

신경망을 이용한 GT 부품군 형성의 자동화*

이성열**

Grouping Parts Based on Group Technology Using a Neural Network

Sung-Youl Lee

〈Abstract〉

This paper proposes a new part family classification system (IPFACS: Image Processing and Fuzzy ART based Clustering System), which incorporates image processing techniques and a modified fuzzy ART neural network algorithm. IPFACS can classify parts based on geometrical shape and manufacturing attributes, simultaneously. With a proper reduction and normalization of an image data through the image processing methods and adding method in the modified Fuzzy ART, different types of geometrical shape data and manufacturing attribute data can be simultaneously classified in the same system. IPFACS has been tested for an example set of hypothetical parts. The results show that IPFACS provides a good feasible approach to form families based on both geometrical shape and manufacturing attributes.

1. 서 론

그룹화기술 (GT: Group Technology)은 제조분야에 있어서 생산성의 향상을 위해 부품들의 설계 및 제조 유사성들을 조직하고 이용하기 위한 중요한 도구로 널리 알려져 있다. GT의 성공적인 구축은 거의 부품군의 형성방법에 달려있다. 설계 및 제조속성 중 어느 하나에 근거를 두고 형성된 부품군이 어느 특정한 제조환경에서, 어떤 이득을 가져온다고 할 지라도, GT의 최대의 이득은 부품군이 설계 및 제조속성들의 유사성을 동시에 고려하여 형성되어질 때 얻어질 수 있을 것이다.

부품군 형성에 관한 연구는 지난 수십년간 많은 방법들이 발표되었지만 대부분 설계 또는 제조속성 중 어느 하나에 근거를 둔 접근방법들 [5, 9, 10, 11, 12, 17, 18] 이었으며 두가지 속성을 동시에 고려한 연구는 최근 한 편 [8]이 발표되었

으나 설계속성을 부품의 길이, 폭 등으로 나타내어 설계의 유사성을 구분하기에는 충분한 정보를 제공할 수 없었다.

그러므로 본 연구에서는 설계속성으로서 부품의 기하학적 형상을, 제조속성으로서는 부품의 생산량, 공정시간, 생산공정 등을 동시에 고려하여 부품군을 형성시켜 주는 새로운 부품군 분류시스템을 제안하였다. 연구목적을 달성하기 위하여 기본적으로 두가지 프로그램이 개발되었다. 먼저 첫번째 영상처리 프로그램은 부품의 2차원 기하학적 형상 데이터로부터 외곽경계선을 찾아주고, 두번째 프로그램에서 분류되기 위해 여러 단계의 영상 전처리과정을 거쳐게 된다. 두번째 프로그램인 수정된 퍼지 아트 신경망 프로그램은 첫번째 프로그램의 결과와 제조속성 데이터를 입력 받아서 부품을 분류한다. 개발된 분류 시스템은 가상적인 7개의 부품에 대해 검증되었으며, 그 결과 비교적 신속하고 정확하게 부품을 분류할 수 있었다.

* 이 논문은 1996년도 한국학술진흥재단의 대학교수 해외 파견 연구지원에 의하여 연구되었음.

** 관동대학교 이공대학 산업공학과.

2. 기하학적 형상데이터 추출 (설계속성)

일반적으로 설계속성은 부품의 외부형상, 치수, 또는 크기를 포함한다. 제안된 시스템에서는 부품의 2차원 기하학적 형상만이 설계속성으로 고려되었다. 왜냐하면, 치수 또는 크기는 부품-기계 인시던스 매트릭스 (Part-Machine incidence matrix)와 가공형상 (Form features)과 같은 제조속성이 추출될 때 포함될 수 있기 때문이다.

닫혀진 2차원 형상 (Closed planar shape)은 2차원화된 형상의 중심과 모든 경계 픽셀들 사이의 유클리드 거리 (Euclidean distance)로 대표되는 정돈된 순서 (Ordered sequence)로 특징 지워 질 수 있다. 이 순서는 각 평면형상 데이터에 대한 고유 표현을 제공한다. 먼저, 경계 픽셀들이 윤곽탐색 알고리즘 (Contour following algorithm)을 이용하여 평면영상으로부터 추출되어지고, 그 다음에 중심이 유도되어진다 [7]. 다음 단계는 중심과 모든 경계 픽셀들 사이의 유클리드 거리들을 시계방향 순서로 구한다. 닫혀진 윤곽만이 고려되어지므로 결과적인 거리 순서들은 항상 닫힌 원이되며 방정식 (1)로 표현될 수 있다.

$$b(N+i)=b(i), \quad i=1,2,3,\dots,N. \quad (1)$$

여기서, N은 경계 픽셀의 총 수를 뜻한다.

이 유클리드 거리는 원래 영상의 위치가 변하더라도 변하지 않기 때문에 이 거리 $b(i)$ 는 이동 불변 (Translation invariant)이 된다. 다음 단계는 윤곽순서를 영상의 크기 관점에서 정규화 (Normalization)하는 일이다. 영상의 축척 (Scaling)은 샘플수와 윤곽순서의 구간의 축척이 요구된다. 그러므로, 축척 정규화는 폭 (Amplitude) 및 구간 (Duration)의 정규화를 수반한다. 순서의 구간 정규화는 본 연구에서는 128개의 고정 점을 이용하며, 그 점들은 다음 식에 따라 윤곽순서들의 재 추출 및 함수 근사화에 의해 구해진다.

$$c(k)=b(k \times N/128), \quad k=1,2,3,\dots,128. \quad (2)$$

구간 정규화 후에, 다음 식에 보여지는 것처럼 폭이 윤곽순서의 총합으로 나눠짐으로써 정규화되어 진다.

$$d(k)=c(k)/s, \quad s=c(1)+c(2)+c(3)+\dots+c(128). \quad (3)$$

이제 순서 $d(k)$ 는 이동 및 축척불변이며, 4번째 단계로서 정규화된 순서 $d(k)$ 의 128개의 푸리에 변환 (FFT: Fast Fourier Transform)이 다음 식을 이용하여 구하여 진다.

$$F(k)=\sum_{n=0}^{127} d(n+1)\exp(-j2\pi kn/128), \quad k=0,1,2,\dots,127. \quad (4)$$

여기서,

$$j=\sqrt{-1}, \quad n=0,1,2,\dots,127.$$

이 순서의 크기, $|F(k)|$ 는 순서 $d(n)$ 이 회전이동 되어도 변하지 않는다. 다시 말해서 $|F(k)|$ 는 형상의 회전에 불변인 특성을 갖고 있다. 이 시점에서, Spectrum analyzer가 데이터 량 감축을 위해 순서 $F(k)$ 에 적용되어진다. Spectrum analyzer는 Ahmed와 Bates (1971)에 의해서 보고된 것처럼 이동 불변 스펙트럼을 산출해준다. 이 방법은 패턴 분류를 위한 충분한 정보를 유지하면서 상당한 데이터량의 감축을 허용해 준다. Spectrum analyzer의 결과는 길이 $\log_2 K+1$ 인 벡터이며, 여기서 K는 순서 $d(n)$ 의 푸리에 변환에서의 항목 수이다. 정렬된 변환에서, 스펙트럼 요소들은 다음과 같이 주어진다.

$$P(0)=F^2(0). \quad (5)$$

$$P(i)=\sum_{j=2^{i-1}}^{k-1} [F^2(j) + F^2(j+1)], \quad i=1,2,3,\dots,n. \quad (6)$$

여기서, j 는 2^{i-1} 씩 증가되며 $n=\log_2 K$ 이다.

두 인접 항인 $F^2(j)$ 와 $F^2(j+1)$ 는 각 주파수에서 합산된다. 이것은 푸리에 전개에서 사인 (Sin) 및 코사인 (Cos) 항에 해당된다. 본 논문에서 K는 128이기 때문에, Spectrum analyzer의 결과의 벡터길이는 8이 된다. 그러나, 마지막 항 외의 대부분의 고차 항의 스펙트럼 요소들은 거의 0이므로, 단지 첫 4요소인 $P(0)$, $P(1)$, $P(2)$, $P(3)$ 와 마지막항인 $P(7)$ 만이 신경망 분류기의 입력으로 이용되어 진다.

$$P(1)=[F^2(1)+F^2(2)]+[F^2(5)+F^2(6)]+\dots+[F^2(125)+F^2(126)]. \quad (7)$$

$$P(2)=[F^2(3)+F^2(4)]+[F^2(11)+F^2(12)]+\dots+[F^2(123)+F^2(124)]. \quad (8)$$

$$P(3)=[F^2(7)+F^2(8)]+[F^2(23)+F^2(24)]+\dots+[F^2(119)+F^2(120)]. \quad (9)$$

$$P(7)=[F^*(127)]. \tag{10}$$

3. 제조속성 데이터 준비

제조유사성에 대한 정보는 부품-기계 인시던스 매트릭스 형태로 표현될 수 있다. 만약 정보가 이진형태 (Binary)로 되어 있다면, 요소 $[A_{ij}]$ 는 부품 i 가 기계 j 를 거치는지 ($A_{ij}=1$) 또는 안거치는지 ($A_{ij}=0$)를 나타낸다. 만약 생산량, 공정시간과 같은 다른 중요한 제조 유사성들이 고려되어 진다면, 인시던스 매트릭스의 엔트리는 그 값들에 의해서 곱해질 것이다. 다시 말해서 각 엔트리는 부품의 공정경로, 공정시간, 생산량에 대한 정보들을 $A_{ij} \times PT \times D$ 의 값으로 유지할 수 있을 것이다. 여기서,

$$A_{ij} = \begin{cases} 1, & \text{부품 } i \text{가 기계 } j \text{를 경유하면} \\ 0, & \text{부품 } i \text{가 기계 } j \text{를 경유하지 않으면} \end{cases}$$

PT = 공정시간

D = 수율

결과적으로 제조속성 벡터는 $NI \times NM$ 행렬로 구성되며, 여기서 NI는 입력데이터 수 (부품수)이며, NM은 기계종류의 수이다. 본 연구에서 기계종류는 편의상 8자리 벡터로 가정한다.

4. 수정된 퍼지 아트 신경망 분류 프로그램

퍼지 아트 신경망은 최근에 Carpenter *et al.* (1991)에 의해서 소개되었다. 이 알고리즘은 ART1에서 교차 오퍼레이터 (\cap)를 퍼지집합 이론의 MIN 오퍼레이터 (\wedge)로 대체함으로써 아날로그 및 이진 입력 패턴 모두를 학습할 수 있도록 일반화한 것이다. Burke 와 Kamal (1992)은 퍼지 아트 신경망을 셀 형성 문제에 적용하여 퍼지 아트가 다른 전통적인 접근방법들보다 우수한 결과를 가져왔다고 보고하였다. Suresh와 Kaparthi (1994)도 또한 부품 및 기계의 분류에서 퍼지 아트 신경망의 성능을 분석하였는데 그들의 결론 역시 퍼지 아트가 전통적인 알고리즘 보다 특히 다량의 데이터에 대해서 보다 우수하고 일관성있는 결과를 제공한다고 보고하였다. 그러므로, 본 연구에서도 퍼지 아트 신경망이 부품군 분류를 위해 이용되었다.

기본적으로 퍼지 아트가 본 연구의 특징데이터에 적합하게 보정되어졌다. 입력데이터를 컬럼 별로 축척변환 (Scaling)해 줌으로써, 입력 데이터 간의 상대적인 크기를 유지시켜 주면서 서로 다른 크기의 설계 및 제조속성 값들을 동일한 시스템


내에서 비교할 수 있도록 하였다.

퍼지 아트에서, 모든 모수들, 즉 (1) 선택 모수 $\alpha > 0$, (2) 학습 모수 $\beta \in [0,1]$, 그리고 경계 모수 $\rho \in [0,1]$ 는 부품군의 수 및 형성방법에 영향을 준다. 학습 또는 경계 모수가 증가할 때, 부품군의 수는 증가하며, 선택 모수가 증가할 때 부품군의 수는 감소한다. 퍼지 아트의 경계 메카니즘은 부품군 내의 유사성의 최소 수준을 유지하도록 도와준다. 학습 모수 β 는 비중벡터 W_j 가 노드 j 에 의해서 요구된 입력벡터의 특성을 학습하는 정도를 나타내 준다

수정된 퍼지 아트에서, 초기에 큰 값의 경계 (ρ) 및 학습 (β) 모수값을 할당함으로써 신경망이 모든 입력값에 고르게 익숙해지도록 하였다. 이때 결과적인 부품군의 수가 원하는 수보다 클 경우는 신경망은 새로운 입력 패턴을 형성하고 다시 축척변환을 할 것이다. 이때 신경망은 새로운 패턴을 다소 감소된 경계 및 학습 모수값으로 재 그룹지우기를 시도할 것이다. 이 루틴은 요구되는 부품군의 수에 도달할 때까지 계속될 것이다. 이것이 여기서 'Add method' 로 불리는 방법이다. 여기에 대한 더 자세한 설명은 참고문헌 [8]을 참고하기 바란다.

5. 실험결과 및 토의


개발된 시스템의 유효성을 확인하기 위해 두 묶음의 가상적인 부품들 즉, 혼련용 9개와 검증용 7개의 부품들이 준비되어 분석되었다. 첫 묶음은 신경망의 혼련을 위해 9개의 부품들에 대한 기하학적 형상 및 3가지 주요 제조속성들 (공정경로, 공정시간, 생산량)의 값을 포함한다. 두번째 묶음은 7개의 검증용 부품들에 대한 유사한 데이터들로 구성되었다. 그 부품들에 대한 형상 및 제조속성 데이터들이 그림 1, 2, 3 및 4에 보여진다.



<그림 1> 혼련용 9 부품들에 대한 형상

0.9934	0.0040	0.0011	0.0001	0.0015	0	0	12	0	0	60	0	36
0.8500	0.1371	0.0091	0.0002	0.0037	0	0	0	1500	0	0	200	100
0.8873	0.1018	0.0065	0.0005	0.0039	0	0	0	1600	0	0	80	40
0.9565	0.0425	0.0006	0.0004	0.0000	60	0	50	0	60	0	0	0
0.9651	0.0305	0.0036	0.0007	0.0000	70	0	25	0	0	0	0	0
0.9131	0.0811	0.0049	0.0007	0.0002	280	91	0	210	84	140	0	0
0.9328	0.0602	0.0055	0.0015	0.0001	420	70	0	70	0	0	0	0
0.9923	0.0032	0.0033	0.0001	0.0011	0	100	100	0	0	75	0	0
0.9922	0.0053	0.0022	0.0003	0.0000	0	60	120	60	0	180	0	0

〈그림 2〉 훈련용 9 부품들에 대한 형상특징 및 제조속성 벡터
(처음 5칼럼: 형상특징, 나머지 8칼럼: 제조 속성).



〈그림 3〉 검증용 7 부품들에 대한 형상

0.9948	0.0033	0.0015	0.0004	0.0000	0	12	18	0	0	120	0	42
0.9277	0.0641	0.0063	0.0016	0.0003	280	160	0	320	160	160	0	0
0.9284	0.0635	0.0067	0.0008	0.0004	560	168	0	240	80	0	0	0
0.8851	0.1045	0.0063	0.0004	0.0037	0	0	0	1400	0	0	120	80
0.8378	0.1561	0.0053	0.0007	0.0001	0	0	0	3000	0	0	180	120
0.9968	0.0020	0.0010	0.0001	0.0000	0	150	150	0	0	120	0	0
0.8781	0.0601	0.0412	0.0005	0.0200	200	100	0	100	0	50	0	0

〈그림 4〉 검증용 7 부품들에 대한 형상특징 및 제조속성 벡터
(처음 5칼럼: 형상특징, 나머지 8칼럼: 제조 속성).

3가지 제조속성들은 0 또는 1 부품-기계 인스턴스 매트릭스에 공정시간 및 생산량을 곱해줌으로써 결합될 수 있다. 본 연구에서는, 사용자에 의해 이들 값들이 임의의 논리적인 값으로 주어졌다. 〈그림 2〉와 〈그림 4〉에서 각각의 가로줄은 입력 부품의 수를 의미하며, 〈그림 4〉를 예로보면 세로줄은 왼쪽부터 5칼럼은 〈그림 3〉의 영상데이터에 대한 특징벡터이며, 나머지 8칼럼은 8가지 서로 다른 종류의 기계에 대한 제조속성 데이터를 의미하고 있다. 기하학적 형상들은 320x400 영상평면에 2치화 되었으며, 형상들의 크기는 의도적으로 불규칙하

게 구성했다.

선택 모수 α 는 그다지 민감하지도 않고 합리적인 결과를 산출해 주었기 때문에, 전 실험을 통해서 0.01로 유지되었다. 학습 모수는 Kamal과 Burke (1996)가 추천한 것처럼 초기값으로 $\beta_{init}=0.999$ 를 이용하였다. 최적 경계 모수를 찾는 일이 신경망의 훈련 모드에서의 주요 과제였다.

신경망은 9개의 훈련용 부품들에 대해서 훈련되어 졌다. 시행 착오법에 의해 최적의 경계 및 학습 모수들의 값들이 주어 진 입력 데이터들에 대해 찾아진 후, 해당되는 비중 값들 (Weights)과 모수 값들이 저장되었다. 다음에, 신경망이 훈련 모드에서 얻어진 최적 값들에 근거해서 7개의 검증용 부품 데이터들에 대해 검사되었다. 이 목적을 위해, 두개의 신경망 프로그램이 훈련용과 검증용사이에 약간의 수정을 통해 개발되었다.

여기서, 훈련 모드에서 얻어진 경계 모수, 적당한 부품군의 수, 부품군 결과와 비중값들은 검증 모드에서 단지 길잡이 값의 역할을 할 뿐이었다. 예를 들면, 훈련 모드에서 찾아진 ρ 값으로 시작해서 대개는 다소 작은 값으로 결정되어진다. 이것은 검증 모드에서 추가된 유사성의 차이를 포함하기 때문으로 판단된다.

개발된 분류 시스템을 통해, 〈그림 4〉에 보여지는 7개 부품들에 대한 기하학적 형상 및 제조속성 데이터들에 대해, 〈표 1〉과 같은 부품군이 형성되어졌다. 〈그림 4〉와 〈표 1〉을 자세히 관찰하면, 이 결과가 설계 및 제조속성들을 동시에 만족시키는 유일한 가능해인 것을 알 수 있다.

〈표 1〉 검증용 7 부품들의 기하학적 형상 및 3가지 제조속성에 근거한 부품군 결과
($\beta=0.999$, $\rho<0.6$, 최대 허용 부품군수=5)

group 1	group 2	group 4	group 5
te1	te4 te5	te2 te3 te7	te6

6. 결론

GT 구축을 통해 얻을 수 있는 가장 큰 이득은 부품들이 설계 및 제조속성들을 동시에 고려해서 그룹지워질 때 실현된다. 부품의 기하학적 형상 및 제조 유사성에 근거를 두고 부품군을 형성하기 위하여, 영상처리 기법과 수정된 퍼지 아트 신경망을 이용한 새로운 부품군 형성 시스템을 개발 하였다.

실험을 통해, 개발된 시스템이 설계 및 제조 유사성을 동시에 고려하여 부품을 분류할 수 있는 유용한 접근 방법임이 확인되었다. 이동, 축척, 회전 불변형상을 인식할 수 있도록 이용된 영상처리기법의 간편성과 퍼지 아트 알고리즘의 단순한 구조 및 신속한 반응은 개발된 시스템을 실제 환경에 적용을 위한 하드웨어 구축을 용이하게 해준다.

앞으로의 연구로는 학습 모수의 영향력이 분명한 이상, 이 모수와 경계 모수의 적절한 결합을 찾는 방법에 대한 연구가 요구되어진다. 일단 샘플 부품들이 적절한 수의 부품군으로 그룹지어진 후, 신경망은 각 그룹의 특성들을 학습하고 유지하기 위하여 훈련을 필요로 한다. 하지만, 퍼지 아트 신경망은 비감독형 신경망이므로 이 역할을 충분히 감당할 수 없다. 이 목적을 위해, 감독형 및 비감독형 학습능력을 동시에 갖고 있는 신경망이 적절한 해결방안으로 기대된다. Fuzzy ARTMAP과 Radial Base 신경망이 이 목적을 위해 현재 탐구 중에 있다.

본 연구에서는 제안된 시스템의 유효성의 검증이 목적이므로 실험의 편의상 비교적 소량의 데이터에 대해 실험하였으나 추후 보다 많은 데이터에 대한 추가 실험을 통해 본 시스템의 어려움 및 성능에 대한 체계적 평가가 2차 연구과제로 뒤따라야 할 것이다.

[참 고 문 헌]

[1] Ahmed, N. and Bates, R. M., "A power spectrum and related physical interpretation for the multi-dimensional BIFORE transform," Proceedings: Applications of Walsh Functions Symp, Naval Res. Lab., AD-727-000, pp.47~50, 1971.

[2] Burke, L. and Kamal, S., "Fuzzy ART for cellular manufacturing," Proceedings of the Conference on Artificial Neural Networks in Engineering, Vol. 1, pp.779~784, 1992.

[3] Burke, Laura Ignizio, "Original Contribution: clustering characterization of adaptive resonance," Neural Networks, Vol. 4, pp.485~491, 1991.

[4] Carpenter, G. A., Grossberg, S. and Rosen, D. B., "Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system (original contribution)," Neural Networks, Vol. 4, pp.759~771, 1991.

[5] Chung, Y. and Kusiak, A., "Grouping parts with a neural network," Journal of Manufacturing Systems, Vol. 13, No. 4, pp.262~275, 1994.

[6] Fausett, Laurene, Fundamentals of Neural Networks - Architectures, Algorithms, and Applications, Prentice Hall International Inc., New Jersey, 1994.

[7] Gonzalez, R. C. and Woods, R. E., Digital Image Processing, Addison-Wesley Publishing Co., Tokyo, 1992.

[8] Kamal, S. and Burke, L. I., "FACT: A new neural network-based clustering algorithm for group technology," International Journal of Production Research, Vol. 34, No. 4, pp. 919~946, 1996.

[9] Kaparthi, S. and Suresh, N. C., "A neural network system for shape based classification and coding of rotational parts," International Journal of Production Research, Vol. 29, No. 9, pp.1771~1784, 1991.

[10] Kaparthi, S. and Suresh, N. C., "Machine-component cell formation in group technology: a neural network approach," International Journal Production Research, Vol. 30, No. 6, pp.1353~1367, 1992.

[11] Ko, C. N. and Rhee, J. T., "Grouping parts by part shape and sequence of operations using neural network," Proceedings of Korea IIE, 1994.

[12] Kusiak, A. and Chung, Y., "GT/ART: Using neural networks to form machine cells," Manufacturing Review, Vol. 4, No. 4, pp.293~301, 1991.


[13] Lee, S. K. and Jang, D. S., "Translation, rotation and scale invariant pattern recognition using spectral analysis and hybrid genetic-neural-fuzzy networks," Computers and Industrial Engineering, Vol. 30, No. 3, pp.511~522, 1996.

[14] Liao, T. W. and Chen, L. J., "An evaluation of ART1 neural models for GT part family and machine cell forming," Journal of Manufacturing Systems, Vol. 12, No. 4, pp.282~290, 1993.

[15] Liao, T. W. and Lee, Kwan S., "Integration of a feature-based CAD system and an ART1 neural model for GT coding and part family forming," Computers and Industrial Engineering, Vol. 26, No. 1, pp.93~104, 1993.

[16] Mathworks Inc., MATLAB - Reference Guide, 1992.

- [17] Moon, Y. B., "Forming part-machine families for cellular manufacturing: a neural network approach," International Journal of Advanced Manufacturing Technology, Vol. 5, pp.278~291, 1990.
- [18] Moon, Y. B. and Chi, S. C., "Generalized part family formation using neural network techniques," Journal of Manufacturing Systems, Vol. 11, No. 3, pp.149~159, 1992.
- [19] Nemcek, W. F. and Lin, W. C., "Experimental investigation of automatic signature verification," IEEE Transactions on Systems, Man, and Cybernetics, pp.121~126, 1974.
- [20] Shafer, S. M. and Meredsith, R., "A comparison of selected manufacturing cell formation techniques," International Journal of Production Research, Vol. 28, No. 4, pp.661~673, 1990.
- [21] Sonka, M., Hlavac, V. and Boyle, R., Image Processing, Analysis and Machine Vision, Chapman & Hall, London, 1993.
- [22] Suresh, N. C. and Kaparthi, S., "Performance of fuzzy ART neural network for group technology cell formation," International Journal of Production Research, Vol. 32, No. 7, pp.1693~1713, 1994.



이성열

현재 관동대학교 산업공학과 교수로 재직중이며, 인하대학교 기계공학과 학사, 산업공학과 석사, 텍사스 주립대 산업공학과 석사, 북다코타 주립대 산업공학과에서 박사학위를 취득하였다. 주요관심분야는 제조분야에서의 신경망응용, 컴퓨터 지원 공정계획, CAD/CAM 등이다.

97년 11월 최초접수, 98년 4월 최종수정