

신경망과 다속성 의사결정 기법을 이용한 일정관리 휴리스틱의 선택

황인수* · 한재민**

Selection of Scheduling Heuristics Using Neural Network and MCDM

Insoo Hwang* · Jaemin Han**

ABSTRACT

This paper presents an approach for classifying scheduling problems and selecting a heuristic rule to yield best solution in terms of certain performance measure(s). Classification parameters are employed from previous studies on job shop scheduling and project scheduling. Neural network is used for learning and estimating the performances of heuristic rules. In addition, multi-criteria decision making techniques are employed to combine the preferences for each performance measure and heuristic rule for the problems with multi-objectives.

1. 서 론

일정관리란 주어진 목표를 달성하기 위해 자원을 할당하는 일련의 과정(Baker, 1974), 또는 필요한 작업들을 할당하며 자원을 통제하는 일련의 의사결정과정(Han, 1991)으로 정의할 수 있으며, Job Shop, 유연생산시스템(flexible manufacturing systems), 로봇(robot), 인적자원관리 등 여러 가지 문제영역에 적용되어 왔다. 일정관리 문

제를 보다 효과적으로 해결하기 위해서 정수계획법, 동적계획법, Branch and Bound, PERT/CPM 기법, 그리고 여러 가지의 휴리스틱 기법 등 많은 접근법이 적용되어 왔으나, 휴리스틱 기법을 제외한 대부분의 접근법들은 현실의 문제를 풀기에는 부적절한 것으로 나타났다. 이는 현실적으로 존재하는 대부분의 일정관리 문제가 NP-complete, 즉 문제의 크기가 증가함에 따라 탐색해야 하는 탐색공간이 지수적으로 증가하는 특성

* 고려대학교 기업경영연구소 연구원

** 고려대학교 경영학과 부교수

을 갖고 있기 때문이다(Garey and Johnson, 1979). 이에 따라, 최적해를 찾기 위해 사용되는 분석적인 기법이나 알고리즘은 점점 더 복잡해지는 현실 세계의 문제에는 더 이상 적용하기가 어렵다는 결론에 도달하고 있다.

Davis와 Patterson(1975)은 여러 가지의 휴리스틱을 분석한 결과, 문제의 성격에 따라서 특정 휴리스틱이 보다 효과적일 수는 있으나, 이들 대부분도 현실적인 문제를 풀기에는 부적절하다는 결론을 내린 바 있다. 이는 일정관리 문제의 특성이나 환경에 관계없이 특정 휴리스틱이 항상 좋은 결과를 가져오기보다는, 일정관리 문제의 특성이나 환경에 따라서 각 휴리스틱의 성과가 다르게 나타난다는 점에도 기인하고 있다. 즉, 모든 스케줄링 문제에 대해서 항상 최적해를 산출해 내는 휴리스틱 규칙은 존재하지 않으며, 일정관리의 수행을 위해 사용되는 자원의 종류와 수량, 성과척도, 그리고 납기의 적절성 등과 같은 일정관리 문제의 특성에 따라 각 휴리스틱의 성과는 달라진다는 것이다(Panwalker and Iskander, 1977; Dar-El and Wysk, 1982; Blackstone *et al.*, 1982; Philipoom and Fry, 1990).

일정관리 문제를 몇 개의 특성에 따라 분류하여 서로 다른 휴리스틱을 적용하는 연구는 주로 Job Shop 일정관리를 대상으로 이루어지고 있는데, 이는 다른 종류의 일정관리 문제에 비하여 비교적 쉽게 문제의 특성을 찾아낼 수 있으며 현실적인 문제의 상당수가 Job Shop 형태로 표현될 수 있기 때문으로 판단된다. Pira-muthu(1993)는 Job Shop 문제의 특성을 결정하는 요인으로 기계의 수, 버퍼의 크기, 최대 기계 부하량, 기계부하량의 변동성, 평균 대체기계의 수, 총 기계의 수에 대한 평균 대체기계의 수, 기계의 동질성, 납기의 적절성 등 여덟 가지를 이용하였으며, 이를 귀납적 학습(inductive learning) 방법을 이용

하는 ID3 프로그램에 적용하여 의사결정나무(decision tree)를 구성하였다. Cho와 Wysk(1993)는 동적인 Job Shop 환경에서 일정관리 문제를 분류하는 요인으로 작업경로의 복잡도, 성과척도, 공정시간에 대한 이동시간의 비율, 시스템 혼잡도(system congestion), 자원의 이용률, 작업의 지연계수, 그리고 대기 중인 작업의 상태계수 등 일곱 가지 요인을 이용하였으며 이를 신경망의 입력 벡터로 사용하였다. 이재식(1994)은 스케줄링이 진행되는 동안 동태적으로 휴리스틱 규칙을 선택하여 적용하는 휴리스틱을 개발하였다. 그러나 가장 일반화된 형태의 일정관리 문제인 프로젝트를 분류할 수 있는 특성을 찾아내기 위한 연구는 Patterson(1976)의 연구를 제외하면 거의 전무한 상태이다. Patterson은 많은 예제를 이용하여 시뮬레이션을 실시한 뒤 이를 통계처리하여 유의한 차이를 보여주는 요인으로써 세 가지 그룹의 약 20여 개를 제시하였다.

이와 같은 연구의 대부분은 예제에 대해 각 휴리스틱으로 일정을 작성하여 문제의 특성과 성과척도별로 성과를 종합한 후, 결과를 ID3나 신경망에 적용하여 학습시키는 방법을 사용하고 있다. 이에 따라, 새로운 문제에 대해서는 학습된 결과를 적용하기만 하면 주어진 상황에 가장 적합할 것으로 예상되는 휴리스틱을 곧바로 찾을 수 있게 된다. 그러나 이들 연구는 하나의 성과척도를 갖는 일정관리 문제를 가정하고 있으므로, 여러 가지의 성과척도를 갖는 문제에 있어서는 적절한 해를 제공하지 못한다는 한계점을 갖고 있다. 따라서, 본 연구에서는 가장 일반화된 형태인 프로젝트 일정관리의 특성요인을 통계적인 기법으로 찾아내었던 Patterson(1976)의 연구결과를 중심으로 특성요인을 구성하고 문제의 분류에 매우 좋은 성과를 보여주는 것으로 평가받고 있는 신경망을 적용하는 방법을 제시한다. 일정관리 문제의 특성

에 따라서 가장 좋은 해를 제공할 것으로 예상되는 휴리스틱 규칙을 선택해 주는 일련의 과정을 기술함으로 향후의 이러한 연구에 대한 개념적인 모델을 제시하고자 한다. 아울러, 여러 가지의 성과척도를 갖는 문제에 있어서 각각의 성과척도에 대한 선호도를 고려하여 휴리스틱별 최종 선호도를 산출할 수 있도록 다속성 의사결정(Multi-Criteria Decision Making, MCDM) 기법을 이용하여 휴리스틱을 선택하는 방법에 대해서도 소개한다.

본 논문의 구성은 다음과 같다. 먼저, 2장에서는 일정관리 문제의 분류에 사용될 신경망에 대해 간략히 살펴보고, 3장에서는 학습을 위한 신경망의 구성에 대해 기술한다. 4장에서는 이와 같은 구성 하에서 학습이 이루어지는 과정에 대해 설명하며, 5장에서는 학습이 이루어진 이후에 여러 가지의 성과척도를 갖는 문제에 있어서 MCDM을 적용하여 가장 적합할 것으로 예상되는 휴리스틱을 선택하는 방법에 대해 기술한다. 끝으로, 6장에서는 본 연구의 결과와 향후의 연구방향에 대해 기술한다.

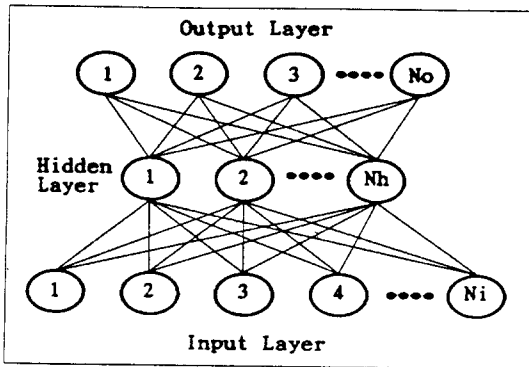
2. 일정관리 문제의 분류를 위한 신경망의 활용

통계학에서는 군집분석(cluster analysis) 등의 방법을 이용하여 고유한 특성을 갖는 개체 혹은 문제를 분류하고 있다. 그러나, 근래에는 기계학습(machine learning)분야에 대한 광범위한 연구 결과에 힘입어, 의사결정나무를 구성하는 ID3나 뉴론들 간의 연결강도를 조절하여 학습을 하는 신경망이 현실 문제에 많이 적용되고 있다. 이재석(1994)은 휴리스틱 규칙을 통태적으로 선택하기 위한 휴리스틱을 제시하였는데 이의 한계점을 지적하면서 향후의 연구방향으로 지식기반 혹은 신경망기반의 시스템에 대한 연구를 제안하였다.

또한, 기존의 많은 연구 결과도 신경망이 예제를 이용하여 학습을 하기 때문에 변화하는 환경에 상당한 적응력을 갖는다는 결론을 내리고 있다(Cho and Wysk, 1993; Caudill, 1988; Kohonen, 1988; Rumelhart *et al.*, 1988). 따라서, 본 연구에서도 학습을 위한 도구로써 신경망을 이용하고 있는데, 신경망을 이용하여 일정관리 문제를 분류하고자 하는 이유를 몇 가지로 구분하여 살펴보면 다음과 같다.

- ① 신경망은 일부의 입력데이터가 부적합하거나 불완전한 경우에도 비교적 안정적으로 해를 제공한다. 즉, 어떤 속성에 대한 데이터가 누락되거나 혹은 잘못된 데이터가 입력되는 경우에도 이를 일반화하여 근사적인 답을 제공한다.
- ② 예제를 이용하여 신경망을 학습시키기 위해서는 비교적 많은 시간이 필요하지만, 학습이 끝나면 새로운 문제에 대해서는 매우 빠른 속도로 답을 제시하기 때문에 환경이 바뀔 때마다 일정을 다시 작성해야 하는 현실의 문제에 매우 적합하다. 아울러, 현장의 일정관리 문제를 또 다른 예제로 사용할 수 있기 때문에 주어진 일정관리 환경에 보다 잘 적응한다.
- ③ 신경망의 입력층에 문제의 특성뿐만 아니라 일정관리에서 적용할 성과척도에 대한 값을 함께 입력하여 학습시키면, 의사결정자가 선택하는 성과척도에 따라서 그에 적합한 휴리스틱을 즉시 제공한다.
- ④ 풀고자 하는 일정관리 문제의 크기가 커질수록 학습에는 많은 시간이 소요되지만, 학습이 끝나면 문제의 크기에 관계없이 학습된 결과인 가중치만을 지식으로 갖고 있기 때문에 현실적으로 존재하는 매우 큰 문제에 대해서도 쉽게 적용될 수 있다.

신경망은 <그림 1>에서 보는 바와 같이, 노드의 형태로 표현된 뉴론(neuron)이라 불리는 간단한 처리요소들로 이루어진 하나의 네트워크로, 이들 뉴론은 몇 개의 층을 구성한다. 신경망은 뉴론들을 연결하는 물리적인 구조, 입력 및 출력을 변환하기 위한 활성화 함수(activation function), 그리고 학습 알고리즘(learning algorithm) 등으로 구성된다. 네트워크 상의 각 층에 위치한 뉴론들은 인접한 뉴론이나 상하위에 있는 다른 뉴론들과 연결되는데, 각각의 연결강도는 수치형태의 가중치로 학습 알고리즘에 의해 일정한 값으로 수렴해 가게 된다. 여기에서, 신경망이 학습을 한다는 말은 뉴론들간을 연결하는 연결강도가 주어진 예제의 입력에 대해서 바람직한 출력을 제공할 수 있도록 수치형태의 연결강도를 자동적으로 조정해 감을 의미한다.



<그림 1> 신경망의 구조

<그림 1>은 가장 많은 문제영역에 적용되고 있는 역전파(backpropagation) 신경망의 구조를 보여주고 있는데, 이는 입력의 값에 대한 바람직한 출력값을 함께 지정함으로써 학습이 가능하도록 하는 대표적인 신경망이다(Rumelhart *et al.*, 1988). 신경망의 구조에 있어서 입력층과 출력층의 뉴론의 개수는 주어진 문제 영역에서 입력 및

출력되는 데이터의 수에 따라 사전에 결정된다. 그러나, 은닉층의 개수와 각 은닉층에 속하는 뉴론의 개수는 문제의 특성에 따라 달라지므로 경험적인 방법에 의해 결정되어야 한다. 또한, 학습의 속도를 결정하게 되는 학습율도 경험적으로 결정되는데, 학습율을 높이면 매우 빠르게 학습을 한다는 장점이 있으나 국부적인 해에 빠질 수 있다는 단점이 있다.

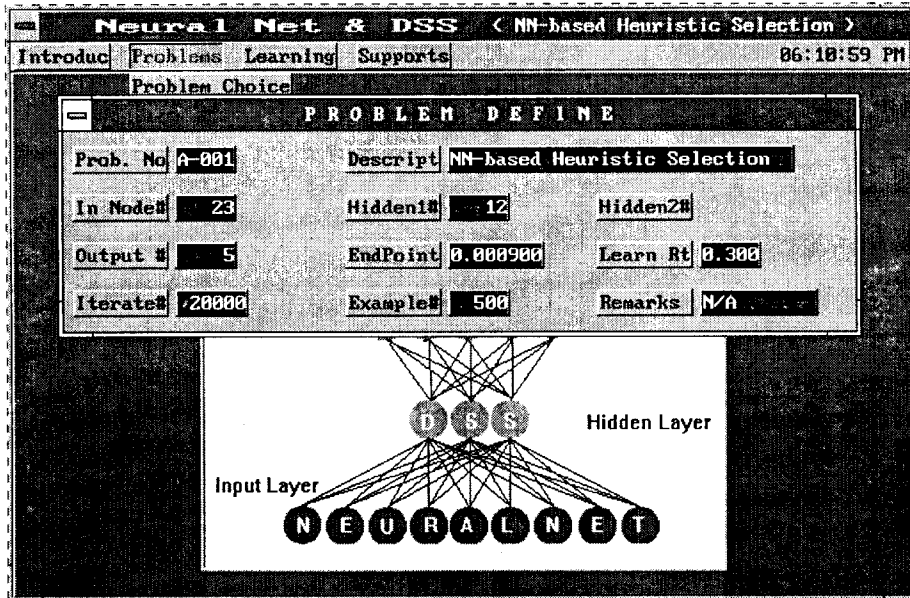
일정관리 휴리스틱을 선택함에 있어서 신경망을 적용하고자 했던 연구는 주로 Job Shop 일정관리문제에서 찾아볼 수 있다. Chryssoulouris (1991)나 Cho와 Wusk(1993) 등에서는 작업장 수준에서 성과척도에 따라 휴리스틱별로 가중치를 산출하기 위해 신경망을 적용하였다. Foo와 Takefuji(1988), Zhou(1990), 그리고 Piramuthu (1993) 등도 Job Shop 문제에 신경망을 적용하는 연구를 하였다. 그러나, Job Shop 일정관리 이외의 문제에서 문제의 특성에 따라 서로 다른 휴리스틱을 선택적으로 적용하기 위해 신경망을 적용한 예는 거의 찾아볼 수 없다. 뿐만 아니라, 여러 가지 성과척도를 갖는 문제에서 신경망을 적용한 연구는 더욱 찾아보기가 어렵다.

3. 신경망의 구성

본 연구에서 신경망은 주어진 일정관리 문제의 특성에 따라 가장 좋은 성과를 가져오는 휴리스틱에 대해 학습한 후에 새로운 문제에 대해 어떤 휴리스틱을 사용하는 것이 바람직한가를 제시하는 역할을 수행한다. 따라서, 가장 적합한 휴리스틱을 선택할 수 있도록 입력층과 출력층의 뉴론의 수, 은닉층의 개수 및 뉴론의 수 등을 결정하게 된다. 입력층에서는 전처리기에 의해 처리된 예제 문제들의 특성을 일련의 벡터로 입력받으며, 은닉층에서의 내부적인 계산과정을 거쳐서 출력

층으로 각 휴리스틱에 대한 선호도를 수치형태로 출력한다. 이를 위해, 본 연구에서는 데이터의 처리를 위해 사용되는 xBase계열의 언어인 클리퍼 5.2와 객체지향언어로 각광을 받고 있는 C++ 언

어를 이용하여 프로그램을 작성하였다. <그림 2>는 신경망 학습을 하기 위한 문제를 정의하는 예를 보여주고 있다.



<그림 2> 휴리스틱 선택을 위한 신경망 정의의 예

3.1 입력층

입력층은 주어진 문제의 특성에 대한 값을 입력할 수 있도록 노드를 구성하면 되기 때문에 비교적 간단하게 설계할 수 있다. 그러나, 입력데이터를 주어진 범위로 정규화하는 부가적인 과정이 필요하며, 일정관리 문제를 거의 완전하게 분류할 수 있는 특성요인을 어떻게 찾아낼 것인가 하는 것이 더 큰 문제로 대두된다. 그러나 이러한 문제는 본 논문의 범위를 벗어나기 때문에 본 연구에서는 기존의 연구결과를 바탕으로 특성요인을 구성하고자 한다.

본 연구는 일정관리 문제의 특성을 규정하는 요인들을 찾기보다는 기존의 연구에서 얻어진 요

인들을 이용하여 신경망 접근법에 따라 문제를 분류하고, 학습된 결과를 다속성 의사결정문제에 적용하기 위한 개념적인 틀을 제시하는데 목적을 두고 있다. 따라서, 본 연구에서는 문제를 분류하는 특성요인에 대한 부가적인 연구를 실시하지 않고 <표 1>과 같은 Patterson(1976)의 연구결과를 인용하여 입력층을 구성하였다. Patterson의 연구결과보다 더 나은 연구결과가 있다면 이를 이용하여 신경망의 입력층을 구성할 수도 있을 것이다. 아울러, 측정하고자 하는 성과척도가 무엇인지를 지정할 수 있도록 한 개의 노드를 추가하였다.

〈표 1〉 프로젝트 스케줄링 문제에 대한 특성요인

구 분	특성요인	내 용
임계경로 분석전의 시간과 네트워크 관련 요인	AvgProcessing	Average job processing time
	VA-Pro	Variance in job processing time
	Complexity	# of precedence relations ÷ # of job
임계경로 분석후의 시간과 네트워크 관련 요인	Nslack	# of jobs possessing non-zero slack
	PctSlack	% of jobs possessing positive slack
	TotalSlack-R	Total slack ratio to CPL
	PctFreeSlk	% of jobs possessing positive free slack
임계경로 분석후의 자원 관련 요인	Avg%Demand	Avg. % of jobs requiring positive amounts of resources
	MinUtil	Min. resource utilization
	MinCon	Min. resource constrainedness
	Var-Con	Variance in resource constrainedness
	MinCon-Tm	Min. resource constrainedness over time
	MaxCon-Tm	Max. resource constrainedness over time
	VarCon-Tm	Var. in resource constrainedness over time
	MaxCon-All	Max. resource constrainedness using all jobs as a base
	MinOFact	Min. obstruction factor
	MaxOFact	Max. obstruction factor
	TotUFact	Total underutilization factor
	MaxUFact	Max. underutilization factor
	MaxOver	Max. excess demand time periods for resources
	MinUnder	Min. time underutilization of resources
MaxUnder	Max. time underutilization of resources	

3.2 출력층

일정관리 문제를 다루는 신경망에서 출력층은 일정을 작성하기 위해 사용되는 일련의 휴리스틱으로 구성된다. 본 연구에서는 대부분의 일정관리 문제에 적용이 가능한 우선순위할당 규칙인 SPT (Shortest Processing Time), EDD(Earliest Due Date), FIFO(First In First Out), LWKR (Least Work Remaining), MDD(Modified Due

Date), 그리고 NDD(a New modified Due Date) 등을 이용하고 있으므로 이들의 개수만큼 출력층의 노드를 만들어야 한다.

3.3 은닉층

앞에서 설명한 입력층과 출력층 이외에도 몇 가지의 인자가 더 결정되어야 하는데, 이들 인자에는 은닉층의 수, 각 은닉층에 속하는 뉴런의

수, 그리고 학습을 등이 포함된다. 그러나 이들은 일정관리 문제의 성격이나 규모에 따라 달라질 수 있기 때문에 경험적인 방법에 의해 결정되어야 한다. 이와 함께, 학습율을 상황에 따라 변화 시킴에 따라 학습속도를 향상시키거나(Jacob, 1988), QuickProp(Fahlman, 1988) 또는 RProp(Riedmiller, 1992) 등과 같이 신경망의 학습속도를 향상시키기 위해 개발되고 있는 많은 방법들 중에서 보다 좋은 해를 제시할 수 있는 방법의 선택이 필요할 것이다.

4. 신경망을 이용한 학습과정

주어진 예제에 대해서 신경망을 이용하여 학습을 하기 위해서는 신경망의 입력으로 사용될 각 예제들의 특성뿐만 아니라, 신경망의 바람직한 출력값을 함께 입력해 주어야 한다. 따라서, 각 예제에 대해 휴리스틱별로 일정을 작성한 후 성과 척도별로 성과를 측정하여 출력층의 값으로 사용해야 하는데, 이를 위한 시뮬레이션 및 학습과정을 간략히 설명하면 다음과 같다.

- ① 주어진 예제에 대해 자원의 제약을 고려하

지 않은 CPM(Critical Path Method) 스케줄을 작성한다.

- ② 신경망의 입력층에 입력될 값으로써 주어진 예제에 대해 <표 1>에서와 같은 각 특성요인들의 값을 계산한다.
- ③ 계산된 요인들의 값을 주어진 범위(예, 0.1~0.9)로 변환한다
- ④ 주어진 예제에 대해 각각의 휴리스틱을 적용하여 시뮬레이션을 실시한 후 성과척도별로 성과를 측정한다.
- ⑤ 일정관리 문제를 특성에 따라 파악한 입력벡터에 대한 바람직한 출력 값으로써의 출력벡터를 계산하기 위해 각 성과척도에 대하여 다음과 같은 방식으로 각 휴리스틱 규칙의 선호도(가중치)를 계산한다. 본 연구에서는 휴리스틱별 성과의 순위를 이용하여 가중치를 계산하는 방식을 채택하고 있는데, <표 2>는 휴리스틱 SPT, EDD, 그리고 LWKR 휴리스틱을 이용하여 시뮬레이션을 실시한 결과 작업공기가 각각 25, 28, 25로 계산되었을 경우, 휴리스틱별로 가중치를 계산하는 예를 보여주고 있다.

<표 2> 우선순위에 따른 가중치 계산

휴리스틱	작업공기	역순위	RSW	순위	1/순위	RRW
SPT	25	2.5	0.4167	1.5	0.6667	0.4000
EDD	28	1	0.1667	3	0.3333	0.2000
LWKR	25	2.5	0.4167	1.5	0.6667	0.4000
합 계		6	1.0001	6	1.6667	1.0000

<표 2>에서 가중치를 부여하는 두 가지 방법 중에서 RSW를 이용하고 출력층의 노드가 [SPT, EDD, LWKR]로 구성되었다고 가정한다면, 주어진 입력에 대한 바람직한 출력의 값은 [0.4167, 0.1667, 0.4167]이 됩

을 알 수 있다.

- ⑥ 모든 예제와 각 성과척도에 대해 위의 과정을 반복하여 입력벡터와 이에 대응하는 출력벡터를 계산한다. <그림 3>은 이와 같은 과정에서 얻어진 입력벡터 및 출력벡터를

Mean Time	Var. Time	Complexity	# of Slack	% Slack
0.78442	0.23423	0.43242	0.12538	0.10435
0.24243	0.43242	0.52342	0.30803	0.12158
0.44234	0.12342	0.73453	0.17565	0.30970
0.12341	0.32431	0.82530	0.35215	0.65020
0.53423	0.56124	0.32340	0.37575	0.13790
0.43242	0.56242	0.12341	0.40945	0.610475
0.75462	0.65412	0.16234	0.35315	0.20527
0.06465	0.42342	0.19124	0.16850	0.15900
0.86523	0.42341	0.24320	0.22250	0.36500
0.02652	0.73254	0.54122	0.20075	0.30525
0.23423	0.23422	0.25042	0.44060	0.65000
0.23413	0.53240	0.53424	0.13095	0.20501
0.13423	0.42341	0.24323	0.24505	0.13320

〈그림 3〉 신경망의 학습을 위한 입력 및 출력값을 정의하는 예

정의하는 예를 보여주고 있다.

- ⑦ 일정관리 문제의 특성과 성과척도로 구성되는 입력벡터와 이에 대응되는 출력벡터를 이용하여 신경망을 학습시킨다. 이 때, 신경망은 다음과 같이 계산되는 오차(E)를 최소화하는 방향으로 뉴론들간의 연결강도를 조절해 나가게 된다.

$$E = \text{Max} \sum_{i=1}^N (t_{pi} - o_{pi})^2 \text{ for all examples}$$

여기에서, N은 출력층에 있는 뉴론의 수 (즉, 휴리스틱의 수), t_{pi} 는 p번째 예제에서 i번째 구성 요소에 대한 바람직한 출력층의 값, 그리고 o_{pi} 는 신경망에 의해 계산된 실제 출력값을 의미한다.

5. 다속성 의사결정(MCDM)기법을 이용한 휴리스틱의 선택

예제를 이용한 신경망의 학습이 끝나면, 신경망의 각 뉴론들을 연결하는 연결강도는 일정관리

휴리스틱을 선택하기 위한 지식으로 이용되어 새로운 일정관리 문제에 적용할 휴리스틱을 제시해 준다. 즉, 새로운 문제의 특성을 파악한 후에 신경망의 입력층에 성과척도와 함께 입력하면 내부적인 계산과정을 거쳐 출력층에 값이 출력되는데, 이들 중에서 가장 큰 값을 갖는 휴리스틱이 주어진 문제에서 해당 성과척도에 대해 가장 좋은 해를 가져다 줄 것으로 예상 할 수 있는 것이다. 〈그림 4〉는 출력층에 나타나는 휴리스틱별 선호도의 예를 보여주고 있다. 이 그림에서는 세 가지의 새로운 문제에 대한 휴리스틱별 성과 예측치를 볼 수 있는데, 첫 번째와 두 번째 문제에서는 MDD 휴리스틱 규칙이, 그리고 세 번째 문제에서는 NDD 휴리스틱 규칙이 주어진 성과척도에 대해서 가장 좋은 해를 제공할 것으로 예상됨을 알 수 있다.

이와 같이, 하나의 성과척도를 갖는 문제에 대해서는 신경망의 출력값을 이용하여 가장 좋은 해를 가져다 줄 것으로 예상되는 휴리스틱을 골

MaxUnder	SPT rule	EDD rule	FIFO rule	MDD rule	NDD rule
0.14231	0.18407	0.43558	0.29606	0.48207	0.47795
0.43218	0.14692	0.37619	0.13677	0.49708	0.44205
0.23182	0.19784	0.26616	0.43790	0.48785	0.49837

<그림 4> 휴리스틱별 선호도 계산결과

바로 선택할 수 있다. 그러나, 여러 가지의 성과 척도를 가지며 각 성과척도별로 가장 좋은 해를 가져다 줄 것으로 예상되는 휴리스틱이 다를 경우에는 결과를 종합하는 추가적인 과정이 필요로 하는데, MCDM은 이러한 문제에서 의미 있는 해를 제공한다. 예를 들어, 일정을 작성함에 있어서 공기의 단축과 함께 납기를 초과하는 지연작업의 수를 최소화하는 두 가지의 목표를 갖고 있으며, 각각의 목표에 대한 가중치는 0.6과 0.4이고, 두 가지 목표에 있어서 최소한 0.1 이상의 선호도를 갖기를 희망한다고 가정해 보자. 여기에서, 최소 선호도는 어떤 휴리스틱이 전반적으로는 좋은 해를 낼 것으로 예상되지만 특정 목표에 대해서는 아주 나쁜 해를 도출할 것으로 예상되는 경우 이러한 휴리스틱은 고려의 대상에서 제외시키기 위해 도입된 제약 조건이다. 이 때, 각각의 성과척도를 주어진 일정관리 문제의 특성과 함께 신경망에 차례대로 입력한 후, 신경망에서 계산된 결과로써 출력층에 나타나는 각 노드의 출력값을

측정하면 이 값이 각 휴리스틱에 대한 선호도가 된다. 예를 들어, 앞의 두 가지 성과척도와 각 휴리스틱에 대해 신경망을 이용하여 출력값을 계산한 결과가 다음과 같다고 가정해 보자.

- {{공정 시간, SPT, 0.30},
- 공정 시간, EDD, 0.40},
- 공정 시간, LWKR, 0.08},
- 공정 시간, ○○○, 0.xx},
- 지연작업수, SPT, 0.30},
- 지연작업수, EDD, 0.20},
- 지연작업수, LWKR, 0.45},
- 지연작업수, ○○○, 0.xx}, ...}

각각의 성과척도 및 휴리스틱에 대한 선호도가 구해지면, MCDM 기법을 이용하여 최적안을 도출하여야 하는데, Hong과 Vogel(1991)이 일반화된 다속성 의사결정지원시스템을 연구하는 과정에서 사용하였던 3 단계 절차를 이용하면 다음과

같다.

- ① 특정 휴리스틱 규칙이 다른 휴리스틱 규칙의 모든 속성, 즉 모든 성과척도에 대해 더 낮은 선호도를 갖는다면(dominated), 이 휴리스틱은 최적의 휴리스틱이 될 수 없으므로 선택의 대상에서 제외시킨다. 앞의 예에서는 이러한 휴리스틱이 하나도 없으므로 다음 단계에서 모든 휴리스틱을 고려하게 된다.
- ② 각 속성, 즉 성과척도에 대한 선호도가 최소 요구수준보다 작은 휴리스틱을 선택의 대상에서 제외시킨다. 앞의 예에서, LWKR 휴리스틱 규칙은 지연작업의 수를 최소화하는 성과척도에 대해서 0.45의 선호도를 갖고 있어 매우 좋은 결과를 가져 올 것으로 기대되지만, 공기를 최소화하는 성과척도에 대해서는 0.08의 낮은 선호도를 갖고 있으므로 최소 요구수준인 0.1에 미달되어 선택의 대상에서 제외되는 결과를 가져오게 된다. 즉, 전체적으로 혹은 부분적으로는 매우 좋은 결과를 가져올 것으로 예상되더라도, 특정 성과척도에 대해 매우 나쁜 결과를 가져올 것으로 예상되는 휴리스틱은 선택에서 제외시킨다.
- ③ 위의 ①과 ②에서 제외되지 않은 나머지 휴리스틱에 대해서 다음의 계산식에 따라 종합 선호도를 계산한다.

$$P_i = \sum_{j \in V} (w_j \times p_{ij})$$

여기에서, i 는 휴리스틱 규칙, j 는 성과척도, 그리고 V 는 고려하는 성과척도들의 집합을 나타낸다. 또한, w_j 는 주어진 문제에서 성과척도 j 에 부과하는 가중치이며, P_i 는 휴리스틱 i 가 갖는 종합적인 선호도로써 w_j 와 p_{ij} 로부터 계산된다. 위의 ②에서 제외된 LWKR 휴리스틱을 제외한 나머지

휴리스틱 규칙에 대해 위의 계산식을 따라 종합 선호도를 계산해 보면 다음과 같다.

○ SPT 휴리스틱의 경우

$$\begin{aligned} P_i &= \sum_{j \in V} (w_j \times p_{ij}) \\ &= (0.6 \times 0.3) + (0.4 \times 0.3) \\ &= 0.3 \end{aligned}$$

○ EDD 휴리스틱의 경우

$$\begin{aligned} P_i &= \sum_{j \in V} (w_j \times p_{ij}) \\ &= (0.6 \times 0.4) + (0.4 \times 0.2) \\ &= 0.32 \end{aligned}$$

따라서, EDD 휴리스틱이 SPT보다 더 좋은 해를 가져올 것으로 예상 할 수 있으므로 이 문제에 있어서는 EDD 휴리스틱을 사용할 것을 제안하게 된다. 그러나, 만일 의사결정자가 위의 두 가지 성과척도에 대한 가중치를 0.6:0.4 대신 0.4:0.6으로 변경하였다면, 이 때 가장 좋은 해를 가져다 주게 될 휴리스틱은 다음과 같은 계산을 통해 찾을 수 있다.

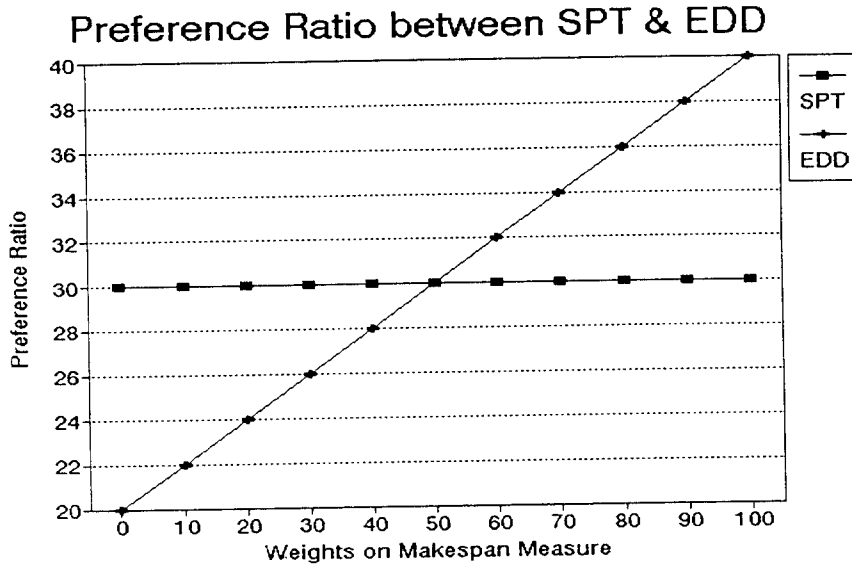
○ SPT 휴리스틱의 경우

$$\begin{aligned} P_i &= \sum_{j \in V} (w_j \times p_{ij}) \\ &= (0.4 \times 0.3) + (0.6 \times 0.3) \\ &= 0.3 \end{aligned}$$

○ EDD 휴리스틱의 경우

$$\begin{aligned} P_i &= \sum_{j \in V} (w_j \times p_{ij}) \\ &= (0.4 \times 0.4) + (0.6 \times 0.2) \\ &= 0.28 \end{aligned}$$

이 경우에는 SPT 휴리스틱이 EDD보다 더 선호됨을 알 수 있는데, 이는 동일하게 학습이 된 상태에서도 의사결정자가 각 성과척도에 부여하



〈그림 5〉 휴리스틱별 선호도

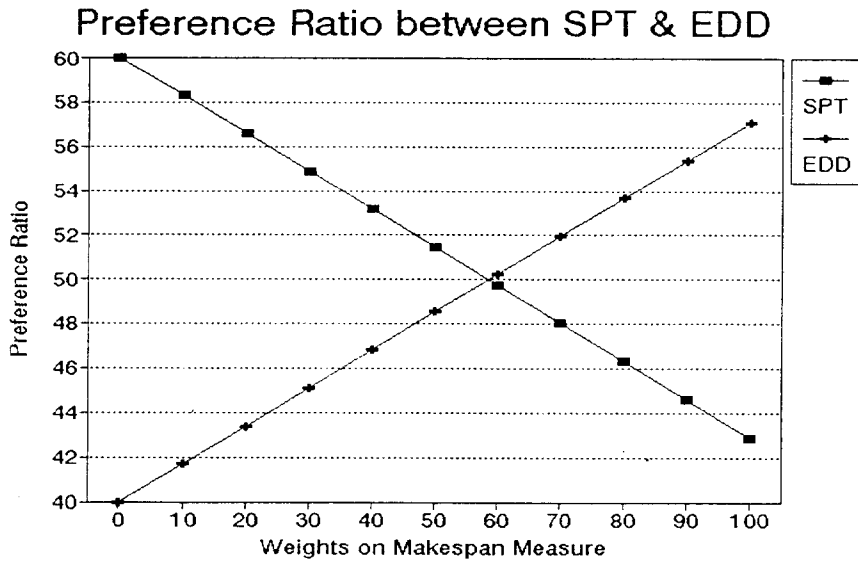
는 가중치에 따라 서로 다른 결과가 나타남을 보여주는 좋은 예라 할 수 있다. 이를 그림으로 나타내면 〈그림 5〉와 같다.

④ 위의 ③에서는 고려의 대상이 되고 있는 휴리스틱인 SPT와 EDD의 성과척도별 선호도를 그대로 이용하여 종합 선호도를 계산하는 방법을 설명하였다. 그러나, 이미 LWKR 휴리스틱은 고려 대상에서 제외되어 있기 때문에 나머지 두 가지 휴리스틱을 비교할 때에는 이들의 성과척도별 선호도를 정규화하여 계산해야 비교의 대상이 되는 휴리스틱간의 정확한 비교가 가능하다. 즉, 공정시간 성과척도에 대해 두 가지 휴리스틱이 갖고 있는 선호도의 합은 0.7인데 반하여 지연작업의 수에 대해서는 0.5라는 값을 이용하여 비교를 한다는 것은 불합리하다는 것이다. 따라서, 이를 정규화하면 각 선호도의 값은

{공정 시간, SPT, 0.429},
 공정 시간, EDD, 0.571},
 지연작업수, SPT, 0.600},
 지연작업수, EDD, 0.400}}

와 같이 수정되는데, 이를 이용하여 앞의 ③에서와 같은 방법으로 성과척도별 중요도에 따른 각 휴리스틱의 선호도를 계산한 뒤 그림으로 표현하면 〈그림 6〉과 같다.

〈그림 6〉은 앞의 〈그림 5〉와는 다른 패턴을 나타내고 있을 뿐만 아니라, 두 휴리스틱에 대한 선호도가 교차하는 점이 서로 다르게 나타남을 잘 보여주고 있다. 위의 예에서는 두 가지의 휴리스틱만을 고려했으나, 실제 문제에서 더 많은 휴리스틱을 동시에 고려해야 할 경우에는 정규화에 따른 효과가 더 크게 나타날 것이다.



〈그림 6〉 정규화한 이후의 휴리스틱별 선호도

6. 결론 및 향후 연구계획

본 연구에서는 일정관리 문제의 특성을 규정하는 요인들을 찾아내기보다는 기존의 연구에서 얻어진 특성요인들을 이용하여 신경망 접근법에 따라 문제를 분류하고, 학습된 결과를 다속성 의사결정문제(MCDM)에 적용하기 위한 개념적인 틀을 제시하고 있다. 신경망의 입력층은 가장 일반화된 형태인 프로젝트 일정관리 문제에 있어서 시뮬레이션 및 통계처리를 통해 유의한 변수들을 찾아내었던 Patterson(1976)의 연구결과를 바탕으로 구성하였다. 아울러, 현실적인 문제에서 흔히 접하게 되는 여러 가지의 성과척도를 갖는 일정관리 문제에 있어서 기존에 개발되어 있는 많은 일정관리 휴리스틱 중 어떤 것을 적용해야 모든 성과척도 측면에서 가장 좋은 성과를 가져올 수 있는지에 대한 답을 제공할 수 있도록 MCDM 기법을 적용하는 방법에 대해 기술하였다. 일반화 능력이 탁월한 신경망을 일정관리 문제에 적용하

는 방법과 여러 가지 성과척도를 갖는 일정관리 문제에서 적합한 휴리스틱 규칙을 선택하는 방법을 구체적으로 제시하였다는 점에서 본 연구의 의미를 찾을 수 있을 것이다.

본 연구에서는 기존의 연구 결과로부터 일정관리 문제의 특성을 도출하여 이용하고 있으나, 일정관리 문제를 보다 명확하게 분류할 수 있는 요인들을 찾으며, 기존의 연구에서 이용하고 있는 많은 예제들을 수집하여 시뮬레이션을 실시한 후 신경망을 적용함으로써 구체적인 성과를 수치로 보여주기 위한 추가적인 연구가 진행되고 있다. 아울러, 이 연구에서 적용하고 있는 역전파 신경망 외에 Carpenter *et al.* (1992)이 제안한 Fuzzy ARTMAP 등을 이용할 경우의 예측성과차이도 함께 분석중에 있다. 또한, 신경망이 갖고 있는 적응성과 계산의 신속성을 이용하여 변화하는 일정관리 환경에 따라 그에 적합한 휴리스틱을 제시해 주는 일정관리 의사결정지원시스템을 구축하기 위한 연구도 진행되고 있다.

참 고 문 헌

- [1] 이재식, "주문생산 일정계획 수립을 위한 휴리스틱의 통태적 선택," 「아주 경영리뷰」, 제2권 (1994), pp. 1-17.
- [2] 한재민, 황인수, "자원제약하의 프로젝트 스케줄링을 위한 의사결정지원시스템," 「경영정보학 연구」, EIS/DSS 특집호 (1995), pp. 205-224.
- [3] 한재민, 황인수, "프로젝트 관리를 위한 프로토타입 의사결정지원시스템," 「경영연구」, 제30권, 제 1호 (1996), pp. 137-164.
- [4] Baker, K.R., *Introduction to Sequencing and Scheduling*, Wiley, New York, 1974.
- [5] Blackstone, J.H., D.H. Phillips and G.L. Hogg, "A state-of-the-art survey of dispatching rules for manufacturing on shops operations," *International Journal of Production Research*, Vol. 20 (1982), pp. 27-45.
- [6] Carpenter, G., S. Grossberg, N. Markuzon, J. Reynolds and D. Rosen, "Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps," *IEEE Transactions on Neural Networks*, Vol. 5, 1992, pp. 698-713.
- [7] Caudill, M., "Neural Networks primer, Part II," *AI Expert*, Feb. 1988, pp. 55-61.
- [8] Cho, H. and R.A. Wysk, "A robust adaptive scheduler for an intelligent workstation controller," *International Journal of Productions Research*, Vol. 31, No. 4 (1993), pp. 771-789.
- [9] Dar-El, E.M. and R.A. Wysk, "Job Shop scheduling-A systematic approach," *Journal of Manufacturing Systems*, Vol. 1 (1982), pp. 77-88.
- [10] Davis, E. and J. Patterson, "A Comparison of Heuristic and Optimal Solutions in Resource-Constrained Project Scheduling," *Management Science*, Vol. 21(1975), pp. 944-955.
- [11] Edward, W. and J.R. Newman, *Multiattribute Evaluation*, SAGE Publications, Inc., 1982.
- [12] Fahlman, S.E., "An Empirical Study of Learning Speed in Back-Propogation Networks," CMU-CS-88-162, September 1988.
- [13] Garey, M. and D. Johnson, *Computer and Intractability* (San Francisco: Freeman), 1979.
- [14] Han, J., "From Automated Planners to Intelligent Schedulers," *The Journal of Management*, Vol. 35 (1991), pp. 181-200.
- [15] Han, J. and I.S. Hwang, "Knowledge Acquisition on Scheduling Heuristics Selection Using Dempster-Shafer Theory(DST)," *Journal of Expert Systems*, Vol. 1, No. 2 (1995), pp. 123-137.
- [16] Hong, I.B. and D.R. Vogel, "Data and Model Management in a Generalized MCDM-DSS," *Decision Science*, Vol. 22 (1991), pp. 1-25.
- [17] Hwang, I.S., *Development of An Expert System For Job Shop Scheduling with Multi-objectives*, Master Thesis, Korea University, 1995.

- [18] Jacobs, R., "Increased Rates of Convergence Through Learning Rate Adaptation," *Neural Networks*, Vol. 1 (1988).
- [19] Kohonen, T., "An introduction to neural computing," *Neural Networks*, Vol. 1 (1988), pp. 1-16.
- [20] Panwalker, S.S. and W. Iskander, "A survey of scheduling rules," *Operations Research*, Vol. 25 (1977), pp. 45-61.
- [21] Park, S.C., N. Raman and M.J. Shaw, "Adaptive Scheduling in Flexible Manufacturing Systems," *Korean Management Science Review*, Vol. 13, No. 1 (1996), pp. 57-70.
- [22] Patterson, J.H., "Project Scheduling the effects of problem structure on heuristic performance," *Naval Research Logistics Quarterly*, Vol. 23, No. 1 (1976), pp. 95-123.
- [23] Philipoom, P.R. and T.D. Fry, "The robustness of selected Job Shop dispatching rules with respect to load balance and work-flow structure," *Journal of Operational Research*, Vol. 41 (1990), pp. 897-906.
- [24] Pierreval, H. "Expert System for Selecting Priority Rules in Flexible Manufacturing Systems," *Expert Systems in Applications*, Vol. 5 (1992), pp. 51-57.
- [25] Piramuthu, S., N. Raman, M.J. Shaw and S.C Park, "Integration of simulation modeling and induction learning in an adaptive decision support system," *Decision Support Systems*, Vol. 9 (1993), pp. 127-142.
- [26] Riedmiller, M. and H. Braun, "RPROP - A Fast Adaptive Learning Algorithm," Proceedings of ISCIS VII (1992).
- [27] Rumelhart, D.E., G.E. Hinton and R.J. Williams, "Learning internal representations by error propagation," *Parallel Distributed Processing* (New York: The MIT Press), 1988.
- [28] Sim, S.K., K.T. Yeo and W.H. Lee, "An Expert Neural Network System for Dynamic Job Shop Scheduling," *International Journal of Production Research*, Vol. 32, No. 8 (1994), pp. 1759-1773.
- [29] Tollenaere, T., "SuperSAB:Fast Adaptive Backpropagation with good Scaling Properties," *Neural Networks*, Vol. 3 (1990), pp. 561-573.