

혼합조립라인에 있어서 투입순서결정을 위한 신경망모형

김 만수

동신대학교 산업공학과

Abstract : This paper suggests a boltzman machine neural network model to determine model input sequences in line balancing process of mixed model assembly line. We first present a proper energy function, next determine the value of parameters using simulation process

Key words : boltzman machine neural network, sequencing of mixed model assembly

1. 서론

.신경망은 화상처리, 음성인식 및 구문처리등과 같은 문제들을 푸는데 탁월한 방법론이다. 복잡한 현실문제들을 신경망모델을 통하여 풀고자 하는 연구들은 Hopfield [5]가 TSP 문제에 신경망모델을 적용한 것을 기점으로 최적화 부문의 여러 분야까지 확대되게 되었다. 특히 스케줄링이나 순서결정 문제에 활용도가 높은 것으로 보고되고 있다.

본 논문은 혼합형 조립라인의 투입순서 결정문제를 신경망모형을 구현하여 풀고자 하였다. 혼합형 조립라인은 현재 대부분의 자동차 조립라인에서 채택하고 있는 방식으로서 다양한 모델을 생산하면서도 납기를 단축하고 동시에 동일 라인에서 다양한 모델들을 만들어 내고자 하는 것으로 경쟁력을 확보하기 위해서는 필연적인 조립방식이라고 볼 수 있다.

이러한 혼합형 조립라인에 있어서 복잡한 의사결정으로서 투입순서 결정문제가 있다. 투입순서 결정(Sequencing)이란 하나의 라인에서 여러종류의 모델을 생산하고자하는 혼합조립라인에서 고정 사이클타임 방식이 적용되었을 때 모델간의 제조순서를 결정하는 절차이다. 그러나 라인밸анс의 결과로서 각 모델에게 할당된 작업시간은 작업장마다 다르고 또한 순서를 정해야 할 품목 갯수에 따라서 가능해 가기하급수적으로 크게 증가하므로 인해 최적해보다는 근사해를 얻는 것이 바람직하다. 이처럼 복잡한 순서결정 문제에 신경망모형을 적용할 때 그 결과가 높을 것으로 예상되고 또한 신경망모형을 조합최적화 문제 및 제조부문의 여러 분야에 적용하는 동기부여와 추후 연구에 기여할 것으로 보여진다.

2.연구배경

2-1. 혼합형 조립라인의 투입순서결정

혼합형 조립라인의 투입순서 결정문제는 모델들의 투입간격 즉 사이클타임을 각 모델마다 다르게 하지 않고 모든 모델에 동일하게 하는 고정 사이클타임(fixed cycle time)방식을 적용한 경우에 발생한다. 이 경우 제품을 완성하는데 요구되는 작업량과 총 조립시간은 모델마다 다른 경우가 대부분이므로 작업장을은 작업부하의 불균형을 초래하게 된다.

이 문제에 대한 휴리스틱 해법들은 목적 함수에 따라 구분할 수 있는데 전체 라인길이를 최소로하는 연구는 Dare-el [4]에 의해서, 영역외 작업량을 최소로 하여 작업장의 효율을 높이려는 연구는 Thomopoulos [8]에 의해 수행되었다.

2-2. 순서결정 문제에 신경망의 응용

Hopfield 및 Tank [5]는 NP-complete 최적화문제로 알려진 TSP를 신경망을 사용하여 모델화하고 해를 구하였다. 이 모델은 미분강 하법(differential gradient descent approach)

을 사용하였는데 이 방법은 초기치로 부터 시작하여 에너지함수 즉 성능평가함수를 줄이는 방향으로 진행하여 어떤 최소점을 얻는 것이다. Kirkpatrick et al [6]에 의한 또 다른 모델은 SA(Simulated Annealing)기법을 응용한 것으로 이는 미분강화법의 결과 얻어지는 부분 최소치(local minimum)를 탈출할 수 있는 방안을 제시하고 있다.

미분강화법을 사용하는 경우에는 어떤 요소 x 의 출력상태 $u(x)$ 는 오직 에너지변화량 ΔE 에 의해서만 0 혹은 1로 결정된다. 즉

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

그러나 SA법을 사용할 경우에는 각 요소들의 출력상태는 ΔE 및 온도변수 T 에 의해 결정되게 된다. 즉

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

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

여기에서 $p(\text{rand})$ 란 임의의 랜덤숫자 추출함수에 의해 얻어진 확률값이다. 온도변수 T 는 초기에는 큰 값을 갖지만 강화율에 의해 점차적으로 적은 값을 갖게 된다. T 의 영향으로 $\Delta E < 0$ 임에도 불구하고 $u(x)$ 값이 1이 되기도 한다. 이러한 변화에 의해 하나의 부분 최소치를 벗어나 다른 최소치를 탐색할 수 있게 된다.

스케줄링문제에 신경망을 적용한 연구들은 최근에 증가하고 있다.[3, 7] 그러나 혼합형 조립라인의 투입순서결정 문제에 신경망모형을 적용한 연구는 없었다.

3. 연구내용

Hopfield의 TSP 신경망모형을 근거로 해서 MAS에 적합한 볼츠만 머어신 신경망 모형의 하나로서 신경망 투입순서모형(NSM: Neural Sequencing Model)을 제안한다. 이 모형은 영역외 작업량을 최소로 하기 위해서는

각 품목들의 투입순서는 작업시간이 긴 품목과 작은 품목들이 번갈아가며 투입되어야 한다는 개념을 볼트만 신경망모델의 에너지함수에 적용한 것이다.

3-1. 혼합형 조립라인에 있어서 신경망 투입순서모형(NSM)

조립라인에서 생산해야 할 모델종류가 n 이라고 하자. 각 모델의 생산비율이 각각 N_1, N_2, \dots, N_n 이면 생산비율의 총합인 $N (= \sum N_i)$ 단위간의 투입순서만을 정하면 된다. 신경망의 각 정보처리 요소는 어떤 단위품목이 몇 번째 투입순서를 갖는가를 표현해야 하므로 총 N^2 개가 필요하게 된다. 따라서 신경망의 정보처리요소들을 $N \times N$ 매트릭스형으로 표현하여 행은 투입순서를, 열은 순서를 결정할 품목을 나타내게 한다. 본 모델에 사용되는 기호들은 다음과 같다.

N : 투입순서를 결정하고자 하는 품목 수

M : 작업장 수

u_{xj} : 정보처리요소(xj)의 출력

t_{xk} : 작업장 k 에서 품목 x 의 작업시간

L_k : 작업장 k 의 작업영역 길이

CT : 모든 품목에 공통으로 적용되는 고정사이클 시간

볼츠만 신경망모델을 구현하는데는 무엇보다도 문제에 맞는 적절한 에너지함수를 만들어야 한다. NSM의 경우 제시된 에너지함수는 두 부분 E_1, E_2 으로 구성되어 있는데 E_1 은 가능해를 보증하기 위한 것이고 E_2 는 최적해에 가까운 근사해를 얻고자 하는 것이다. NSM은 E_1 과 E_2 를 동시에 감소시켜서 가능근사해를 제공하게 된다. E_1 은 아래와 같다.

$$E_1 = \alpha \sum_{i=1}^N \sum_{j \geq i} \sum_{x=1}^N U_{xi} U_{xj} + \beta \sum_{x=1}^N \sum_{y \geq x} \sum_{j=1}^N U_{xj} U_{yj}$$

$$+ \gamma \sum_{x=1}^N \sum_{j=1}^N (U_{xj} - N)^2$$

첫번째 항에서는 각 품목은 하나의 투입순서만을 갖도록 두번째 항에서는 각 투입순서는 오직 하나의 품목에 할당되는 방향으로 나아가도록 유도하고 있다. 그리고 세번째 항은 출

력이 1인 정보처리 요소의 갯수가 N이 되도록 제한하고 있다. 이로써 가능한 해가 얻을 수가 있게 된다. 여기에서 사용된 변수 a , β 및 γ 는 일종의 Lagrangian 상수로써 각 항에 적당한 가중치를 부여함으로써 가능해에 도달하도록 한다.

E_2 는 가능한 한 작업장의 작업영역 범위 내에서 작업이 완료될 수 있게 하는 상태를 표현하게 된다. 이를 위하여 NSM에서는 작업 완료시간이 작업영역내의 고정사이클시간 위치로 되돌아오는 것을 반복하면서 궁극적으로 고정 사이클시간 위치로 수렴하는 형태가 되도록 투입순서를 결정한다. 어떤 작업장에서 투입순서에 의해 처리되어야 할 품목들의 작업시간들이 평균 작업시간 즉 고정사이클시간 CT를 중심으로 분포되어 있으므로 모든 작업 시간들은 합의 평균이 CT에 근접하는 쌍들로 구분할 수 있고, 각 쌍에 속하여 있는 품목들의 투입순서는 인접시킨다. 이러한 작업장상태를 반영할 에너지 함수 E_2 는 아래와 같이 주어진다.

$$E_2 = \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} \sum_{k=0}^{M-1} \sum_{i=0}^{N-4} e_{xyk} u_{x,i} (u_{y,y+3} + u_{y,i-3}) \\ + \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} \sum_{k=0}^{M-1} \sum_{i=0}^{[(N-1)/3]} d_{xyk} u_{x,3i} (u_{y,3i-2} + u_{y,3i+1}) \\ + \sum_{x=0}^{N-1} \sum_{k=0}^{M-1} f_{xk} u_{x,0} + \sum_{x=0}^{N-1} \sum_{k=0}^{M-1} g_{xk} u_{x,2}$$

여기에서

$$d_{xyk} = (-\pi_1 + \delta(\pi_2 + \pi_1))(t_{xk} + t_{yk} - 2CT)$$

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

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

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

π_1 = 작업영역의 하한 한계손실비용

π_2 = 작업영역의 상한 한계손실비용

$$\delta = \begin{cases} 0, & \text{if } t_{xk} + t_{yk} \leq 2CT \\ 1, & \text{o/w} \end{cases}$$

[A] = A를 초과하지 않는 가장 큰 정수

첫번째 항은 작업시간의 합의 평균이 CT

에 가까운 품목들은 투입순서가 인접되어야 함을 설명하고 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 CT값에 가장 가까운 품목의 투입순서를 세번째로 하는 것을 표현하고 있다.

따라서 E_2 를 최소화하는 것은 각 품목들의 완료시간들이 작업장의 작업영역내의 CT 위치로 되돌아오고 궁극적으로 CT위치로 수렴하는 것을 의미하게 된다. 그러므로 총 에너지함수 E (= $E_1 + E_2$)를 최소화시킴으로써 만족할만한 가능해를 얻게 된다.

3-2. 변수 값 결정을 위한 시뮬레이션

Hopfield의 TSP 신경망모형의 경우와 마찬가지로 간단한 사전테스트에 의해 NSM의 효율 및 실행 가능해는 에너지함수 E의 변수 a , β 및 γ 에 민감한 것을 알 수 있었다. 일반적으로 변수 값이 클수록 실행 가능해에 손쉽게 도달하나 다른 실행 가능해를 더 탐색하지 않고 일찌기 수렴해 버리는 성질을 갖는다. 물론 적은 값을 할당하는 경우에는 반대 현상이 발생하여 많은 실행 가능해를 탐색하지만 정해진 탐색 횟수내에 실행 가능해에 수렴하지 못할 확률이 커진다.

이와같은 이유로 해서 적절한 변수를 얻기 위해서 수렴률(Convergence Ratio)용어를 정의하고 이에 근거하여 변수 값은 결정하고자 한다. 수렴률은 다음과 같다.

$$\text{수렴율} = \frac{\text{총 학습횟수} - \text{평행상태의 진입시점}}{\text{총 학습횟수}}$$

여기에서 총 학습횟수 n은 초기온도가 T_I , 종료온도가 T_F 로 주어지고 온도강하율이 ϕ 로 주어진 경우

$$n = \log_\phi (T_F / T_I)$$

가 된다. 평행상태의 진입시점이란 에너지 값이 최종해로 수렴되기 시작하는 학습횟수를 말한다. 변수 값이 증가함에 따라서 수렴률도 대체적으로 증가하게 될 것이다. 수렴률이 미

리 정한 기준치에 최초로 초과할 때의 변수값을 선택한다.

그림1는 표1에 제시된 간단한 예제에 대하여 변수값에 따라서 수렴률이 변화하는 것과 변수값이 ($\alpha = \beta = 20$, $\gamma = 19$)로 결정되는 것을 나타내고 있고 그림 2은 선택된 변수값을 가진 에너지 함수가 실행 가능해에 수렴해가는 것을 보여준다.

표1. 예제

| 생산모델 및 $N_A=2$, $N_B=3$, $N_C=1$ | |
|------------------------------------|---|
| 생산비율 | |
| 사이클시간 | CT = 85 |
| 작업장수 | M = 5 |
| 작업편성 | $t_{A1} = 85$, $t_{A2} = 100$, $t_{A3} = 95$, $t_{A4} = 90$, $t_{A5} = 97$ $t_{B1} = 70$, $t_{B2} = 80$, $t_{B3} = 83$, $t_{B4} = 90$, $t_{B5} = 84$ $t_{C1} = 95$, $t_{C2} = 70$, $t_{C3} = 65$, $t_{C4} = 80$, $t_{C5} = 70$. |
| 비용계수 | $\Pi_1 = 5$, $\Pi_2 = 6$ |
| 작업영역 | $L_k = 100$ |

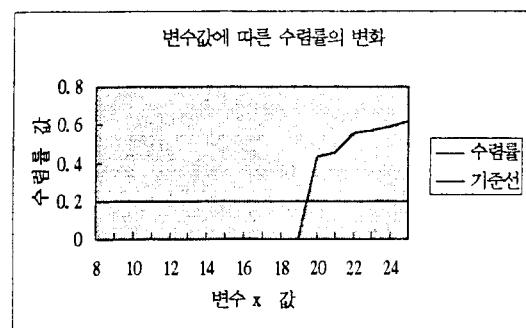


그림 1. 변수값에 따른 수렴률의 변화
($\alpha = \beta = x$, $\gamma = x-1$)

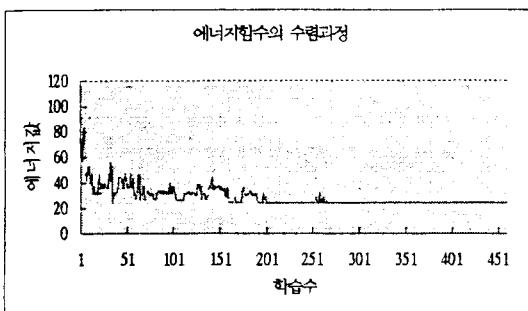


그림 2. 에너지함수의 극사해 수렴과정

4. 추후 연구 과제

MAS모형으로는 보편적으로 사용되어온 Thomopoulos [8]를 위시한 조합최적화 모형과 최근 연구로는 유전 알고리즘을 이용한 모형[2]이 제안되고 있다. 이들 모형들과의 비교 연구가 계속하여 수행되어야 할 것이다.

NSM을 개발하는데 있어서 에너지함수 및 변수설정 방법등에 여러가지 대안이 있을 수 있다고 본다. 이러한 대안모색도 남은 연구 과제가 될 것으로 본다.

5. 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., 30, 3, 503-511, 1992
- [4] Dar-el, E. M, Mixed model assembly line sequencing problems, Omega 6, 4, 313-323, 1978
- [5] Hopfield, J. J and D. W. Tank, Neural computation of decision in optimization problem, Biological Cybernetics 52, 141-152, 1985
- [6] Kirkpatrick, S., C.D. Gelatt and M. P. Vecchi, Optimization by simulated annealing, Science 22, 671-680, 1983
- [7] Lo, Z. P and B. Bavarian, Multiple job scheduling with artificial neural networks, Computers Elect. Engng. 19, 2, 87-101, 1993
- [8] Thomopoulos, N. T., Line balancing-sequencing for mixed model assembly, Management Science 14, 2, B.59-75, 1967