

신경회로망을 이용한 생산라인 최적화

Manufacturing Line Optimization Using Artificial Neural Networks

허 철 회*, 박 진 희**, 정 환 목**

*성덕대학 컴퓨터정보계열

** 대구가톨릭대학교 컴퓨터정보통신공학부

Chulwhei Her, Jinhee Park, Hwanmok Chung
Faculty of Computer Information & Communication,
Catholic University of Taegu
E-mail : herch@hanmir.com

ABSTRACT

생산품을 제조하는 과정에서 처리 시간에 따른 제조 기계를 최적의 수로 결정함으로서 공정 과정에서 비효율적인 제조 기계의 활용 비율을 줄일 수 있으며, 이는 공정 과정의 비용을 최소화할 수 있는 방법 중에 하나이다.

본 논문에서는 핸드폰에 사용되는 여러 가지 모델의 배터리를 생산하는 공장의 작업 과정을 조사하고, 일정하지 않은 처리 시간과 작업에 필요한 제조 기계를 조사하였다. 이를 인공 신경망(ANN)의 역전파 알고리즘을 이용하여 생산현장에서 효율적인 처리 시간과 공정 과정에서 생산에 적합한 기계의 수를 최적화시키는 방법을 제안한다.

키워드 : 신경망, 역전파알고리즘, 자동화 시스템, 최적화

I. 서론

자동화시스템에서 최적의 생산 조건 즉 공정의 최적화를 이루기 위해서 가장 큰 문제점은 여러 기계의 초기치(setup value) 또는 공정 파라미터를 설정하는 데 있다. 여러 제품을 생산하는 산업현장이나 찾은 조업 조건의 변화, 예측할 수 없는 상황 즉 기계의 고장 등의 변화에 따른 적절한 공정 파라미터를 산정하기 위해서는 온라인 학습기능과 여기서 얻은 지식을 바탕으로 한 최적화 기법이 더욱 중요하다 [5]. 주로 패턴 인식이나 분류에 이용되던 신경망의 역전파알고리즘을 이용한 인자간의 관계 도출의 경우 회귀식에 의한 방법보다 효율적임이 증명되었다[4]. 이 후 주로 역전파 신경망의 보다 효율적인 학습 알고리즘을 위한 연구가 진행되어 왔으며 제약 조건이 없을 때와 있을 때에 최적화 문제에 신경망을 이용하는 방법을 Chen & Lee가 제안하였다[5,6]. 또한 Rangwala

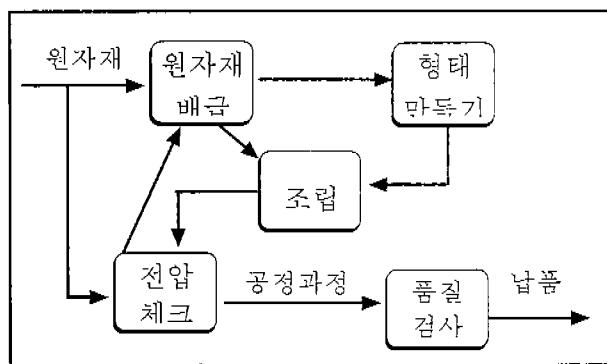
& Dornfeld[7]는 절삭 작업에서의 최적의 절삭율을 위한 파라미터의 산출을 위하여 역전파 신경망을 적용하였다.

본 논문에서는 핸드폰에 사용되는 여러 가지 모델의 배터리를 생산하는 공장의 작업 과정을 조사하고, 일정하지 않은 처리 시간과 작업에 필요한 제조 기계를 조사하였다. 이를 인공 신경망(ANN)의 역전파 알고리즘을 이용하여 생산현장에서 효율적인 처리 시간과 공정 과정에서 생산에 적합한 기계의 수를 최적화시키는 방법을 제안한다.

II. 제조 과정 및 시스템 분석

배터리 조립의 공정은 원자재 배급, 형태 만들기, 조립, 전압 확인, 품질 검사소 등의 5개의 부문으로 구성된다. 여러 가지 모델의 원자재가 공장에 들어오면 첫 번째 공정인 원자재 수급에서 모델에 따라 분류된다. 그리고 형태 만들

기의 공정에서는 원자재를 주어진 모델에 따라 그 형태를 만든다. 조립 공정에서는 기계가 형틀에 맞게 조립한다. 전압 확인 공정에서는 배터리 완제품을 위한 전압과 필요한 내용을 확인한다. 다음 공정은 품질 검사소인데 여기서는 만들어진 배터리를 마지막으로 충격 검사 및 외형 검사, 상표 부착 상태 등을 검사한다. 그리고 배터리의 정상적인 동작여부를 검사한다. 그래서 그 배터리들이 패키이지화 되고 출고될 준비가 된다. 이것이 각각의 과정이다. 이러한 작업을 위한 기계의 대수는 어떤 합리적인 방법보다는 경험에 위해서 수행되고 있다. 자연히 그들의 공정 과정에서 작업 처리에 불일치가 일어난다.

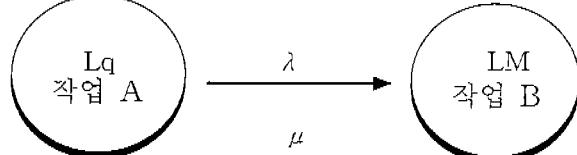


[그림 1] 배터리 제조 과정에서 작업 흐름도

III. 신경망을 이용한 최적화

3.1 신경망의 구축

효과적인 시스템 관리는 최소의 처리 공정 재고와 충분한 기계의 작업으로 생산품을 만들어내는 것이다. 그러나 일반적으로 작업을 할 수 있는 기계는 제한되어 있다. [그림 2]에서는



[그림 2] 작업 상태 사이의 관계

작업 공정에서 작업하는 상태의 관계도를 볼 수 있다. 여기서

Lq : 처리 작업의 평균 시간

λ : 자재가 작업A에서 B로 가는 시간
(자재/시간)

μ : 작업B에서 처리되는 비율 (자재/시간)

Mc : 작업장 B에서의 작업 기계 수
을 나타낸다.

[그림 2]의 작업 상태 사이의 관계에서 처리 과정에서의 재고는 항상 충분하나 작업간의 자재 이동시간이 불규칙하면, 작업 처리 시간과 기계의 수를 최적화시키는 것이 가장 바람직한 시스템 운영이다. 따라서 중요한 학습 파라미터는 각 공정에서 처리하게 될 기계의 경로를 결정하는 것으로 여기서는 시스템의 상황에 따라 선택하는 동적(Dynamic) 방법을 이용한다. 그러므로 원자재의 처리시간과 처리비용을 최적화 할 수 있는 작업순서의 결정도 시스템 상태에 적응할 수 있는 동적 방법을 이용한다.

처리 작업(Lq)의 평균 시간은 작업상태(λ)에서 자재의 여러 가지 흐름과 자재 처리(μ) 비율, 그리고 작업에 이용되는 기계의 수(Mc) 등을 고려하여 대기행렬(queuing)이론을 이용하여 구할 수 있다. 이 계산 방법은 Lq 에 대응하는 λ , μ , Mc 의 값을 ANN으로 학습시켜 얻을 수 있다. 기계(Mc)가 병렬로 나열되어 있고, 사용이 일정하지 않은 시스템의 순서를 유지하기 위하여 다음과 같이 표현할 수 있다.

$$\lambda / \mu < Mc$$

어느 기계도 작업하지 않을 확률 P_0 을 계산하면 식(1)과 같다.

$$P_0 = \frac{1}{\sum_{n=0}^{Mc-1} \frac{(Mc \varphi)^n}{n!} + \frac{(\lambda / \mu)^{Mc}}{Mc! (1 - \varphi)}} \quad \dots(1)$$

또한 각 기계의 평균 작업 시간의 기대치는 식(2) 같이 계산할 수 있다 [2,3].

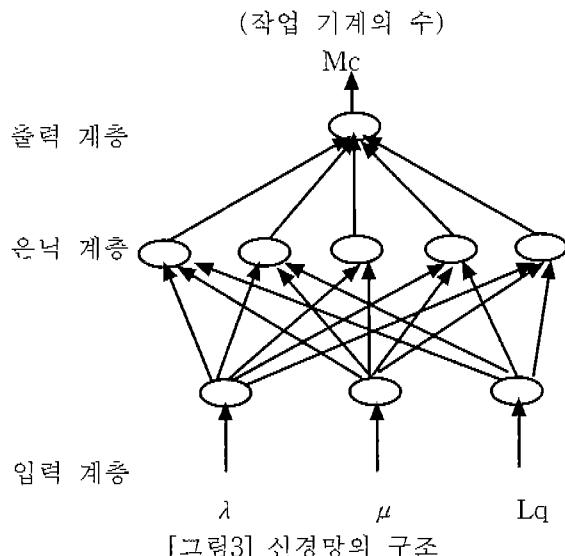
$$Lq = \frac{\lambda \mu (\lambda / \mu)^{Mc}}{P_0} = \frac{(Mc \varphi)^{Mc} \varphi P_0}{(Mc-1)! (Mc \mu - \lambda)^2} \quad \dots(2)$$

여기서 $\varphi = \lambda / Mc \mu$ 이다.

본 논문에서는 역전파 학습을 기본으로 하는 3 단계 ANN을 이용한다. 이 모델의 구조는 [그림 3]과 같다. 이 맵은 입력 계층, 출력 계층, 은닉 계층으로 구성된다. 은닉 계층의 네트워크는 3개의 입력과 5개의 노드를 가지며 한 개의 출력 계층을 갖는다.

일반적으로 역전파 신경망에서 이용하는 활성 함수는 시스모이드나 hyperbolic-tangent 비선형 함수를 적용한다. 시스모이드 함수는 패턴 분류에 적합하고 hyperbolic-tangent 비선형 함수는 일반적인 학습에 적합하다. 이 함수를 사용하여 학습능력을 향상시키며, 다중 퍼셉트론 네트워크를 사용하고, 최적의 결과는 은닉 계

총을 이용하여 얻을 수 있다. 학습률 $\epsilon = 0.7$ 로 하였다. 또한, 지역 최소점에서 탈출하기 위하여 모멘텀 항(momentum term)을 이용하여 조절하며, 그 학습 처리 속도의 조절량은 $\alpha = 0.7$ 로 한다.



3.2 최적화 알고리즘

최적화 알고리즘은 출력치 즉 작업 시간 내에 사용할 최적의 기계 수를 찾는 것이다. 자재의 흐름 및 처리(μ)의 입력치는 보통 조정이 가능한 변수로서 기계의 초기치, 공정에서의 파라미터들은 상한과 하한이 주어진다. 출력치는 목표 값에 근사한 값이, 기계 고장을 방지하거나 부담을 주지 않기 위해 상한만이 주어진다.

알고리즘

1 단계: 학습할 때 사용한 자료에서 목표 값이 있는 출력인자들의 값을 비교하여 그 절대 편차의 합이 가장 작은 자료를 입력인자의 초기치를 설정하여 탐색시간을 줄이는 효과와 최적해에 가까운 곳에서 탐색을 시작할 수 있도록 한다.

2 단계: 1단계에서 구한 초기해와 출력된 값을 비교하여 그 차이만큼 목표 값을 변경 한다.

3 단계: 목표 값이 있는 출력인자에 대한 최적 입력치를 탐색한다.

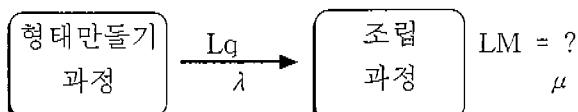
4 단계: 3단계에서 구한 최적 입력에 대한 출력 값이 상한의 제약 조건을 만족하면 탐색을 끝낸다. 만족하지 못할 경우 입력치를 갱신한다.

입력의 하한과 상한은 제약 조건에 따라 3 단계와 4 단계의 해의 갱신 과정에서 검증하여 제약 조건을 만족시키지 못하면 그 값을 한계

에 고정시키고 그 이외의 인자를 변화시켜 출력인자를 만족시키도록 한다.

IV. 적용 사례

배터리의 여러 가지 종류가 공장에서 제조된다. 그러나 여기에서는 제조 과정이 까다로운 2개 모델의 배터리를 선정하였다. 이 2개의 모델을 하나의 예로 들었다. 형태 만들기 과정에서 조립 과정으로 넘어가는 배터리의 자료에 관해서는 아래와 같이 주어진다. 작업 처리 계층의 생산 과정에 문제가 발생하지 않는다면 어떻게 작업 기계의 수를 결정하는지 알아보자.



[그림 4] SCH-A100모델의 흐름도

- 형태 만드는 과정(λ): 8 자재/시간 자재 이동
- 조립 과정(μ) 자재 처리 비율 : 3 자재/시간
- 비용 자재 : 1,500 원/시간
- 작업 기계의 비용 : 10,000 원/시간

이들의 관계를 다음과 같이 구할 수 있다.

TLq : 작업처리과정의 총 비용

ULq : 작업처리과정의 단위 비용

NL : 작업처리과정 단계

CM : 기계의 비용

만약 $TLq > CM$ 이면

기계를 이용하여 작업을 한다.

만약 $TLq < CM$ 이면,

다음과 같이 처리 작업 과정을 만든다

$$TLq = ULq * NL \dots (1)$$

따라서, 다음과 같은 부등식을 얻을 수 있다.

$$NL < CM / ULq \dots (2)$$

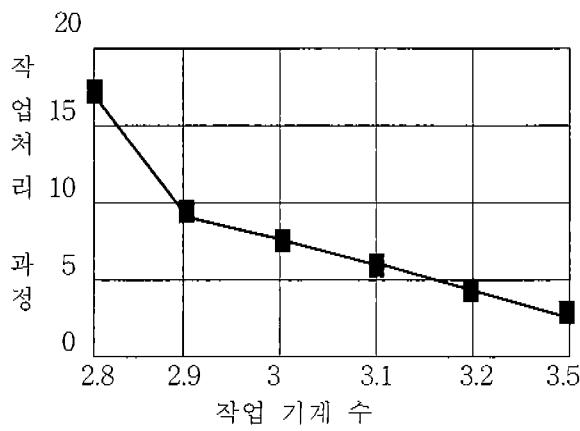
처리 계층 작업 = $< 10000 / 1500 = 6.66$ 수/시간

(1)과 (2)식에서 8개의 원자재가 주어지고, 원자재 처리 비율이 3이면, 처리 계층의 작업 6.66이 신경망의 입력 계층에 주어지면, 알고리즘에 의해 출력 계층에 3개의 처리작업 기계를 얻을 수 있다.

그러므로 총비용을 다음과 같이 구할 수 있다.

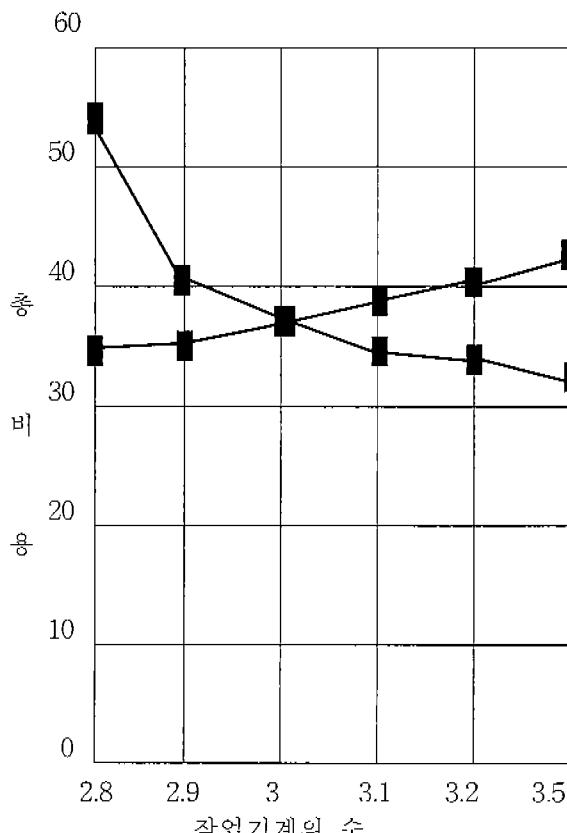
총비용 = 작업기계의 비용 + 처리작업과정의 비용

$$\begin{aligned} \text{총비용} &= (3 * 10000) + (6.66 * 1500) \\ &= 39,990 \text{ 원/시간} \end{aligned}$$



[그림 5] 작업처리과정 대 작업 기계의 수

[그림6]에서는 총비용이 가장 작은 비용으로 계산되는 것을 알 수 있다.



[그림 6] 작업기계의 최적화 수

V. 결론

통계적 방법이나 대기행렬 이론을 이용하여 작업 처리 과정의 각 계층에서 입력 값으로 받아들이는 최적화 된 작업 기계의 수를 찾는 것은 불가능하다. 그래서, 본 논문에서는 대기행렬의

규칙과 함께 ANN학습으로부터 결과를 얻는 방법을 이용하였다.

본 연구는 대기행렬이론의 규칙으로부터 값을 구하여 ANN에 위한 학습 집합을 이용하는 것이다. 생산라인에 2 종류의 배터리와 5개의 공정으로 이루어지는 단순한 예로 구성하였다. 이것은 생산라인의 종류에 따라 학습하는 상태를 나타낼 수 있기 때문이다. 그러나 공정 과정 중에 기계가 고장나거나 외부의 비용이 전혀 없는 것으로 하였으나 이는 비용 산정에 있어 중요한 요소이기 때문에 이에 대한 연구가 있어야 하겠다.

감사의 글 : 본 연구는 2000년도 중소기업청 연구비지원으로 수행되었음

참고문헌

- [1] Peter B. Luh, Xiaohui Zhou, Robert N. Tomastik "An Effect Method to Reduce Inventory in Job Shop" Proceedings of the 1999 IEEE International Conference on Robotic & Automation Detroit, Michigan, PP.787-792, May, 1999
- [2] 이규화, O.R., 전영사, 1971
- [3] Wayne L. Winston, "Operation Research : Applications and Algorithms", Indiana University, 1987
- [4] P. J. Werbos, "Building and understanding adaptive system : A statistical/numerical approach to factory automation and brain research", IEEE Trans. on Systems, Man and Cyber., SMC-17, 1987, pp.7-20
- [5] H. Chen & S. J. Lee, "Optimization search using neural networks", IJCNN-1990, Vol. II, pp.503-506
- [6] H. Chen & S. J. Lee, "Design Optimization with back-propagation neural networks", IJCNN-1992, Vol.II, pp.507-512
- [7] Rangwala & Dornfeld, "Learing and optimization of machining operation using cumputing abilities of neural networks", IEEE Trans. on Systems, Man and Cyber., Vol.19, No.2, 1989, pp.299-314