

제조셀 형성을 위한 신경망 기법 비교 연구

이 준 한

경주대학교 경영학부 경영정보학과

E-mail : leejh@tour.kyongju.ac.kr

초 록

다품종 소량생산 체제는 혼란의 비경제로 인하여 생산관리의 효율을 향상시키는데 어려움이 많고 제품 표준화에 의한 대량생산에 비하여 효율과 경제성이 떨어진다.

이러한 비효율성을 극복하기 위한 방안 중 하나가 셀생산방식이며, 이의 적용을 위해서는 부품군(part family)과 기계셀(machine cell)을 구성하는 제조셀 형성이 이루어져야 한다.

제조셀 형성을 위한 연구가 활발히 이루어지고 있는 가운데 최근에는 신경망을 이용한 제조셀 형성기법이 소개되고 있다.

본 연구에서는 기존에 연구된 신경망 기법 중 가장 제조셀 형성에 적합하다는 ART1 신경망 기법을 GLVQ 신경망 기법과 비교하여 제조셀 형성의 효율성을 분석하였다.

I. 서론

다품종 소량생산 체제는 생산해야 할 제품의 종류가 많고 생산량과 납기가 다양하기 때문에 혼란의 비경제로 인하여 생산관리의 효율을 향상시키는데 어려움이 많고 제품 표준화에 의한 대량생산에 비하여 효율과 경제성이 떨어진다.

다품종 소량생산 체제의 이러한 비효율성을 극복하기 위해 여러 가지 체계적인 접근방법

들이 개발되어 왔는데 그 중 하나로 그룹 테크놀로지(group technology) 또는 셀생산방식(cellular manufacturing)을 들 수 있다. 그룹 테크놀로지 적용을 위해서는 부품들간의 유사성을 고려하여 부품을 부품군(part family)으로 구성하고, 각 부품군을 생산하는데 필요한 기계들을 기계셀(machine cell)로 구성하는 제조셀 형성이 이루어져야 한다.

제조셀 형성을 위한 연구로는 주로 부품을 생산하기 위한 작업순서와 기계내 공정흐름을 분석하여 기계-부품 가공행렬(machine-part incidence matrix)을 구성한 후 행렬을 이용하여 그룹을 구성하는 알고리즘이나 휴리스틱의 개발에 관한 연구가 주류를 이루고 있으며, 최근에는 신경망을 이용한 제조셀 형성기법이 많이 소개되고 있다.

본 연구에서는 기존에 연구된 신경망 기법 중 가장 제조셀 형성에 적합하다는 ART1 신경망 기법을 GLVQ 신경망 기법과 비교하여 제조셀 형성 알고리즘의 효율성을 분석하였다.

II. 제조셀 형성을 위한 신경망 원리

1. ART1 신경망의 원리

Carpenter와 Grossberg(1986,1988)에 의해 제안된 ART(Adaptive Resonance Theory) 모

델은 Hartigan의 순차적 리더 알고리즘 (sequential leader algorithm)과 거의 유사하게 수행된다. 이 알고리즘은 첫 번째 입력을 첫 번째 클러스터의 대표패턴(exemplar pattern)으로 선택하고, 다음 입력이 들어오면 첫 번째 대표패턴과 비교하여 그 거리가 임계값(vigilance threshold)보다 작으면 첫 번째 클러스터로 분류되고 그렇지 않으면 새로운 클러스터를 생성하게 된다. 이러한 과정이 모든 입력 벡터들에 적용되므로 클러스터의 개수는 시간에 따라 점점 커질 수가 있는데, 입력과 클러스터의 대표패턴과의 거리측정 방법과 임계값에 따라 다르다.

ART1 알고리즘은 다음과 같은 단계로 이루어진다.

절차1.

하향연결강도와 상향연결강도를 초기화하고 임계값 (ρ) 설정 :

For input nodes $i=0$ to $N-1$ and output nodes $j=0$ to $M-1$,

하향연결강도 : $t_{ij}(0)=1$;

상향연결강도 : $b_{ij}(0)=1/(1+N)$;

$$0 \leq \rho \leq 1.$$

절차2.

0/1으로 구성된 입력벡터 X 를 적용.

절차3.

일치점수 계산:

모든 출력노드 j 의 출력인

$$\mu_j = \sum_i b_{ij}(t)x_i \text{ for } j=0, \dots, M-1.$$

절차4.

가장 일치되는 대표패턴 선택:

$$\mu_\theta = \max(\mu_j)$$

다른 노드의 출력은 억제(측면제어),

값이 같은 경우에는 가장 먼저 나오는 j 선택.

절차5.

임계값 테스트:

Compute $\|X\| = \sum_i x_i$; 입력벡터의 "1" 개수;

Compute $\|T \cdot X\| = \sum_i t_{i\theta} x_i =$ 입력벡터와

대표패턴간에 일치되는 "1"의 개수;

If $\|T \cdot X\|/\|X\| > \rho$, go to 절차7;

else go to 절차6.

절차6.

가장 일치되는 대표패턴 일시적 불활성화:

절차4에서 선택된 일치노드의 출력을 일시적으로 0으로 설정;

Then go to 절차3.

절차3에서 출력층의 새로운 노드가 새로운 클래스로 대표되기 위해 선택.

절차7.

가장 일치되는 대표패턴 갱신:

$$t_{i\theta}(t+1) = t_{i\theta}(t)x_i;$$

$$b_{i\theta}(t+1) = \frac{t_{i\theta}(t) x_i}{0.5 + \sum_i t_{i\theta}(t) x_i}.$$

절차8.

반복:

절차6에서 불활성화된 모든 노드들을 활성화 시킨 후 go to 절차2.

2. GLVQ 신경망의 원리

Kohonen 신경망의 학습철학은 승자독점으로서 승자만이 출력을 낼 수 있으며, 승자와 그의 이웃들만이 가중치를 조정할 수 있다. 승자 뉴런의 가중치벡터는 입력벡터와 가장 가까운 것이며, 이 뉴런과 그의 이웃 반경 안의 뉴런들은 가중치를 조정해가면서 학습을 한다. 이러한 측면제어(lateral inhibition)의 효과는 맥시칸 모자와 유사하여 승자 뉴런과 가까울수록 영향을 많이 받고 멀어질수록 영향을 적게 받는다.

GLVQ는 Kohonen의 LVQ알고리즘을 일반화한 수정 알고리즘인데, LVQ를 이용하면 분류되지 않는 p -차원의 데이터에 숨어 있는 군집 하부구조를 발견할 수 있다. $X = \{x_1, x_2, \dots, x_n\} \subset R^p$ 를 입력벡터 집합이라고 하고 c 를 경쟁층에서의 노드의 수(X 의 군집수)라고 할 때, LVQ는 입력벡터와 군집중심(v_i)간의 유클

리디언 거리를 계산하여 가장 가까운 노드를 승자 노드로 결정하고, 입력벡터와 군집중심간의 유클리디언 거리의 기대값을 최소화하도록 c 개의 중심점을 설정한다. 이때 학습규칙으로는 최급강하 규칙(steepest descent rule)을 이용한다.

즉 LVQ에서는 하나의 입력벡터가 주어지면 최근접 군집중심을 찾아 그 군집중심을 입력벡터가 있는 방향으로 $(x - v_i)$ 벡터를 따라 이동시키는데, 이때 이동하는 양은 0과 1사이의 학습율 a 에 따라 달라진다. LVQ는 기본적으로 MacQueen의 sequential hard c -means(SHCM) 알고리즘과 동일한 개념이며, 따라서 MacQueen의 알고리즘과 마찬가지로 초기 군집중심점 선택에 따라 지역 최적해(locally optimal solution)에 빠질 수 있다. 이러한 문제가 발생하게 되는 이유는 초기 군집중심점의 부적절한 선택과 각 입력벡터가 승자 노드만을 갱신하기 때문이다. Pal 등은 이러한 LVQ의 문제점을 보완하기 위해 입력벡터와 승자 노드간의 국지적 가중치로 정의되는 손실함수를 최소화하도록 승자 노드와 비승자 노드에 대해 각각 다른 갱신규칙을 적용하는 일반화된 LVQ(GLVQ) 알고리즘을 개발했다(Pal et al., 1993).

따라서 GLVQ에서는 하나의 입력벡터가 들어오면 승자 노드 뿐만 아니라 비승자 노드도 새로운 입력벡터의 방향으로 이동하는데, 승자 노드는 많이 이동하고 비승자 노드는 적게 이동하게 된다. 또한 입력벡터와 승자 노드의 거리가 멀수록(즉, quantization 오차가 크면 클수록) 가중치 벡터에 미치는 영향이 커져서 많이 이동하게 되고, 반대의 경우는 적게 이동하게 되는데, 궁극적으로 입력벡터와 승자 노드가 정확히 일치하는 경우에는 모든 노드가 갱신되지 않게 되어 LVQ 알고리즘과 같게 된다.

GLVQ 알고리즘은 다음과 같은 단계로 이루어진다.

<기호정의>

X : 기계-부품 가공행렬(입력벡터 집합)

c : 셀(경쟁층의 노드)의 수

T : 총 학습 횟수

ϵ : 학습중지 매개변수 (stop parameter)

V : 군집중심(가중치) 벡터

a_t : 학습율

E_t : t 번째와 $(t-1)$ 번째 군집중심간의 유클리디언 거리

절차1.

주어진 초기 data set $X = \{x_1, x_2, \dots, x_n\} \subset R^p$ 에 대하여 c, T 와 $\epsilon > 0$ 에 초기값을 부여.

절차2.

$V_0 = (v_{1,0}, \dots, v_{c,0}) \in R^p$ 와 $a_0(0 \sim 1)$ 의 초기값을 설정.

절차3.

For $t = 1, 2, \dots, T$,

Compute $a_t = a_0(1-t/T)$.

For $k = 1, 2, \dots, n$,

a. Find $\|x_k - v_{i,t-1}\| = \min_{1 \leq j \leq c} \{ \|x_k - v_{j,t-1}\| \}$ - 승자 노드 결정

b. 모든 가중치벡터 $\{v_{r,t}\}$ 를 갱신.

$$v_{i,t} = v_{i,t-1} + a_t(x_k - v_{i,t-1}) \cdot (D^2 - D + \|x_k - v_{i,t-1}\|^2) / D^2 \quad \text{- 승자 노드}$$

$$v_{r,t} = v_{r,t-1} + a_t(x_k - v_{r,t-1}) \cdot (\|x_k - v_{r,t-1}\|^2) / D^2 \quad (r \neq i) \quad \text{- 비승자 노드}$$

$$\text{where } D = \sum_{r=1}^c \|x_k - v_{r,t-1}\|^2$$

Next k .

절차4.

Compute

$$E_t = \|V_t - V_{t-1}\|$$

$$= \sum_{r=1}^c \|v_{r,t} - v_{r,t-1}\|$$

절차5.

If $E_t \leq \epsilon$ stop; Else Next t .

절차6.

기계-부품 가공행렬의 각 입력패턴과 군집중심간의 유클리디언 거리를 계산하여 각 입력패턴을 그룹핑.

"GLVQ_{ik} =

$$\begin{cases} 1, & \text{if } \|x_k - v_i\| \leq \|x_k - v_j\|, 1 \leq j \leq c, \\ & j \neq i - \text{입력패턴이 특정군집에 포함} \\ 0, & \text{otherwise} \end{cases} \quad 1 \leq i \leq c \text{ and } 1 \leq k \leq n.$$

III. 제조셀 형성 성과비교

1. 측정도구

셀 형성 기법의 성과는 여러 가지 기준에서 그들의 우열을 평가할 수 있으며, 지금까지 많은 측정도구가 개발되었다. 본 연구에서는 두 가지 신경망 기법의 성과를 비교하기 위해 세 가지 측정도구(Grouping Efficiency, Grouping Efficacy, Grouping Index)를 이용하였다.

Chandrasekharan과 Rajagopalan(1986)이 개발한 Grouping Efficiency(η)의 특징은 0~1 사이의 비음값을 취하며, void(대각블록내의 0)와 예외요소(대각블록 밖의 1)가 동일한 가중치를 갖는 큰 매트릭스나 1의 값이 드문 매트릭스(sparse matrix)들에 대해서는 아주 낮은 q 값을 선택해야 한다는 것이다. 또한 예외요소가 많이 발생하는 아주 나쁜 해의 경우에도 그 값이 0.75 가까이 되어서 전반적으로 판별력이 약하고, 매트릭스의 크기가 커지면 grouping efficiency도 1에 가까워지는 한계점이 있다.

Kumar와 Chandrasekharan(1990)이 개발한 Grouping Efficacy(τ)의 특징으로는 void와 예외요소에 각각 다른 가중치를 부여하는데, 사용자는 그 가중치를 알지 못하며, 사용자가 상황에 따라 void와 예외요소의 가중치를 부여할 수 있는 자유가 없다. 또한 이론적인 경우이긴 하지만 매트릭스 전체가 0일 때, grouping efficacy가 0이 되어야 함에도 불구하고 값을 결정할 수 없어서 0~1 사이의 범위를 갖지 못하는 변칙(anomaly)이 발생한다.

Nair와 Narendran(1996)이 개발한 Grouping Index(γ)의 특징은 0~1 사이의 비음값을 취하며, 극단값의 해석이 가능하여 변칙이 발생하지 않는다. 또한 grouping

efficacy의 경우 명시적으로 가중치를 부여하지는 않지만 예외요소 수의 변화보다 void 수의 변화에 더 민감하게 반응하여 void의 가중치가 예외요소의 가중치보다 큰데, grouping index에서는 void와 예외요소의 효과가 사용자에 의해 주어진 q 값에 의해 결정되며, $q = 0.5$ 일 때 void와 예외요소가 동일한 가중치를 가지며, q 값이 작아질 수록 void보다 예외요소의 가중치가 크게 된다.

2. 실험자료

두 기법의 셀형성 성과를 비교하기 위하여 17개의 자료를 기존의 연구문헌에서 발췌하여 이용하였다. 각 문제의 출처와 크기는 [표 1]과 같다.

[표 1]에서 크기는 기계행과 부품열의 수를 나타내며 e 는 전체 가공행렬내의 1의 개수를 나타낸다.

[표 1] 실험 문제

No.	Source	크기	e
1	Askin & Chiu ('90)	14*24	60
2	Boctor ('91)	7*11	21
3	Boe & Cheng ('91)	20*35	152
4	Chow & Hawaleshka ('91)	5*11	25
5	Chan & Milner ('82)	10*15	49
6	Chen & Cheng ('95)	8*10	27
7	Ham et al. ('85)	10*8	26
8	Harhalakis et al. ('90)	20*20	79
9	Kumar et al. ('86)	23*20	113
10	Viswanathan ('96)	10*12	41
11	Mosier & Taube ('85)	10*10	24
12	Waghodekar & Sahu ('84)	5*7	20
13	King & Nakornchai ('82)	5*7	16
14	Seifoddini ('89)	5*18	46
15	Srinivasan et al. ('90)	16*30	116
16	Venugopal & Narendran ('92)	18*17	69
17	de Witte ('80)	12*19	75

3. 성과 비교

ART1 기법과 GLVQ 기법을 이용하여 [표 1]의 자료로 셀형성을 한 것을 세 가지 측정

도구로 비교한 결과가 [표 2]이다. 가중치는 0.5를 부여했다.

[표 2] 결과 비교(†:GLVQ열등,*:동등,**:우수)

No.	해법	셀수	e_0	η (%)	τ (%)	γ (%)
1**	ART1	4	3	82.54	64.04	68.63
	GLVQ	4	2	83.32	65.91	70.30
2†	ART1($\rho=0.3$)	3	8	64.08	35.14	41.46
	ART1($\rho=0.4$)	3	2	84.58	67.86	70.49
3**	GLVQ	3	2	84.58	67.86	70.49
	ART1	4	58	66.00	34.56	41.25
4†	GLVQ	4	42	81.95	56.06	56.18
	ART1	2	4	83.49	70.00	70.49
5**	GLVQ	2	4	83.49	70.00	70.49
	ART1	6	21	89.60	56.00	45.00
6**	GLVQ	3	5	91.50	80.00	80.18
	GLVQ	2	0	80.25	60.49	67.01
7**	ART1	4	10	84.17	56.67	50.94
	GLVQ	3	4	85.73	69.70	70.59
8†	GLVQ	2	0	82.14	64.29	69.70
	ART1	3	2	90.93	80.00	80.65
9†	GLVQ	3	2	92.56	82.76	83.05
	ART1	5	18	86.82	64.21	63.83
10**	GLVQ	4	17	77.54	52.10	56.32
	ART1	2	16	85.23	26.08	44.28
11**	GLVQ	2	37	60.81	30.89	40.67
	ART1	2	6	70.96	48.61	56.21
12**	ART1	3	12	69.74	46.03	50.00
	GLVQ	3	9	77.08	56.14	58.68
13†	ART1	6	10	73.14	51.85	44.68
	GLVQ	3	0	85.29	70.59	76.19
14†	ART1	셀형성 불가능				
	GLVQ	2	7	62.34	50.00	49.02
15**	ART1	2	2	85.62	73.68	74.36
	GLVQ	2	2	85.62	73.68	74.36
16**	ART1	2	5	86.76	77.36	77.78
	GLVQ	2	5	86.76	77.36	77.78
17†	ART1	5	24	86.36	65.71	65.71
	GLVQ	4	20	86.55	67.61	68.28
18**	ART1	3	21	72.13	43.64	48.33
	ART1	4	25	68.36	37.93	43.31
19†	GLVQ	4	16	80.47	56.38	58.38
	ART1	3	21	72.39	48.65	51.89
20†	GLVQ	3	33	68.85	41.67	42.47

[표 2]의 결과를 보면 총 17개 문제 중에서 3개 문제에서 ART1이 우수하고 4개 문제에서 동일한 결과를 나타내며, 10개 문제에서 GLVQ가 우수한 결과를 제공한다.

그동안 ART1 기법은 여러 연구자들에 의해 제조셀 형성에 적용되어 좋은 성과를 나타내었다(Kaparthi & Suresh - 92, Kaparthi et al. - 93). 그러나 본 연구에서 ART1 기법과 GLVQ 기법을 비교해 본 결과 GLVQ 기법의 성과가 보다 좋게 나타났을 뿐만 아니라 ART1 기법은 몇가지 한계점을 가지고 있는 것으로 드러났다.

첫째, ART1 기법은 Kaparthi 등(1993)이 지적했듯이 동일한 형태의 입력벡터라도 들어오는 순서에 따라 다르게 분류되는 문제점을 가지고 있다. [표 3]은 이러한 예를 보여주고 있다.

[표 3] Kaparthi 등의 예제

부품	입력 벡터	class	대표값			
			class 0	class 1	class 2	class 3
-	초기화	-	11111111	11111111	11111111	11111111
9	001001100	0	001001100	11111111	11111111	11111111
4	100010010	1	001001100	100010010	11111111	11111111
1	010100001	2	001001100	100010010	010100001	11111111
5	000000010	1	001001100	000000010	010100001	11111111
8	001001100	0	001001100	000000010	010100001	11111111
2	010100001	2	001001100	000000010	010100001	11111111
3	010100000	2	001001100	000000010	010100000	11111111
6	100010010	3	001001100	000000010	010100000	100010010
7	000000100	0	000000100	000000010	010100000	100010010

[표 3]의 예제는 임계치 0.5에서 구한 해인데 부품 4와 부품 6은 동일한 자료임에도 불구하고 부품 4는 class 1에 할당된 반면, 부품 6은 class 1의 대표값이 선행하는 부품 5에 의해 변경됨으로 인해 class 3에 할당되게 된다. Kaparthi 등은 이러한 ART1 알고리즘의 문제점을 해결하기 위해 입력벡터의 0과 1을 바꾼 자료를 이용하였는데, 셀 형성 결과 대각블록 밀도(대각블록내의 1의 비율)가 낮거나 임계

치가 높은 경우에는 동일한 문제가 여전히 존재했다.

둘째, 12번 문제에서와 같이 전혀 셀을 형성 못하는 경우도 발생하였다. 이 문제에서 기계셀은 임계값 0.1~0.7에서는 두 개의 그룹 $\{(1,2)(3,4,5)\}$ 으로 분류되고, 0.8 이상에서는 다섯 개의 그룹 $\{(1)(2)(3)(4)(5)\}$ 으로 분류된다. 그러나 부품군의 경우에는 임계값 0.1~0.7에서 한 개의 그룹 $\{(1,2,3,4,5)\}$ 으로 분류되고, 0.8 이상에서는 세 개의 그룹 $\{(1,4,6)(2,3,5)(7)\}$ 으로 분류되어 기계셀과 부품군들을 연결시키지 못하는 것이다.

GLVQ 기법의 경우에는 클러스터의 개수를 임의로 지정하여 분류할 수 있으나, ART1 기법의 경우에는 클러스터의 개수를 임의로 지정하여 분류하는 것이 불가능 한 경우도 있었다.

셋째, ART1의 경우 임계값에 민감하게 반응하여 임계값이 조금 변하더라도 2번 문제와 같이 그 결과가 많이 달라질 수 있다. 이러한 현상은 첫 번째 문제점과도 관련이 있다.

IV. 결론

오늘날 소비자의 욕구 다양화에 따라 다품종 소량생산체제의 도입이 불가피함에도 불구하고 그 방식에 내재하고 있는 비효율성을 극복하기 위한 방법 중 하나로 셀생산방식을 들고 있다. 셀생산방식에서 다루어지는 가장 중요한 문제는 부품들간의 유사성을 고려하여 부품군과 기계셀을 구성하는 제조셀 형성이다.

그러나, 다품종 소량생산 체제하에서 한 공장에서 처리하는 품목의 수와 각 품목들이 필요로 하는 공정과 기계의 수가 많아지면, 수작업으로 최적의 제조셀을 구성한다는 것은 현실적으로 불가능한 일이다. 즉, 셀을 구성하는 문제는 문제의 크기가 증가함에 따라 탐색공간이 지수적으로 증가되는 NP-complete이기 때문에 현실적인 문제에서 최적해를 찾는다는 것은 거의 불가능하다.

본 연구에서는 제조셀 형성을 위하여 두 가

지 신경망 기법을 이용하여 그 결과를 비교해 보았다. 기존에 제조셀 형성을 위하여 사용되어 왔던 ART1 기법은 몇가지 문제점을 드러냈으며, 그 성과도 GLVQ 기법이 전반적으로 우수한 것으로 나타났다.

추후 성과 측정에 있어서의 가중치 결정문제와 초기 파라메타 선택에 따른 결과 변화에 대한 지속적인 연구가 요망된다.

[참고문헌]

- [1] 김대수, 신경망 이론과 응용(I), 제6판, 하이테크정보, 1996.
- [2] Askin, R. G. and Chiu, K. S., "A graph partitioning procedure for machine assignment and cell formation in group technology," *International Journal of Production Research*, Vol.28, No.8, 1990, pp. 1555-1572.
- [3] Boctor, F. F., "A linear formulation of the machine-part cell formation problem," *International Journal of Production Research*, 29, 1991, pp. 343-356.
- [4] Boe, W. J. and Cheng, C. H., "A close neighbour algorithm for designing cellular manufacturing systems," *International Journal of Production Research*, 29, 1991, pp. 2097-2116.
- [5] Chen, S. J. and Cheng, C. S., "A neural network-based cell formation algorithm in cellular manufacturing," *International Journal of Production Research*, Vol.33, No.2, 1995, pp. 293-318.
- [6] Ham, I., Hitomi, K. and Yoshida, T., *Group Technology*, Kluwer-Nijhoff Publishing, 1985.
- [7] 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, 1992, pp. 1353-1367.

- [8] Kaparathi, S., Suresh, N. C. and Cervany, R. P., "An improved neural network leader algorithm for part-machine grouping in group technology," *European Journal of Operational Research*, 69, 1993, pp. 342-356.
- [9] 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, 1982, pp. 117-133.
- [10] Kumar, K. R. 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, 1990, pp. 233-243.
- [11] Nair, G. J. K. and Narendran, T. T., "Grouping index : a new quantitative criterion for goodness of block-diagonal forms in GT," *International Journal of Production Research*, Vol.34, No.10, 1996, pp. 2767-2782.
- [12] Pal, N. R., Bezdeck J. C. and Tsao, C. K., "Generalized clustering networks and Kohnen's self-organizing schme," *IEEE Transactions on Neural Networks*, 4(4), 1993, pp. 549-557.
- [13] Seifoddini, H. and Wolfe, P.M. "Application of the similarity coefficient method in group technology," *IIIE Transactions* ,18, 1986, pp. 271-277.
- [14] Srinivasan, G., Narendran, T. T., and Mahadevan, B., "An assignment model for the part-families problem in group technology," *International Journal of Production Research*, 28, 1990, pp.145-152.