

▣ 응용논문

셀 생산방식에서 자기조직화 신경망과 K-Means 알고리즘을 이용한 기계-부품 그룹 형성

Machine-Part Grouping in Cellular Manufacturing Systems Using a Self-Organizing Neural Networks and K-Means Algorithm

이상섭*

Lee, Sang Sub

이종섭*

Lee, Jong Sub

강명규*

Kang, Maing Kyu

Abstract

One of the problems faced in implementing cellular manufacturing systems is machine-part group formation. This paper proposes machine-part grouping algorithms based on Self-Organizing Map(SOM) neural networks and K-Means algorithm in cellular manufacturing systems.

Although the SOM spreads out input vectors to output vectors in the order of similarity, it does not always find the optimal solution. We rearrange the input vectors using SOM and determine the number of groups. In order to find the number of groups and grouping efficacy, we iterate K-Means algorithm changing k until we cannot obtain better solution.

The results of using the proposed approach are compared to the best solutions reported in literature. The computational results show that the proposed approach provides a powerful means of solving the machine-part grouping problem. The proposed algorithm is applied by simple calculation, so it can be for designer to change production constraints.

1. 서론

그룹 테크놀로지(Group Technology: GT)는 부품의 형상, 치수, 가공공정 등의 유사성을 고려하여 부품을 그룹화하여 생산효율을 높이는 기법이다. GT는 여러 작업들을 그룹화하여 같은 공구나 고정구를 사용할 수 있게 하고 각 작업의 준비시간, 공정간 운반거리, 비용 등을 감소시킬 수 있다. GT의 이러한 개념을 제조시스템에 적용시킨 것이 셀 생산방식(cellular manufacturing)이다. 셀 생산방식에서는 모든 부품과 기계를 유사한 그룹의 셀로 그룹화시켜 경제적 이익을 창출한다[1].

셀 생산방식 시스템의 설계는 셀 형성, 기계 배치, 셀 배치의 세 가지 단계로 이루어진다. 이 세 단계 중에서 가장 먼저인 셀 형성 단계가 가장 중요한 단계이다. 셀 형성 단계에

* 한양대학교 산업공학과

서는 부품 그룹(part family)과 기계 그룹(machine cell)을 형성하고, 각 부품 그룹을 대응하는 기계 그룹에 배치하는데 이를 기계-부품 그룹형성(machine-part group formation)이라고 한다 [1, 9].

그림 1은 기계-부품 그룹형성 문제의 한 예로서, 입력데이터가 (a)와 같이 주어졌을 때, 각 기계 및 부품들을 두 개의 그룹 중 하나에 할당해야 하고, 하나의 그룹은 각각 두 세 개의 기계 및 부품으로 구성되어야 한다는 제약 조건하에 (b)와 같은 행렬을 찾는 문제이다.

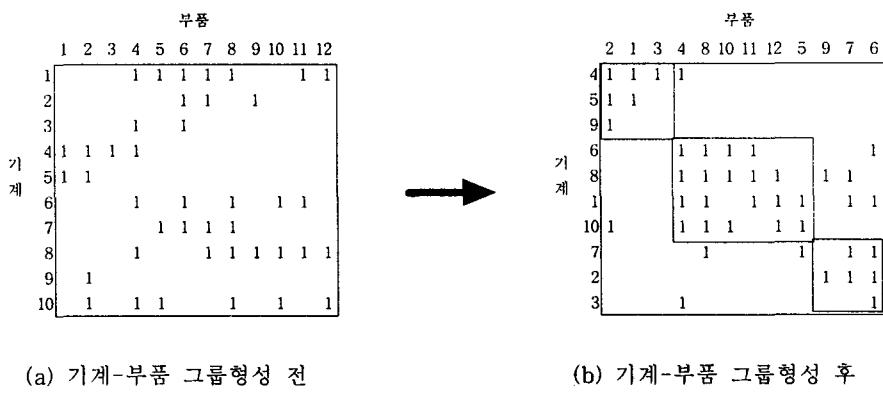


그림 1 기계-부품 그룹형성 문제

기계-부품 그룹형성 문제의 해법에 대한 성능을 평가하는 척도로서 흔히 사용되는 것은 그룹화 효율(Grouping Efficacy: GF), 그룹화 능률(grouping efficiency), 그룹화 척도(grouping measure), 예외 요소의 수 등이다. 본 연구에서는 성능 평가 척도로서 Kumar와 Chandrasekharan[19]가 정의한 다음의 GF를 사용한다.

$$GF = \frac{\text{기계 - 부품 그룹안의 '1'의 수}}{\text{기계 - 부품 그룹의 면적} + \text{기계 - 부품 그룹밖의 '1'의 수}} \quad (1)$$

GF는 그룹의 질을 평가하기 위한 척도로서 널리 사용되며 식별력이 적은 그룹화 능률의 단점을 극복하고 예외 요소 등 중요한 요소를 고려할 수 있고, 0과 1사이의 값을 가지며 1에 가까울수록 그룹이 잘 된 것이다.

기계-부품 그룹형성 문제를 해결하기 위해서 지금까지 매우 다양한 해법이 제시되었다. 배열을 이용한 방법[15]은 그룹이 형성될 수 있도록, 행렬에서 주 대각선 주변으로 '1'의 값을 옮기기 위해 행과 열을 재정렬하는 방법이다. 이 밖에 유사계수법[24], 수리계획법[21], 그래프 이론[20]등이 있다. 최근에는 인공지능에 기초한 방법[18]이 많이 연구되었고, 그 중 하나인 자기조직화 신경망(Self Organizing feature Map: SOM)은 학습 능력을 통하여 실제 생산 현장의 문제에 대하여 유연하고 적응력 있는 해를 제공한다[18].

전과 강[1]은 SOM을 이용하여 기계-부품 그룹형성 문제의 해를 구하는 알고리즘을 제시하였다. SOM의 출력층의 구조를 1차원으로 하고 출력노드의 수를 충분히 크게 만들어 주면 입력벡터를 유사한 순서로 출력노드에 펼쳐놓을 수 있다. 그러나 좋은 GF와 그룹 수를 정해주지 못하는 결과가 발생할 수 있다.

본 연구에서 제안하는 알고리즘은 기계-부품 그룹형성 문제에서 입력패턴의 유사성을 반영할 수 있는 SOM을 사용하여 입력벡터를 재배열하고, 이를 분석하여 그룹 수를 구한다. 그리고 클러스터링 방법(clustering method) 중 하나인 K-Means 알고리즘을 이용하여 그룹 수

를 변화시키면서 가장 좋은 해와 그룹 수를 구한다.

1.1 SOM에 대한 일반적인 고찰

코호넨[17]에 의하여 제시된 SOM은 비지도 학습을 사용하는 신경망의 일종으로 입력 패턴과 연결강도 간의 가까운 정도에 따라 경쟁을 통하여 출력층에서 승자 노드를 결정하고 승자 노드의 연결강도를 입력 패턴에 대응하여 조절하는 학습방법이다. 여기서 말하는 가까운 정도는 유clidean 공간상의 벡터의 거리(Euclidean distance)를 말하며 식(2)와 같다.

$$D_i = \sqrt{(x_1 - w_{i1})^2 + (x_2 - w_{i2})^2 + \cdots + (x_m - w_{im})^2} \quad (2)$$

SOM은 학습과정에서 이웃의 개념을 사용한다. 즉, 승자 노드뿐만 아니라 승자 노드의 이웃 노드들의 연결강도도 함께 조절함으로써, 출력층에 입력 패턴의 유사성을 반영하는 특징 지도를 스스로 형성한다. 연결강도를 조절하는 식은 다음과 같다.

$$w(\text{new})_{ij} = w(\text{old})_{ij} + \alpha(x_i - w(\text{old})_{ij}) \quad (3)$$

여기에서 $w(\text{new})_{ij}$ 는 노드 i와 j 사이의 조절된 후 연결강도, $w(\text{old})_{ij}$ 는 노드 i와 j 사이의 조절되기 전 연결강도, α 는 학습률 ($0 < \alpha \leq 1$), x_i 는 노드 i의 활성값이다. SOM에서 신경망을 학습시키는 과정은 다음과 같다.

단계 1. 연결강도 벡터를 초기화한다. 학습률과 이웃의 범위를 정한다.

단계 2. 입력층에 입력벡터를 입력한다.

단계 3. 각 입력벡터에 대하여 다음의 과정을 반복한다.

(3.1) 출력층의 각 출력노드의 연결강도 벡터와 입력벡터 간의 거리를 구한다.

(3.2) 연결강도 벡터와 입력벡터의 거리가 가장 짧은 승자노드를 구한다.

(3.3) 승자노드와 일정범위 내 이웃노드의 연결강도를 조절한다.

단계 4. 학습률과 이웃의 범위를 줄인다.

단계 5. 단계 2로 간다.

1.2 K-Means에 대한 일반적인 고찰

K-Means 알고리즘은 먼저 전체 데이터를 주어진 그룹 수 k개로 분할한 후 각 그룹의 중심값을 계산하는 방법으로 알고리즘 수행과정에서 복잡한 연산을 하지 않기 때문에 대용량 데이터에서도 빠른 시간 내에 좋은 해를 구할 수 있다[12]. k개 그룹으로 초기 분할하는 것은 임의로 하거나, 다른 방법에 의하여 실행할 수 있다. 다음에는 각 데이터들을 데이터와 거리가 가장 가까운 클러스터로 할당한다. 여기서 말하는 거리는 식(4)와 같다.

$$D = \sum_{i=1}^K \sum_{j=1}^K \|w_{ij} - \bar{w}\| \quad (4)$$

그리고, 클러스터들의 중심값을 구하는 과정을 안정상태에 도달할 때까지 반복한다. K-Means 알고리즘의 수행절차는 다음과 같다.

단계 1. 각 클러스터들의 중심값을 초기화한다.

단계 2. 각 노드들을 데이터와 가장 가까운 중심값을 갖는 클러스터에 할당한다.

단계 3. 각 클러스터들의 중심값을 계산한다.

단계 4. 각 클러스터들의 중심값이 안정상태에 도달할 때까지 단계 2-3을 반복한다.

2. 제안하는 알고리즘

기계벡터를 입력벡터로 하는 SOM을 구성하여 학습시키고, 학습이 완료된 후 기계벡터를 입력하여 출력노드에 대응된 기계벡터 순서대로 행렬을 구성하여 재배열된 기계-부품 행렬을 구한다. 그 결과 재배열된 기계-부품행렬은 부품벡터가 유사한 순서대로 펼쳐지게 된다.

이번에는 기계-부품 행렬에서 부품벡터를 입력벡터로 하여 SOM을 학습시키고, 학습이 완료된 후 부품벡터를 입력하여 출력노드에 대응된 부품벡터 순서대로 행렬을 구성하여 재배열된 기계-부품 행렬을 구한다. 이 과정을 거치고 나면 초기의 기계-부품 행렬이 유사한 순서대로 모여서 재배열된 기계-부품 행렬은 몇 개의 그룹을 형성한다[1].

하지만 좋은 해를 구하지 못하는 결과가 발생할 수 있다. 이 단점을 극복하기 위하여 SOM에서 구한 그룹 수와 재배열된 기계-부품 행렬을 입력데이터로 하여 K-Means 알고리즘을 수행한다.

K-Means 알고리즘에서 입력데이터의 순서는 실행시간과 해에 큰 영향을 미친다. SOM에 의하여 재배열된 기계-부품 행렬은 입력패턴의 유사성을 반영하게 된다. 따라서 K-Means 알고리즘 과정에서 실행시간과 해의 질을 향상시킬 수 있다.

재배열된 기계-부품 행렬에서 그룹 수만큼 데이터를 선택하여 초기 중심값으로 정한다. 초기 중심값을 결정할 때 같은 값이나 유사한 값이 선택되는 것을 방지하는 것이 좋다. 따라서 각 그룹의 중심값을 데이터에서 선택할 때 기준에 중심으로 선택된 데이터와의 유사성을 측정하여 임계값(threshold value)으로 정하고 0-1사이의 난수를 발생하여 임계값보다 크면 중심값으로 선택한다. 계속적으로 중심값이 선택되지 않을 경우 K-Means 알고리즘을 종료한다. 임계값에서 sin함수를 사용하면 중심값의 중복과 선택되지 않아서 알고리즘이 종료되는 확률을 동시에 줄여줄 수 있다. 임계값은 다음의 식(5)을 사용하여 구한다.

$$\theta = \sin\left(\frac{\pi}{2} \times \frac{\sum_{i=1}^j f(i, j, k)}{\sum_{i=1}^j x_{ij}}\right) \quad (5)$$

여기에서 x_{ij} 는 기계-부품행렬에서 i번째 기계의 j번째 부품의 값, w_{kj} 는 k번째 그룹의 j번째 부품의 중심값, $f(i, j, k) = \begin{cases} 1 & w_{ij} = 1, w_{kj} = 1 \text{ 일 때 } \\ 0 & \text{그 외} \end{cases}$ 이다.

각 그룹의 중심값은 식(6)을 사용하여 구한다.

$$w_{kj} = \begin{cases} 1 & (K_k/2) \leq \sum_{i=1}^{K_k} x_{ij} \text{ 일 때,} \\ 0 & \text{그 외} \end{cases} \quad (6)$$

여기에서 x_{ij} 는 k번째 그룹에 속한 i번째 기계의 j번째 부품의 값, w_{kj} 는 k번째 그룹의 j번째 부품의 중심값, K_k 는 k번째 그룹의 개수다.

K-Means 알고리즘을 수행하여 그룹 수만큼 기계그룹을 할당한 후, 그 결과를 토대로 부품그룹을 형성한다. 각 부품벡터를 부품 그룹에 할당하여 해를 구한다. 그 중 가장 좋은 해가 발생하는 부품 그룹에 부품벡터를 할당한다.

SOM을 수행하여 정해진 그룹 수를 하나씩 단계적으로 증감하면서 K-Means 알고리즘을 수행한다. 그룹 수가 K-1일 때 GF가 가장 좋으면 그룹 수가 감소하는 방향으로 K-Means 알

고리즘을 수행하고, K+1일 때 GF가 가장 좋으면 그룹 수가 증가하는 방향으로 K-Means 알고리즘을 수행한다. 더 이상 해의 향상이 없으면 알고리즘을 종료한다. 제안하는 알고리즘의 수행절차를 정리하면 다음과 같다.

- 단계 1. 기계-부품 행렬에서 기계벡터를 입력벡터로 하여 SOM을 수행한다.
- 단계 2. 단계 1에서 재배열된 기계-부품 행렬에서 부품벡터를 입력벡터로 하여 SOM을 수행한다.
- 단계 3. 단계 2에서 재배열된 기계-부품 행렬을 토대로 K개의 기계-부품 그룹을 형성하고 GF를 계산한다.
- 단계 4. SOM에 의하여 재배열된 기계-부품 행렬을 K-Means 알고리즘의 입력데이터로 사용한다. 새로운 임계값을 사용하여 초기의 중심값을 정한다. 그리고 K-1, K, K+1에 대하여 K-Means 알고리즘을 수행하고 결과를 비교한다.
- 단계 5. 가장 좋은 GF를 얻은 그룹 수가 K-1이면 단계 (5.1)로 가고, K+1이면 단계 (5.2)로 가고 그리고 K이면 알고리즘을 종료한다.
 - (5.1) 이전 단계의 GF 보다 더 좋은 GF를 구하지 못할 때까지 그룹 수를 하나씩 감소시키면서 K-Means 알고리즘을 수행한다.
 - (5.2) 이전 단계의 GF 보다 더 좋은 GF를 구하지 못할 때까지 그룹 수를 하나씩 증가시키면서 K-Means 알고리즘을 수행한다.

3. 수치 예제

그림 1의 (a)는 Ben-Arieh와 Chang[3]의 예제이며 기계와 부품의 개수는 각각 10개, 12개다. 제안하는 알고리즘이 전개되는 과정을 단계별로 보이면 다음과 같다.

- 단계 1. 본 예제에서 기계벡터를 입력벡터로 하는 SOM의 구조는 그림 2와 같으며 m, n은 각각 12, 10이다. 그림 3은 SOM을 수행한 결과이며 부품벡터가 유사한 순서로 펼쳐져 있다.

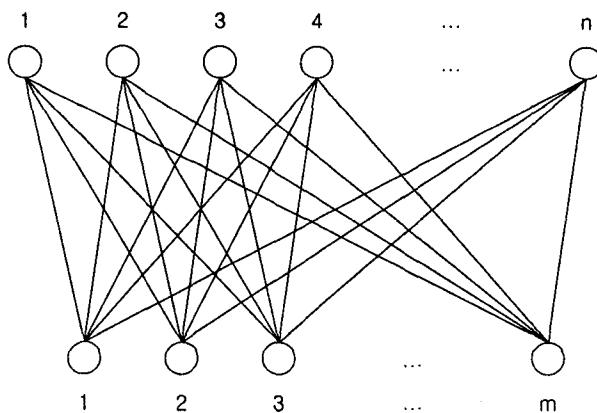


그림 2. SOM의 구조

- 단계 2. 부품벡터를 입력벡터로 하는 SOM의 구조는 그림 2와 같으며 m, n은 각각 10, 12이다. 그림 4는 SOM을 수행한 결과이며 기계벡터가 유사한 순서로 펼쳐져 있다.
- 단계 3. 그림 4의 재배열된 기계-부품 행렬에서 '1'이 그룹을 이루는 것을 볼 수 있다. 그룹을 이루는 부품과 기계를 묶어서 2개의 그룹을 형성하고 구한 GF는 52.7%이다.

부품												
1	2	3	4	5	6	7	8	9	10	11	12	
1		1	1	1	1	1			1	1		
7			1	1	1	1						
10	1	1	1			1			1	1		
8		1		1	1	1	1		1	1	1	
6		1	1	1					1	1		
2			1	1	1							
3		1	1									
4	1	1	1	1								
5	1	1										
9	1											

그림 3. 기계에 대하여 재배열된 기계-부품 행렬

부품

4	6	8	10	11	7	5	12	9	1	2	3	
1	1	1		1	1	1	1					
7		1	1			1	1					
10	1		1	1		1	1		1			
8	1		1	1	1	1	1					
6	1	1	1	1								
2	1			1			1					
3	1	1										
4	1				1	1	1					
5					1	1						
9					1							

4	6	8	10	11	7	5	12	9	1	2	3	
1	1	1	1	1	1	1	1	1	1	1	1	
7		1	1			1	1					
10	1		1	1		1	1		1	1	1	
8	1		1	1	1	1	1	1	1	1	1	
6	1	1	1	1		1	1	1	1	1	1	
2	1			1			1		1		1	
3	1	1										
4	1				1	1	1					
5					1	1						
9					1							

그림 4. 부품에 대하여 재배열된 기계-부품 행렬과 그룹 수(2개)를 찾아낸 결과

단계 4. SOM을 수행하여 결정된 그룹 수 2와 재배열된 기계-부품 행렬을 입력데이터로 하여 그룹 수를 3일 때 GF를 구한 결과는 59.6%이며, 그룹 수가 2일 경우보다 GF가 더 좋

표 1. K-Means 알고리즘 수행 결과
(단위:%)

그룹 수	그룹화 효율
2	52.7
3	59.6
4	55.3

부품												
2	1	3	4	8	10	11	12	5	9	7	6	
4	1	1	1	1								
5	1	1										
9	1											
6			1	1	1	1	1		1	1		
8			1	1	1	1	1	1	1	1		
1			1	1	1	1	1	1	1	1		
10	1		1	1	1	1	1	1	1	1		
7				1				1		1	1	
2								1	1	1	1	
3					1				1	1	1	

그림 5. 제안하는 알고리즘을 수행하여 찾아낸 가장 좋은 해

으므로 K값을 증가시키면서 알고리즘을 수행한다.

단계 5. 그룹 수가 4일 경우의 GF는 55.3%이며, 이 값은 그룹 수가 3일 경우의 GF보다 안 좋으므로 알고리즘을 종료한다. K-Means 알고리즘을 수행한 결과는 표 1과 같다.

그림 5는 제안하는 알고리즘을 수행하여 찾아낸 결과이며 기존 알고리즘에서 제시하는 GF보다 더 좋은 59.6%이다. 따라서 수치예제를 통하여 제안하는 알고리즘이 우수하다는 것을 알 수 있다.

4. 실험결과와 분석

본 연구에서 제안하는 알고리즘의 성능을 평가하기 위하여 사용된 문제는 기존 연구에서 많이 인용되는 문제를 대상으로 하였다. 그리고 예외 부품이 있는 경우와 예외 부품이 없는 경우로 나누어서 실험하였다. 제시하는 알고리즘은 Visual C++ 6.0을 이용하여 프로그램하고 윈도우 NT환경의 Pentium 133MHz CPU, 메모리 64M의 컴퓨터에서 수행하였다.

예제에 의한 실험에 의하여 SOM의 학습률은 0.03, 이웃의 크기는 처음에는 출력층의 모든 노드가 포함되도록 하다가 학습이 진행됨에 따라 하나씩 줄여나갈 때 좋은 해를 얻을 수 있었다. 또한 출력층의 크기는 입력벡터의 개수로 하고, 학습횟수는 데이터가 작은 경우 데이터 개수의 절반을, 데이터가 큰 경우 20번 학습으로 학습시킬 경우 결과와 수행속도를 동시에 향상시킬 수 있었다.

인용된 문제에 본 연구에서 제안한 알고리즘을 적용하여 구한 해법과 가장 좋은 해를 구한 기존 해법을 비교한 결과는 표 2와 같다. 표 2에서 보면 7×10 문제는 기본 해법과 비교하여 GF가 46.3에서 54.8로 18.4%가 향상된 새로운 그룹 수를 찾아주었다. 10×8 문제는 기존 해법과 동일한 그룹 수에서 GF가 3.4% 향상되었다. 10×12 문제는 그룹 수가 2일 경우에는 기존 해법과 동일한 결과가 나타났으며, 그룹 수가 3일 경우에는 GF가 1.2%가 향상되었다. 그리고 나머지 문제에서도 본 연구에서 제안하는 알고리즘의 해가 기존 해법의 GF와 같음을 알 수 있다. 따라서 제안하는 알고리즘이 기존의 여러 해법과 비교하여 성능이 우수함을 알 수 있다.

표 2. 본 연구에서 제안한 알고리즘을 적용하여 구한 해법과 가장 좋은 해를 구한 기존 해법의 그룹화 효율 비교

문제	출처	기존 해법			제안하는 해법		
		출처	그룹 수	그룹화 효율(%)	그룹 수	그룹화 효율(%)	실행시간(초)
5×7	King 외[16]	King 외[16]	2	82.4	2	82.4	0.07
7×8	Kusiak 외[23]	Kusiak 외[23]	3	85.0	3	85.0	0.06
15×10	Chan 외[5]	Chan 외[5]	3	92.0	3	92.0	0.04
10×20	Srinivasan 외[25]	Srinivasan 외[25]	4	100.0	4	100.0	0.26
24×40	Chandrasekharan 외[8]	Kaparthi 외[14]	7	100.0	7	100.0	4.81
6×8	Kusiak 외[22]	Kusiak 외[22]	2	76.9	2	76.9	0.06
7×11	Kusiak 외[23]	Kusiak 외[23]	2	46.3	3	54.8	0.07
8×20	Chandrasekharan 외[6]	Crama 외[10]	3	85.2	3	85.2	0.21
10×8	Ham 외[11]	Arvindi 외 Irani[2]	3	74.2	3	76.7	0.08
10×12	Ben-Arieh 외[3]	Arvindi 외 Irani[2]	2	52.7	2	52.7	0.05
10×12	Ben-Arieh 외[3]	Viswanathan[26]	3	58.9	3	59.6	0.05
16×30	Srinivasan 외[25]	Srinivasan 외[25]	4	67.8	4	67.8	1.28
20×35	Carriel[4]	Kaparthi 외[13]	4	75.1	4	75.1	2.86
40×100	Chandrasekharan 외[7]	전 외[1]	10	84.0	10	84.0	46.30

5. 결론

본 연구에서는 SOM과 K-Means를 이용하여 기계-부품 그룹 형성문제에서 그룹 수를 결정하고, 더 좋은 해를 제공하는 알고리즘을 제안한다. SOM을 수행하여 입력벡터를 유사한 순

서로 재구성한 후, K-Means 알고리즘을 수행하여 그룹 수와 해를 결정한다.

SOM에서 출력노드의 개수를 입력벡터의 개수 이상으로 했을 경우 입력벡터가 충분히 펼쳐져서 데이터의 구조를 세밀하게 파악할 수 있다. 출력노드의 개수를 입력벡터의 개수와 같이 할 경우 확정된 그룹 수와 유사한 그룹 수를 정해주면서 수행속도도 향상시킬 수 있었다.

또한, K-Means 알고리즘을 사용하여 그룹 수를 변화시키면서 구한 가장 좋은 해와 여러 기존 해법에서 구한 가장 좋은 해를 비교한 결과, 7×11 문제는 기존의 해보다 18.4% 향상된 그룹화 효율을 구했고, 10×8 문제는 3.4%, 10×12 문제는 1.2% 향상된 그룹화 효율이 나타났으며, 나머지 문제는 기존의 해와 동일한 결과가 나타났다.

제안하는 알고리즘은 복잡한 연산을 사용하지 않기 때문에 실시간으로 사용할 수 있으며 의사결정자의 목적에 따라서 변화하는 생산현장의 상황에 유연하게 적용할 수 있다.

참고문헌

1. 전용덕, 강맹규, “셀 생산 방식에서 자기조직화 신경망을 이용한 기계-부품 그룹 형성”, *공업 경영학회*, 제 21권, 제 48집, 123-132, 1998.
2. Arvindi, B. and Irani, S. A., “Principle component analysis for evaluating the feasibility of cellular manufacturing without initial machine-part matrix clustering,” *International Journal of Production Research*, Vol. 32, No. 8, pp. 1909-1938, 1994.
3. Ben-Arieh, D. and Chang, P. T., “An extension to p-median group technology algorithm,” *Computers and Operation Research*, Vol. 21, No. 1, pp. 101-114, 1994.
4. Carrie, A. S., “Numerical taxonomy applied to group technology and plant layout,” *International Journal of Production Research*, Vol. 11, No. 1, pp. 399-416, 1973.
5. Chan, H. M. and Milner, D. A., “Direct clustering algorithm for group formation in cellular manufacturing,” *Journal of Manufacturing Systems*, Vol. 1, No. 1, pp. 65-75, 1982.
6. Chandrasekharan, M. P. and Rajagopalan, R., “MODROC: An extension of rank order clustering for group technology,” *International Journal of Production Research*, Vol. 25, No. 6, pp. 835-850, 1987.
7. Chandrasekharan, M. P. and Rajagopalan, R., “ZODIAC: An algorithm for concurrent formation of part-families and machine-cells,” *International Journal of Production Research*, Vol. 25, No. 6, pp. 835-850, 1987.
8. Chandrasekharan, M. P. and Rajagopalan, R., “Groupability: An analysis of the properties of binary data matrices for group technology,” *International Journal of Production Research*, Vol. 27, No. 6, pp. 1035-1052, 1989.
9. Chen, J. S. and Heragu, S. S., “Stepwise decomposition approaches for large scale cell formation problems,” *European Journal of Operational Research*, Vol. 113, pp. 64-79, 1999.
10. Crama, Y. and Oosten, M., “Models for machine-part grouping in cellular manufacturing,” *International Journal of Production Research*, Vol. 34, No. 6, pp. 1693-1713, 1996.
11. Ham, I., Hitomi, K., and Yoshida, T., *Group Technology: Production Methods in Manufacture*, Kluwer-Nijhoff, Boston, Ma, 1985.
12. Huang, Z., “Extentions to the k-Means algorithm for clustering large data sets with categorical values,” *Data Mining and Knowledge Discovery*, Vol. 2, pp. 283-304, 1998.
13. Kaparthi, S. and Suresh, N. C., “Machine-component cell formation in group technology: A neural network approach,” *International Journal of Production Research*, Vol. 30, No. 6, pp. 1353-1367, 1992.
14. Kaparthi, S., Suresh, N. C., and Cerveny, R. P., “An improved neural network leader algorithm for part-machine grouping in group technology,” *European Journal of Operational Research*, Vol. 69, No. 3, pp. 342-366, 1993.
15. King, J. R., “Machine-component grouping in production flow analysis: An approach using a rank order clustering algorithm,” *International Journal of Production Research*, Vol. 18, No. 2, pp. 213-232, 1980.
16. King, J. R. and Nakornchai, V., “Machine-component group formation in group

- technology: Review and extension," *International Journal of Production Research*, Vol. 20, No. 2, pp. 117-133, 1982.
17. Kohonen, T., "Self-organization and association memory", *Springer*, Berlin, 1984.
18. Kulkarni, U. R. and Kiang, M. Y., "Dynamic grouping of parts in flexible manufacturing systems: A self-organizing neural networks approach," *European Journal of Operational Research*, Vol. 84, No. 2, pp. 192-212, 1995.
19. Kumar, C. S. and Chandrasekharan, M. P., "Grouping efficacy: A quantitative criterion for goodness of block diagonal forms of binary matrices in group technology," *International Journal of Production Research*, Vol. 28, No. 2, pp. 233-243, 1990.
20. Kumar, K. R., Kusiak, A., and Vannelli, A., "Grouping of parts and components in flexible manufacturing systems," *European Journal of Operation Research*, Vol. 24, No. 3, pp. 387-397, 1986.
21. Kusiak, A., "The generalized group technology concept," *International Journal of Production Research*, Vol. 25, No. 4, pp. 561-569, 1987.
22. Kusiak, A. and Cho, M., "Similarity coefficient algorithms for solving the group technology problem," *International Journal of Production Research*, Vol. 30, No. 11, pp. 2633-2646, 1992.
23. Kusiak, A. and Chow, W. S., "An algorithm for cluster identification," *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-17, No. 4, pp. 696-699, 1987.
24. McAuley, J., "Machine grouping for efficient production," *The Production Engineer*, Vol. 51, pp. 53-57, 1972.
25. Srinivasan, G., Narendran, T. T., and Mahadevan, B., "An assignment model for the part families problem in group technology," *International Journal of Production Research*, Vol. 28, No. 1, pp. 145-152, 1990.
26. Viswanathan, S., "A new approach for solving the p-median problem in group technology," *International Journal of Production Research*, Vol. 34, No. 10, pp. 2691-2700, 1996.