

혼합형 조립라인의 투입순서결정을 위한 시뮬레이티드 어닐링 신경망모형*

Simulated Annealing Neural Network Model for Sequencing in a Mixed Model Assembly Line*

김민수** · 김동묵**

Man-Soo Kim** · Dong-Mook Kim**

Abstract

This paper deals with a simulated annealing neural network model for determining sequences of models inputted into a mixed model assembly line. We first present a energy function fitting to our problem, next determine the value of the parameters of the energy function using convergence ratio and the number of searched feasible solution. Finally we compare our model NMS with the modified Thomopoulos model. The result of the comparison shows that NMS and Thomopoulos offer a similar output in the problems having good smoothness.

Keywords : Simulated annealing neural network, Sequencing of mixed model assembly

1. 서론

인공지능을 갖춘 차세대 컴퓨터의 구현을 위한 노력의 일환으로 신경망에 대한 연구가 진행되어 왔다. 신경망은 두뇌의 처리방식이 갖는 특성, 즉 간단한 뉴런들의 병렬처리와 학습의 축적에 의하여 추론과 판단등의 지능적인 의사결정을 행하는 점을 모방하여 단순한 학습처리기의 학습과 병렬처리로서 의사결정을 수행하는 방법론이다. 따라서 신경망은 화상처리, 음성인식 및 구문처리등과 같은 복잡한 문제들을 푸는데 탁월한 방법론이다. 여러 형태의 현실문제들을 신경망모형을 통하여 풀고자 하는 연구가 계속되는 중에, Hopfield 와 Tank [6]가 TSP

에 신경망모형을 적용한 것을 기점으로 최적화 부문의 여러 분야에도 응용되게 되었다. 특히 스케줄링이나 순서결정 문제에 활용도가 높은 것으로 보고되고 있다. 본 연구는 혼합형조립라인의 순서결정 문제를 푸는데 신경망모형을 적용한 것이다. 혼합형 조립라인은 현재 대부분의 자동차 조립라인에서 채택하고 있는 방식으로서, 동일 라인에서 다양한 모델들을 함께 만들어 내고자 하는 것으로 경쟁력을 확보하기 위해서는 필연적인 조립방식이라고 볼 수 있다. 이러한 혼합형 조립라인에 있어서 복잡한 의사결정으로서 순서결정(Sequencing)문제가 있다. 순서결정이란 하나의 라인에서 여러 종류의 모델을 생산하고자 하는 혼합형 조립라인에서 고정 사이클타임 방식이 적

* 본 연구는 1996년도 학술진흥재단 지방대육성과제 연구비에 의하여 수행되었음.

** 동신대학교 산업공학과

용되었을 때, 작업장의 작업영역을 효과적으로 사용하기 위하여 모델간의 라인투입순서를 결정하는 절차이다. 그러나 라인발란싱의 결과로서 각 모델에게 할당된 작업시간은 작업장마다 다르고, 또한 순서를 정해야 할 모델 개수에 따라서 가능해가 기하급수적으로 크게 증가하므로 인해 최적해보다는 근사해를 얻는 것이 바람직하다. 이처럼 복잡한 순서결정 문제에 신경망모형을 적용할 때 그 결과가 높을 것으로 예상되고, 또한 신경망모형을 조합적 최적화 문제 및 제조부문의 여러 분야에 적용하는 동기부여와 추후 연구에 기여할 것으로 보여진다.

2. 혼합형 조립라인의 순서결정과 신경망모형

2.1 혼합형 조립라인의 순서결정

혼합형 조립라인은 소품종대량 생산체제에 적합했던 단일모델 전용흐름라인을 다품종 소량시대에 대응할 수 있도록, 한 라인에서 유사한 여러 모델을 함께 생산하는 조립라인이다. 이러한 라인의 대표적인 예로서 승용차 조립라인을 들 수 있는데, 고객으로부터의 요구(옵션사항)에 따라 여러가지 차종을 다양한 모델로 연속하여 생산하고 있다. 이러한 혼합형 라인의 가동을 향상을 위한 의사결정 문제로서 라인발란싱과 순서결정이 있다. 라인발란싱은 통합선행관계도에 나타난 선행조건을 만족하고 작업장의 작업부하가 균형을 이루면서 요구되는 작업장의 수가 최소가 되도록 각 작업장에 작업을 할당하는 절차이다. 이 반면에 순서결정 문제는 라인발란싱의 결과로서 각 작업장에 할당된 모델들의 작업부하를 최대한 각 작업장의 작업영역안에서 행할 수 있도록 모델간의 투입순서를 결정하는 절차이다. 이 중에서 순서결정문제는 모델들의 투입간격 즉 사이클타임을 각 모델마다 다르게 하지 않고 모든 모델에 동일하게 하는 고정 사이클타임(fixed cycle time)방식을 적용할 경우에 발생한다. 작업장에 할당된 모델별 작업량과 모델들의 총조립시간은 모델별로 다르기 때문에 합리적으로 순서결정을 하지 않으면 작업장간의 작업부하의 불균형을 초래하게 된다. 이 경우 작업시간이 고정 사이클타임보다 큰 모델이 연속적으로 투입되면 가외작업량이 많아져서 라인길이 및 사이클타임을 길게 해야하는 등, 라인 운영에 어려움을 초래하고 급기야는 콘베이어를 정지해야 만하는 경우까지도

발생하게 된다. 이러한 순서결정 문제는 작업장의 수와 모델 수가 증가하면 최적해를 구하기 어려운 NP-hard 문제가 된다. 따라서 휴리스틱 해법들이 제안되고 있는데, 지금까지 연구되어온 휴리스틱 해법들을 목적함수에 따라 구분해 보면, 전체 라인길이를 최소화하는 연구는 Dar-EL[4]에 의해서, 가외작업량을 최소로 하여 작업장의 효율을 높여려는 연구는 Thomopoulos [9]에 의해 이루어졌다.

2.2 시뮬레이티드 어닐링 신경망모형

신경망은 여러 층으로 구분되는 계층구조형과 층 구분이 없는 상호조합형이 있다. 계층구조형은 요소들이 입력층, 은닉층 및 출력층으로 구분되어, 같은 층에 속한 요소들 끼리는 연결되지 않고 입력층에 속한 요소들은 은닉층에 속한 요소들과, 은닉층은 출력층과 연결되어 있는 구조이다. 이 구조를 사용하는 신경망모형의 대표적인 것은 다층퍼셉트론으로 패턴인식, 음성인식, 신호처리나 제어 등의 광범위한 분야에 응용되고 있다. 상호조합형은 계층구조와 달리 모든 요소들이 상호연결되어 있어서 층 구분이 불가능한 구조를 하고 있다. 이 구조를 사용하는 신경망모형으로서 홉필드 네트워크와 볼츠만 머신을 들 수 있으며, 이 모형들은 조합적 최적화 문제에 응용되고 있다. 이 두 모형들은 문제에 맞는 에너지함수를 설정하여 이를 최소화한다는 점에서는 같으나 홉필드 네트워크는 미분강하법(differential gradient descent approach)을, 볼츠만 머신은 시뮬레이티드 어닐링(SA: Simulated Annealing)을 사용하는 점이 다르다[1].

Hopfield 및 Tank [6]는 NP-complete 최적화문제로 알려진 TSP(Traveling Salesman Problem)를 신경망을 사용하여 모형화하고 해를 구하였다. 이 모형은 미분강하법을 사용하였는데 이 방법은 초기치로부터 시작하여 에너지 함수 즉 성능평가함수의 값을 줄이는 방향으로 진행하여 어떤 최소점에 도달하는 것이다. Kirkpatrick et al. [7]에 의한 또 다른 모델은 SA기법을 응용한 것으로, 이는 미분강하법의 결과 얻어지는 극소치(local minimum)를 탈출할 수 있는 방안을 제시하고 있다.

미분강하법을 사용하는 경우에는 어떤 요소 x 의 출력 상태 $u(x)$ 는 오직 에너지변화량 ΔE 에 의해서만 0 혹은 1로 결정된다.

$$u(x) = \begin{cases} 0, & \Delta E < 0 \\ 1, & \Delta E \geq 0 \end{cases}$$

여기에서 $\Delta E = E_{[u(x)=0]} - E_{[u(x)=1]}$ 이고, $E_{[u(x)=0]}$ 은 다른 요소의 출력값을 변함없는 상태로 두고, 요소 x 값만을 0으로 했을 경우의 에너지값이다.

이에 반해서 SA법은 각 요소들의 출력상태를 확률값으로 취하는데, 다음 식에서 보듯이 ΔE 와 함께 온도변수 T 를 사용하고 있다.

$$p(x) = 1/(1+\exp(-\Delta E/T))$$

$$u(x) = \begin{cases} 0, & p(x) < p(rand) \\ 1, & o/w \end{cases}$$

여기에서 $p(rand)$ 란 임의의 랜덤숫자 추출함수에 의해 얻어진 확률값이다. 온도변수 T 는 초기에는 큰 값을 갖지만 강하율에 의해 점차적으로 적은 값을 갖게 된다. T 가 클 때는 $p(x)$ 및 $u(x)$ 값에 영향이 커서, $\Delta E < 0$ 임에도 불구하고 $u(x)$ 값이 1이 되기도 한다. 이러한 변화에 의해 하나의 최소치를 벗어나 다른 최소치를 탐색할 수 있게 된다.

스케줄링문제에 신경망을 적용한 연구들은 최근에 증가하고 있다[3, 8]. 이러한 연구들의 성과에 힘입어 복잡한 혼합형 조립라인의 순서결정 문제에 시뮬레이티드 어

닐링 신경망모형을 적용해 보고자 한다.

3. 혼합형 조립라인의 투입순서결정을 위한 시뮬레이티드 어닐링 신경망모형

3.1 혼합형 조립라인의 순서결정문제

본 연구에서 다루는 혼합형 조립라인은 일정한 속도로 진행되는 컨베이어시스템으로, 작업자는 컨베이어 위에 올라타서 함께 이동하면서 작업하는 형태이다. 작업을 완료한 작업자는 후속하는 모델의 작업을 하기 위하여 라인 상류방향 즉 컨베이어 진행방향과 반대 방향으로 이동한다. 본 연구에서 다루는 혼합형 조립라인의 순서결정 문제(MASP : Mixed Assembly Sequencing Problem)는 다음과 같은 가정을 하고 있다.

- (1) 유사한 여러 모델이 일정시간 즉 고정사이클 간격으로 투입되고 있다.
- (2) 각 작업장의 작업편성 즉 모델별 작업시간은 사전에 라인발란싱이 수행된 결과이다.
- (3) 작업장의 형태는 개방작업장으로서 작업영역을 벗어난 영역에서의 작업 즉 가외작업(그림 1의 a, c)이 가능하나, 후속작업장과의 작업간섭이 발생되어서는 안된다.




그림 1. 가외작업이 발생하는 개방작업장

- (4) 각 작업장에는 1인의 작업자가 배치되어 있다.
- (5) 각 작업장의 작업영역은 정하여져 있으나 모든 작업장의 작업영역의 길이는 동일하지 않아도 된다.
- (6) 모델변경에 의한 작업 준비시간은 무시할 정도로 적다.
- (7) 새로운 작업을 위해 컨베이어 상류방향으로 움직이는 작업자의 이동 속도는 일정하다고 본다.

그림 1은 개방작업장에서 가외작업이 발생하는 경우를 보여주고 있다. 작업장 K에서 3번째 작업을 수행하는 중에 가외작업 a가 발생하고 있으며 이로 인해 미리 도착한 후속작업자는 선행작업이 완료될 때까지(그림 1에서 b) 기다려야 한다. 연속적인 조립라인에서 한 작업장의 가외작업량은 후속하는 작업장에 연쇄적으로 영향을 미쳐 라인의 운용에 어려움을 초래하게 된다.

따라서 작업영역안에서 작업이 수행되어 가외작업량이 줄어지도록 투입순서를 결정할 필요가 있다. 이러한 가외작업량을 최소화 하는 목적함수식은 다음과 같다.

$$\text{Minimize } \sum_{x=1}^N \sum_{k=1}^M \psi_{xk}^w$$

여기에서 N 은 품목수, M 은 작업장수를 나타내며, ψ_{xk}^w 은 투입순서중의 x 번째 품목에 대하여 k 번째의 작업장에서 발생하는 제 w 종류의 가외작업량을 나타낸다.

MASP는 TSP와 마찬가지로 순서를 정하는 문제이지만, 일반적인 TSP보다 풀어나가기에 난해한 특성을 갖고 있다. TSP는 총 방문거리를 최소화 하는 순서를 정하는 문제이고, MASP는 총 가외작업량을 최소화 하는 순서를 정하는 문제이다. TSP에 있어서는 두 방문지점간의 거리는 방문순서에 관계없이 동일하지만, MASP에 있어서는 모델의 가외작업량은 투입순서 구성에 따라 다른 값을 갖게 된다. 예를들면, 어떤 작업장의 작업영역의 길이가 110이고, 품목A, B, C, D의 작업시간이 각각 85, 90, 50, 85이며, 고정사이클 시간이 70이라고 하자. 그림 2와 3에서 나타나 있듯이 B→C→A→D로 투입된 경우와 B→A→D→C로 투입된 경우를 살펴보면, 두 경우 모두 A 다음에 D를 투입하였지만 D가 투입된 후의 가외작업량은 각각 0, 10으로서 차이가 있음을 알 수 있다.

본 연구는 Hopfield의 TSP신경망모형을 근거로해서




그림 2. B→C→A→D순서로 투입된 경우




그림 3. B→A→D→C순서로 투입된 경우

MASP에 적합한 시뮬레이티드 어닐링 신경망모형을 제시한 것으로, 편이상 제시된 모형을 투입순서를 위한 신경망모형(NMS: Neural Model for Sequencing)이라고 명명한다. 이 모형은 순서에 영향을 받는 가외작업량을 최소화 하기 위해서는, 각 품목들의 투입순서는 작업시간이 긴 품목과 작은 품목들이 번갈아가며 투입되어야 한다는 개념을 에너지함수에 반영한 것이다.

3.2 혼합형 조립라인에 있어서 신경망 투입순서 모형

조립라인에서 생산해야 할 모델 종류가 n 이라고 하자. 흔히 혼합형 조립라인에서는 각 모델의 수요량에 대한 최소부품집합(MPS : Minimum Part Set)으로 반복 생산한다. 각 모델의 MPS를 각각 N_1, N_2, \dots, N_n 이라 하자. 이때 한 사이클동안 생산할 총품목수는 $N (= \sum_{i=1}^n N_i)$ 이다. 따라서 한 사이클동안 N 개 품목의 투입순서만을 정하면 된다. NMS의 모형화에 사용되는 기호들은 다음과 같다.

- N : 투입순서를 결정하고자 하는 품목 수
- M : 작업장 수
- u_{xj} : 품목 x 에 투입순서 j 가 할당된 상태를 나타내는 정보처리요소의 출력, $x=1, \dots, N, j=1, \dots, N$
- t_{xk} : 작업장 k 에서 품목 x 의 작업시간, $x=1, \dots, N, k=1, \dots, M$
- L_k : 작업장 k 의 작업영역 길이, $k=1, \dots, M$
- CT : 모든 품목에 공통으로 적용되는 고정사이클 시간

$$E_1 = \alpha \sum_{i=1}^N \sum_{j \geq i}^N \sum_{x=1}^N u_{xi} u_{xj} + \beta \sum_{x=1}^N \sum_{y \geq x}^N \sum_{j=1}^N u_{xj} u_{yj} + \gamma \sum_{x=1}^N \sum_{j=1}^N (u_{xj} - N)^2$$

첫번째 항에서는 각 품목은 하나의 투입순서만을 갖도록, 두번째 항에서는 각 투입순서는 오직 하나의 품목에 할당되는 방향으로 나아가도록 유도하고 있다. 그리고 세번째 항은 출력이 1인 정보처리요소의 개수가 N 이 되도록 제한하고 있다. 이로써 세 개의 항이 모두 0이 될 때 가능한 해가 얻어지게 된다. 여기에서 사용된 변수 α, β 및 γ 는 일종의 Lagrangian 상수로서, 적절한 값을 할당함으로써 가능해에 도달하도록 한다.

E_1 는 조립작업이 가능한한 각 작업장의 작업영역 범위 내에서 작업이 완료되게 함으로써, 가외작업을 하는 경향이 완화되는 상태를 표현하게 된다. 이를 위하여 NMS에서는 다음과 같은 배정규칙에 따른다.

- 규칙 1. 모든 작업시간들을 평균이 CT 에 근접하는 쌍들로 구분하여, 각 쌍에 속하여 있는 품목들의 투입순서를 인접시킨다.
- 규칙 2. 쌍을 구성하는 품목들의 작업시간 차를 구하여, 그 차이가 큰 것들 부터 먼저 배정한다.
- 규칙 3. 작업시간이 CT 에 가까운 품목들을 한 쌍이 배정된 직후에 배정한다.

규칙 1을 통하여 작업 완료시간을 작업영역내의 고정 사이클시간 위치로 되돌릴 수가 있다. 어떤 작업장에서 투입순서에 의해 처리되어야 할 품목들의 작업시간들이 평균 작업시간 즉 고정 사이클시간 CT 를 중심으로 분포되어 있다고 볼 수 있으므로, 모든 작업시간들을 합의 평균이 CT 에 근접하는 쌍들로 구분하여, 각 쌍에 속하여 있는 품목들의 투입순서를 인접시키면 작업 완료시간을 고정 사이클시간 위치로 되돌릴 수 있다. 규칙 2는 작업시간이 사이클타임에 근접한 품목들로 구성된 쌍을 나중에 배정하자는 것으로 이를 통하여 작업 완료시간이 궁극적으로 고정 사이클시간 위치로 수렴되도록 한다. 또한 규칙 3은 작업시간들이 CT 를 중심으로 비대칭으로 분포되어 있는 경우에 규칙 1과 2만을 사용하면 가외작업량이 증가하게 되므로 이를 해소하는 역할을 하게 된다.




그림 4. NMS의 정보처리요소 구성

신경망의 각 정보처리요소는 어떤 품목이 몇 번째의 투입순서를 갖는가를 표현해야 하므로 총 N^2 개가 필요하게 된다. 그림 4는 품목이 4개인 경우의 정보처리요소들의 배치를 보여주고 있다. 여기서 행은 투입할 품목을 나타내며, 열은 각 품목들의 순서를 나타내게 한다. 수식의 간결한 표현을 위해 A, B, C, D로 표현된 품목들을 각각 1, 2, 3, 4 숫자로 나타내기로 한다. 가능해가 얻어지면 각 행과 열에서 단 하나의 u_{xj} 가 1이되며 그 외는 0이 된다. 그림 4에서 $u_{14}=u_{23}=u_{31}=u_{42} = 1$ 이며, 그 외는 0이므로 가능해를 얻게되며, 품목들의 투입순서는 C → D → B → A가 된다.

불츠만 신경망모형을 구현하는데는 무엇보다도 문제에 맞는 적절한 성능평가함수 즉 에너지함수를 만들어야 한다. NMS의 경우 제시된 에너지함수는 두 부분 E_1, E_2 로 구성되어 있는데 E_1 은 가능해를 보증하기 위한 것이고, E_2 는 최적해에 가까운 근사해를 얻고자 하는 것이다. NMS는 E_1 과 E_2 를 동시에 감소시켜서 가능근사해를 제공하게 된다. E_1 은 아래와 같다.

이러한 배경규칙에 의하여 작업 완료시간은 작업영역 내의 고정 사이클시간 위치로 되돌아오는 것을 반복하면서 궁극적으로 고정사이클시간 위치로 수렴하는 형태가 되도록 투입순서가 결정된다. 이러한 작업장 상태를 반영할 에너지 함수 E_2 는 아래와 같이 주어진다.

$$E_2 = \sum_{x=1}^N \sum_{y=1}^N \sum_{k=1}^M \sum_{j=1}^{(N+2)/3} d_{xyk} u_{x,y,j-2} (u_{y,y,j-1} + u_{y,y,j-1}) + \sum_{x=1}^N \sum_{y=1}^N \sum_{k=1}^M \sum_{j=1}^{N-3} e_{xyk} u_{x,y,j+3} + \sum_{x=1}^N \sum_{k=1}^M f_{xk} u_{x,1} + \sum_{x=1}^N \sum_{k=1}^M g_{xk} u_{x,3}$$

여기에서

$$d_{xyk} = (t_{xk} + t_{yk} \cdot 2CT)$$

$$e_{xyk} = |t_{xk} - t_{yk}|$$

$$f_{xk} = |L_k - t_{xk}|$$

$$g_{xk} = |t_{xk} - CT|$$

[A]=A를 초과하지 않는 가장 큰 정수

첫번째 항은 작업시간의 합의 평균이 CT 에 가까운 2개의 품목으로 구성된 쌍에 속한 품목들은 투입순서가 인접되어야 함을 나타내고 있고, 두번째 항은 작업시간이 비슷한 품목들은 주기적으로 나타나야 함을, 그리고 세번째와 네번째 항은 작업시간이 작업영역의 길이와 가장 비슷한 품목, 즉 작업시간이 가장 긴 품목의 투입순서를 첫번째로 하고, CT 값에 가장 가까운 품목의 투입순서를 세번째로 함을 표현하고 있다. 따라서 E_2 를 최소화시킨다는 것은, 각 쌍에 배정된 두 품목의 작업완료 후에는 작업자의 위치가 작업장의 작업영역내의 CT 위치에 근접하고, 작업시간이 CT 값에 근접하는 품목들은 각 쌍들에 속한 품목들 다음으로 할당되어 가의작업으로 나아가는 경향이 좋고, 궁극적으로도 작업자의 위치가 CT 위치로 수렴하는 경향을 갖는다는 것을 의미한다. 그러므로 총에너지 함수 $E (= E_1 + E_2)$ 를 최소화 시킴으로써 가의작업량이 적은 해를 얻을 수 있게 된다.

3.3 변수값 결정을 위한 시뮬레이션

Hopfield의 TSP 신경망모형에서와 마찬가지로, NMS의

효율 및 검색된 가능해 갯수는 에너지함수에 포함된 변수 α, β 및 γ 에 민감하다. 가능해를 보장하기 위한 에너지함수 E_1 을 구성하고 있는 각 항에 가중치를 할당한다면, 첫 번째와 두 번째 항은 동일한 값을, 그리고 세 번째 항은 약간 적은 값을 부여하는 것이 타당하므로 $\alpha = \beta = \gamma + 1$ 의 관계를 설정한다. 일반적으로 변수값이 클수록 가능해에 손쉽게 도달하나, 많은 가능해를 탐색하지 않고 일찌기 수렴해 버리는 성질을 갖는다. 물론 적은 값을 할당하는 경우에는 반대 현상이 발생하여 많은 가능해를 탐색하지만, 정해진 탐색 횟수내에 실행 가능해에 수렴하지 못할 가능성이 커진다. 이와같은 이유로 해서 적절한 변수값을 얻기 위해서 수렴률(Convergence Ratio) 용어를 정의하고 이에 근거하여 변수값을 결정하고자 한다. 수렴률은 다음과 같다.

$$\text{수렴률} = \frac{\text{총학습횟수} - \text{수렴상태의 진입시점}}{\text{총 학습횟수}}$$

여기에서 총학습횟수 NR 은 초기온도가 T_f , 종료온도가 T_c 로 주어지고 온도감하율이 ϕ 로 주어진 경우

$$NR = \log_{\phi} (T_f / T_c)$$

가 된다. 여기에서 수렴상태의 진입시점이란 에너지 값이 수렴해로 진입하여 마지막 학습횟수까지 지속될 때 최초의 학습횟수를 말한다. 만일 에너지값이 수렴해로 진입하여 진행하다가 1~2회 정도 수렴해를 벗어났으나 곧바로 수렴해로 복귀하는 경우에도 수렴상태가 지속된 것으로 본다. 변수값이 증가함에 따라서 수렴률도 대체적으로 증가하게 된다. 변수값을 증가시키면서 NMS를 실행시켜 수렴률을 얻되 수렴률이 미리 정한 기준치에 최초로 초과할 때의 변수값을 선택한다. 그림 5는 표 1에 제시된 예제에 대하여 NMS가 해를 구해가는 학습과정을 에너지함수값의 변화로 나타내주고 있는 것으로, 학습이 진행되면서 에너지 함수값이 24.3 에 수렴해가는 것을 보여주고 있다. 이 그림에서 총학습횟수는 460이고, 수렴상태의 진입시점은 332이므로 수렴률은 0.28이 된다. 또한 그림 6은 수렴된 에너지 함수값에 대응되는 투입순서 즉 a→c→b→a→b→b 순서대로 조립라인에 투입되었을 때의 작업장내의 작업자의 이동을 보여주고 있다.

표 1. 예제

생산모델 및 생산 비율	$N_s=2, N_r=3, N_c=1$
고정사이클시간	CT = 85
작업장수	M = 5
각 작업장에 있어서 모델별 작업시간	$t_{s1}=85, t_{s2}=100, t_{s3}=95, t_{r1}=90, t_{r2}=97$ $t_{c1}=70, t_{c2}=80, t_{c3}=83, t_{c4}=90, t_{c5}=84$ $t_{c1}=95, t_{c2}=70, t_{c3}=65, t_{c4}=80, t_{c5}=70$
작업장의 작업영역	$L_k=100$

4. 실험 및 분석

시뮬레이티드 어닐링 신경망모형인 NMS는 SA기법을 이용하여 에너지함수의 최소화를 추구하는 것으로, 이 과정이 완료되면 하나의 수렴해를 얻게 된다. NMS의 에너지함수는 가능해를 보장하기 위한 부분 E_1 에 변수 α, β 및 γ 가 존재한다. 적절한 변수값을 결정하기 위하여 다양한 변수값에 따른 가능해 갯수 및 수렴률을 조사하였다

문제유형은 각 작업장에 배분된 모델의 작업시간이 모

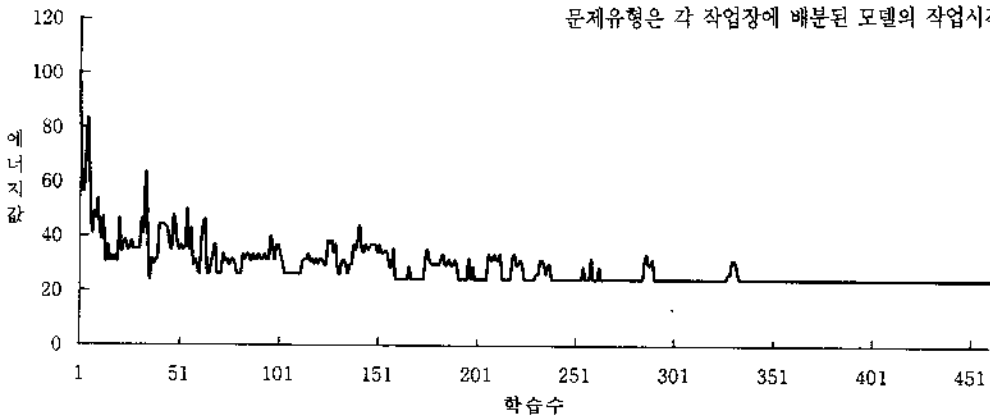


그림 5. 에너지함수의 수렴과정




그림 6. 수렴해에 의한 작업장 구성

든 작업장에 대하여 비슷한 값을 갖는 정도 즉 균등화를 이룬 정도에 따라서 A-type, B-type, C-type 으로 나누었는데, B-type은 균등화가 잘 이루어져서 편차범위가 평균치에 $\pm 5\%$ 미만이고, C-type은 균등화가 거의 이루어져 있지 않아서 $\pm 20\%$ 로 매우 큰 상황을 나타내며, A-type은 보통으로 $\pm 10\%$ 이다. 문제크기는 품목수 N 와 작업장수 M 의 쌍 (N, M) 으로 나타내며, 본 실험에서는 편의상 (6, 5), (6, 10), (9, 10) 및 (9, 15)의 4가지 경우에 한정하였다. 각 실험은 설정된 모든 문제에 대하여 문제유형에 약간의 변동을 가하여 3가지 경우로 나누어서, 각 경우마다 5회씩 반복실험하였다. NMS 및 비교기법인 Thomopolous 기법은 C언어를 이용하여 프로그래밍했고, 166MHz의 펜티엄CPU를 갖는 IBM-PC에서 실행되었다. 실험조건으로서 초기온도 $T_i = 5.0$, 종료온도 $T_f = 0.5$, 온도감하율 $\phi = 0.995$ 를 사용하여 총확습횟수 $n = 460$ 으로 하였다.

이 반복실험을 통하여 NMS수렴해의 신뢰성도 알아보았다. NMS는 SA기법을 사용하여 많은 가능해를 검색하지만, 수렴해가 반드시 검색한 여러 가능해 중에 최소값으로 수렴하지는 않는다. 온도감하율을 미세하게 함으로써 반드시 최소해로 수렴할 수는 있지만[5], 이를 위해서는 수많은 실행횟수가 요구됨으로 인해 적정횟수에서 검색을 종료하게 된다. 따라서 수렴해에 대한 신뢰성의 문제가 제기되게 된다.

그림 7은 변수값에 따른 검색된 가능해 수의 변화를 보여주는 것으로서, 변수값이 증가함에 따라 검색된 가능해 수가 증가하다가 점차로 감소하는 형태를 보이고 있다. 즉, 변수값이 적으면 많은 해를 검색하지만 가능해 수는




그림 8. 수렴률 추이($\alpha = \beta = \gamma + 1 = z$)

많지 않고, 변수값이 크면 검색된 해의 대부분이 가능해이지만, 이른 시점에 수렴해버리므로 검색된 총 가능해 수는 적어지게 된다. 이와 비슷한 결론을 그림 8의 수렴률추이 그래프에서 알 수 있는데, 변수값이 클수록 이른 시점에 수렴하는 것을 알 수 있다. 따라서 본 문제에 적합한 변수값으로는, 검색된 가능해가 많으면서 적절한 시점에서 수렴하는 범위인 $9 \leq \alpha = \beta = \gamma + 1 \leq 11$ 이 적당한 것을 알 수 있다.




그림 9. 유형별 검색된 가능해수($\alpha = \beta = \gamma + 1 = z$)




그림 7. 검색된 가능해수($\alpha = \beta = \gamma + 1 = z$)




그림 10. 유형별 수렴률($\alpha = \beta = \gamma + 1 = z$)

그러나, 검색된 가능해 수 및 수렴률추이는 문제유형에 따라 뚜렷한 차이를 보여주고 있다. 그림 9에서 보면 다른 유형에 비해 균형화가 잘 이루어져 있는 B-type일수록 적은 변수값에도 가능해로 수렴하는 것을 알 수 있고 검색된 가능해의 최대값도 적은 변수값에서 얻고 있음을 보여주고 있다. 또한 같은 변수값에도 이른 시기에 수렴하는 경향을 보이고 있음을 그림 10을 통하여 알 수 있다.

그림 11과 12는 수렴해들의 최소화율(=(수렴해-최소해)/수렴해)의 평균과 표준편차를 나타낸 것으로 수렴해가 최소해에 근접할수록 적은 값을 갖는다. 그림에서 알 수 있듯이, B-type은 평균과 표준편차가 큰 것으로 나타나므로 수렴해보다는 최소해를 최종해로 사용하는 것이 바람직하다고 보여진다. C-type의 경우는 수렴해를 최종해로 사용해도 무방하다고 본다.

NMS로 얻은 해와 수정된 Thomopoulos 휴리스틱기법을 사용하여 얻은 해와 비교분석을 실시하였다. Thomopoulos 휴리스틱기법은 가외작업량을 최소로 하고자 한 것으로, 작업장의 작업영역을 4구역으로 나누고 각각 비용계수를 주어서 전체비용을 최소로 하는 투입순서를 결정하는 것으로, 일반적으로 사용되고 있는 기법중의 하나이다. 본 비교실험을 위하여 가외작업영역을 2구역(그림 1에서 a, c)으로 수정하였고 비용계수를 1로 하였다. 비교실험 대상문제는 변수결정을 위해 사용했던 문제와 동일한 것이

다.




그림 11. 수렴해의 최소화율(평균)




그림 12. 수렴해의 최소화율(표준편차)

비교결과는 표 2에 요약되어 있다. 표 2에 나오는 NMS 결과치들은 수렴해(B-type의 경우는 최소해)의 총 가외작

표 2. NMS와 Thomopoulos기법과의 해의 비교

문제 유형	크기 (N,M)	문제 (1)			문제 (2)			문제 (3)			평균
		Thomo.	NMS	개선률	Thomo.	NMS	개선률	Thomo.	NMS	개선률	
A-type	(6, 5)	89.07	103.7	-0.16	79	82	-0.04	110.5	109.9	0.00	-0.07
	(6, 10)	114.1	127.2	-0.11	87.6	108.8	-0.24	136	151.5	-0.11	-0.16
	(9, 10)	206.8	222.7	-0.08	562.6	675.8	-0.2	608.9	686.7	-0.13	-0.14
	(9, 15)	405.7	421.9	-0.04	1029	983.6	0.04	777.2	837.8	-0.08	-0.02
B-type	(6, 5)	63	72.3	-0.15	32.8	32.8	0	54.7	47.9	0.13	-0.01
	(6, 10)	160.3	159.1	0.01	95.7	109.1	-0.14	102.6	113.4	-0.11	-0.08
	(9, 10)	183.1	182.3	0.00	140.3	125	0.11	302	284.8	0.06	0.06
	(9, 15)	243.2	214.2	0.12	293.7	302.3	-0.03	335.7	326.1	0.03	0.04
C-type	(6, 5)	550.4	564.4	-0.02	319.4	401	-0.26	212.4	235.4	-0.11	-0.13
	(6, 10)	594.6	663.4	-0.12	755.1	977	-0.29	1173	1204	-0.03	-0.15
	(9, 10)	1004	1111	-0.11	1399	1779	-0.27	1920	2174	-0.13	-0.17
	(9, 15)	3608	4230	-0.17	2266	2515	-0.11	2248	2645	-0.18	-0.15

업량이며 5회 반복실험한 평균치이다. 개선률은 Thomopoulos해법의 결과치에 대한 NMS결과치의 개선비율이고, 평균은 각 개선률의 평균치이다. 표 2에서 알 수 있는 것은 B-type의 문제처럼 작업시간의 균등화가 좋은 문제의 경우에는 NMS해가 Thomopoulos 휴리스틱기법의 해와 비슷한 결과 혹은 더 좋은 결과를 제공하고 있다. 이는 순서결정기법으로 NMS를 사용하려면 먼저 작업장간의 작업시간 균등화가 선행되어야 한다는 것을 알 수 있다. 또한 그림 7에서 알 수 있듯이 NMS는 460번의 학습횟수 중에 최대 20 ~ 30 개의 가능해를 검색하고 있다. 이러한 검색횟수는 문제크기가 큰 문제에는 충분하지 못함으로 인해 적은 문제의 경우보다 결과가 좋지 않음을 보여주고 있다.

5. 결론 및 추후 연구 과제

혼합형조립라인의 순서결정문제에 시뮬레이티드 어닐링 신경망모형을 구현하여 Thomopoulos기법과 결과분석을 수행하였다. 분석결과 작업장간의 작업부하의 균등화가 잘 이루어진 문제에 대해서는 주어진 학습횟수에서 개선안을 찾아내었지만 대부분의 문제에 대해서는 좋은 결과를 얻지 못했다. 이는 시뮬레이티드 어닐링 신경망모형이 과도한 실행시간이라는 현실적인 제약으로 인해 개선안을 찾아낼 만큼 충분한 학습을 할 수 없었기 때문이다.

MASP모형으로는 Thomopoulos [9]를 위시한 조합최적화 모형과 최근 연구로는 유전 알고리즘을 이용한 모형 [2]이 제안되고 있다. 이들 모형들과의 비교연구가 계속하여 수행되어야 할 것이다. NMS를 개발하는데 있어서 문제유형에 따라 혹은 실제 상황에 따라 에너지함수 및 변수설정 방법등에 여러가지 대안이 있을 수 있다고 본다. 이러한 대안 모색도 남은 연구과제가 될 것으로 본다.

참고문헌

- [1] 김대수, 신경망이론과 응용, 하이테크정보, 1994
- [2] 현철주, "혼합모델조립라인의 투입순서결정을 위한 유전알고리즘", 전남대학원 산업공학과, 박사논문, 1996.2
- [3] Arizono, I., A. Yamamoto, and H. Ohta, "Scheduling for minimizing total actual flow time by neural networks", *Int. J. Prod. Res.*, Vol.30, No.3, pp. 503-511, 1992
- [4] Dar-EL, E. M., "Mixed model assembly line sequencing problems", *Omega*, Vol.6, No.4, pp. 313-323, 1978
- [5] Geman, S., and D. Geman, "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images", *IEEE Trans, PAMI-6*, pp.721-741, 1984
- [6] Hopfield, J. J., and D. W. Tank, "Neural computation of decision in optimization problem", *Biological Cybernetics*, Vol.52, pp.141-152, 1985
- [7] Kirkpatrick, S., C.D. Gelatt, and M. P. Vecchi, "Optimization by simulated annealing", *Science*, Vol. 22, pp.671-680, 1983
- [8] Lo, Z. P., and B. Bavarian, "Multiple job scheduling with artificial neural networks", *Computers Elect. Engng.*, Vol.19, No.2, pp.87-101, 1993
- [9] Thomopoulos, N. T., "Line balancing-sequencing for mixed model assembly", *Management Science*, Vol. 14, No.2, pp.B59-75, 1967