만들어진 주문 리스트가 들어오면 시뮬레이터는 우선순위 원칙 기반의 의사결정을 통해서 다양한 일정계획을 생성한다. 트레이닝 데이터 생성기(Training Data Generator) 부분에서는 랜덤하게 주문 리스트를 생성한다. 현재 모델에서는 20,000개의 주문 리스트를 만들었다. 리스트가 완성되면 시뮬레이터(Simulator)부분에서는 랜덤한 방법과 우선순위 원칙을 활용하여 일정계획을 생성한다. 만들어진 20,000개의 주문 리스트를 가지고 총 120,000개의 스케줄 테이블을 만들었다. 그 다음으로 비용 생성기(Cost Generator)에서는 생성된 일정계획을 식 (1)을 기반으로 비용을 측정한다. 작업물 종류 변경과 납기를 준수하지 못한 주문에 따른 비용은 자유롭게 설정할 수 있다. 그러나 본 연구에서는 작업물에 대한 납기 준수를 우선순위로 처리해야하는 공정을 가정하여 납기 비용점수를 5배로 가정하였다. 납기에 대한 비용 점수를 낮게 설정하고 작업물 종류 변경에 대한 점수를 높게 설정할 경우, 본 연구에서 학습한 모델은 납기를 어기더라도 작업물 종류 변경을 안하려는 경향을 보였다. 본 연구에서는 납기에 대한 비용을 10점, 작업물 종류 변경에 대한 비용을 2점으로 설정하였다.

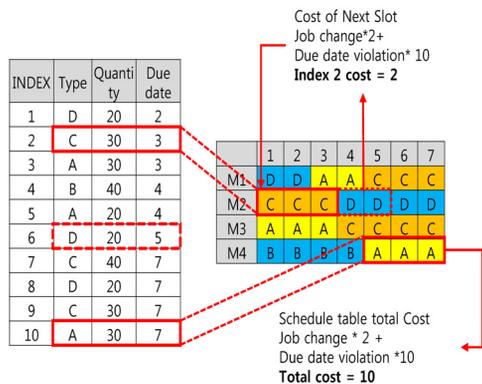
- * 일정계획 벌칙 비용함수(Cost)
 - = 작업물 r 종류 변경횟수 $\times 2$ +납기 d 를 어긴 주문 수 $\times 10$
- * 점수할당 방식 (1)

1. 생산 장비에 다음 작업이 있는 경우: 다음 작업의 비용점수(Cost)

2. 생산 장비에 다음 작업이 없는 경우: 전체 테이블의 비용점수

또한, 배치 사이즈에 따라 작업 준비 횟수와 납기 지연 여부가 달라질 수 있으므로 본 연구에서는 10 단위의 주문량을 하나의 배치로 처리하는 것으로 가정하였습니다.

<Figure 2>에서 보면 주문 리스트의 2번째 항목인 C의 비용점수는 다음 작업이 있으므로, 다음 작업인 D를 기준으로 판단한다. 다음 작업인 D는 이전 작업인 C와 다른 작업이므로 작업물 종류 변경이 발생하고, 납기를 준수하였으므로 납기일 초과는 발생하지 않는다. 따라서 C의 비용점수는 2가 된다. 마지막 주문인 A의 경우 다음 작업이 없으므로 테이블 전체의 비용점수인 10이 된다. 이렇게 현재 작업의 비용점수가 아닌 다음 작업의 비용점수를 고려하는 이유는 현재의 비용점수만 고려하지 않고, 현재 작업이 할당되면 다음에 올 작업에 주는 영향을 고려하기 위해서 이다. 다양한 비용함수 생성방법을 비교하는 연구는 추후 진행할 계획이다.



<Figure 2> Cost Calculation Method of Decision Making

이렇게 각 작업별로 점수가 할당되면 심층 신경망을 통하여 학습을 진행하게 된다. 일정 계획 모델의 DNN 구조를 설명하면 모델은 1개의 입력층(Input Layer)과 3개의 은닉층(Hidden layer), 1개의 출력층(Output layer)로 연결되어 있다. 활성화함수(activation function)로는 하이퍼볼릭 탄젠트(hyperbolic tangent function)를 사용하였으며, 모든 레이어는 완전 연결 층(fully connected layer)으로 구성되어 있다. 이때 손실함수(loss function)으로는 평균 제곱 오차를 사용하였다. 활성화 함수는 ReLU (Rectified Linear Unit), Sigmoid 등의 여러 종류의 활성화 함수가 있지만 본 연구에서는 반복적인 실험을 통해 성능이 가장 우수한 하이퍼볼릭 탄젠트 함수로 설정하였다[11, 12]. 학습 횟수는 1000번으로 하였다. <Table 1>은 입력값(Input state)을 만드는 방법이다. 입력 값은 현재 주문의 작업량, 납기일, 할당되었을 때 작업물 종류 변경이 일어나는지, 납기일을 초과하는지, 주문 리스트에 같은 작업물이 얼마나 있는지, 자신보다 납기일이 빠른 주문이 몇 개 있는지, 현재 작업물이 장비에 배치된 상태에서 평균 이상의 주문이 할당되었는지, 현재 생산설비에 몇 개의 주문이 할당되었는지, 현재 작업물 종류와 같은 작업물이 모두 같은 장비에 할당되었다고 가정하였을 때 초과하는 납기일의 시간을 판단하여 입력 값을 만들게 된다. 입력된 값들은 단위간의 불일치한 값들을 해결하기 위해 정규화(normalization) 기법을 통해 0에서 1 사이의 값으로 변환한다[9]. 학습에 사용되는 최적화 (Optimizer) 기법은 Adam optimizer를 사용하였고, 학습률(learning rate)은 0.001로 하였다.

<Table 1> Input State of DNN Model

1	Quantity of current order	unit
2	Due date of current order	Numbers
3	Determine if a Job change is triggered when assigned to a machine	1/0
4	Determine if Due date is violated when assigned to Machine	1./0
5	Quantity of Same order	Numbers
6	Number of Faster orders than Current order	Numbers
7	Machine balancing	1/0
8	Number of orders assigned to machine	Numbers
9	Assuming that the same order type as the current order type is allocated to the same slot, total time of due date violation	Numbers

출력값(Output state)은 고려되어진 주문에 대한 특정 기계에 할당 되었을 때의 비용 점수를 나타낸다. 따라서 고려되어지는 주문과 기계 상태에 따른 비용점수를 계산하여 학습함으로써 본 연구에서 제안한 모델은 실제 테스트 데이터를 이용하여 모든 기계에 대한 고려되어지는 주문의 비용점수를 기반으로 일정계획을 생성한다.

본 연구에서 제안한 모델은 실제 공정 상태를 기반으로 실시간에서 모든 기계에 대해 고려되어지는 주문의 비용점수를 계산하여 비용점수가 가장 낮은 기계에 할당하기 때문에 현실 세계에서 실시간으로 빠른 시간에 의사결정을 하여 납기일을 준수하고 작업물 종류 변경을 최소화 하는 일정계획을 생성할 수 있는 장점이 있다.

<Figure 3>은 심층 신경망을 이용하여 학습시킨 일정계획의 테스트 사례이다. 일정 계획 생성 결과, 작업물 변경 횟수는 총 4회, 납기일을 어긴 주문의 수는 1개이다. 따라서, 식 (1)과

같이, 본 연구에서 제시한 일정계획 벌칙 비용 함수를 계산하는 방법으로 일정 계획 결과에 대한 점수를 계산할 경우, 이 일정계획의 벌칙 비용은 총 18이라는 결과 값을 알 수 있다.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
M1	(E E E E E)	(C C)	(C C C C C)												
M2	(B B B B)	(B B)	(B B B B B)												
M3	(D D D D D)	(D D D D D)													
M4	(D D D)	(D D D D D)	(D D D D)												
M5	(B B B)	(B B B B)	(B B B B)												
M6	(B B)	(B B B B B)	(B B B)												
M7	(B B B B)	(B B B B)													
M8	(D D D D D)	(D D D)	(D D D)												
M9	(D D D D)	(D D D D)	(E E E E E)												
M10	(B B B)	(C C)	(C C)	(C C C C)	(C C)										
M11	(B B B B B)	(A A A A A)													
M12	(E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)
M13	(E E)	(E E E)	(E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)	(E E E E)
M14	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)
M15	(A A A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)	(A A A)
M16	(A A)	(A A A A)	(A A)	(A A)	(A A)	(A A)	(A A)	(A A)	(A A)	(A A)	(A A)	(A A)	(A A)	(A A)	(A A)

<Figure 3> Example of Schedule Table

3. DNN모델의 일정계획 성능평가

본 논문에서 제안한 DNN 기반의 일정계획 생성 기법모델과 기존의 우선순위 원칙 기반의 일정계획 생성기법의 결과를 비교하였다. 비교 대상으로 사용한 우선순위 원칙 기반의 생성기법 종류는 총 3가지로 하였다. 일정 계획 생성은 주문 리스트 중 주문 선택 과정과 기계 선택과정으로 2가지 단계로 나뉘며, 먼저 주문 리스트 중 주문 선택 과정은 다음과 같이 우선순위 원칙 기반으로 선택한다. MDD는 납기일에서 현재시간을 뺀 값을 사용하였다.

- 1) MDD-LPT(Modified Due Date-Longest Processing Time): Modified due date순으로 정렬 후 동일한 MDD에서는 주문 처리시간이 큰 순서대로(LPT) 정렬하여 선택한다.
- 2) MDD-SPT(Modified Due Date-Shortest

Processing Time): Modified due date순으로 정렬 후 동일한 MDD 에서는 주문 처리시간이 적은 순서대로(SPT) 정렬하여 선택

3) Slack-MDD Slack = (납기일-주문 처리시간): Slack이 적은 순서대로 정렬 후 동일한 Slack에서는 MDD가 적은 순서대로 정렬 후 선택한다.

위 주문 선택기준을 각각 MDD, SPT, Slack으로 구분하여 비교하였다.

다음으로 기계 선택 방법은 다음과 같은 방법으로 수행한다. 먼저 고려되어지는 주문과 같은 제품이 할당되어 있는 기계를 고려하는데, 만약 같은 제품의 종류가 할당되어 있는 기계에, 고려하고 있는 주문을 할당할 경우 납기일을 준수하면 할당하고, 그렇지 않으면 다른 기계 중 가장 적은 양의 주문을 처리하고 있는 기계에 할당한다. 납기일을 준수하면서 같은 종류의 제품을 할당할 기계가 다수이면 그중에서 가장 적은 양의 제품을 생산하는 기계에 할당한다.

DNN 기반의 일정 계획 생성 기법의 주문 리스트 선택 과정은 우선순위 원칙 중 MDD 기반으로 정렬한다. 다음으로 기계 선택 과정에서는 고려하고 있는 주문에 대해 모든 기계의 대한 비용을 계산 후 가장 낮은 비용을 갖은 기계에 할당한다. 최종적으로 생성된 일정계획을 식 (1)을 기반으로 비용을 계산하여 우선순위 원칙 기반의 모델과 제안한 모델의 성능을 평가하였다.

3.1 실험 환경

본 연구에서 제안한 모델의 성능을 평가하기 위해 기계의 수, 주문의 수, 제품의 종류는 각각 20대, 100개, 7종류로 설정하였으며, 주문량과

기계의 수를 고려한 밀집도(density)에 따른 3가지 데이터 세트를 기반으로 제안한 모델의 성능을 평가했다.

$$density = \frac{order\ list\ 의\ 수 \times\ 주문의\ 평균시간}{전체기계의수 \times\ 최대납기} \quad (2)$$

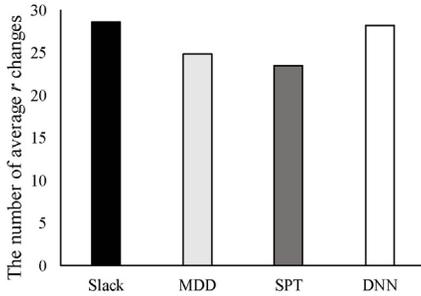
밀집도는 식 (2)와 같이 계산되며 값이 작을수록 기계의 유휴상태가 많이 존재한다는 것을 의미하며, 밀집도가 높을수록 기계의 유휴 상태가 없기 때문에 일정계획을 생성하는데 난이도가 높다는 것을 의미한다. 성능평가를 위하여 각각 밀집도가 0.9, 1.0, 1.1인 dataset I, dataset II, dataset III를 생성하여 비교 평가하였다. 각 데이터세트는 주문 100개짜리 10 세트를 생성하여 성능을 비교하여 평균하였다.

3.2 실험 평가

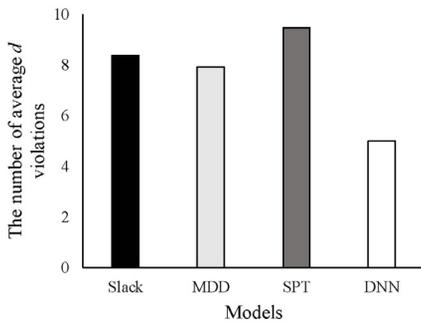
3.2.1 dataset I 에 대한 실험 평가

<Figure 4>는 dataset I 를 이용하여 제안한 모델과 우선순위 규칙 모델의 성능을 나타낸다. 여기에서 MDD-LPT와 MDD-SPT는 MDD, SPT로 모든 실험 평가 부분에 나타내었다.

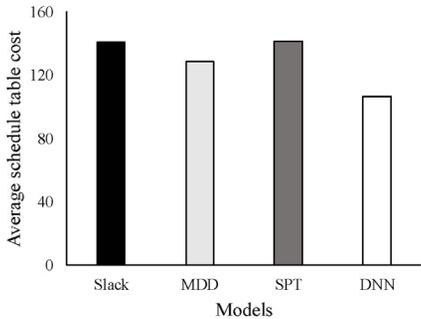
먼저, 평균 r 변화 관점에서는 SPT 기반의 모델이 가장 높은 성능을 보였다. 반면에, 평균 d 변화 관점에서는 SPT 기반의 모델이 가장 낮은 성능을 보였으며 본 연구에서 제안한 DNN 기반의 모델이 가장 높은 성능을 보였고, MDD기반의 모델은 평균 r 변화와 평균 d 변화에 대해 비슷한 성능을 보였다. 따라서 일정 계획에 대한 평균 비용 점수는 DNN 기반의 모델이 가장 낮아, dataset I 에 대해 가장 좋은 성능을 보인다는 것을 확인하였다.



(a) In cases of average r changes



(b) In cases of average d violations



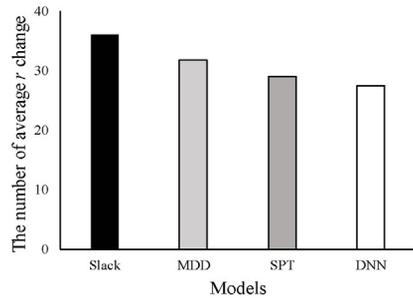
(c) In cases of the average cost

〈Figure 4〉 The Average Error Results According to r Changes, d Violations, and Cost in Terms of Density 0.9

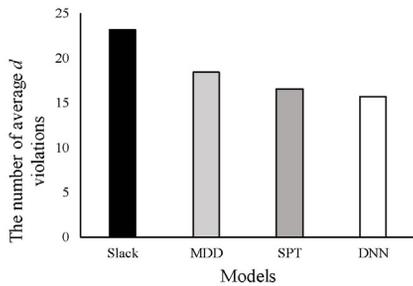
3.2.2 dataset II 에 대한 실험 평가

〈Figure 5〉는 dataset II를 이용하여 제안한 모델과 우선순위 규칙 모델의 성능을 나타낸다. dataset II는 dataset I 과는 다르게 모든 모델들이 낮은 성능을 보였다. 그러나 SPT 기반의 모델은

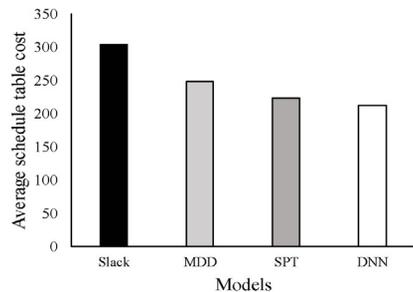
dataset I 과는 다르게 평균 r 변화와 평균 d 변화 관점에서 모두 본 연구에서 제안한 모델과 유사한 성능을 보였다. 반면에, Slack 기반의 모델은 dataset I 에서 비해 가장 낮은 성능을 보였으며, 일정 계획에 대한 평균 비용 점수 결과, 본 연구에서 제안한 모델이 가장 우수한 성능을 나타냈다.



(a) In cases of average r changes

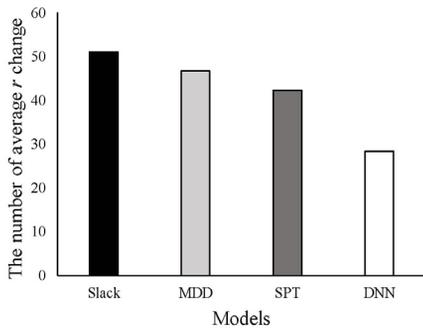


(b) In cases of average d violations

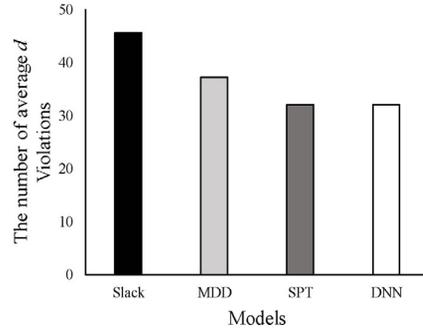


(c) In cases of the average cost

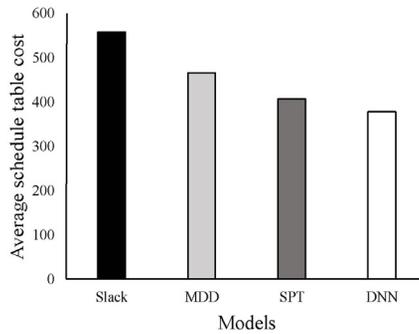
〈Figure 5〉 The Average Error Results According to r changes, d Violations, and Cost in Terms of Density 1.0



(a) In cases of average r changes



(b) In cases of average d violations



(c) In cases of the average cost

〈Figure 6〉 The Average Error Results According to r Changes, d Violations, and Cost in Terms of Density 1.1

〈Table 2〉 The Average Scheduling Error

		density		
amount of change	model	0.9	1	1.1
r changes	Slack	28.5	36.1	51.1
	MDD	24.8	31.7	46.6
	SPT	23.5	28.9	42.2
	DNN	28.2	27.4	28.4
d violations	Slack	8.4	23.1	45.5
	MDD	7.9	18.4	37.2
	SPT	9.5	16.5	32.1
	DNN	5	15.7	32
table cost	Slack	140.7	303.2	557.2
	MDD	128.7	247.4	465.2
	SPT	141.5	222.8	405.4
	DNN	106.4	211.8	376.8

<Table 3> The Improvement Performances between Applied Models

		Improvement ratios (%)			
		Slack	MDD	SPT	DNN
(a) In terms of dataset I					
Against	Slack	-	+8.5	-0.5	+24.4
	MDD	-	-	-8.9	+17.3
	SPT	-	-	-	+24.8
	DNN	-	-	-	-
(b) In terms of dataset II					
Against	Slack	-	+18.4	+26.5	+30.1
	MDD	-	-	+9.9	+14.3
	SPT	-	-	-	+4.9
	DNN	-	-	-	-
(c) In terms of dataset III					
Against	Slack	-	+16.5	+27.2	+32.3
	MDD	-	-	+12.8	+19.0
	SPT	-	-	-	+7.0
	DNN	-	-	-	-

<Table 2>는 density 차이에 따른 r 변화 d 변화, 평균 비용의 변화를 함께 나타낸다. density의 차이에 따라 모든 모델에서 평균 r 변화와 d 변화가 증가한다는 것을 확인하였다.

3.2.3 dataset III에 대한 실험 평가

마지막으로, datasetII와 마찬가지로 일정 계획에 대한 평균 비용 점수 결과 또한 본 연구에서 제안한 DNN모델이 가장 우수한 성능을 나타냈다.

<Table 3>은 실험 3.2.1, 3.2.2, 3.2.3의 결과를 기반으로 구체적인 평균비용의 성능 향상 비율을 나타낸다. 여기에서 +는 성능이 향상된 것을 의미하고, -는 성능이 하락된 것을 의미한다. MDD 기반의 모델은 밀집도가 낮았을 때 다른 우선순위 모델의 비해 성능이 우수하였으

나 밀집도가 높아질수록 성능이 낮아졌다. 반면에 SPT 기반의 모델은 밀집도가 낮았을 때 성능이 좋지 못하였으나 밀집도가 높아질수록 다른 우선순위 모델에 비해 성능이 좋다는 것을 확인 할 수 있었다. 또한 본 연구에서 제안한 DNN 기반의 모델은 밀집도에 상관없이 성능이 가장 우수하다는 것을 확인하였다.

4. 결 론

본 연구는 제품종류, 주문량, 납기가 정해진 주문 리스트에 대해 작업물 종류 변경과 납기 지연을 최소화하는 딥러닝 기반의 일정 생성 모델을 제안하였다. 본 연구에서 제안한 모델의 성능을 평가하기 위해 밀집도에 따른 3가지

데이터 셋을 통해 실험을 평가하였다. 실험을 통해 본 연구에서 제시한 모델의 성능을 평가한 결과, 납기 준수와 작업물 종류 변경을 최소화하는 일정 계획을 생성하기 위해서는 일정 계획에 영향을 끼치는 특징들을 기반으로 많은 양의 데이터를 이용하여 반복적으로 학습하는 모델이 필수적이라는 것을 확인하였다. 또한, 학습 시 출력 값에 대한 비율을 측정할 때, 작업물 변경과 납기 지연에 대한 고려해야할 우선순위에 패널티 점수를 더 부과하여 학습해야 성능이 향상 된다는 것을 확인하였다.

본 연구에서는 장비 제약이 없는 일정계획 문제의 모델을 개발하였지만, 추후 장비 제약이 있는 문제와 주문을 분할하여 할당하는 문제등과 같이 복잡한 문제로 확장하여 개발한다면 제조시스템 현장의 문제에서도 적용할 수 있을 것으로 판단된다.

References

- [1] Chung, B. S., Lim, J., Park, I. B., Park, J., Seo, M., and Seo, J., "Setup change scheduling for semiconductor packaging facilities using a genetic algorithm with an operator recommender," *IEEE Transactions on Semiconductor Manufacturing*, Vol. 27, No. 3, pp. 377-387, 2014.
- [2] Gabel, T. and Riedmiller, M., "Distributed policy search reinforcement learning for job-shop scheduling tasks," *International Journal of Production Research*, pp. 41-61, 2012.
- [3] Huh, J. S., Park, I. B., Lim, S. M., Paeng, B. H., Park, J. H. and Kim, K. H., "Learning to Dispatch Operations with Intentional Delay for Re-Entrant Multiple-Chip Product Assembly Lines," *Sustainability*, Vol. 10, No.11, pp. 1-21, 2018.
- [4] Jeong, H. S., Kim, M. W., Lee, B. J., Kim, K. T., and Youn, H. Y., "An Neural Network Approach to Job-shop Scheduling based on Reinforcement Learning," *Proceedings of the Korean Society of Computer Information Conference*, pp. 47-48, 2018.
- [5] Kang, J. H., "Feasibility Study on the Reinforcement Learning for a Dynamic Scheduling Problem," *Journal of Advanced Engineering and Technology*, Vol. 10, No. 4, pp. 453-456, 2017.
- [6] Kim, A. K., "Ensemble-based Quality Classification and Deep Reinforcement Learning-based Production Scheduling : Ensemble-based Quality Classification and Deep Reinforcement Learning-based Production Scheduling," Ph.D. dissertation, KyungHee University, 2018.
- [7] Lee, D. H. and Kim, K. H., "Deep Learning Based Prediction Method of Long-term Photovoltaic Power Generation Using Meteorological and Seasonal Information," *The Journal of Society for e-Business Studies*, Vol. 24, No. 1, pp. 1-16, 2019.
- [8] Oh, S. W., Lee, H. K., Shin, J. Y., and Lee, J. H., "Antibiotics-Resistant Bacteria Infection Prediction Based on Deep Lear-

- ning,” *The Journal of Society for e-Business Studies*, Vol. 24, No. 1, pp. 105-120, 2019.
- [9] Quadt, D., “Simulation-based Scheduling of Parallel Wire-bonders with Limited Clamp & Paddles,” *Proceedings of the 38th Conference on Winter Simulation*, Winter Simulation Conference, Monterey, CA, USA, 3-6, pp. 1887-1892, 2006.
- [10] Shahrabi, J., Adibi, M. A. and Mahootchi, M., “A reinforcement learning approach to parameter estimation in dynamic job shop scheduling,” *Journal of Computers and Industrial Engineering*, Vol. 110, pp. 75-82, 2017.
- [11] Shin, H. J., Ru J. P., and Lee J. W., “Adaptive scheduling algorithm for manufacturing process with nonstationary rework probabilities using reinforcement learning,” *Proceedings of the KAIS Fall Conference*, pp. 1180-1180, 2010.
- [12] Swietojanski, P. and Renals, S., “Learning hidden unit contributions for unsupervised speaker adaptation of neural network acoustic models,” *Proceedings of the Spoken Language Technology Workshop*, pp. 171-176, 2014.
- [13] Zhang, S., Liu, X., and Xiao, J., “On Geometric Features for Skeleton-Based Action Recognition Using Multilayer LSTM Networks,” *Proceedings of the IEEE Winter Conference on Applications of Computer Vision*, Santa Rosa, CA, USA, 2017.
- [14] Zhang, Y. and Ge, S. S., “Design and Analysis of a General Recurrent Neural Network Model for Time-Varying Matrix Inversion,” *Journal of IEEE Transactions on Neural Networks*, Vol. 16, No. 6, pp. 1477-1490, 2005.

저 자 소 개



유우식
1985년
1987년
1991년
1992년~현재
관심분야

(E-mail: wsyoo@inu.ac.kr)
서울대학교 공과대학 산업공학과 (학사)
한국과학기술원 산업공학과 (석사)
한국과학기술원 산업공학과 (박사)
인천대학교 산업경영공학과 교수
물류정보시스템, CAD/CAM, 생산정보시스템



서주혁
2017년
2018년~현재
관심분야

(E-mail: seojuhuk@naver.com)
인천대학교 산업공학과 (학사)
인천대학교 산업경영공학과 석사과정
CAD/CAM, 생산정보시스템, 딥러닝



이동훈
2016년
2017년~2019년
2019년~현재
관심분야

(E-mail: dhlee@inu.ac.kr)
단국대학교 산업공학과 (학사)
인천대학교 산업경영공학과 (석사)
인천대학교 산업경영공학과 박사과정
텍스트 마이닝, 기계학습, 딥러닝



김다희
2016년
2017년~2019년
2019년~현재
관심분야

(E-mail: kmdj2003@nate.com)
인천대학교 산업공학과 (학사)
인천대학교 산업경영공학과 (석사)
㈜VMS solutions 사원
생산정보시스템, 인공지능



김관호
2006년
2012년
2013년
2014년~현재
관심분야

(E-mail: khokim@inu.ac.kr)
동국대학교 정보시스템전공 (학사)
서울대학교 산업공학과 (박사)
경희대학교 (연구박사)
인천대학교 산업경영공학과 교수
통계적 기계학습, 빅데이터, 딥러닝