

신경망을 이용한 금형공장용 일정계획 시스템에 관한 연구

이형국* · 이석희**

A Study on Scheduling System for Mold Factory Using Neural Network

Hyung-Kook Lee · Seok-Hee Lee

〈Abstract〉

This paper deals with constructing a scheduling system for a mold manufacturing factory. The scheduling system is composed of 4 submodules such as pre-processor, neural network training, neural networks and simulation. Pre-processor analyzes the condition of workshop and generates input data to neural networks. Network training module is performed by using the condition of workshop, performance measures, and dispatching rules. Neural networks module presents the most optimized dispatching rule, based on previous training data according to the current condition of workshop. Simulation module predicts the earliest completion date of a mold by forward scheduling with the presented dispatching rules, and suggests a possible issue date of a material by backward tracking. The system developed shows a great potential when applied in real mold factory for automotive parts.

Key Words : Neural networks(신경망), Scheduling(일정계획), Dispatching rule(공정선택규칙)

1. 서 론

다품종 소량생산, 점점 짧아지는 제품 수명주기 등으로 인하여 금형의 개발 및 제작 기간 또한 짧아지고 있다. 따라서 금형 생산 업체들은 납기 단축과 품질향상, 원가절감 등을 위하여 노력하고 있다. 특히 정해진 기간내에 더 많은 금형을 생산하기 위하여 일정관리에 관심을 가지고 있다. 그러나, 여러 가지 요인에 의한 일정계획의 수시 변동과 이에 따른 대응 미흡, 공장의 생산능력에 대한 부하 예측의 부적절, 공정 및 가공시간에 관한 데이터의 미표준화, 작업 실적분석의 지연 등은 공장 운영의 불합리한 요인을 초래하여 상당한 생산관리 손실이 되어왔다. 이에 대한 대책으로는 무엇보다도 생산계획과 통제가 이루어져야 한다.

일정계획(scheduling)은 생산계획내지는 제조 명령을 구체화시키는 과정이다. 다시말해, 제품 또는 부품을 가공 조립하기 위해 필요한 자원(인력, 자재, 공간)을 배분하고 기계를 할당하여 작업을 수행하기 위한 작업 일정표를 작성하는 것이다. 그러나, 제품의 수가 많아지고 공정이 복잡해짐에 따라 수작업으로 일정을 관리하기는 어렵다. 따라서 일정계획문제를 풀기 위한 많은 연구가 수행되어 왔다[1-5]. 예를들면, 수학적 방법(mathematical methods), 발견적 방법(heuristic methods), 인공지능 방법(artificial intelligent methods), 신경망(neural networks)을 사용하는 방법 등이다.

특히 최근에는 신경망을 사용하여 공정선택 규칙을 설정하는 연구가 활발히 진행되어 오고 있다[6-10]. 또한 일정계획 문제를 풀기위해 수행된 연구결과를 현장에 적용하기 위한 범

* 대우정보시스템(주)

** 부산대학교 공과대학 기계공학부

용의 공정관리용 제품들이 개발되고 있다. 그러나, 업무 특성, 관리 방식, 표준화 정도 및 기술 수준 등이 상이한 작업장에 범용의 일정계획 시스템을 적용하기 위해서는 작업장의 특성에 맞도록 많은 수정을 해야한다. 따라서 작업장의 특성이나 업무의 종류에 적합한 일정계획 시스템의 개발이 필요하다.

본 연구에서는 금형공장의 금형 생산을 위한 일정계획 수립에 초점을 맞춘 금형공장용 일정계획 시스템으로서, 신경망을 사용하여 현재의 작업장의 상태에 적합한 공정선택 규칙을 선정하며, 이 선정된 규칙을 사용하여 일정계획을 수립한다. 특정한 하나의 공정선택 규칙을 사용하지 않고, 발견적 방법에 의하여 제시된 여러 가지 규칙들 중에서 현재의 작업장 상태에 가장 적절하게 적용될 수 있다고 판단되는 규칙을 선정하여 일정계획을 수립한다. 이는 공정선택 규칙 선정에 유연성을 주어 현재의 작업장에 가장 적절한 일정계획을 수립하기 위함이다.

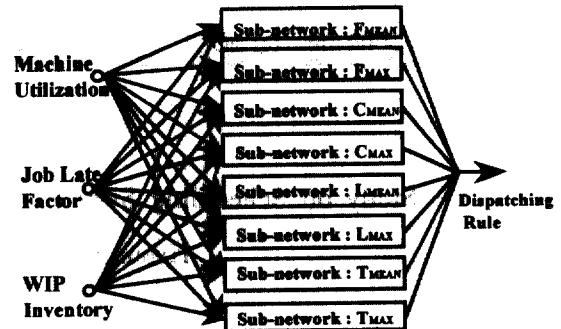
공정선택 규칙을 선정하기 위한 여러 가지 방법중에서 신경망을 사용하는 이유는, 신경망은 학습을 기초로 하기 때문에 실시간 제어 시스템에 사용할 수 있을 정도로 빠른 응답을 줄 수 있으며, 학습되지 않은 새로운 데이터나, 변경된 데이터가 입력되어도 적절한 응답을 줄 수 있기 때문이다.

2장에서는 공정선택 규칙을 선정하기 위하여 사용된 신경망에 대하여 설명하고, 3장에서 일정계획시스템, 4장에서 적용 예에 대하여 기술한 후, 5장에서 결론을 내리고자 한다.

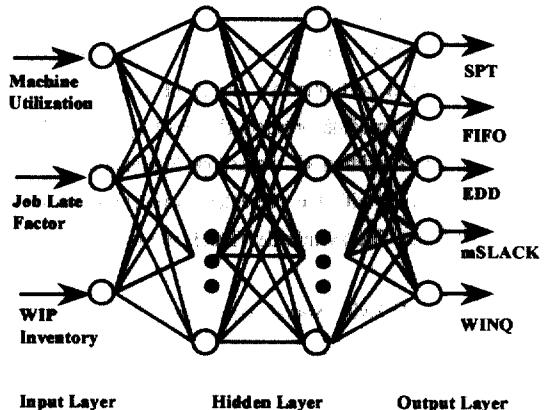
2. 신경망의 구성

본 연구에서 사용한 신경망은 <그림 1>과 같이 8개의 서브 신경망으로 구성되어 있으며, 각 서브 신경망은 <그림 2>와 같이 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)로 구성되어 있다. 8개의 서브 신경망은 작업장의 상태에 관한 3개의 뉴런을 가진 입력층, 각각 14개의 뉴런을 가진 2개의 은닉층, 그리고 공정선택 규칙에 해당하는 5개의 뉴런을 가진 출력층으로 구성되어 있다.

신경망의 학습은 각 뉴런들을 연결하는 연결 가중치(connection weight)를 조절하여 이루어 진다. 신경망 학습 데이터의 입력 패턴들에 대한 원하는 출력값을 목표값(t_{pl})으로 하고, 신경망의 출력층에서 얻어진 최종 출력값을 실제 출력값(o_{pl})으로 하여, 두 출력값 사이의 차이를 오차($t_{pl} - o_{pl}$)로 정의한다. 그리고 오차의 제곱($(t_{pl} - o_{pl})^2$)을 신경망의 시스템 오차라고 하는데 이 시스템 오차를 최소화하는 델타 규칙(Delta



<그림 1> 공정선택 규칙 선정을 위한 신경망 구조



<그림 2> 서브 신경망의 구성도

rule)을 신경망의 학습 알고리즘으로 사용한다. 패턴 p 에 대한 오차의 제곱은 식 1과 같고 전체 시스템 오차의 제곱의 합은 $E = \sum_p E_p$ 이다.

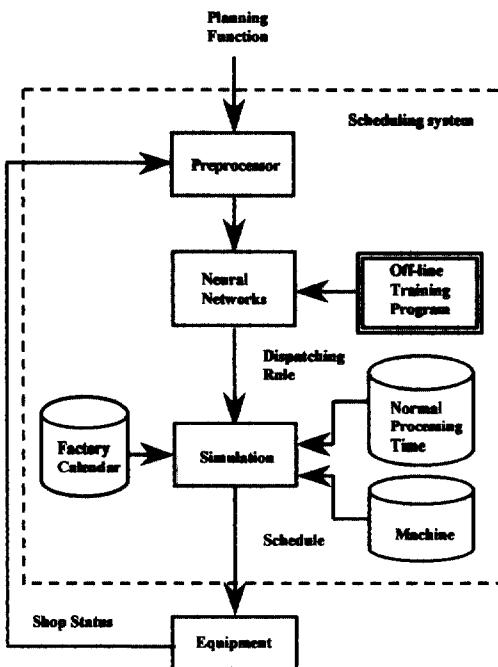
$$E_p = \frac{1}{2} \sum_l (t_{pl} - o_{pl})^2 \quad (1)$$

연결 가중치의 조절에 있어서는 출력층의 뉴런으로의 연결 가중치를 먼저 조절하고 차례로 하위층 뉴런으로의 연결 가중치를 조절하는 백-프로파게이션(back-propagation) 알고리즘을 사용한다. 또한 연결 가중치의 조절에 있어서 국소 최소치의 문제를 해결하기 위하여 모멘텀 항을 추가하고, 각 뉴런을 활성화시키는 전달함수는 시그모이드 함수(sigmoid function)를 선정하여 큰 입력값과 작은 입력값에 대해서도 적절히 반응할 수 있도록 한다.

3. 일정계획 시스템

3.1 시스템의 구성

시스템의 구성은 〈그림 3〉과 같이 전처리 과정(pre-processor), 신경망(neural networks), 오프 라인 신경망 학습(off-line training program), 시뮬레이션(simulation) 등으로 구성되어 있다. 전처리 과정은 현재의 작업장의 상태를 파악하여 신경망에 입력하기 위한 데이터를 생성한다. 오프라인 신경망 학습 모듈은 작업장 상태에 따라 가장 적절한 우선 규칙을 제시할 수 있도록 공정선택 규칙과 작업장의 상태, 그리고 작업장의 성능 평가기준에 관한 데이터를 사용하여 신경망을 학습시키는 모듈이다. 신경망 모듈은 전처리 과정에서 생성된 작업장의 상태에 관한 데이터를 입력 벡터로 하여 현재 작업장 상태에 가장 적합한 공정선택 규칙을 제시하여 준다. 시뮬레이션 모듈은 신경망 모듈에서 제시된 우선 규칙을 사용하고, 사용 가능한 공작기계, 회사 근무일, 금형 가공 공정, 표준 공정 시간 등의 입력 데이터를 사용하여 일정계획을 수립한다.



〈그림 3〉 일정계획 시스템의 구성도

일정계획을 수립하기 위한 가정으로, 첫째, 각 공정에서 필요로 하는 공구는 재고량이 충분히 준비되어 있어, 공구의 부족으로 인해서는 일정계획에 영향을 끼치지는 않는다. 둘째, 이동시간 및 셋업(set up) 시간은 공정 시간에 포함시킨다. 공작 기계간의 이동 시간과 공작 기계마다 셋업 시간이 다르나, 그 시간간의 차이는, 최소 4시간에서 최대 150 시간인 공정당 작업시간에 비하면 무시해도 될 정도로 근소하다.

신경망의 구성은 C 언어를 사용하였고, 시뮬레이션은 SIMAN을 사용하였다.

3.2 후보 규칙 및 성능 평가 기준

본 논문에서 사용한 공정선택 규칙들은 일반적으로 많이 사용되고 있는 SPT, FIFO, EDD, mSLACK, WINQ 등이다[4]. 각각의 규칙들에 대한 설명은 다음과 같다.

$$\text{SPT}(\text{Shortest Processing Time}) : \min_{i \in s_k} \{p_{ij}\}$$

$$\text{FIFO}(\text{First In, First Out}) : \min_{i \in s_k} \{C_{i,j-1}\}$$

$$\text{EDD}(\text{Earliest Due Date}) : \min_{i \in s_k} \{d_i\}$$

$$\text{mSLACK}(\text{minimum SLACK time}) : \min_{i \in s_k} \left\{ d_i - t - \sum_{j=q_i}^{m_i} p_{ij} \right\}$$

$$\text{WINQ}(\text{Work In Next Queue}) : \min_{i \in s_k} \left\{ \sum_{i' \in s_{k+1}} p_{i'j'} \right\}$$

여기서

i : 부품, j : 공정, C_{ij} : 작업 완료 시간, d_i : 납기 일, m_i : 공정수, p_{ij} : 공정 시간, q_i : 현재 공정, s_k : 기계 k에 대기중인 부품의 집합, t : 현재 일이다.

작업장 성능평가를 위해 일반적으로 사용되는 기준은 재고 수준과 납기다. 그러나 Job shop에서는 재고수준과 납기성능을 정확하게 측정할 수 있는 기준은 없다. 따라서 다양한 대체 기준들이 사용된다. 본 논문에서는 여러가지 작업장 성능 평가(measures of performance) 기준들 중에서 평균처리시간 (F_{MEAN}), 최대처리시간(F_{MAX}), 평균작업완료시간(C_{MEAN}), 최대작업완료시간(C_{MAX}), 평균납기지연시간(L_{MEAN}), 최대납기지연시간 (L_{MAX}), 평균순수납기지연시간(T_{MEAN}), 최대순수납기지연시간 (T_{MAX}) 등을 사용한다. 성능 평가의 종합적 기준은 이상적으로

〈표 1〉 신경망의 입력 벡터의 특성

Input vector	Characteristics
Performance criteria	1 : C_{MEAN} 2 : C_{MAX} 3 : F_{MEAN} 4 : F_{MAX} 5 : L_{MEAN} 6 : L_{MAX} 7 : T_{MEAN} 8 : T_{MAX}
Machine utilization	(average machine busy time) / (any time interval)
Job late factor	(number of late parts) / (total number of parts in system)
WIP	Work in process inventory

는 총비용을 나타내는 기준이 된다. 그러나 일반적으로 총비용 기준을 구체적인 함수 형태로 나타내기가 어렵기 때문에 보통 종합적 기준이라고 함은, 이들 기초적 기준들의 가중치의 합으로 정한다. 이때 가중치는 주관적으로 결정된다. 본 연구에서는 작업장 성능 평가 기준들에 대한 가중치를 1로 주고 앞에 제시된 5가지의 공정선택 규칙을 평가한다.

신경망의 입력 데이터로 사용되는 작업장의 상태를 나타내는 것으로는 기계효율(machine utilization), 작업 지연(job late

factor), WIP 등이다. 신경망에 사용된 입력데이터의 특성은 〈표 1〉과 같다.

3.3 신경망의 학습

초기에는 신경망을 학습시키기 위한 축적된 데이터가 없기 때문에 신경망을 학습시키기 위한 데이터를 SIMAN을 사용한 시뮬레이션을 통하여 획득한다.

시뮬레이션을 수행하기 위한 입력 데이터로 부품 수(14, 16), 기계 수(25, 28), 공정 수(10, 12), 공정시간(4, 120) 등의 범위에서 랜덤하게 발생시켜 사용한다. 시뮬레이션을 수행하기 위해서는 먼저 시뮬레이션 시스템에 작업을 투입하고 FIFO 규칙을 사용하여 작업장의 기계 효율, 지연 작업률, 재공 등의 데이터를 산출한다. 다음으로 초기 작업장 부하 상태에서 새로운 작업을 추가로 투입하고, SPT, FIFO, EDD, mSLACK, WINQ 등의 공정선택 규칙들을 적용하여 일정계획을 수행한 후 작업장의 평균처리시간, 최대처리시간, 평균작업완료시간, 최대작업완료시간, 평균납기지연시간, 최대납기지연시간, 평균

〈표 2〉 신경망의 학습 데이터

Input vectors				Desired output vectors				
Performance criteria	Machine utilization	Job late factor	WIP	SPT	FIFO	EDD	mSLACK	WINQ
1	0.66	0.0	1.3	0.5	0.3	0.7	0.0	1.0
1	0.76	0.24	3.9	0.0	0.4	0.8	0.7	1.0
2	0.72	0.0	1.8	0.3	0.6	0.8	1.0	0.0
2	0.63	0.25	1.6	0.0	0.8	0.9	1.0	0.3
3	0.70	0.27	2.4	0.0	0.2	0.5	0.2	1.0
3	0.79	0.0	2.3	0.0	0.5	0.8	0.8	1.0
4	0.69	0.14	2.3	0.2	0.8	0.9	1.0	0.0
4	0.62	0.0	1.0	0.6	0.7	0.9	1.0	0.0
5	0.69	0.44	2.7	0.0	0.3	0.7	0.5	1.0
5	0.66	0.0	1.3	0.5	0.3	0.7	0.0	1.0
6	0.74	0.0	1.4	0.6	0.8	1.0	1.0	0.0
6	0.59	0.0	1.0	0.6	0.7	0.9	1.0	0.0
7	0.69	0.14	2.3	0.6	0.7	1.0	0.9	0.0
7	0.78	0.0	2.9	0.0	0.8	1.0	1.0	0.7
8	0.70	0.27	2.4	0.0	0.4	0.9	1.0	0.2
8	0.62	0.0	1.4	0.3	0.8	1.0	0.9	0.0

순수납기지연시간, 최대순수납기지연시간 등의 데이터를 산출 한다. 그리고, 이들 출력값들을 다시 최대값은 0.0으로, 최소 값은 1.0으로 하여 신경망의 학습 데이터를 만든다. <표 2>에 신경망 학습 데이터 240개중 일부를 나타내었으며, 표에서 “Input vectors”는 작업장의 상태에 관한 입력 벡터이며, “Desired output vectors”는 입력 벡터에 의해 신경망의 수행 후 출력 되기를 원하는 목표값이다.

신경망 학습은 시스템 오차가 0.01 이하($E \leq 0.01$)가 될 때 정지한다.

신경망의 모든 연결 가중치는 0.0과 1.0 사이의 난수로 초기화 된다. 이를 연결 가중치가 시스템의 학습 정지 오차를 만족할 때까지 학습을 반복시킨다. 학습 데이터 수는 각 서브 신경망 당 30개로 전체 240개다.

기준 이하의 시스템 오차를 만족할 때 까지 신경망을 학습시키기 위해서는 많은 시간이 소요되나 일단 시스템 오차를 만족하는 연결 가중치 데이터가 생성되면, 신경망은 입력 벡터에 대하여 빠른 응답을 한다. 이는 신경망이 이미 학습된 연결 가중치 데이터를 사용하여 입력에 대한 적절한 응답을 하기 때문이다.

3.4 시뮬레이션

일정계획을 세우기 위해서는 금형의 부품 구조(parts structure)와 가공 공정, 그리고 각 공정에서의 표준 공정 시간이 정의되어 있어야 한다. 본 논문에서 대상으로 하고 있는ダイケース팅(die casting) 금형은 90 개에서 130 개의 부품으로 구성되어 있다. 부품들의 대부분은 표준화된 부품들로서 구매에 의존하며, 고정축과 이동축 캐비티 등 주요 부품만을 직접 사내 가공한다. 사내 가공품과 구매품은 조립 공정에서 조립되며, 검사 공정을 거친 후 납품된다. 따라서 일정계획 수립시 주요

사내 가공품만을 대상으로 일정계획을 수립하고, 구매품은 사내 가공품의 가공 일정에 맞추어 발주한다.

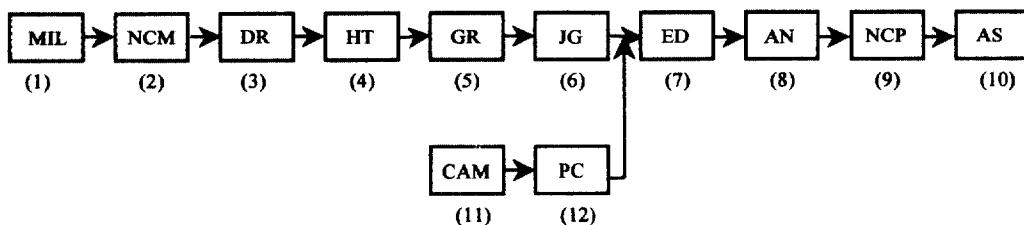
캐비티 가공 작업은 <그림 4>와 같이 12개의 공정으로 구성되어 있다.

여기서

- (1) MIL : Milling 공정으로 재료의 외각 가공 공정.
- (2) NCM : NC Milling 공정으로 캐비티 형상 가공 공정.
- (3) DR : Drilling 공정으로 구멍 가공.
- (4) HT : 열처리 공정.
- (5) GR : Grinding 공정.
- (6) JG : JIG Boring 공정.
- (7) ED : 흑연전극을 사용한 방전 공정.
- (8) AN : 전류응력 제거 공정.
- (9) NCP : NC Milling 후가공 공정.
- (10) AS : 사상, 조립 공정.
- (11) CAM : 흑연가공을 위한 NC 프로그래밍 공정.
- (12) PC : 흑연 전극 가공 공정이다.

표준 가공 시간은 금형의 크기와 캐비티 형상의 복잡도에 따라 다르다. 일차적으로 금형의 톤(ton)과 외형 크기에 따라 기존의 축적된 데이터를 바탕으로 하여 표준 공정시간을 제시하여 주고, 이 데이터를 기준으로 하여 경험을 가진 일정계획자에 의해 캐비티 형상의 복잡도에 따라 공정시간을 수정한다. 가공 공정과, 공정 시간의 수정이 완료되면, 이 데이터를 사용하여 일정계획을 수행한다.

<그림 4>에서와 같이, 캐비티 가공 공정에서의 공정 특징은 중간 공정에서 두 공정이 합류하는 공정이 발생한다. 이는 방전 공정에서 발생하는데, 방전 가공을 위해서는 흑연 전극이 방전 공정전에 준비되어 있어야 한다. 그리고 전극을 가공하



<그림 4> 고정축 및 이동축 캐비티의 작업 공정

기 위해서는 전극 가공용 NC 프로그램이 준비되어 있어야 한다. 따라서 전극 가공 공정과 NC 프로그래밍 공정은 방전 공정 시작 시점을 기준으로 하여 후방향 전개를 하여 NC 프로그래밍 시작 시점을 정한다.

제품의 종류, 수량 또는 구성품의 수, 반복 작업의 시간 간격, 작업장의 여건 등에 따라 일정계획을 수립하는 방법은 다양하지만, 전개방식에 따라 전방향 전개 일정계획(forward scheduling)과 후방향 전개 일정계획(backward scheduling)으로 나눌 수 있다. 전방향 전개 일정계획은 가장 빠른 작업 시작 시점(the earliest start time)에 맞추어 계획을 세우고, 후방향 전개 일정계획은 납기를 기준으로 가장 늦어도 되는 작업 시작 시점(the latest start time)에 맞추어 계획을 세운다.

금형공장용 일정계획 시스템은 먼저 전방향 전개를 하여 작업장의 부하 능력에 따른 수주 금형의 예상 납기를 산출해낸다. 다음으로 시스템에서 제시한 예상 납기와 수주 납기를 비교하여 실제 납기를 정의한다. 다음으로, 실제 납기를 기준으로 하여 후방향 전개를 함으로써 실제 작업 투입일을 결정한다. 후방향 전개를 하여 작업 투입일을 정하는 이유는 전방향 전개에 의하여 실제 작업 투입일 보다 소재 및 반가공품이 미리 준비됨으로 인한 제공체고를 최소한으로 줄이기 위함이다.

일정계획 수행 단계는 다음과 같다.

[단계 1] 기계 효율, 지역 작업률, 재공을 산출하여 신경망에 입력한다.

[단계 2] 신경망을 사용하여 공정선택 규칙을 선정한다.

[단계 3] 선정된 공정선택 규칙을 사용하여 전방향 전개로 일정계획을 수립한다.

[단계 4] 예상 납기일을 산출한다.

[단계 5] 예상 납기일과 수주 납기일을 고려하여 후방향 전개를 위한 납기를 정한다.

[단계 6] 확정된 납기일을 기준으로 하여 후방향 전개로 일

정계획을 수립한다.

[단계 7] 후방향 전개에 의한 작업의 투입일을 결정한다.

4. 적용례

신경망을 이용하여 작업장의 상태에 의한 공정선택 규칙 선정의 타당성을 검증하기 위하여 다섯 번의 시뮬레이션을 수행하였다. 시뮬레이션을 위한 작업장에는 12개의 공정, 각 공정 시간이 4시간에서 120시간, 그리고 35대의 공작기계로 구성되어 있다. 부품의 투입은 22개에서 28개의 고정측 및 이동측 캐비티가 작업 중에 있으며, 이 상태에서 작업장의 기계 효율, 지역작업, 재공 등의 데이터를 추출하였다. 이 데이터를 사용하여 신경망을 수행하여 작업장의 상태에 적절한 공정선택 규칙을 선정하였으며, 그 결과를 <표 3>에 나타내었으며, 각 시뮬레이션 수행결과 5개의 공정선택 규칙중 가장 높은 순위의 규칙에 *표를 하였다.

새로운 부품을 기존의 공정에 투입하여 시뮬레이션을 수행하여 작업장 성능평가 기준중에서 평균처리시간, 최대처리시간, 평균순수납기지연시간, 최대순수납기지연시간 등을 모두 합하여 공정선택 규칙들을 서로 비교하였으며, 그 결과를 <표 4>에 나타내었으며, 가장 좋은 결과치에 *표를 하였다.

신경망에서 제시한 규칙과 다른 5가지의 공정선택 규칙에 의한 시뮬레이션 결과를 <그림 5>에서 그래프로 나타내었다. 신경망을 통하여 EDD 규칙은 3번, mSLACK 규칙은 2번 선정되었으며, 시뮬레이션 수행 결과 신경망에서 제시된 규칙이 작업장 성능평가에서 가장 좋은 결과를 얻었다. 이는 하나님의 특정한 공정선택 규칙을 사용하는 것 보다는 작업장의 상태에 따라 적절한 규칙을 사용하는 것이 현재의 작업장 상태에 적합한 일정계획을 수립할 수 있다는 것을 보여주는 것이다.

다음은 일정계획 시스템의 수행을 확인하기 위하여 먼저 작

<표 3> 신경망의 시뮬레이션 결과

Simulation	Machine Utilization	Job late factor	WIP	SPT	FIFO	EDD	mSLACK	WINQ
1	0.79	0.33	1.8	1.9	3.8	6.7*	5.0	3.8
2	0.79	0.07	1.8	3.5	5.3	6.8	7.2*	3.0
3	0.81	0.23	2.1	1.2	4.6	6.8	6.9*	4.0
4	0.73	0.19	0.73	2.7	5.0	5.5*	4.0	3.7
5	0.71	0.07	1.7	4.0	4.2	6.6*	5.3	3.0

〈表 4〉 공정선택 규칙을 사용한 시뮬레이션 결과

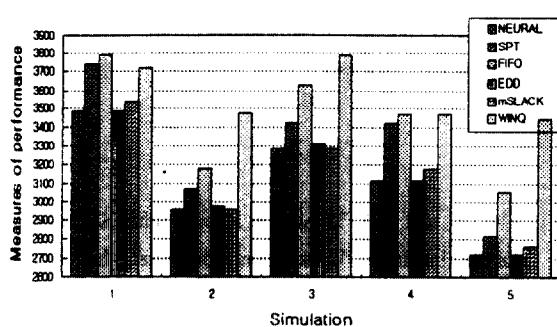
(unit : hour)

Simulation	Dispatching rules	F _{MEAN}	F _{MAX}	T _{MEAN}	T _{MAX}	Sum
1	SPT	712	2130	81	815	3738
	FIFO	966	2100	102	620	3788
	EDD	767	2100	77	540	3484*
	mSLACK	844	2100	94	500	3538
	WINQ	725	2130	103	756	3714
2	SPT	712	2130	10	215	3067
	FIFO	966	2100	6	100	3172
	EDD	773	2100	2	100	2975
	mSLACK	815	2050	2	88	2955*
	WINQ	725	2130	30	588	3473
3	SPT	716	2290	22	396	3424
	FIFO	1058	2260	41	270	3629
	EDD	780	2260	11	260	3311
	mSLACK	815	2210	12	248	3285*
	WINQ	725	2290	33	738	3786
4	SPT	658	2000	60	706	3424
	FIFO	880	1910	66	610	3466
	EDD	717	1970	51	376	3114*
	mSLACK	771	1970	60	370	3171
	WINQ	687	2000	76	706	3469
5	SPT	662	2020	5	126	2813
	FIFO	932	1940	8	175	3055
	EDD	729	1990	0	0	2719*
	mSLACK	770	1990	0	0	2760
	WINQ	709	2088	31	616	3444

업장의 상태를 입력 데이터로 하여 신경망을 수행하여 공정선택 규칙을 선정한다. 다음으로 작업장에 새로운 부품을 투입하여 시뮬레이션을 수행하여 그 결과를 간트 도표(Gantt chart)로 나타낸다.

현 작업장의 기계효율 : 0.66, 작업지연율 : 0, WIP : 0.7의 작업장 상태인 경우, 신경망을 수행한 결과 제시된 공정선택 규칙들의 우선 순위를 〈표 5〉에 나타내었다. 이 결과에서는 EDD 우선 규칙이 주어진 현재의 작업장 상태에 가장 적합한 것으로 제시되었다. 작업장 성능 평가기준 각각의 가중치를 1로 하였기 때문에 신경망의 수행 결과를 모두 더하여 가장 큰 수를 1순위로 하여 순위를 정하였다.

신경망에서 제시된 EDD 규칙을 사용하여 일정계획을 수립

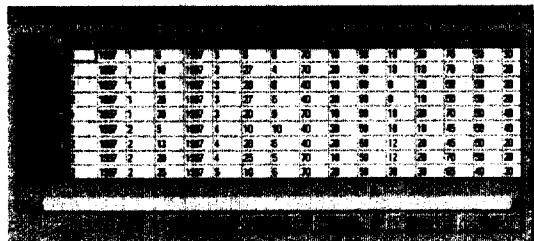


〈그림 5〉 작업장 성능평가 기준에 의한 공정선택 규칙 비교

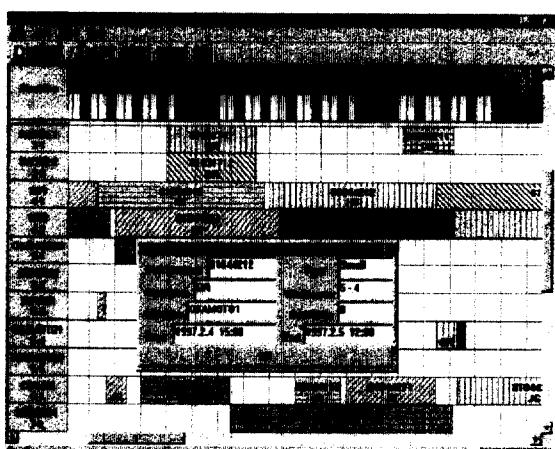
〈표 5〉 예제를 위한 신경망의 수행 결과

	F _{MEAN}	F _{MAX}	C _{MEAN}	C _{MAX}	L _{MEAN}	L _{MAX}	T _{MEAN}	T _{MAX}	Sum.	Rank
SPT	0.2	0.0	0.3	0.0	0.0	0.3	0.0	0.0	0.8	5
FIFO	0.3	0.6	0.3	0.5	0.5	0.6	0.3	0.8	3.9	3
EDD	0.7	1.0	0.7	0.7	0.7	0.8	1.0	1.0	6.6	1
mSLACK	0.0	1.0	0.0	1.0	0.3	1.0	1.0	1.0	5.3	2
WINQ	1.0	0.0	1.0	0.9	1.0	0.0	0.0	0.0	3.9	3

한다. 〈그림 6〉은 캐비티의 품번과 각각의 공정시간을 나타낸다. 공정시간은 예상 공정시간이므로 작업자에 의해 수정이 가능하다. 고정측 및 이동측 캐비티를 가공 및 조립하기 위한 공정은 12개이며, 각 공정에 사용되는 기계 수는 35대이다. 〈그림 7〉은 일정계획 수행을 통하여 생성된 일정을 전체적으로 파악할 수 있도록 간트 도표로 나타낸 것이다.



〈그림 6〉 일정계획을 수행하기 위한 작업 공정 시간



〈그림 7〉 금형가공작업의 진도를 나타내는 간트도표의 예

5. 결 론

제품 종류나 기계가 적은 소규모의 작업장에서는 일정계획 전문가에 의하여 수작업으로 일정계획을 수립하였다. 그러나 제품의 종류가 많아지고 공정이 복잡해짐에 따라 수작업으로 일정계획을 세우는 것은 비효율적이다. 또한, 전산기에 의해 일정계획을 수립하는 경우에도 공정선택 규칙을 작업장의 상태는 고려하지 않고 특정한 하나의 규칙을 적용하는 것은 최적의 일정계획을 세우는 데 있어서 적절하지 않다. 부적절한 일정계획은 낭비 자연의 원인이 된다.

이러한 문제점을 해결하기 위하여 수행된 본 연구에서는 먼저 신경망을 사용하여 작업장의 상태에 가장 적절한 공정선택 규칙을 선정하였고, 이 선정된 규칙을 사용하여 일정계획을 수립하였다. 신경망에 의하여 제시된 규칙의 타당성을 검증하기 위하여 시뮬레이션을 수행하였으며, 작업장 성능 평가 기준을 사용하여 각 공정선택 규칙을 비교, 분석하였다.

분석결과 하나의 특정한 규칙을 사용하기보다는 작업장의 상태에 따라 적절한 공정선택 규칙을 신경망을 사용하여 선정 사용하는 것이 타당하다는 결론을 얻었다.

개발된 신경망을 이용한 일정계획 시스템은 금형공장을 대상으로 하였으며, 금형공장에 적용시 일정계획 수립에 많은 도움이 될 것으로 기대된다.

【참 고 문 헌】

- [1] Cho, H. and R.A. Wysk, "A Robust Adaptive Scheduler for an Intelligent Workstation Controller", *Int. J. Prod. Res.*, Vol. 31, No. 4, pp. 771-789, 1993.
- [2] Patrick, R. P. and D.F. Timothy, "The Robustness of Selected Job-shop Dispatching Rules with Respect to Load Balance and Work-flow", *J. Opl Res. Soc.*, Vol. 41, No.

- [10] pp. 897-906, 1990.
- [3] Panwalkar, S.S. and W. Iskander, "A Survey of Scheduling Rules", Operations Research, Vol. 25, No. 1, pp. 45-61, January-February, 1977.
- [4] Blackstone, J. H., D.T. Phillips, and G.L. Hogg, "A State-of-the-art Survey of Dispatching Rules for Manufacturing Job Shop Operations", Int. J. Prod. Res., Vol. 20, No. 1, pp. 27-45, 1982.
- [5] 박지형, "개별 생산체제의 지능형 작업 일정계획 및 통제 시스템에 관한 연구", 박사학위논문, 서울대학교, 1993.
- [6] Foo, S. Y. and Y. Takefuji, "Integer-linear Programming Neural Networks for Job-shop Scheduling", Proceedings of IEEE IJCNN '88, San Diego, pp. 341-348, 1988.
- [7] Zhou, D. N., V. Cherkassky, T.R. Baldwin, and D.E. Olson, "A Neural Network Approach to Job-shop Scheduling", IEEE Trans. Neural Networks, 2, 175-179, 1991.
- [8] Zhen-Ping Lo and Bavarian, "Scheduling with Neural Networks for Flexible Manufacturing System", Proceedings of the 1991 IEEE International Conference on Robotics and Automation, Sacramento, California, pp. 818-823, 1991.
- [9] Arizono, Ikuo, Akio Yamamoto, and Horoshi Ohta, "Scheduling for Minimizing Total Actual Flow Time by Neural Networks", Int. J. Prod. Res., Vol. 30, No. 3, pp. 503-511, 1992.
- [10] Sim, S.K., K.T. Yeo, and W.H. Lee, "An Expert Neural Network System for Dynamic Job Shop Scheduling", Int. J. Prod. Res., Vol. 32, No. 8, pp. 1759-1773, 1994.
- [11] 김대수, 신경망이론과 응용(1), 하이테크정보, 1994.
- [12] Pao, Yoh-Han, Adaptive Pattern Recognition and Neural Networks, Addison-Wesley Publishing Company, Inc., 1989.
- [13] Conway, R. W., W.L. Maxwell, and L.W. Miller, Theory of Scheduling, Addison-Wesley, 1967.
- [14] French, S., Sequencing and Scheduling : An Introduction to the Mathematics of the Job-Shop, John Wiley & Sons, 1982.
- [15] Kang, M., S. G. Kim, and Chong-won Lee, "CIM for Mold Factory Automation", Annals of the CIRP, Vol. 39/1, pp. 467-470, 1990.



이형국(李炯國)

1989년 부산대학교 생산기계공학과
졸업
1991년 부산대학교 기계공학과 졸업(공학석사)
현재 대우정보시스템(주) 근무
관심분야 일정계획, 생산자동화, PDM



이석희(李錫熙)

1976년 서울대학교 기계공학과
졸업
1978년 한국과학기술원 기계공학과
졸업(공학석사)
1983년 UMIST(영) 기계공학과 졸업(공학석사)
1985년 UMIST(영) 기계공학과 졸업(공학박사)
현재 부산대학교 기계공학부 교수
관심분야 패속조형(RP), 생산자동화,
FMS