

유연생산시스템의 효율적 운용을 위한 지능적 기법의 적용에 관한 연구*

문 석 환**

Application of Intelligent Technique for the Efficient Operation of the Flexible Manufacturing System*

Seok-Hwan Moon**

■ Abstract ■

This research involves the development and evaluation of a work flow control model for a type of flexible manufacturing system(FMS) called a flexible flow line(FFL). The control model can be considered as a kind of hybrid intelligent model in that it utilizes both computer simulation and neural network technique. Training data sets were obtained using computer simulation of typical FFL states. And these data sets were used to train the neural network model. The model can easily incorporate particular aspects of a specific FFL such as limited buffer capacity and dispatching rules used. It also dynamically adapts to system uncertainty caused by such factors as machine breakdowns. Performance of the control model is shown to be superior to the random releasing method and the Minimal Part Set(MPS) heuristic in terms of machine utilization and work-in-process inventory level.

1. 서 론

오늘날 급변하는 생산환경과 치열한 국내외의 경쟁은 생산시스템에 커다란 변화를 초래하게 되

었다. 최근 21세기를 향한 생산시스템의 전개방향은 크게 두 가지 측면, 즉 생산설비(하드웨어적인)면에서의 '자동화'와 운용관리(소프트웨어적인)면에서의 '지능화'로 요약해 볼 수 있다.

* 본 논문은 한국학술진흥재단 '96대학교수해외파견사업의 지원을 받아 수행되었음.

** 경북대학교 경영학부

먼저 자동화측면에서 보면, 오늘날 생산시스템은 과거의 대량생산 형태의 고정형 자동화에서 탈피하여, 컴퓨터수치제어(Computer Numerical Control)기계, 로봇, 무인운반시스템(AGVS : Automated Guided Vehicle Systems), 무인저장창고시스템(Automated Storage and Retrieval Systems), 유연생산시스템(Flexible Manufacturing Systems), 및 컴퓨터통합제조시스템(Computer Integrated Manufacturing) 등과 같은 신생산기술(Advanced Manufacturing Technology)을 활용한 통합적 유연자동화로 급속히 탈바꿈하고 있다. 이러한 유연자동화는 기업이 급변하는 경제환경에 신속히 적응하고, 경쟁적 우위를 확보하기 위한 주요한 전략적 무기로 인식되고 있다.

다른 한편으로 생산시스템의 운용관리기법들은 점차 지능화 되는 추세이다. 신생산기술의 도입 및 실행과 관련하여 가장 큰 문제점의 하나로 지적되고 있는 것이 바로 민감하고 복잡한 자동설비의 효율적인 운용관리이다. 고가의 투자를 요하는 신생산기술은 효과적인 운용관리 기법의 지원을 받을 때 그 능력을 최대한 발휘할 수 있을 것이다. 신생산기술의 운용관리를 위해 전통적으로 경험적인 휴리스틱 규칙이나, 수학적인 모형이 널리 이용되어 왔다. 그러나 일반적으로 휴리스틱 규칙들을 이용하는 방법은 지나치게 단순하여 시스템의 동태적인 상황에 유연하게 적응하지 못하며, 또한 수학적 모형 이용하는 방법들도 국지적 최적해(local optimum)에 머물거나, 아니면 지나치게 복잡하여 실용성에 한계가 따른다. 따라서 이러한 전통적인 문제해결기법 대신에 최근 들어 인공지능, 전문가시스템, 인공지능망, 퍼지이론, 유전자 알고리즘 등의 새로운 지능적 기법들의 활용이 널리 확산되고 있다. 또한 이러한 지능적 기법들은 단독으로 이용되기보다는 다른 지능적 기법들이나 전통적 문제해결 기법들과 복합적으로 결합되어 혼합적으로 적용되는 혼합지능시스템(hybrid intelligent systems)의 형태를 띄어가고 있다.

이러한 배경에서 본 연구는 유연생산시스템의

한 형태인 유연흐름라인(FFL : flexible flow line)의 효율적인 작업흐름통제를 위해 인공지능망 모형을 구축하고 그 성과를 평가하고자 한다. 본 연구에서는 인공지능망의 학습에 필요한 훈련데이터를 전통적인 컴퓨터 시뮬레이션을 통해 생성하였으므로, 본 연구가 제시하는 작업흐름통제 모형은 전통적인 컴퓨터 시뮬레이션 기법과 지능적인 인공지능망 모형을 결합한 일종의 혼합지능모형으로 볼 수 있을 것이다. 본 연구가 제시하는 작업흐름통제모형의 가장 큰 장점은 개별 시스템이 지니는 특성적인 측면을 보다 쉽게 반영할 수 있을 뿐 아니라, 기계고장과 같은 시스템의 불확실성에도 동태적으로 적용할 수 있다는 점이다.


2. 유연흐름라인의 작업흐름통제

2.1 유연흐름라인

유연흐름라인에서는 모든 부품들이 연속된 일련의 작업장(work center, machine center 또는 stage)상의 동일한 경로를 거쳐 처리된다. 그리고 각 작업장은 하나 또는 그 이상의 동일한 기계들로 구성된다. 이 점에서 작업장이 단일의 기계들로만 구성된 전통적인 flow shop과는 차이가 있다. 각 부품은 각 작업장내의 한 기계에서만 가공되고 경우에 따라 어떤 부품은 특정 작업장을 건너 뛸 수도 있다. 이러한 FFL의 일반 모형이 [그림 1]에 예시되었다. [그림 1]의 FFL은 각 작업장 앞에 한정된 능력의 저장공간을 가정하고 있다. 이러한 형태의 FFL상의 작업흐름을 통제하는 데 있어 주된 목적은 한정된 저장공간 제약하에서 주어진 저장공간의 능력을 최대한 활용하여 전체 작업을 끝내는데 걸리는 시간, 즉 schedule makespan을 최소화하는 것이다.

일반적으로 FFL은 수치제어기계나 로봇 등의 자동화된 설비로 연결되어 있어, 한 부품의 작업을 끝내고 다른 부품의 작업을 시작하는 데 걸리는 시간, 즉 준비시간(setup time)은 거의 무시할 정도로

서 이론상으로 하나의 유연흐름라인이 여러 상이한 종류의 부품을 동시에 처리하는 것이 가능하다. 자동화된 설비들은 주기적인 조정을 요하거나 고장이 발생할 수가 있는데, 효과적인 작업흐름통제 기법은 이러한 시스템상의 불확실성에 동태적으로 적용할 수 있어야만 한다. FFL은 일반적으로 LAN으로 연결되어 시스템의 상태에 관한 정보들이 각종 센서에 의해 수집되어 통제용 컴퓨터에 on-line으로 전달되는 것이 보통이다. 이러한 정보를 바탕으로 시스템의 상태변화에 실시간으로 적응하는 작업흐름통제가 가능하다. 본 연구에서는 부품이 한 작업장에서 다음 작업장으로 이동되는 시간은 무시할 정도라고 간주하였다.



[그림 1] 유연흐름라인

2.2 유연흐름라인의 작업흐름 통제문제

일반적으로 작업흐름통제의 목적은 생산과정에 관련된 비용요인을 최적화 하는 것이다. 이러한 비용관련요인으로 생산율(throughput)의 최대화, makespan의 최소화, 재공품 재고의 최소화, 작업의 평균흐름시간(sojourn time), 또는 이들을 결합한 기준을 예로 들 수 있다. 실제로 어떤 기준을 택할 것이냐는 시스템의 특성이나 기업의 생산환경 및 전략과도 관련된다.

본 연구에서는 FFL에 대한 생산계획 및 통제가 기본적으로 자재소요계획(MRP : material requirements planning)환경 하에서 이루어지는 것으로 가정하고 있다. 이러한 상황에서는 주생산일정(MPS : master production scheduling)과 MRP가

시간별로 결정이 되며, 당해 생산계획기간에 속하는 부품들은 동일한 납기를 가지게 되므로 어느 부품의 요구량이 먼저 충족되어야 할 필요는 없다. 또한 같은 기간 내에 요구되는 부품들이 일정한 비율로 생산되어야 한다는 조건이 충족되어야 할 필요도 없다. 중요한 것은 당해 생산기간동안 FFL이 처리해야할 모든 부품의 가공이 완성되는 시점, 즉 schedule makespan의 단축이다. schedule makespan을 단축시키는 것은 여러 가지로 바람직하다. 왜냐하면, schedule makespan의 단축으로 생긴 여분의 시간으로 FFL의 유지보수나 기타의 잔업처리에 활용될 수 있기 때문이다. 이러한 상황에서 FFL상의 작업흐름통제의 주목적은 schedule makespan의 최소화가 되며, 이는 기계활용율(machine utilization)의 최대화와 일치한다.

FFL상의 세부적인 작업흐름통제는 크게 다음과 같은 세 가지의 기능을 포함하고 있다.

- (1) 투입결정(releasing) : FFL에 투입할 각 부품의 수량과 투입시점의 결정.
- (2) 경로결정(routing) : 각 작업장에서 특정 부품을 처리하게 될 기계의 선택.
- (3) 작업순서결정(dispatching) : 각 작업장에서 다음으로 처리될 작업의 선택.

투입결정기능은 시스템 내로 투입할 부품의 수량과 투입시점을 결정하는 것으로 시스템의 수문장 역할을 맡게된다. 투입시점간의 간격, 즉 통제기간(control period)은 통제모형에 따라 고정적일 수도 있고 변동적일 수도 있다. 만약 통제기간이 고정적이라면 투입결정은 일정기간의 간격으로 반복적으로 이루어질 것이다. 또한, 통제기간이 변동적이라면 특정한 시스템상황, 즉 triggering event가 발생할 때마다 투입결정이 내려지게 될 것이다. 이러한 triggering event로는 주로 기계의 고장과 수리완료, 재공부품의 수준, 시스템자원(저장장소, 운송장치, fixture나 pallet 등)과 같은 상태변동이 이용된다. 투입결정의 주된 목적은 시스템의 최대 활용과 재공부품 수준의 통제에 있으며, 이들 두 목적간에는 trade-off 관계가 존재한다. 즉 기계의

고장을 대비하여 보다 많은 재공부품을 유지할 경우 다른 조건이 동일하다면 시스템 활용도는 증가될 것이다. 본 연구에서는 저장공간이 제한되어 있다고 가정한다. 저장공간이 한정된 경우는 어느 한 기계가 부품에 대한 가공을 끝내더라도 다음 작업장에서 그 부품을 저장할 공간을 확보하지 못하면 그 부품을 내보내지 못하는 blocking 현상이 생김으로써 시스템내의 재공부품의 수준이 통제된다. 이러한 상황에서는 주어진 저장공간을 최대한 활용하여 makespan 또는 기계활용율을 최대화하는 것이 과제가 될 것이다. 즉 저장공간의 능력을 초과하여 투입될 경우는 blocking이 발생하게 되고, 반대로 저장공간의 능력을 미달하여 투입할 경우는 저장공간에 처리할 작업이 전혀 없는 starvation 상태가 발생할 가능성이 높게 된다. 이 때 투입기능은 첫 번째 작업장의 기계가 작업을 마칠 때마다 새로 작업할 부품을 투입하되 blocking이나 starvation을 최소화하는 부품을 선정하는 문제로 단순화시킬 수 있을 것이다. 이러한 경우 투입기능은 작업순서결정과 유사한 기능을 수행하는 것이 된다.

경로결정은 각 작업장에서 특정 부품을 처리하게 될 기계를 선택하는 문제로서 각 작업장이 두 개 이상의 기계로 구성되어 있을 때 생기는 문제이다. 경로결정은 크게 정태적(static)인 방법과 동태적(dynamic)인 방법으로 나눌 수 있다. 정태적 경로결정이란 전체 작업이 착수되는 시점에 모든 부품을 처리할 기계를 미리 결정해 두는 방법이다. 이 방법은 단순하다는 이점은 있으나, 기계의 고장과 같은 시스템상의 확률적 이상이 발생할 때는 적절하게 대응하지 못한다는 단점이 있다. 반면에 동태적 경로결정은 시스템 상황에 따라 마지막 순간에 처리할 기계가 선택되는 방법이다. 이 방법이 시스템 상황의 변동에 보다 잘 적응할 수 있을 것이다. 경로결정은 한 작업장이 상이한 성능을 가진 기계로 구성되어 있어 부품의 처리시간에 차이가 있다든지 작업장내의 각 기계별로 별도의 저장장소가 마련되어 있을 경우는 보다 복잡하고 중요한

문제가 된다. 그러나 본 연구에서는 각 작업장이 동일한 기계로 구성되어 있으며 각 기계들은 작업장별로 마련된 공동의 저장장소에 있는 어느 부품이든 선택하여 처리할 수 있다고 가정하고 있으므로 경로결정은 별 문제가 되지 않는다. 이러한 상황에서 각 부품들을 가장 먼저 이용 가능한 기계에 배정하는 방법이 효과적인 경로결정이 될 것이다.

작업순서결정이란 각 작업장의 저장장소에 대기 중인 부품중 이용 가능한 기계에 의해 다음으로 처리될 부품을 선택하는 것을 말하며, 엄밀한 의미에서 sequencing과 구별되는 개념이다. sequencing이란 모든 부품에 대하여 처리될 작업순서를 미리 결정하며 이 작업순서가 모든 작업장에서 동일하게 지켜지도록 하는 방법으로 전통적인 flow shop scheduling에 주로 적용된다. 부품의 수나 작업장의 수가 한정된 소규모의 scheduling문제라면 complete enumeration, branch and bound technique 또는 정수계획법 등을 사용하여 최적해를 구하는 것이 가능하겠지만, 현실적 문제의 경우는 그러한 방법을 사용하는 것이 불가능하므로 휴리스틱한 방법을 많이 사용하게 된다. 일반적으로 job shop에서는 shortest processing time(SPT) 규칙이 효과적이라고 알려져 있으나, 본 연구에서 다루고 있는 FFL의 경우 모든 작업장에 일률적으로 SPT 규칙을 적용하게 되면 병목(bottleneck) 작업장의 blocking을 증가시켜 기계활용율을 하락시킬 우려가 높다. 따라서 시스템 상태에 적응하여 blocking과 starvation을 최소화하여 기계활용율을 높이는 동태적인 작업순서결정방법이 요구된다.

2.3 기존의 유연흐름라인 통제기법

유연흐름라인보다 단순한 형태인 flow shop에 대하여는 비교적 많은 연구들이 이루어져왔다. 2개의 기계로 구성된 flow shop의 makespan을 최소화하는 Johnson[17]의 최적해 알고리즘은 너무나 유명하다. 그리고 3개의 기계에 대해서도 특별한 경우에 makespan을 최소화하는 최적해가 알려져

있으나, 그 이외의 flow shop 문제는 NP-complete 임이 증명되었다. Palmer[23], Campbell et al.[4], Gupta[12], 그리고 Dannenbring[7] 등은 flow shop 문제의 휴리스틱을 개발하였으며, Santos et. al. [30] 등을 이러한 flow shop 휴리스틱을 유연흐름 라인에 적용하였다. 최근 들어 flow shop 스케줄링에 관하여 퍼지이론이나 유전자 알고리즘 등의 지능적 기법을 적용한 연구들이 많이 이루어지고 있다. Reeves[27], Murata, et. al.[22]과 Chen, et. al.[5], Ishibuchi, et. al.[16] 등은 유전자 알고리즘을 적용하였으며, Gangadharan & Rajendran[9]은 simulated annealing 기법을 이용하였다.

그러나 유연흐름라인의 작업흐름통제 문제는 작업장별 단일의 기계를 가정하는 flow shop 작업순서결정문제 보다 훨씬 복잡한 문제로서 flow shop의 해법을 유연흐름라인에 바로 적용하기는 어려울 것이다. 그리고 대다수 flow shop 휴리스틱들은 재공부품의 저장공간능력을 고려하지 않고, 또한 모든 작업장에서의 동일한 작업순서(permutation schedule)를 가정하고 있어, 동태적인 시스템의 변화에 적응하는 데는 한계가 있다.

유연흐름라인의 일정계획에 대한 연구는 flow shop에 비해 상대적으로 그 수가 많지 않은 편이다. 단순한 유연흐름라인 통제모형 중의 하나로 Hitz[15]에 의해 제시된 MPS(Minimal Part Set) 휴리스틱을 들 수 있다. MPS란 당해 생산기간 동안 FFL에 의해 생산되어야 할 소요 부품수량과 같은 비율로 이루어진 최소의 정수 개수로 이루어진 부품 집합을 말한다. 예를 들면 A 부품 1000개, B 부품 3000개, C 부품 2000개가 요구된다면, MPS는 A 부품 1개, B 부품 3개, C 부품 2개로 구성되며, 이 MPS를 일정한 시간 간격을 두고 시스템에 주기적으로 투입하게 된다. 따라서 FFL은 한 MPS를 끝낸 후에야 그 다음 MPS를 처리하게 된다. 한 MPS의 투입에서 다음 MPS의 투입에 걸리는 시간, 즉 MPS 기간은 MPS내의 모든 부품을 처리하는데 걸리는 시간이 가장 긴 작업장을 기준으로 결정된다. MPS의 기본정신은 전체 부품에 대하여

작업순서를 정하는 대신 MPS에 속하는 부품들에 대해서만 최적의 작업순서를 정하여 반복하여 시스템 내로 투입함으로써 문제를 단순화시키고자 하는데 있다. Wittrock[32]은 작업장간의 작업부하가 동태적으로 균등화 되도록 MPS내의 부품투입순서를 결정하는 기법을 제시하였다. 그러나 근본적으로 MPS 휴리스틱은 기계고장과 같은 시스템 내의 불확실성에 동태적으로 적용하는 데 한계가 있다.

시스템 상황을 고려하는 동태적인 모형의 대표적인 예로서 Gershwin et. al.[10]과 Han & McGinnis[13] 및 Deane & Moon[8] 등의 연구들을 들 수 있다. Gershwin et. al.[10]이 제시한 모형은 각 부품의 생산율을 일정하게 유지하고자 하는 것으로 MRP에 의한 생산계획 및 통제를 가정하고 있는 본 연구와는 상이한 성과변수를 가정하고 있다. Han & McGinnis[13]는 선형계획법을 이용한 Discrete Time Control(DTC)모형을 개발하여 부품생산율(throughput rate)을 극대화하고자 하였다. DTC 모형은 매 통제기간 초에 시스템 내로 투입할 부품의 수를 결정하며, 매번 고정된 통제기간의 시작 시점에 반복적으로 적용된다. DTC 모형은 작업장내의 가동기계대수, 재공부품의 수 및 저장공간의 제약 하에서 부품생산량을 극대화시키는 작업장별 부품의 흐름율을 구하도록 고안되었다. 그러나 실제로 작업투입결정에 이용되는 것은 첫 번째 작업장에서의 부품 흐름율이며, 후속작업장에서의 부품흐름율을 선형계획법의 해로 구해진 흐름율과 일치시키기 어렵다는 문제가 있다. Deane & Moon[8] 역시 선형계획법을 이용하여 작업장별로 통제기간 동안의 이상적인 작업부하를 정하여 이 이상적인 작업부하에 보다 일치하도록 시스템 내로 투입할 부품의 수를 결정하는 Inventory Flow Management(IFM) 모형을 제시하였다. 작업장별 이상적인 작업부하는 통제기간에다 부품이 시스템 내로 투입되어 그 작업장에 도달하는 시간(lead time)을 더한 기간동안에 처리될 수 있는 최대의 작업부하를 의미한다. IFM 모형도

DTC와 유사하게 통제시점에서의 작업장 상태에 대한 스냅샷(snapshot)을 고려하여 최적의 투입 부품을 결정하고자 하였다. 그러나 통제기간동안 작업장에서의 부품 흐름율은 실제로 작업장에서 적용된 작업순서결정방법에 의하여 크게 영향을 받게 되는데, 이들 모형들은 이를 전혀 고려하지 못하고 있다.

본 연구에서 제시하는 인공신경망을 이용한 작업투입방법은 작업순서결정방법을 포함하는 실제 FFL 상황을 컴퓨터 시뮬레이션 모형으로 구축하고 이로부터 인공신경망의 학습에 필요한 훈련 데이터를 구하게 된다. 이러한 인공신경망 모형은 시스템의 동태적인 불확실성에 보다 잘 적응할 수 있을 뿐 아니라, 개별 시스템이 적용하는 작업순서결정방법 등과 같은 특정 FFL의 여러 측면들을 보다 잘 반영할 수 있을 것이다.

3. 인공신경망

인공신경망은 신경세포 수준에서 인간두뇌의 지적기능을 모방하고자 한 것으로 수많은 뉴런(신경세포)들이 서로 시냅스를 통하여 망의 구조를 이루면서 여러 가지 기능을 수행하게 된다. 인공신경망은 최근 들어 그 연구가 활발히 전개되어 다양한 형태의 모형이 개발되는 등, 그 응용도 확산되어 더 이상 새로운 기법으로 볼 수 없을 정도다.

인공신경망의 구조(architecture)는 뉴런(neuron)의 연결형태에 따라 feedforward network와 recurrent network으로 분류된다. 뉴런들이 단일방향으로 연결된 feedforward network은 일반적으로 input-output 표본 데이터를 이용하여 학습규칙에 따라 훈련시키는 대표적인 모형으로 사용되며, 변수가 많은 대규모 시스템이나, 분석적 지식이 거의 없는 복잡한 시스템에 주로 응용된다. 반면 뉴런 간에 feedback이 허용되는 recurrent network은 연상기억(associative memories)으로 정보를 저장하거나 최적해 문제(optimization problem)를 해결하는 데 주로 이용된다[31]. 본 연구는 최적의 스케줄

링 해를 구하는 것이 아니라, 전형적인 시스템상태에서 부분적, 국지적인 시뮬레이션을 실행하여 훈련 데이터를 구하고, 이를 이용하여 신경망을 학습시켜 시스템상태에 적합한 부품을 투입하고자 하므로 feedforward network이 보다 적절할 것이다. 본 연구에서는 대표적인 feedforward network으로서 입력층, 은닉층, 출력층의 3층 구조를 지닌 Perceptron을 이용하고, 신경망의 학습에는 가장 널리 알려진 역전파법을 사용하였다.

역전파법은 학습시켜야 할 모든 패턴들에 대하여 기대되는 출력과 실제 신경망이 산출해낸 출력과의 차이를 최소화하기 위한 가중치를 구한다. 이러한 과정은 크게 두 부분으로 나누어지는데, 먼저 입력층으로부터의 입력이 전이함수(일반적으로 시그모이드 함수)에 의해 출력층에 전달되면, 출력층에서는 실제 값과 계산된 출력치를 비교하여 오차를 구한다. 이 과정을 전향적 단계라 한다. 다음은 오차를 줄이기 위해 연결가중치를 조정하는 단계로서 출력층에서 바로 아래의 은닉층으로 오차를 역전파하고 은닉층에서는 연결된 상위층으로부터 오차를 추정한 후 다시 입력층으로 오차를 역전파시키는 후향적 단계이다.

인공신경망의 대표적인 적용분야로 패턴매칭(pattern matching)을 들 수 있다. 유연흐름라인의 작업통제문제도 패턴매칭의 관점으로 파악할 수 있다. 즉, 작업장의 현재 상태에서 주어진 성과변수를 최적화 시킬 수 있는 부품을 선정하는 것이다. 여기서 작업장의 현재상태가 입력벡터의 형태로 주어지고 여기에 상응하는 각 부품들의 선호도가 출력벡터가 된다. 작업장의 현재상태를 표시하는 입력변수로는 각 작업장들의 저장공간에 대기 중인 부품의 수, 이들의 총 가공시간 즉, 작업부하(workload), 그리고 현재 이용 가능한 기계의 대수 등의 변수가 포함된다. 그리고 출력층의 처리요소수는 전체 부품의 수와 일치하며, 출력벡터 값은 각 부품들의 특정시스템상태(입력벡터)에 상응하는 부품의 선호도를 반영하게 된다.

인공신경망을 이용한 유연흐름라인의 작업흐름

통제에서 가장 핵심적인 요소는 특정 작업장상태에서의 각 부품의 선호도를 나타내는 성과변수의 선정과 인공지능망을 학습시킬 훈련 데이터의 생성이다.

훈련 데이터의 생성을 위해 본 연구에서는 먼저 전형적인 시스템 상태를 선정하였다. 이러한 전형적 시스템상태는 앞서 언급한 입력변수들의 대표적인 수준 값들이 결합된 상태를 의미한다. 그리하여 이러한 전형적 시스템상태에서 각 부품이 선정되어 유연흐름라인 상에 투입되어 최종적으로 시스템을 빠져나갈 때까지의 기간동안을 시물레이션 하였으며, 이때의 기계활용율을 성과변수로 하였다. 모든 부품에 대하여 각 시스템상황에서의 기계활용율을 구하였고, 이 기계활용율의 순위를 토대로 하여 훈련 데이터의 출력벡터를 정하였다. 물론 각 부품에 대하여 동일한 작업장 상태에서 출발하도록 하였으며, 대상부품의 투입 이후에 투입되는 부품들은 무작위방법에 의해 결정되도록 하여 모든 부품에 동일하게 적용하였다.


이처럼 시스템 상태와 부품의 선호도를 대응시키는 함수관계는 매우 복잡하고 비선형적인 관계를 지닐 것이다. 일반적으로 인공지능망은 특히 이러한 비선형적이고 비모수적인 관계를 추출하는데 매우 효과적이라고 알려져 있다.

본 연구에 적용된 구체적인 신경망모형의 구조와 훈련 데이터의 생성에 관한 세부적인 내용은 5.절에 상세히 기술하였다.

4. 시물레이션 모형

본 연구에서 개발된 인공지능망모형의 학습에 필요한 훈련 데이터의 생성과 모형의 성과를 평가를 위해 컴퓨터 시물레이션이 이용되었다. 본 연구는 유연흐름라인의 작업흐름통제를 위해 인공지능망모형이 효과적으로 적용될 수 있는지 그 가능성을 검증하는데 초점을 두고 있다. 따라서 인공지능망 구축과 실험에 포함된 관련영향요인의 수를 최소화하도록 시물레이션에 이용된 FFL 모형은 [그

림 2]와 같이 단순한 형태를 가정하였다. 여기서 FFL은 두 개의 연속 작업장으로 구성되었으며, 각 작업장은 두 개의 동일한 기계로 이루어졌다. 물론 본 연구의 결과는 작업장의 수와 기계의 수가 많은 보다 복잡한 형태의 FFL모형에도 쉽게 확장하여 적용될 수 있을 것이다.



[그림 2] FFL 시물레이션 모형

작업장 1에서는 각 기계가 이용가능 할 때마다, 간여작업 집합에서 다음 처리할 작업을 선택하여 작업을 시작하게 된다. 또한 작업장 1의 산출저장공간은 작업장 2의 투입저장공간이다. 이때 최초 작업장의 투입저장공간과 마지막 작업장의 산출저장공간은 무한대로 가정한다. 이러한 가정은 실제 적용에는 별 문제가 없을 것이다. 왜냐하면 이들 저장공간에 제한이 있을 경우는 저장공간이 무한한 가상적인 작업장을 추가하면 될 것이기 때문이다. 두 개 작업장 사이에 있는 저장공간은 한정되었다고 가정하며 본 실험에서 5, 10, 15로 변화시켰다.

최종작업장인 작업장 2에서의 작업처리순서는 SPT 규칙을 적용하였다. 단일기계의 경우 SPT 규칙은 재공품 재고와 부품흐름시간을 최소화시키므로 [1], 본 연구에서와 같은 유연흐름라인에서도 최종작업장의 한정된 저장공간의 활용을 최대화할 수 있는 SPT 규칙이 적합한 작업처리규칙이 될 것이다. 따라서 본 연구에서의 다루는 유연흐름라인 상의 작업흐름통제는 작업장 1에서의 부품투입 결정에 국한된다.

본 연구에서 제시된 인공지능망 모형의 상대적

인 성과를 간략히 비교하기 위하여, 무작위에 의한 투입방법, 그리고 MPS에 의한 투입방법을 이용하였다. MPS에 의한 방법은 부품을 MPS 단위로 작업장내로 투입하되, MPS 내에서는 Johnson의 알고리즘을 적용하여 부품의 투입순서를 결정하였다.

FFL 작업흐름통제모형의 성과를 측정하는 데 사용된 생산계획문제는 무작위로 10개의 표본을 추출하였으며 이는 <표 1>과 같다. 처리되어야 할 부품의 수는 8개로 한정하였으며, 이들 8개 부품의 각 작업장에서의 가공시간은 1-20 사이의 정수 값을 취하도록, 그리고 소요량은 50-500 사이에서 50의 배수 값을 취하도록 일양분포를 이용하여 결정하였다. 부품의 소요량을 50개 단위로 한 것은 MPS의 적용을 용이하게 하기 위한 것이다.

<표 1> 단기 FFL 생산계획 표본문제

<Test problem 1>

부품 \ 작업장	1	2	3	4	5	6	7	8
1	11	4	4	13	1	5	18	15
2	13	10	7	13	2	20	7	20
소요량	250	250	450	100	200	500	200	50

<Test problem 2>

부품 \ 작업장	1	2	3	4	5	6	7	8
1	7	19	3	10	18	8	7	18
2	5	14	6	15	15	5	17	1
소요량	250	100	50	100	450	250	450	250

<Test problem 3>

부품 \ 작업장	1	2	3	4	5	6	7	8
1	3	20	4	10	14	10	14	16
2	19	19	18	14	2	9	12	12
소요량	250	450	50	100	50	450	500	250

<Test problem 4>

부품 \ 작업장	1	2	3	4	5	6	7	8
1	14	5	16	15	11	6	3	12
2	13	15	3	11	20	11	19	12
소요량	50	50	200	250	450	400	300	350

<Test problem 5>

부품 \ 작업장	1	2	3	4	5	6	7	8
1	19	17	10	11	16	19	11	10
2	14	17	6	11	13	5	14	16
소요량	500	300	50	150	100	300	150	350

<Test problem 6>

부품 \ 작업장	1	2	3	4	5	6	7	8
1	15	8	13	14	6	10	11	1
2	14	13	3	2	7	13	4	5
소요량	150	350	450	450	450	150	400	100

<Test problem 7>

부품 \ 작업장	1	2	3	4	5	6	7	8
1	13	3	20	4	2	13	9	3
2	9	9	8	8	7	10	19	6
소요량	50	50	450	400	400	300	450	100

<Test problem 8>

부품 \ 작업장	1	2	3	4	5	6	7	8
1	17	11	2	20	11	13	9	14
2	7	3	8	12	3	17	19	2
소요량	350	100	300	400	200	300	400	250

<Test problem 9>

부품 \ 작업장	1	2	3	4	5	6	7	8
1	5	19	6	7	10	5	16	17
2	4	9	11	3	18	12	5	2
소요량	100	350	350	50	500	100	200	300

<Test problem 10>

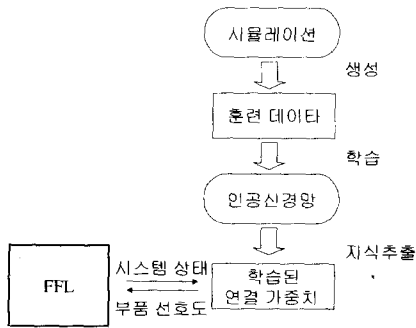
부품 \ 작업장	1	2	3	4	5	6	7	8
1	10	1	9	7	17	10	5	20
2	14	18	16	10	17	6	17	3
소요량	50	250	400	100	450	50	300	150

각 작업장별 기계고장특성은 두 개 작업장 모두 MTBF는 1000, 그리고 MTTR은 100으로 하여 지수분포를 따르는 것으로 가정하였다. 이 기계 고장

이 시뮬레이션에 포함된 유일한 확률요인이며, 이것에 대하여 10번의 반복실험(replication)이 시행되었다. 저장공간의 크기, 시험문제 및 작업흐름 통제기법이 결합된 각 실험조건에 대하여 동일한 난수초기 값(random number seed)을 적용하였다.

5. 인공신경망 작업투입모형

본 연구에서 제시된 인공신경망을 이용한 작업 투입모형의 개괄적 구조는 [그림 3]에서 보는 바와 같다. 먼저 컴퓨터 시뮬레이션을 이용하여 전형적 시스템 상태에서의 부품의 기계활용율에 관한 데이터를 수집한 후, 이를 토대로 훈련 데이터를 구하여 인공신경망을 학습시키게 된다. 학습된 인공신경망에서 얻어지는 연결 가중치는 훈련 데이터로부터 추출된 시스템에 관한 지식으로 볼 수 있으며, 이를 이용하여 FFL의 작업투입결정이 이루어지게 된다.



[그림 3] 인공신경망을 이용한 작업흐름통제모형


본 연구에 적용된 인공신경망은 [그림 4]와 같이, 입력층, 은닉층, 출력층의 3개의 계층으로 구성되었다. 먼저 입력층은 4개의 처리요소로 구성되었으며, 부품투입결정 당시의 작업장 2의 투입저장공간(본 모형에서의 유일한 저장공간이므로, 이후로 단순히 저장공간이라 함)에 존재하는 부품의 수와 작업부하량, 그리고 작업장 1과 2의 가동 기계대수를 나타낸다.

대표적 시스템 상황은 저장공간에 존재하는 부품의 수와 각 작업장의 가동 기계대수를 기준으로 하여 정하였다. 저장공간에 있는 부품의 수는 <표 2>와 같이 4가지 수준으로 하였다.

<표 2> 대표적 재공부품 수준 선정

저장공간능력	5	10	15
저장공간내 부품수	0, 1, 3, 5	0, 3, 6, 10	0, 5, 10, 15

그리고 각 작업장의 가동 기계대수는 1 과 2의 2 가지 경우를 고려하였다. 작업장에서 모든 기계가 동시에 고장이 발생하는 경우, 즉 가동 기계대수가 0인 경우는 제외하였다. 왜냐하면, 이때 그 작업장에서 스케줄링 결정이 이루어 질 수 없기 때문이다. 그리하여 주어진 test problem과 저장공간능력 별로 각 16개(4가지 재공부품 수준 × 2가지 작업장 1 가동 기계대수 × 2가지 작업장 2 가동 기계대수)씩 총 480개(10×3×16)의 훈련 데이터를 구하였다.



[그림 4] 인공신경망 구조

본 연구에서는 전형적 작업장 상태 선정을 위해 저장공간내의 작업부하량은 따로 고려하지 않고 단지 저장공간내의 부품을 무작위로 결정하여 작업부하량을 결정하였다. 물론 작업부하량까지를 고려하고 또한 저장공간의 부품 수에 대하여도 보다 많은 경우를 고려하여 훈련 데이터 수를 더욱 늘일 수 있을 것이다. 그러나 지나치게 세분하여 많은

시스템상황을 고려할 경우 인공지능망 학습에 보다 많은 시간이 소요될 것이므로, 부품의 선호도에 상당한 변화를 줄 수 있을만한 작업장 상황을 포함시키는 것으로 충분할 것이다.

입력변수의 값들은 변수의 절대적 크기에 따른 편(bias)을 최소화하도록, 0과 1 사이의 값을 취하도록 정규화하고 다시 시그모이드 함수로 변환하였다.

출력변수의 값은 특정 작업장상태에서 부품을 투입했을 때, 그 부품이 시스템에 투입될 때부터 나갈 때까지의 시간, 즉 부품의 흐름시간동안의 전체 평균 기계활용율을 구한 다음, 부품간에 이들 활용율의 순위를 결정하고, 다시 이들 순위에 따라 0과 1 사이의 등간격 점수를 배정하였다. 이처럼 기계활용율을 직접 이용하지 않고 순위를 사용한 이유는 부품의 선호도를 보다 차별화시키고자 한 것이며, 실제로 부품투입결정에서는 특정부품을 선정하는나, 선정하지 않느냐 하는 이산적 성격을 지니고 있으므로, 기계활용율과 같은 연속변수보다는 순위가 보다 적합한 것으로 판단된다. 기계활용율을 계산하게 되는 시간, 즉 각 부품의 흐름시간은 고정적인 것이 아니라 그 부품의 가공시간과 작업

장에서의 작업처리순서규칙에 따라 달라진다.

부품 저장공간 능력을 5로 한 test problem 1에 대한 원래의 훈련 데이터와 변환된 훈련 데이터가 각각 <표 3>과 <표 4>에 나타나 있다.

<표 3>의 훈련 데이터를 보면, 저장공간에 대기 부품이 전혀 없는 경우(패턴 1)에는 작업장 2에서의 가공시간이 작업장 1에서의 가공시간보다 상대적으로 큰 부품 6, 2, 5의 순으로 선호하게 되고, 대기부품이 저장공간에 꽉 찬 경우(패턴4)는 반대로 부품1, 4, 7을 선호하게 된다. 여기서 패턴 4의 경우 작업장 2에서의 가공시간이 상대적으로 크거나 같은 부품 1, 4가 부품 7과 동일한 1.0의 활용율을 달성한 이유는 현재 저장공간에 대기중인 일부 작업들의 작업장 2에서의 가공시간이 짧아서 곧바로 저장공간에 여유가 생기게 되어 이들 부품이 blocking현상을 유발시키지 않았음을 의미한다. 그러나 저장공간에 대기중인 작업의 수가 많고, 또한 작업부하량이 매우 큰 경우에는 부품 1과 4가 blocking을 야기시킬 가능성이 높아지고, 따라서 활용율도 떨어지게 될 것이다. 이처럼 작업부하량을 동시에 고려하여 보다 많은 작업장상태를 고려할 경우 더욱 세밀한 학습이 이루어질 수 있게 될

<표 3> 원래의 훈련 데이터 예 : test problem 1, 저장공간능력 = 5

훈련 데이터	입력 변수*				출 력 변 수							
	(1)	(2)	(3)	(4)	부품 1	부품 2	부품 3	부품 4	부품 5	부품 6	부품 7	부품 8
패턴 1	0	0	2	2	0.85	0.92	0.88	0.83	0.90	0.95	0.70	0.87
패턴 2	30	1	2	2	1.00	1.00	1.00	0.99	1.00	0.98	0.84	0.98
패턴 3	45	3	2	2	1.00	0.94	0.96	1.00	0.88	0.92	0.98	0.97
패턴 4	72	5	2	2	1.00	0.87	0.87	1.00	0.66	0.88	1.00	0.95
패턴 5	0	0	2	1	0.69	0.72	0.71	0.69	0.71	0.53	0.67	0.55
패턴 6	23	1	2	1	0.64	0.60	0.75	0.66	0.75	0.51	0.75	0.54
패턴 7	43	3	2	1	0.57	0.50	0.57	0.59	0.61	0.48	0.72	0.52
패턴 8	65	5	2	1	0.51	0.46	0.45	0.53	0.40	0.44	0.66	0.48
패턴 9	0	0	1	2	0.46	0.56	0.53	0.44	0.55	0.67	0.34	0.51
패턴 10	30	1	1	2	0.63	0.73	0.72	0.58	0.75	0.73	0.46	0.60
패턴 11	45	3	1	2	0.72	0.75	0.75	0.66	0.64	0.75	0.52	0.69
패턴 12	72	5	1	2	0.75	0.71	0.70	0.74	0.59	0.73	0.64	0.74
패턴 13	0	0	1	1	0.45	0.47	0.46	0.44	0.46	0.49	0.34	0.45
패턴 14	23	1	1	1	0.50	0.50	0.50	0.50	0.50	0.48	0.43	0.50
패턴 15	43	3	1	1	0.50	0.48	0.49	0.50	0.37	0.45	0.50	0.49
패턴 16	65	5	1	1	0.46	0.39	0.41	0.48	0.33	0.44	0.50	0.46

주) * 입력변수 : (1) 작업부하 (2) 재공부품 수 (3) 작업장 1 가동기계대수 (4) 작업장 2 가동기계대수

〈표 4〉 변환된 훈련데이터 예 : test problem 1, 저장공간능력 = 5

훈련 데이터	입력 변수*				출 력 변 수							
	(1)	(2)	(3)	(4)	부품 1	부품 2	부품 3	부품 4	부품 5	부품 6	부품 7	부품 8
패턴 1	0.50	0.50	0.73	0.73	0.28	0.86	0.57	0.14	0.72	1.00	0.00	0.42
패턴 2	0.54	0.52	0.73	0.73	1.00	1.00	1.00	0.42	1.00	0.28	0.00	0.28
패턴 3	0.56	0.55	0.73	0.73	1.00	0.28	0.42	1.00	0.00	0.14	0.72	0.57
패턴 4	0.59	0.58	0.73	0.73	1.00	0.28	0.28	1.00	0.00	0.42	1.00	0.57
패턴 5	0.50	0.50	0.73	0.62	0.57	1.00	0.86	0.57	0.86	0.00	0.28	0.14
패턴 6	0.53	0.52	0.73	0.62	0.42	0.28	1.00	0.57	1.00	0.00	1.00	0.14
패턴 7	0.55	0.55	0.73	0.62	0.57	0.14	0.57	0.72	0.86	0.00	1.00	0.28
패턴 8	0.58	0.58	0.73	0.62	0.72	0.42	0.28	0.86	0.00	0.14	1.00	0.57
패턴 9	0.50	0.50	0.62	0.73	0.28	0.86	0.57	0.14	0.72	1.00	0.00	0.42
패턴 10	0.54	0.52	0.62	0.73	0.42	0.86	0.57	0.14	1.00	0.86	0.00	0.28
패턴 11	0.56	0.55	0.62	0.73	0.57	1.00	1.00	0.28	0.14	1.00	0.00	0.42
패턴 12	0.57	0.58	0.62	0.73	1.00	0.42	0.28	0.86	0.00	0.57	0.14	0.86
패턴 13	0.50	0.50	0.62	0.62	0.42	0.86	0.72	0.14	0.72	1.00	0.00	0.42
패턴 14	0.53	0.52	0.62	0.62	1.00	1.00	1.00	1.00	1.00	0.14	0.00	1.00
패턴 15	0.55	0.55	0.62	0.62	1.00	0.28	0.57	1.00	0.00	0.14	1.00	0.57
패턴 16	0.58	0.58	0.62	0.62	0.72	0.14	0.28	0.86	0.00	0.42	1.00	0.72

주) * 입력변수 : (1) 작업부하 (2) 재공부품 수 (3) 작업장 1 가동기계대수 (4) 작업장 2 가동기계대수

것이다.


신경망 모형의 적용에 있어 은닉층의 수와 은닉층 최적 처리요소수의 결정에 대하여는 절대적인 기준은 없다. 본 연구에서는 은닉층을 하나로 고정하고 예비실험에서 은닉층 처리요소 수는 2에서 15까지로 변화시켜보고 그 결과를 바탕으로 최종적으로 은닉층 처리요소 수를 결정하였다.

리요소수가 8 이하인 경우는 그 성과가 다소 변동적인 경향을 보이는 것 같다. 그리고 처리요소 수가 9 이상에서는 다소 안정적인 성과를 보이는 듯하다.

6. 실험결과

6.1 은닉층 처리요소 수

은닉층 처리요소수의 효과를 알아보기 위하여, test problem 1에 대하여 사전 예비실험을 하였다. 처리요소 수를 2에서 15까지 14가지의 경우로 변화시켰으며, 이들 처리요소 수를 3개의 저장공간능력과 기계고장에 대한 10번의 반복실험에 적용하여 총 420회(14×3×10)의 시뮬레이션을 실행하였다. 그 실험결과는 [그림 5]에 요약되었다. [그림 5]에는 참고로 무작위 및 MPS 투입방법의 성과가 함께 표시되어 있다. 한 번의 실험으로 은닉층 처리요소 수의 효과를 단정키는 어려우나, 대체로 처



[그림 5] 은닉층 처리요소 수 효과

그리고 처리요소 수에 상관없이 항상 인공신경망이 무작위나 MPS 방법보다 높은 성과를 나타내고 있다. 그리고 은닉층 처리요소 수가 최소인 2개의 경우에 상당히 높은 성과를 보여주고 있다. 본 연구에서는 은닉층 처리요소 수를 다음과 같은 2가지 이유에서 2개로 정하였다. 첫째는 비슷한 성과라던가 급적 처리요소 수를 줄이는 것이 계산상 효율적이라는 점이다. 그리고 둘째는 시스템의 상

태와 부품을 대응시킬 경우 본 연구처럼 매우 단순한 FFL구조에서 부품의 특성은 오로지 작업장 1과 2의 저장공간에 의하여 결정되므로, 그 대응관계가 그렇게 복잡하지는 않을 것이라 생각되기 때문이다.

6.2. 투입모형의 비교

인공신경망에 의한 작업투입방법의 성과를 무작위에 의한 투입방법, 그리고 MPS에 의한 투입방법과 비교하였다. 본 연구의 시뮬레이션 실험은 3가지 투입모형, 3가지 수준의 저장공간 능력, 10개의 test problem과 10회의 기계고장에 대한 반복을 포함하여, 총 900회(3×3×10×10)가 수행되었다. 그리고 주요 성과 변수는 평균 기계활용율로 하였으며, 부차적으로 평균 재공부품의 수를 비교하였다. 한정된 저장공간의 가정에서 재공부품 재고 수준은 크게 문제가 되지 않을 것이나, 동일한 기계활용율이라면, 가급적 낮은 재공부품 재고를 요구하는 모형이 보다 선호될 것이다.


기계활용율을 종속변수로 하고 부품투입모형과 저장공간능력을 독립변수로 한 ANOVA 분석 결과는 <표 5>에 제시되었다. 부품투입모형과 저장공간능력간의 상호작용 효과는 통계적 유의성이 없는 것으로, 그리고 투입방법과 저장공간능력의 효과는 모두 유의한 것으로 나타났다.

<표 5> 기계활용율에 대한 ANOVA 분석결과

	제곱합	자유도	평균제곱	F	유의확률
주효과	.496	4	.124	50.420	.000
(결합)	.410	2	.205	83.363	.000
투입모형	.086	2	.043	17.477	.000
2원배치 저장공간	.013	4	.0032	1.283	.275
상호작용					
모형 투입모형*	.509	8	.0636	25.852	.000
저장공간	2.191	891	.0025		
잔차	2.699	899	.003		
전체					

저장공간 저장공간별 FFL투입모형의 구체적인 평균 기계활용율 성과는 [그림 6]에 나타나 있다. MPS방법이 무작위방법 보다 높은 성과를 나타내

었으며, 본 연구에서 제시된 인공신경망 모형이 이들 두 방법보다 월등히 높은 성과를 나타내었다. 실제로 인공신경망모형이 이들 두 방법 보다 열등한 경우는 전체 실험에서 한 번도 발견되지 않았다. 3가지 방법 모두가 저장공간의 능력이 증가할 수록 높은 성과를 나타내었다.



[그림 6] 투입모형의 기계활용율 성과


평균 재공부품 수를 종속변수로 한 ANOVA 분석 결과는 <표 6>에 제시되었다. 투입모형과 저장공간능력간의 상호작용효과는 유의확률이 0.043으로 다소 통계적 유의성이 있는 것으로, 그리고 투입모형과 저장공간에 의한 주 효과는 모두 높은 통계적 유의성을 보였다.

<표 6> 재공부품 수에 대한 ANOVA 분석결과

	제곱합	자유도	평균제곱	F	유의확률
주효과	3074.127	4	768.532	90.467	.000
(결합)	269.590	2	134.795	15.867	.000
투입모형	2804.538	2	1402.269	165.067	.000
2원배치 저장공간	84.144	4	21.036	2.476	.043
상호작용					
모형 투입모형*	3185.271	8	394.784	46.472	.000
저장공간	7569.190	891	8.495		
잔차	10727.461	899	11.933		
전체					

[그림 7]은 FFL투입모형의 저장공간별 평균 재공품 성과를 보여주고 있다. 여기서 MPS방법은 무작위 방법보다 다소 높은 평균 재공품 수준을 나타내었다. 그리고 인공신경망 모형은 이들 두 방법들 보다 현저히 낮은 평균 재공품 수준을 보였다. 그리고 이러한 차이는 저장공간의 능력이 증가할

수록 더욱 뚜렷이 나타남을 알 수 있는데, 이는 투입모형과 저장공간능력간에 상호작용효과가 있음을 말해주고 있다.



[그림 7] 투입모형의 재고수준 성과

결론적으로 본 실험결과와는 MPS나 무작위에 의한 FFL 작업투입방법은 시스템의 동태적인 상태 변화에 잘 적응하지 못하는 반면, 본 연구가 제시하는 인공신경망 모형은 주어진 저장공간의 능력을 최대한 활용하여, 기계의 blocking이나 starvation 현상을 최소화하도록 시스템의 상태변화에 잘 적응함을 보여주고 있다.

7. 결론과 향후 연구과제

본 연구는 유연생산시스템의 한 형태인 유연흐름라인의 효율적인 작업흐름통제를 위해 전통적인 컴퓨터 시뮬레이션 기법과 지능적 기법에 속하는 인공신경망 기법을 결합한 일종의 혼합지능모형을 구축하고 그 성과를 평가하였다.

본 연구에서 제시된 FFL 작업흐름통제모형의 성과를 무작위 및 MPS에 의한 작업투입방법과 비교한 실험에서, 본 연구가 제시하는 모형이 기계활용율과 재공품 재고 수준 면에서 이들 두 방법보다 현격히 높은 성과를 보였다. 이는 본 연구에서 제시하는 모형이 기계고장과 같은 시스템의 불확실성에 동태적으로 적응할 수 있다는 것을 의미한다. 뿐만 아니라 본 연구의 FFL 작업흐름통제 모형은 실제시스템의 시뮬레이션으로부터 훈련 데이터를

생성하므로 한정된 저장공간이나 사용된 작업순서 결정 규칙 등과 같은 개별 시스템이 지니는 특성적인 측면을 보다 쉽게 반영할 수 있다는 이점을 지니고 있다.

본 연구는 인공신경망을 이용한 FFL의 작업흐름통제 모형의 구축방법과 그 가능성을 보여주는 데 그 일차적 목적을 두고 있어 가장 단순한 FFL 구조를 그 연구 대상으로 하였다. 앞으로 본 연구에서 제시된 방법을 보다 많은 수의 작업장과 기계를 포함하는 복잡한 형태의 FFL에 확대하여 적용하여야 할 것이다. 이럴 경우, 인공신경망의 구조를 결정한다든지, 훈련 데이터를 생성하는 문제들이 다소 복잡해 질 수 있겠으나, 극복하지 못할 문제는 아니라고 본다. 특히 최적의 은닉층 처리요소수를 결정하기 위한 추가적인 연구가 필요할 것이다. 또한 시뮬레이션으로부터 가상적인 훈련 데이터를 구할 뿐 아니라, 실제 시스템에서 구해지는 데이터로 인공신경망을 학습시키는 문제도 충분히 고려해 볼 가치가 있을 것이다.

참 고 문 헌

- [1] Baker, K.R., *Introduction to Sequencing and Scheduling*, John Wiley & Sons, New York, 1974, p.18.
- [2] Brah, S.A., "A Comparative Analysis of Due Date Based Job Sequencing Rules in a Flow Shop with Multiple Processors," *Production Planning & Control*, Vol.7, No.4(1996), pp. 362-373.
- [3] Brown, D.E., W.T. Scherer, *Intelligent Scheduling Systems*, Kluwer Academic Publishers, Boston, 1995.
- [4] Campbell, H.G., R.A. Dudek, and N.L. Smith, "A Heuristic Algorithm for the n Job, m Machine Sequencing problem," *Management Science*, Vol.16(1970), pp.630-637.
- [5] Chen, C., V.S. Vempati, and N. Aljaber, "An

- Application of Genetic Algorithms for Flow Shop Problems," *European Journal of Operational research*, Vol.80(1995), pp.389-396.
- [6] Conway, R.W., W.L. Maxwell, and L.W. Miller, *Theory of Scheduling*, Addison-lesley, Massachusetts, 1967.
- [7] Dannenbring, D.G., "An Evaluation of Flow Shop Sequencing Heuristics," *Management Science*, Vol.23(1977), pp.1174-1182.
- [8] Deane, R.H., and S.H. Moon, "Work Flow Control in the Flexible Flow Line", *International Journal of FMS*, Vol.4, No.3/4 1992), pp.217-235.
- [9] Gangadharan R. and C. Rajendran, "A Simulated Annealing Heuristics for Scheduling in a Flowshop with Bicriteria," *Computers & Industrial Engineering.*, Vol.27, Nos.1-4.(1994), pp.473-476.
- [10] Gershwin S.B., R. Akella, and Y.F. Choong, "Short-term Production Scheduling of an Automated Manufacturing Facility," *IBM Journal of Research and Development*, Vol.29, No.4(1985), pp.392-400.
- [11] Gupta, J.N.D., "Two-stage, Hybrid Flowshop Scheduling Problem," *Journal of the Operations Research Society*, Vol.39(1988), pp. 359-364
- [12] Gupta, J., and W.P. Darrow, "The Two-machine Sequence Dependent Flowshop Scheduling Problem," *European Journal of Operational Research*, Vol.24(1986), pp.439-446.
- [13] Han M.H., and L.F. McGinnis, "Throughput Rate Maximization in Flexible Manufacturing Cells," *IIE Transactions*, Vol.20, No.4 1988), pp.409-417.
- [14] Hecht-Nielsen R., *Neurocomputing*, Addison-lesley, Massachusetts, 1990.
- [15] Hitz, K.L., "Scheduling of Flexible Flow Shops-II," *Technical Report LIDS-R-1049*, Laboratory for Information and Decision Systems, Massachusetts Institute of Technology, Cambridge, MA, 1980.
- [16] Ishibuchi H., N. Yamamoto, T. Murata, and H. Tanaka, "Genetic Algorithms and Neighborhood Search Algorithms for Fuzzy Flow Shop Scheduling Problems," *Fuzzy Sets and Systems*, Vol.67(1994), pp.81-100.
- [17] Johnson, S.M., "Optimal Two-and Three-tage Production Schedules with Setup Times Included," *Naval Research Logistics Quarterly*, Vol.1, No.1(March 1954)
- [18] Leu, B.Y., "Simulation Analysis of Scheduling Heuristics in a Flow-Line Manufacturing Cell with Two Types of Order Shipment Environments," *Simulation*, Vol.66, No.2(1996), pp.106-116.
- [19] Lin L., and J.K. Cochran, "Optimization of a Complex Flow Line for Printed Circuit Board Fabrication by Computer Simulation," *Journal of Manufacturing Systems*, Vol.6, No.1(1987), pp.47-57.
- [20] Kochhar, S. and R. Morris, "Heuristic Methods for Flexible Flow Line Scheduling," *Journal of Manufacturing Systems*, Vol.6, No.4(1987), pp.299-314.
- [21] McClelland, J.L. and Rumelhart, D.E., *Explorations in Parallel Distributed Processing*, MA : MIT Press, 1988.
- [22] Murata, T., H. Ishibuchi, and H. Tanaka, "Genetic Algorithms for Flowshop Scheduling Problems," *Computers & Industrial Engineering.*, Vol.30, No.4(1996), pp.1061-1071.
- [23] Palmer, D.S., "Sequencing Jobs through a Multi-stage Process in the Minimum Total

- Time-a Quick Method of Obtaining a Near Optimum," *Operations Research Quarterly* Vol.16(1965), pp.101-107.
- [24] Parker, R.G., *Deterministic Scheduling Theory*, Chapman & Hall, London, 1995.
- [25] Peng, T.M, L.F. Hubele and G.G. Karady, "An Adaptive Neural Network Approach to One-Week Ahead Load Forecasting," *IEEE Transactions on Power Systems*, Vol.8, No.3(1993), pp.1195-1203.
- [26] Philipoom, P.R., L.P. Rees and L. Wiegmann, "Using Neural Networks to Determine Internally-Set Due-Date Assignments for Shop Scheduling," *Decision Sciences*, Vol. 25, No.5/6(1994), pp.825-851.
- [27] Reeves, C.R., "Genetic Algorithm for Flow-shop Sequencing," *Computers & Operations Research*, Vo.22, No.1(1994), pp.5-13.
- [28] Sawik, T.J., "Scheduling Flexible Flow Lines with No In-Process Buffers," *International Journal of Production Research*, Vol.33, No.5(1995), pp.1357-1367.
- [29] Toure, S., L. Rabelo, and T. Velasco, "Artificial Neural Networks for Flexible Manufacturing Systems Scheduling," *Computers and Industrial Engineering*, Vol.25, Nos.1-4(1993), pp.385-388.
- [30] Santos, D.L., J.L. Hunsucher, and D.E. Deal, "An Evaluation of Sequencing Heuristics in Flow Shops with Multiple Processors," *Computers & Industrial Engineering*, Vol.30, No.4(1996), pp.681-692.
- [31] Wang, J., "Recurrent Neural Networks for Optimization," in *Fuzzy Logic and Neural Network Handbook*, edited by Chen, C.H., McGraw-Hill, New York, 1996, p.4.
- [32] Wittrock, R., "Scheduling Algorithms for Flexible Flow Lines," *IBM Journal of Research and Development*, Vol.29, No.4(1985), pp.401-412.